



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

GILDERLANIO BARBOSA ALVES PALACIO

**CLASSIFICAÇÃO DE NÍVEIS DE DESBALANCEAMENTO DE UM
AEROGERADOR EM ESCALA UTILIZANDO MÁQUINA DE VETORES SUPORTE**

FORTALEZA

2021

GILDERLANIO BARBOSA ALVES PALACIO

CLASSIFICAÇÃO DE NÍVEIS DE DESBALANCEAMENTO DE UM AEROGERADOR
EM ESCALA UTILIZANDO MÁQUINA DE VETORES SUPORTE

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. Dr. 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)

- P176c Palacio, Gilderlanio.
CLASSIFICAÇÃO DE NÍVEIS DE DESBALANCEAMENTO DE UM AEROGERADOR EM ESCALA UTILIZANDO MÁQUINA DE VETORES SUPORTE / Gilderlanio Palacio. – 2021.
61 f. : il. color.
- Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Mecânica, Fortaleza, 2021.
Orientação: Prof. Dr. Elineudo Pinho de Moura.
Coorientação: Profa. Dra. Carla Freitas de Andrade.
1. Aerogeradores. 2. Análise de Vibração. 3. DFA. 4. SVM. I. Título.
- CDD 620.1
-

GILDERLANIO BARBOSA ALVES PALACIO

CLASSIFICAÇÃO DE NÍVEIS DE DESBALANCEAMENTO DE UM
AEROGERADOR EM ESCALA UTILIZANDO MÁQUINA DE VETORES
SUPORTE

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 20/07/2021

BANCA EXAMINADORA

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

Prof.^a Dra. Carla Freitas de Andrade
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)

Aos meus pais, à minha irmã e à Ana
Carmelita.

AGRADECIMENTOS

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

Ao Prof. Dr. Elineudo Pinho de Moura, pela excelente orientação.

Aos professores participantes da banca examinadora Carla Freitas de Andrade, Paulo Alexandre Costa Rocha e Francisco Olímpio Moura Carneiro pelo tempo e pelas valiosas colaborações e sugestões.

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

“Há perigo na esquina, eles
venceram e o sinal está fechado
para nós, que somos jovens”

Belchior

RESUMO

Todo sistema rotativo, como os aerogeradores, sofre com problemas de desbalanceamentos devido a intempéries, degradação e problemas durante a operação que podem causar diminuição do seu desempenho. A presente dissertação analisa sinais de vibração capturados em uma turbina em escala com diferentes níveis de desbalanceamentos. Tais desbalanceamentos foram provocados pela adição de massas nas pontas das pás. Foram utilizadas massas de 0,5 g, 1,0 g e 1,5 g na ponta de uma ou duas pás. As rotações escolhidas para o ensaio foram de 900, 1200 e 1500 rpm. Os sinais de vibração passaram por uma DFA (Análise de Flutuações Destendenciadas), que reconhece propriedades e correlações de séries temporais não-estacionárias. Os dados de saída da DFA foram classificados utilizando o método de máquina de vetores suporte SVM (Support Vector Machine) em grupos de 3 e 7 classes. Nas etapas de treinamentos da máquina de vetores suporte implementada no grupo com três classes, observou-se uma pequena redução na taxa de acerto com o aumento na velocidade de rotação, dentro da faixa de valores de 100% até 98,80%. Para etapa de testes, as taxas de acerto foram levemente inferiores, ainda apresentando o fenômeno da queda da taxa de acerto com o aumento da rotação. Para o conjunto com sete classes, a rotação com 1200 rpm tem as menores taxas de acerto, em relação ao nível de rotação de 900 rpm e 1500 rpm, sendo que a etapa de testes em relação à de treinamento, há quedas, algumas vezes sensíveis, outras mais significativas dependendo da classe analisada nos três níveis de rotação. Comparando-se com outros métodos implementados para classificação dos mesmos dados, percebe-se que o SVM se destaca, pois consegue manter padrões relativamente elevados de acertos na classificação.

Palavras-chave: Aerogeradores. Análise de Vibração. DFA. SVM.

ABSTRACT

Every rotating system, such as wind turbines, suffers from unbalance problems due to bad weather, degradation and problems during operation that can cause a decrease in its performance. This dissertation analyzes vibration signals captured in a scaled turbine with different levels of unbalance. Such unbalances were caused by the addition of masses at the tips of the blades. Masses of 0.5 g, 1.0 g and 1.5 g at the tip of one or two blades were used. The rotations chosen for the test were 900, 1200 and 1500 rpm. The vibration signals went through a DFA (Extended Fluctuation Analysis), which recognizes properties and correlations of non-stationary time series. The DFA output data were classified using the support vector machine method SVM (Support Vector Machine) into groups of 3 and 7 classes. In the training stages of the support vector machine implemented in the group with three classes, there was a small reduction in the success rate with the increase in rotation speed, within the range of values from 100% to 98.80%. For the testing stage, the hit rates were slightly lower, still showing the phenomenon of a drop in the hit rate with the increase in rotation. For the set with seven classes, the rotation with 1200 rpm has the lowest success rates, in relation to the rotation level of 900 rpm and 1500 rpm, and the test stage in relation to the training stage, there are falls, sometimes sensitive, others more significant depending on the class analyzed in the three levels of rotation. Comparing with other methods implemented to classify the same data, it is clear that the SVM stands out, as it manages to maintain relatively high standards of correct answers in the classification.

Keywords: Wind turbines. Vibration Analysis. DFA. SVM.

LISTA DE FIGURAS

Figura 1 - Tipo de aerogeradores: à esquerda TEEH, à direita TEEV.....	21
Figura 2 - Componentes de um sistema eólico TEEH.....	22
Figura 3 - Esquema da sequência metodológica do trabalho. Aplica-se DFA na penúltima fase.....	26
Figura 4 - Diagrama em bloco de um algoritmo DFA.....	27
Figura 5 - Diagrama em ordem sequenciada dos métodos elaborados para obtenção dos resultados da pesquisa.....	34
Figura 6 - Bancada de testes.....	35
Figura 7 - Representação esquemática do ensaio com uma massa de 0,5, 1,0 e 1,5g.....	36
Figura 8 - Representação esquemática do ensaio com massas em duas pás, com valores de 0,5, 1,0 e 1,5 g.....	37
Figura 9 - Representação esquemática do ensaio livre de massas.....	37
Figura 10 - Sinal de vibração normalizado obtido pela rotação de 900rpm com uma pá desbalanceada.....	42
Figura 11 - Curva DFA obtida dos sinais mostrados na Figura 10.....	43

LISTA DE TABELAS

Tabela 1 – Representação da quantidade de sinais em cada procedimento.....	38
Tabela 2 – Representação dos dois conjuntos de classes e a definição das classes.....	39
Tabela 3 – Matriz de confusão média para classificação de três classes de desbalanceamento e nível de rotação de 900 rpm.....	44
Tabela 4 – Matriz de confusão média para classificação de três classes de desbalanceamento e nível de rotação de 1200 rpm.....	45
Tabela 5 – Matriz de confusão média para classificação de três classes de desbalanceamento e nível rotação de 1500 rpm.....	46
Tabela 6 – Matriz de confusão média para classificação de sete classes de desbalanceamento no nível de rotação de 900 rpm.....	47
Tabela 7 – Matriz de confusão média para classificação de sete classes de desbalanceamento no nível de rotação de 1200 rpm.....	48
Tabela 8 – Matriz de confusão média para classificação de sete classes de desbalanceamento no nível de rotação de 1500 rpm.....	49
Tabela 9 - Comparação das TMA entre os classificadores: DG, KLT RNA e SVM.....	50

LISTA DE ABREVIATURAS E SIGLAS

DFA	Análise de Flutuações Destendenciadas (<i>Detrended Fluctuation Analysis</i>)
DG	Discriminador Gaussiano
IPCC	Painel Intergovernamental De Mudanças Climáticas
LNER	Laboratório Nacional de Energias Renováveis
MP	Manutenção Preventiva
RNA	Rede Neural Artificial
SIN	Sistema Interligado Nacional
SVM	Máquina de Vetores Suporte
TEEH	Torre Eólica de Eixo Horizontal
TEEV	Torre Eólica de Eixo Vertical
USD	Dólar

LISTA DE SÍMBOLOS

%	Porcentagem
US\$	Dólar Americano
β	Margem de separação do classificador SVM
α	Multiplicador Lagrangeano
ξ	Variável de Folga
σ	Parâmetro Função Kernel
°C	Grau Celsius
ϕ	Função vetor no espaço característico
α	Coefficiente de correlação da DFA
y	Sequência integrada da DFA
w	Vetores de peso do hiperplano do método SVM

SUMÁRIO

1	INTRODUÇÃO	15
2	JUSTIFICATIVA	17
3	OBJETIVOS	18
3.1	Objetivos Específicos	18
4	FUNDAMENTAÇÃO TEÓRICA	19
4.1	Potencial Eólico	19
4.1.1	<i>Regime de vento no Nordeste (NE) do Brasil</i>	19
4.2	Turbina Eólica	20
4.3	Turbina Eólica de Eixo Horizontal	21
4.4	Falhas Operacionais e Manutenção em Aerogeradores	22
4.5	Análise de Vibração	24
4.6	Análise de Flutuações Destendenciadas (DFA)	24
4.7	Métodos de Reconhecimento de Padrão	28
4.7.1	<i>Support vector machine (SVM)</i>	28
4.7.2	<i>Support vector machine com margem flexível</i>	30
4.7.3	<i>Função Kernel</i>	31
4.7.4	<i>Escolha dos hiperparâmetros</i>	33
5	METODOLOGIA	34
5.1	Sinais de Vibração	34
5.1.1	<i>Ensaio de captura dos sinais de vibração</i>	35
5.1.2	<i>Procedimentos no ensaio de captura de dados de vibração</i>	36
5.2	Aplicação da DFA	38
5.3	Máquina de Vetores Suporte	39
6	RESULTADOS E DISCUSSÕES	41
6.1	Filtragem dos Dados e Processamento pelo Método DFA	41
6.2	Classificação de Sinais	43
6.3	Comparação com Outros Métodos	50
7	CONCLUSÃO	52
	REFERÊNCIAS	53

1. INTRODUÇÃO

O relatório do painel intergovernamental de mudanças climáticas (IPCC) apontou que a temperatura média global cresceu $1,50^{\circ}\text{C}$ em relação aos níveis pré-industriais. Além disso, aconselha que seja revertido esse valor de $1,50^{\circ}\text{C}$ até o final deste século para evitar impactos irreversíveis e catastróficos. Isso implica em reduzir as emissões de dióxido de carbono (CO_2) em cerca de 45% até 2030 e alcançar o zero líquido em 2050. O relatório ainda enuncia que é necessário transformações sociais e econômicas sem precedentes (IPCC, 2018).

Entre 2010 e 2017, o custo da eletricidade média global gerado pelas turbinas eólicas onshore caiu de 0,08 \$/KWh para 0,06 \$/KWh. Dentre as fontes renováveis de energia, ficou atrás somente da geração hidroelétrica (IRENA, 2020). As usinas movidas pela força do vento produziram 16.126,91 MW médios em junho de 2020 frente aos 15.058,25 MW médios entregues ao Sistema Interligado Nacional (SIN) em junho de 2019, o que representa um crescimento de 7% (CCEE, 2020).

As turbinas eólicas, assim como outras estruturas rotativas, dependem da integridade estrutural das pás usadas para gerar o torque necessário para a rotação e, finalmente, a geração de energia elétrica (KHADKA et al., 2020). Essas lâminas são expostas a condições operacionais extremas, incluindo, entre outras, cargas variáveis contínuas, radiação ultravioleta, mudanças de temperatura, condições climáticas severas e relâmpagos (NIVEDH, 2014). Como consequência dessas condições adversas, muitas turbinas param de operar devido as falhas nas pás (CIANG et al., 2008), e durante os reparos dos danos, há muito gasto financeiro e de tempo (FLEMMING, 2003).

Durante sua operação, discernir os problemas em uma pá antes de qualquer falha catastrófica é uma tarefa desafiadora. O principal objetivo do monitoramento é identificar se as pás da turbina eólica estão em boas condições e, caso apresente defeitos, fazer o monitoramento do estado em que se encontra (JOSHUVA, 2020). Quando houver uma consciência do tempo de ocorrência e categorias de defeitos, ações de manutenção podem ser organizadas com antecedência (HAMEED et al., 2009). Assim, a condição o monitoramento das pás é uma atividade crítica.

Esta dissertação visa discernir alterações geradas pelo desbalanceamento controlado das pás de um aerogerador em escala, através da análise de vibração. Para provocar tal desbalanceamento, massas foram incorporadas às pontas de uma ou duas pás de forma padronizada. Primeiramente, uma massa foi acrescentada à ponta de uma única pá. Posteriormente a adição de massas se deu nas extremidades de duas pás. Essas combinações geraram 6 conjuntos de dados, que foram acrescentados ao conjunto de dados gerados sem massas acopladas as pás (sistema balanceado). Uma análise de flutuações destendenciadas (DFA) foi aplicada aos sinais de coletados

antes da sua classificação realizada por uma Máquina de Vetores Suporte (Support Vector Machine - SVM). As taxas de acerto na classificação alcançadas pelo SVM foram comparadas com as obtidas por outros métodos encontrados na literatura.

2. JUSTIFICATIVA

Os aerogeradores são produtos que requerem investimentos onerosos em equipamento, mão de obra qualificada e logística. Em um cenário ideal, o aerogerador deve permanecer em operação contínua desde sua montagem em campo até o último dia de vida útil do sistema. Porém, devido a fatores externos como maresia, chuva, acúmulo de neve e choque contra aves, ou fatores internos como desalinhamento de eixos, má lubrificação e desbalanceamento, as turbinas eólicas sofrem paradas periódicas para a correção de problemas. Além dos elevados custos de manutenção essas paradas provocam prejuízo pela paralisação temporária da geração de energia durante a correção de avarias. Visando substituir a manutenção corretiva pela manutenção preditiva, a metodologia proposta para essa dissertação é aplicar técnicas de processamento de sinais combinadas às técnicas de reconhecimento de padrões para identificar níveis de desbalanceamento das pás através da análise de vibração.

3. OBJETIVOS

O objetivo geral desta dissertação é a identificação e a classificação de desbalanceamentos induzidos nas pás de um aerogerador em escala através da análise de vibrações e um método reconhecimento de padrões (SVM).

3.1 Objetivos Específicos

- Produzir níveis de desbalanceamento em uma turbina eólica em escala pela adição de diferentes massas de ensaio em diferentes configurações.
- Aplicar *Detrended Fluctuation Analysis* (DFA) com a finalidade de extrair informações dos sinais de vibração observados.
- Utilizar uma máquina de vetores suporte (SVM) para classificar os diferentes níveis de desbalanceamento

4. FUNDAMENTAÇÃO TEÓRICA

4.1 Potencial Eólico

Em 2019 o Brasil gerou 55,9 TWh de energia elétrica proveniente dos ventos, dos quais 47,13 TWh (84%) foram produzidos em fazendas onshore na região Nordeste, principalmente nos estados do Rio Grande do Norte, Bahia e Ceará (ABEEólica, 2019). A energia eólica ainda representa uma pequena parcela (9,1%) da capacidade instalada total do Brasil, que é dominada pelas fontes hidrelétricas (60,6%) (EPE, 2019).

Como parte desse crescimento nacional rápido e expressivo, as usinas da região Nordeste relataram fatores de capacidade média (nível de produtividade) acima de 42,7% (ABEEólica, 2020), muito acima das médias de países ao redor do mundo (DIÓGENES et al., 2020). Conseqüentemente, mesmo enfrentando barreiras com impacto nos custos de desenvolvimento, a energia eólica na região atingiu 0,035 \$/kWh (JONG et al., 2016), bem abaixo de outras regiões do mundo (IRENA, 2015).

Os parques eólicos têm negociado eletricidade com tarifas competitivas em comparação com usinas termelétricas e, ultimamente, também com usinas hidrelétricas (ANEEL, 2018). Além disso, há previsões de geração confiáveis, devido aos ventos fortes e estáveis, com grande potencial comercial e adequados para a integração da rede. No cenário atual de altas perdas de disponibilidade hidrelétrica devido às secas frequentes, a energia eólica está bem posicionada para se tornar a alternativa necessária com urgência (JONG et al., 2017).

Ventos fortes e consistentes existem ao longo da costa nordeste do Brasil e nos planaltos do interior. Estes são os resultados da convergência dos ventos anticiclones subtropicais do Atlântico Sul em direção à depressão equatorial e dos ventos constantes do Leste (SCHUBERT, 2013). Vários parques eólicos no NE estão sendo construídos em dunas costeiras, que normalmente apresentam baixa rugosidade, enquanto outros parques eólicos localizados nas elevações mais altas dos planaltos interiores se beneficiam da compressão vertical do fluxo de ar (AMARANTE, 2001).

A maior parte do potencial de energia eólica no Brasil está na região Nordeste (SCHUBERT, 2013). Além disso, enquanto a região Nordeste do Brasil exhibe ventos consistentemente fortes e intensas depressões tropicais, os ciclones tropicais não se formam sobre o Atlântico Sul devido a uma troposfera média seca (JONG, 2017). Portanto, os parques eólicos no nordeste brasileiro não correm risco do surgimento de ciclones.

Schubert (2013) demonstrou que a maior parte do potencial de energia eólica na Bahia ocorre nos planaltos interiores entre as 20:00 e as 08:00 horas, porque as velocidades médias do vento são significativamente mais altas durante a noite. Como resultado, a geração horária média

diurna de energia eólica no interior da Bahia cai para seu nível mais baixo durante o meio da tarde (JONG et al., 2016).

Da mesma forma, Eichman et al. (2013) demonstraram que as turbinas eólicas na Califórnia produzem a maior parte de sua eletricidade durante a noite e, portanto, quando combinadas à energia solar, existe uma complementaridade. Purvins et al. (2012) demonstraram a existência de vários jatos noturnos recorrentes de baixo nível em vários locais, como nas Grandes Planícies da América do Norte, noroeste da China, Sudeste Asiático, Austrália, Etiópia, Angola, Namíbia, Índia, Irã e Venezuela, etc. Jatos noturnos recorrentes de baixo nível também pode ser observados em gráficos no mesmo artigo do Purvins et al. (2012), que ocorrem sobre as terras altas do nordeste brasileiro no verão e em menor grau no inverno. Este jato noturno de baixo nível explica a existência de um ciclo de vento diurno com velocidades de vento mais altas ocorrendo à noite nos planaltos da Bahia. Do mesmo modo, os parques eólicos costeiros na região Nordeste geram a maior parte de sua energia durante o dia (MASON et al., 2010) e, portanto, complementam a geração de parques eólicos interiores na região.

4.2 Turbinas Eólicas

As turbinas eólicas são máquinas que conseguem converter a energia cinética dos ventos em energia elétrica e podem ser agrupadas nas categorias de turbinas de eixo horizontal ou vertical, dependendo da orientação do eixo de rotação das pás. A Figura 1 mostra as configurações geométricas típicas das turbinas eólicas de eixo horizontal e vertical (TEEH e TEEV) (AL-KHARBOSY, 2012). As pás das TEEH giram em torno do eixo horizontal e são perpendiculares à direção do fluxo do vento, enquanto as pás das TEEV giram em torno do eixo vertical e as pás não são perpendiculares a direção dos ventos. Atualmente, como as TEEH dominam o mercado de turbinas eólicas em escala de utilidade, então o número de trabalhos sobre esse tipo de turbina é mais amplamente divulgado e discutido (ZUO et al., 2020).

Figura 1 – Tipo de aerogeradores: à esquerda TEEH, à direita TEEV.



Fonte: Adaptado de Beraldo (2019)


4.3 Turbina Eólica de Eixo Horizontal

O rápido crescimento das aplicações de energia eólica tem como destaque as TEEH. Essa tendência intensificou o desenvolvimento de novas tecnologias que tornam esse tipo de aerogerador cada vez mais competitivo em relação aos outros sistemas de geração de energia. Como as TEEH produzem energia proporcional a área varrida do rotor, então os novos aerogeradores tendem a possuir dimensões cada vez maiores. A empresa dinamarquesa Vestas conseguiu desenvolver um aerogerador cujo rotor atingiu o diâmetro de 164 m e uma potência nominal de 9,5 MW (LI et al., 2020)

No final de 2016, foram instalados mais de 54 GW de potencial eólico, e com isso a capacidade acumulada atingiu 486,8 GW, com uma taxa de crescimento anual de 12,6%. O mercado de energia eólica ainda está crescendo rapidamente e a capacidade instalada acumulada aumentará para 800 GW até o final de 2021 (GWEC, 2016). No entanto, uma das desvantagens mais importantes das TEEHs é chamada de fenômeno de estol dinâmico, que envolve uma série de conexões, separações e realojamentos de fluxo de fluido que ocorrem na superfície da lâmina do rotor, especialmente para as grandes pás das turbinas eólicas (THÉ, 2017). Isso afeta ainda mais as cargas aerodinâmicas do aerofólio e o desempenho da TEEH durante o giro do rotor (GUNTUR, 2016).

As TEEH possuem componentes demonstrados na Figura 2. As pás com seus ângulos de ataque, sofrem arrasto quando o vento escoa por ela, gerando uma força suficiente para rotacionar o eixo do sistema. Esse movimento rotativo é amplificado na caixa de engrenagem, no caso dos geradores síncronos, e então transmitido para o gerador, produzindo energia elétrica. Todo esse sistema está estruturado em uma torre e o sistema de transmissão de potência, por sua vez, é suportado na nacela.

Figura 2 – Componentes de um sistema eólico TEEH.



Fonte: Adaptado de Clark (2011).

4.4 Falhas Operacionais e Manutenção em Aerogeradores

As turbinas eólicas geralmente estão localizadas em áreas rurais, expostas a um ambiente hostil e, conseqüentemente, sujeitas a altas taxas de falhas, especialmente para aquelas impostas a um ambiente marítimo. É relatado que os custos operacionais e de manutenção das turbinas eólicas offshore representam 20% a 35% da receita total da eletricidade gerada (DOUGLAS WESTWOOD, 2010). À medida que a demanda por energia eólica continua a crescer

a taxas exponenciais, as técnicas para monitoramento eficaz de condições e diagnóstico de falhas ganharam atenção crescente para reduzir o tempo de inatividade dispendioso e evitar danos catastróficos nas aplicações das turbinas (WANG et al., 2020).

Entre os vários componentes de um sistema eólico, como mostrado na Figura 2, a caixa de engrenagens é a mais onerosa e vulnerável aos tipos de falhas que provocam um alto tempo de inatividade (HAHN, 2015). Isso se deve principalmente à complexidade de seus procedimentos de reparo e manutenção, principalmente em aplicações offshore. De acordo com as estatísticas mais recentes do banco de dados de confiabilidade da caixa de velocidades do Laboratório Nacional de Energias Renováveis (LNER) (SHENG, 2016), a maioria (cerca de 76,2%) das falhas na caixa de engrenagens de turbinas eólicas são causadas por rolamentos defeituosos.

A caixa de engrenagens da turbina eólica está sujeita a cinco modos principais de falha, incluindo falha no rolamento planetário, falha na engrenagem planetária, falha no rolamento do eixo de velocidade intermediária, falha no rolamento do eixo de alta velocidade e mau funcionamento do sistema de lubrificação (CHRISTOPHER, 2010). A maioria das falhas na caixa de engrenagens é iniciada nos locais dos rolamentos e migra para os dentes da engrenagem como detritos dos rolamentos, levando a consequentes falhas (IGBA, 2014).

Para diagnosticar defeitos incipientes e prever a vida útil restante de um aerogerador, técnicas eficazes de processamento de sinais e modelos de prognóstico foram investigadas no monitoramento de medições sensoriais (TENG et al., 2016). Teng et al. (2014) mostraram uma abordagem integrativa de decomposição do modo empírico do conjunto e da análise de componentes independentes foi investigada para separar os sinais relacionados a defeitos de rolamento dos sinais de engrenagens para análise de vibração do diagnóstico de falha de rolamento. Uma abordagem de análise de regressão linear foi apresentada por Feng et al. (2012) para extrair recursos independentes de carga para o diagnóstico de rolamentos de turbinas eólicas. Posteriormente, Feng et al. (2015) apresentaram um algoritmo dinâmico de distorção do tempo para eliminar a flutuação de velocidade no diagnóstico de falha de vibração de um aerogerador.

As abordagens orientadas a dados geralmente requerem uma grande quantidade de dados históricos de muitas sequências de degradação de dispositivos do mesmo tipo para treinar o modelo (GONZALEZ-CARRATO, 2017). Tais abordagens podem não ser adequadas para o diagnóstico e prognóstico de falhas de aerogeradores com medidas limitadas de dados de degradação disponíveis na prática. Os sistemas de geração eólica são geralmente complexos e em larga escala, caros e demorados para obter medições de dados de falhas.

A degradação é frequentemente afetada por muitos fatores, por exemplo, diferentes modos de falha, condições operacionais variáveis, entre outros. Portanto, o padrão de degradação difere de tempos em tempos (HERP et al., 2018). A sequência de degradação pode conter apenas

algumas medidas de degradação. Isso dificulta a construção do modelo orientado a dados. Conseqüentemente, o diagnóstico e prognóstico de falhas com base em amostras limitadas de dados de falhas ainda são questões desafiadoras (WANG et al., 2020).

Para cada tipo defeito, há técnicas de detecção mais apropriadas, como por exemplo: medição de deformação, emissão acústica, ultrassom, vibração, termografia e inspeção visual de máquinas (DU et al., 2019). Este trabalho foi desenvolvido utilizando apenas a técnica de análise de vibração.

4.5 Análise de Vibração

A manutenção tem sido historicamente reativa ou totalmente proativa. Enquanto o primeiro é geralmente chamado de abordagem “falhar e consertar”, o segundo é uma abordagem de “prever e prevenir” (LEE et al., 2006) que leva à chamada Manutenção Preventiva (MP) (FORSTHOFFER, 2017). O aspecto comum dessas duas abordagens é a ineficiência econômica. Enquanto uma estratégia de manutenção reativa leva a um tempo de inatividade significativo dos ativos, a MP é excepcionalmente inútil, pois inclui a substituição de peças ou estruturas perfeitamente funcionais, exigindo força de trabalho significativa ou levando ao abandono prematuro. Além disso, nenhum deles evita com eficiência falhas inesperadas (RIBEIRO et al., 2020).

Com o advento da tecnologia, as pás estão cada vez maiores e torres mais altas para capturar mais energia durante toda a sua vida útil. Por outro lado, à medida que a torre ou as pás das turbinas eólicas ficam mais longas, sua flexibilidade aumenta. Portanto, toda a estrutura de um aerogerador está se tornando mais sensível a cargas ambientais, especialmente excitações dinâmicas por ondas do mar, correntes e vento. A frequência de excitação pode estar próxima de uma das frequências naturais do sistema, o que leva à ressonância e conseqüentemente aumenta o estresse por fadiga em partes flexíveis do sistema. Portanto, as características dinâmicas (frequências naturais e suas formas correspondentes) das turbinas desempenham um papel essencial no projeto e controle dessas estruturas (JOKAR, 2020).

O princípio fundamental da utilização da análise de vibração como técnica preditiva consiste em identificar o grau de excitação dinâmica incoerente com o estado normal de vibração devido a algum fator preponderante. Há a vantagem ainda de relacionar o estado de vibração com a raiz do problema (RAO, 2009).

O sinal de vibração é uma série temporal, uma vez que pode ser relacionada com o tempo em uma representação cartesiana. As séries podem ser divididas entre os dois tipos: determinísticas ou probabilística. A primeira é relacionada aos comportamentos previsíveis com o tempo, já a segunda está relacionada com as leis probabilísticas. Portanto os dados presentes são apenas

parcialmente determinados pelos valores antigos (SILVA, 2011).

4.6 Análise de Flutuações Destendenciadas (DFA)

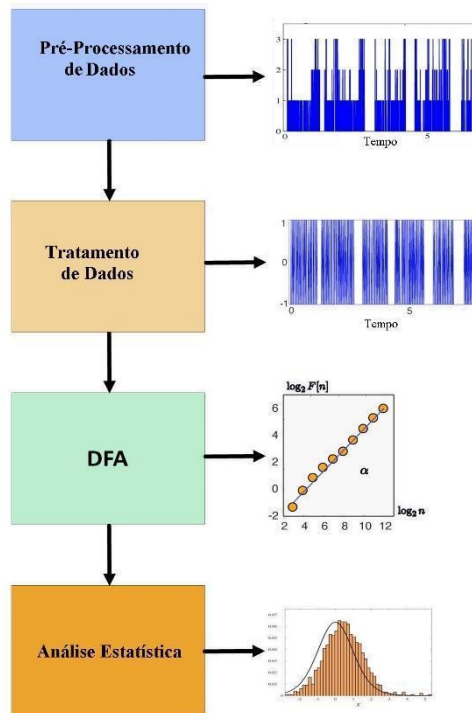
Os sistemas naturais geralmente exibem dinâmicas complexas com correlações de lei de potência de longo alcance (SORNETTE, 2004). As características desse comportamento são definidas por expoentes de escala, que são usados como medidas quantitativas em muitos estudos. No caso de processos estacionários produzidos por sistemas com parâmetros estáveis, a dependência da frequência da potência espectral ou o decaimento da função de correlação podem ser facilmente estimados com ferramentas convencionais para processamento de sinais, e os expoentes de escala correspondentes são relacionados entre si (WIENER, 1990).

A dinâmica não estacionária de sistemas de variação temporal restringe a aplicação de análises espectrais e de correlação, e os resultados desses métodos podem ser tratados indevidamente. A pré-filtragem elimina variações temporais para o valor médio local e geralmente permite um processamento adicional de sinal com abordagens tradicionais. Este procedimento, no entanto, não garante que os conjuntos de dados se tornem estacionários, pois a dinâmica variável no tempo pode ser associada a diferentes faixas de escalas. Supondo que a não estacionariedade seja causada apenas por uma tendência lenta, sua remoção se torna uma etapa necessária no processamento de dados. Alternativamente, métodos que consideram a variação de um sinal em torno da tendência, como exemplo da análise de flutuações destendenciadas (PENG et al., 1995), podem ser aplicados.

A vantagem da DFA é a capacidade de analisar dados experimentais sem um estágio de pré-processamento, uma vez que alguma tendência é ajustada e eliminada nessa abordagem. O DFA encontrou várias aplicações em campos distintos, devido à sua simplicidade e eficácia na quantificação de correlações de longo alcance (PENG et al., 1995). No entanto, sua aplicabilidade a processos altamente não estacionários ainda está em debate. Alguns autores argumentam que a não estacionariedade pode afetar fortemente os resultados da DFA (BRYCE, 2012), mas há outros estudos que não apoiam essa conclusão (HU, 2001).

A Figura 3 demonstra a sequência de tratamento de dados e a posição onde é usado o DFA, além de esquematizar a metodologia do trabalho até o ponto da análise estatística.

Figura 3 – Esquema da sequência metodológica do trabalho. Aplica-se DFA na penúltima fase.



Fonte: Adaptado de MENDEZ et al. (2020).

Bryce (2012) descreve um sinal de vibração com N comprimento de série dados por $\{x_i\}$, sendo $i = 1, 2, 3, \dots, N$. A série acumulada $\{y_j\}$, pode ser representada pela Equação 1:

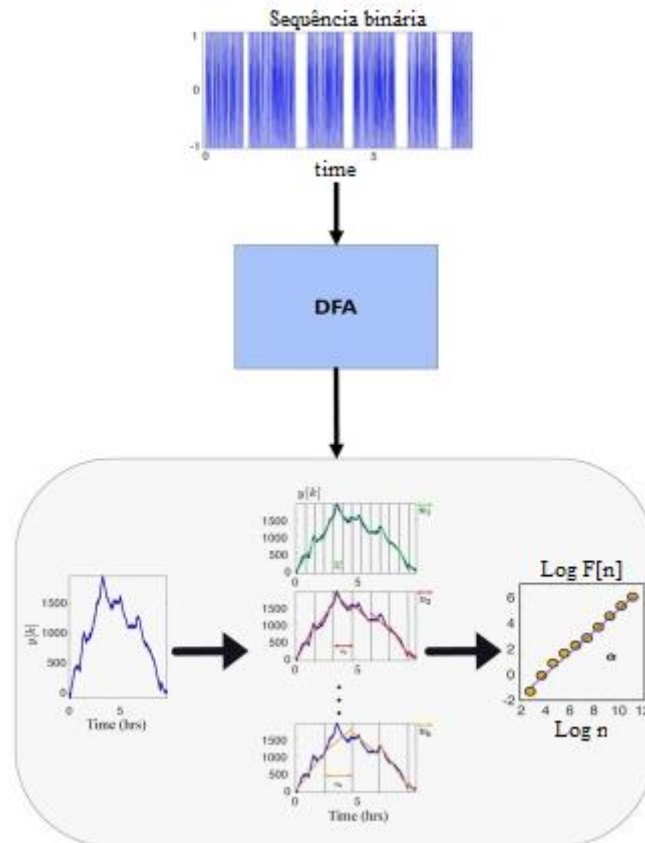
$$y_i = \sum_{i=1}^j (x_i - \langle x \rangle) \quad (1)$$

E o valor médio representado por $\langle x \rangle$ é dado pela Equação 2:

$$\langle x \rangle = \frac{1}{N} \sum_{i=1}^N x_i \quad (2)$$

A sequência integrada y_j é segmentada em $N[n] = \frac{N}{n}$ janelas não sobrepostas de vários tamanhos n . Este processo é ilustrado na Figura 4. Para cada janela, uma sequência linear em partes $y_j[n]$ é ajustada aos dados integrados, ajustando um modelo linear de mínimos quadrados aos dados em cada janela, representando a tendência local. A sequência y_j é subtraída a tendência local associada $y_j[n]$. Depois disso, a série de flutuação quadrada média da raiz é calculada por meio da Equação 3 (PENG et al., 1995).

Figura 4 - Diagrama em bloco de um algoritmo DFA.



Fonte: Adaptado de MENDEZ et al. (2020)

$$F[n] = \sqrt{\frac{1}{N} \sum_{j=1}^N (y_j - y_j[n])^2} \quad (3)$$

Este procedimento é repetido para diferentes valores da escala de tempo n . Considerando as escalas de tempo $n = 2^j$, para $j = 2, \dots, N$ para garantir $N[n] > 10$ segmentos. A sequência $Z[k]$ pode ser caracterizada pela relação entre $F[n]$ e n ; por exemplo, em muitas sequências aleatórias, é comum observar que $F[n]$ tem uma dependência a potência de n , que pode ser escrita como na Equação 4.

$$F[n] \sim n^\alpha \quad (4)$$

Onde α é um expoente que caracteriza as propriedades de correlação automática da sequência original. Nesse caso, diz-se que a série temporal analisada possui um comportamento de escala fractal com o expoente de escala e flutuação α . Esse expoente pode ser encontrado em um gráfico de log-log, $\log F[n]$ vs. $\log n$, como a inclinação da linha de ajuste, demonstrado na Figura 5. Como dito acima, o parâmetro α (expoente de escala ou expoente de autocorrelação) é uma

medida da autocorrelação do sinal. Como é indicado por Delignières (2015), um valor de $\alpha = 0,5$ indica nenhuma correlação e, portanto, o sinal não é correlacionado (ruído branco), enquanto $0 < \alpha < 0,5$ representa um comportamento anticorrelacionado, alternando valores pequenos e grandes, e a série temporal é considerada anti-persistente; se $0,5 < \alpha < 1$, as correlações na série temporal são persistentes, onde valores grandes na série de dados têm maior probabilidade de aparecer após valores grandes e vice-versa.

4.7 Métodos de Reconhecimento de Padrões

Os algoritmos de aprendizado de máquina podem ser classificados em dois grandes grupos: Supervisionados e não-supervisionados. Nos casos supervisionados, para cada observação do preditor x_i , $i = 1, \dots, n$, há uma resposta associada medição y_i . Deseja-se ajustar um modelo que relacione a resposta à preditores, com o objetivo de prever com precisão a resposta para futuras observações (previsão) ou melhor compreensão da relação entre a resposta e os preditores (inferência). Por outro lado, a aprendizagem não supervisionada descreve a situação um pouco mais desafiadora na qual, para cada observação $i = 1, \dots, n$, observamos um vetor de medições x_i , mas nenhuma resposta associada y_i . Nesse cenário, trabalha-se, de certo modo, às cegas; a situação é referida como não supervisionada porque nos falta uma variável de resposta que possa supervisionar a análise (JAMES et al., 2013).

As técnicas de reconhecimento de padrão podem extrair informações de quaisquer conjuntos de dados. Neste trabalho foram extraídos dos expoentes gerados pelo DFA dos sinais de vibração. Os expoentes são vetores multicomponentes, o que dificulta uma análise prévia dos dados, por isso a utilidade das técnicas de reconhecimento de padrão e nesse trabalho foram utilizadas técnicas supervisionadas.

4.7.1 Support Vector Machine (SVM)

O método da máquina de vetores suporte (SVM) é baseado na teoria estatística de aprendizado. Existem três vantagens (WU, 2013):

- (i) Pode usar uma pequena parte de um grande número de dados de treinamento para a construção de modelos;
- (ii) Possibilidade de usar variável de relaxamento e função de kernel para lidar com problemas de classificação não lineares;
- (iii) SVM simplifica a complexidade computacional e aumenta a velocidade da operação.

O SVM adota o princípio de minimização de risco estrutural e possui excelente capacidade de generalização (CORTES, 1995). Considerando a capacidade de aprendizagem adaptativa e aproximação não linear, o SVM possui vantagens distintas no manuseio de pequenas amostras e dados não lineares (WANG, 2015). Para um determinado conjunto de dados, a i -ésima amostra de entrada x_i em um espaço de baixa dimensão é mapeada para um espaço vetorial de maior dimensão por uma função de mapeamento não linear $\phi(x)$. A função de classificação deve estimar corretamente os valores x_i e d_i que representam o vetor de características e a classe da i -ésima amostra, respectivamente, como exposto a seguir:

$$(x_1, d_1), \dots, (x_n, d_n) \in R^N$$

A divisão entre duas classes pode ser seccionada por um hiperplano, e caso seja linearmente separável, existirá infinitas soluções. Para isso, deve existir um vetor de pesos $w^T \in R^2$ e um viés $b \in R$ que logram em separar valores de entrada $x \in R^2$, entre duas regiões, para isso é preciso que as condições impostas pela Equação 5 sejam satisfeitas.

$$\begin{cases} w^T x_i + b > 0 & \text{se } d_i = +1 \\ w^T x_i + b < 0 & \text{se } d_i = -1 \end{cases} \quad (5)$$

Portanto, entre os dois conjuntos de dados é possível passar infinitos hiperplanos, porém existe apenas um hiperplano em que há uma máxima distância entre as duas classes no conjunto de treinamento, que é representado pela Equação 6.

$$w_o^T x + b_o = 0 \quad (6)$$

Surge assim, o conceito de margem de separação ρ , que é a menor distância entre o hiperplano e o elemento do padrão de treinamento mais próximo. Ou seja, há duas margens de separação que tornam possível reduzir um problema de classificação a um problema de maximização de função, como representado na Equação 7.

$$\rho(w, b) = \min_{[x:y=+1]} \frac{xw}{|w|} - \max_{[x:y=-1]} \frac{xw}{|w|} \quad (7)$$

Pode-se reduzir a Equação 7 na Equação 8 para o hiperplano ideal.

$$\rho = \frac{2}{|w_o|} \quad (8)$$

Como mencionado, o problema de otimização originado exige que o vetor de suporte seja maximizado, para isso o denominador da Equação 8 precisa ser o menor possível (ROCHA NETO, 2017).

4.7.2 Support Vector Machine com margem flexível

O hiperplano ideal nem sempre consegue separar as classes sem a presença de erros. Os casos em que há sobreposição de dados entre as classes e presença de *outliers* são exemplos da inexistência de um hiperplano ideal com capacidade de classificação sem erros associados, portanto flexibilizar as margens demasiadamente nesses casos pode acarretar no fenômeno de *overfitting* (CHANG, 2011).

A Equação 9 considera que nem todos os dados precisam ser classificados corretamente, e para permitir esse relaxamento na classificação foi introduzido uma variável de folga $\{\xi_i\}_{i=1}^n$.

$$d_i(w^T x_i + b) > 1 - \xi_i \quad (9)$$

Sendo $\xi_i \geq 0$, para $i = 1, 2, 3 \dots n$. Há três casos possíveis para o valor da variável de folga:

1. Quando ξ_i estiver no intervalo $]0,1]$, significa que a amostra i está dentro da margem de separação no lado correto do hiperplano.
2. Quando ξ_i possuir valor maior que 1, significa que a amostra i está dentro da margem de separação no lado errado do hiperplano.
3. Quando ξ_i for igual a zero, representa todas as amostras que estão corretamente classificadas fora da margem de folga.

Diante do que foi exposto anteriormente, o método SVM de margem flexível apresenta uma nova variável, em relação ao método sem margens. Pode-se reduzir o problema de otimização como formulado pela Equação 10.

$$\min \tau(\xi) = \frac{1}{2}(w^T w) + C \sum_{i=0}^n \xi_i \quad (10)$$

Onde C é o parâmetro de regularização entre os dois termos, ambos precisam ser minimizados para atingir o valor satisfatório. O parâmetro C tem a importância de acrescentar um maior peso, se necessário, para a variável de folga, a fim de obter uma flexibilidade satisfatória (MAIA, 2019).

As variáveis w , b e ξ precisam ser minimizadas, enquanto as variáveis α e β precisam ser maximizadas. A utilização da função lagrangeana $L(w, b, \xi, \alpha, \beta)$, demonstrada na Equação 11, informa o ponto de sela em que satisfaz as condições das variáveis do sistema.

$$L(w, b, \xi, \alpha, \beta) = \frac{1}{2}w^T w + C \sum_{i=1}^n \xi_i - \sum_{i=1}^n \alpha_i (d_i (x_i^T w + b) - 1 + \xi_i) - \sum_{i=1}^n \alpha_i \beta_i \quad (11)$$

A derivada parcial da função lagrangeana em relação as variáveis que precisam ser minimizadas ($\frac{\partial L}{\partial w}$, $\frac{\partial L}{\partial b}$ e $\frac{\partial L}{\partial \xi}$) possuem valor 0. Substituindo os resultados obtidos pelas derivações parciais novamente na Equação 11, podemos reduzir a equação lagrangeana para $L(\alpha)$, como mostrado na Equação 12, assim o problema de otimização apresenta somente os multiplicadores de Lagrange.

$$\begin{cases} L(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j d_i d_j x_i^T x_j \text{ s. a.} \\ \sum_{i=1}^n \alpha_i d_i \text{ s. a} \\ 0 \leq \alpha_i \leq C \text{ para } i = 1, 2, \dots, n \end{cases} \quad (12)$$

O limite superior do multiplicador de Lagrange coincide com o parâmetro de regularização C , enquanto o limite inferior é 0. Há casos em que a implementação do método de margem flexível não é satisfatória, são os casos de não linearidade de classificação possível (ROCHA NETO, 2017)

4.7.3 Função Kernel

A função Kernel é um conceito de mapeamento para problemas que são não linearmente separáveis, constitui em elevar a dimensão do conjunto de dados. O conjunto de entrada de dados $x_i \in R^N$ são mapeados para um espaço $\phi(x) \in R^M$, tal que $M > N$ (HAYKIN, 2009).

A representação da função Kernel pode ser feita pelo produto interno dos vetores no espaço característico, como representado na Equação 13.

$$K(x, y) = \sum_{i=1}^M \phi_i(x)\phi_i(y) \quad (13)$$

Pode-se então redefinir a Equação 12, referente ao método SVM de margem flexível, acrescentando a função Kernel apresentada na Equação 13. A nova forma de representação simplificada para os métodos de classificação não lineares é expressa pela Equação 14.

$$\begin{cases} L(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j d_i d_j x_i^T x_j K(x_i, x_j) \text{ s. a.} \\ \sum_{i=1}^n \alpha_i d_i \text{ s. a.} \\ 0 \leq \alpha_i \leq C \text{ para } i = 1, 2, \dots, n \end{cases} \quad (14)$$

Portanto, a função discriminante que representa o espaço característico fica representada na forma da Equação 15.

$$f(x) = \sum_{i=1}^n \alpha_i d_i K(x_i, x) + b_o \quad (15)$$

Uma função sinal y é aplicado em $f(x)$, como resultado esperado, $y_i = +1$ é o rótulo pertencente a uma classe, e $y_i = -1$ é o rótulo pertencente a classe oposta.

De acordo com Rocha Neto (2017), as funções Kernel mais comuns são as lineares, polinomiais e gaussianas (RBF), representadas de forma genérica nas Equações 16, 17 e 18, respectivamente.

$$K(x_i, x) = x_i^T x \quad (16)$$

$$K(x_i, x) = (x_i^T x + 1)^d \quad (17)$$

$$K(x_i, x) = \exp\left\{\frac{-\|x-x_i\|^2}{\sigma^2}\right\} \quad (18)$$

Sendo d na Equação 17, o grau do polinômio. Na Equação 18, o termo σ é um parâmetro de escolha do projeto, juntamente com o parâmetro C da Equação 10, forma um par de constantes que precisam ser adaptadas de acordo com as particularidades do sistema. O termo $\|x - x_i\|^2$ da Equação 18 representa a distância euclidiana entre as amostras.

4.7.3 Escolha dos hiperparâmetros

O conjunto de dados é dividido em dois subconjuntos: treinamento e teste. O parâmetro dos multiplicadores lagrangeanos são definidos na fase de treinamento de acordo com as características dos dados de entrada. No caso do SVM de margem flexível com uma função Kernel do tipo gaussiana, os parâmetros considerados são: a constante de regularização C e o parâmetro do Kernel σ .

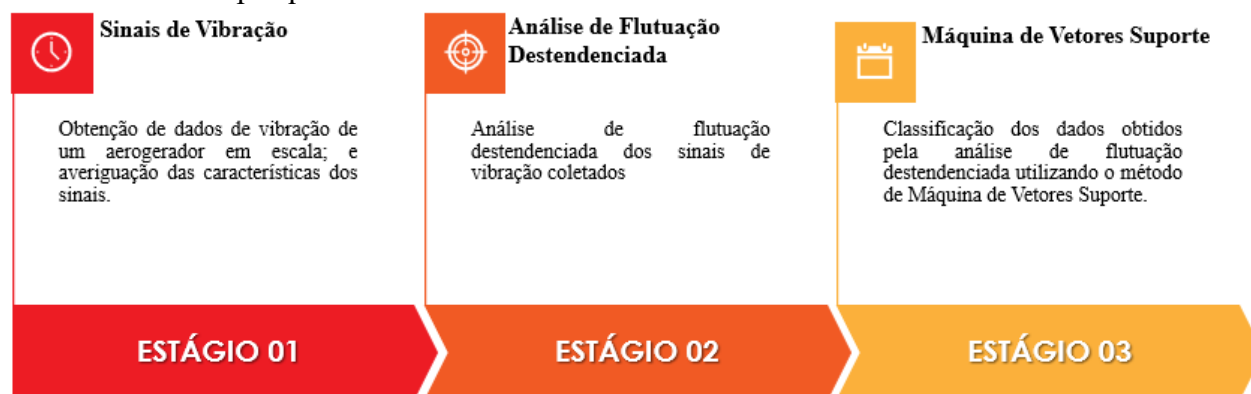
A escolha de valores altos para C gera o fenômeno do *overfitting*, que é o excesso de ajuste aos dados de treinamento e baixa taxa de acertos na etapa de teste. Já valores insuficientes da constante de regularização promovem o fenômeno do *underfitting*, que é a falta de ajuste aos dados de treinamento e baixa taxa de acertos na etapa de teste (ALPAYDIN, 2009).

Em paralelo com a escolha do valor da constante de regularização, o valor do parâmetro do Kernel precisa ser escolhido para otimizar o modelo. Escolhas que se distanciam do valor de otimização ocasionam os fenômenos de *overfitting* e *underfitting*, uma vez que as classes podem se tornar completamente separáveis, ou de forma oposta, podem continuar mescladas e de difícil classificação. Por isso, a escolha de ambos parâmetros devem estar relacionados no processo de otimização (WEBB, 2003).

5 METODOLOGIA

A metodologia foi dividida em três subtópicos: sinais de vibração, análise de flutuações destendenciadas e máquina de vetores suporte. A Figura 5 demonstra o diagrama em ordem sequenciada para se obter os resultados da pesquisa.

Figura 5 - Diagrama em ordem sequenciada dos métodos elaborados para obtenção dos resultados da pesquisa.



Fonte: Elaborado pelo autor

5.1 Sinais de Vibração

Os dados dos sinais de vibração utilizados foram resultados de artigos anteriores produzido por Moura et al. (2016), que tinham como linha de pesquisa o estudo do desbalanceamento de aerogeradores em escala utilizando a análise de vibração como uma ferramenta de estudo para conseguir resultados de classificação do grau de desbalanceamento das pás de um aerogerador em escala.


As atividades realizadas por Moura et al. (2016) constituíram-se em cinco etapas: projetar e fabricar o aerogerador em escala; realizar ensaios com o aerogerador em um túnel de vento; capturar dados de vibração nesses ensaios utilizando um acelerômetro; tratar os dados aplicando DFA; utilizar técnicas de reconhecimento de padrões nos dados tratados para classificação do desbalanceamento.

Os dados dos ensaios realizados no artigo produzido por Moura et al. (2016) serviram para a conclusão de outros trabalhos, mas não foi exaurido todo seu potencial de informação a ser estudada, ainda há margem para estudos que possam complementar as pesquisas realizadas anteriormente. A mesma base de dados foi usada para a construção deste trabalho.

5.1.1 Ensaio de captura dos sinais de vibração

A bancada usada para a realização dos ensaios foi projetada e construída por Almeida (2013). A bancada de ensaio, como pode ser vista na Figura 6, possui um eixo, um transdutor de torque, que converte um valor físico de velocidade e torque em sinal elétrico, 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.

Figura 6 - Bancada de testes.



Fonte: Adaptado pelo autor.

Sinais de vibração foram capturados através de um acelerômetro posicionado no mancal do eixo mais próximo das pás (ver Figura 7). O sensor foi acoplado a um amplificador e, em seguida, passou um filtro do tipo passa banda, com os limites 1,0 Hz (alto) e 100,0 Hz (baixo). Os sinais de vibração foram registrados com uma taxa de amostragem de 250 Hz (250 amostras/s) por 2 segundos, gerando sinais com 500 pontos. Para cada condição de trabalho (níveis de desbalanceamento e de rotações) foram registrados 50 sinais de vibração.

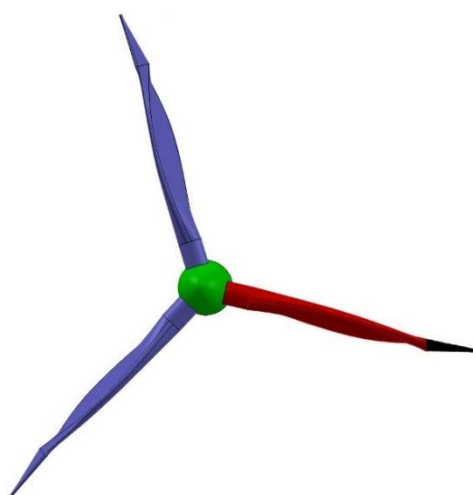
5.1.2 Procedimentos no ensaio de captura de dados de vibração

Como mencionado nos tópicos anteriores, um aerogerador em campo sofre com intempéries diversas, como ventos oscilantes, chuvas, neve e até choque de pássaros, durante todo seu funcionamento. Devido a esse fato, é comum uma pá sofrer de erosão ou acúmulo de materiais e conseqüentemente um desbalanceamento. Dependendo do estado de anormalidade em que a pá se encontra, pode haver excesso de vibração e, posteriormente, defeitos mais severos começam a interferir na potência do aerogerador.

Com o intuito de simular essas situações, o ensaio realizado por Moura et al. (2016) para gerar desbalanceamento no aerogerador em escala consistiu em acrescentar massas com pesos padrões acoplados as pontas das pás. O padrão do ensaio cumpriu os seguintes procedimentos:

1 – Desbalanceamento com acréscimo de massa em apenas uma pá: Representa dois cenários, o primeiro é deposição de um corpo estranho em uma pá, como areia, pássaros ou neve, por exemplo. O segundo é a situação em que há perda de massa por erosão nas outras pás em que a massa de ensaio não está acoplada. Para simular essas condições, massas de 0,5, 1,0 e 1,5 g foram adicionadas à ponta de uma pá como representado na Figura 7, a ponta de cor preta representa a massa fixada a pá. O acoplamento de cada massa representa ensaios distintos.

Figura 7 - Representação esquemática do ensaio com uma massa de 0,5, 1,0 e 1,5g.




Fonte: Elaborado pelo autor.

2 – Desbalanceamento com acréscimo de massa em duas pás. Esse teste representa

situações críticas de defeitos, pois representa um cenário em que a pá sem peso acoplado perdeu massa devido a alguma quebra. Esses casos precisam ser identificados em um curto espaço de tempo para não comprometer o aerogerador de forma permanente. No trabalho, a representação desse caso foi feita pela adição de massas de 0,5, 1,0 e 1,5 g em suas pontas, assim como representado na Figura 8. O acoplamento dos pares de massas representam ensaios distintos.


Figura 8 - Representação esquemática do ensaio com massas em duas pás, com valores de 0,5, 1,0 e 1,5 g.



Fonte: Elaborado pelo Autor.

3 – Sem desbalanceamento induzido. Esse caso representa os valores de vibração em níveis normais de operação de um aerogerador, sem a presença de corpos estranhos ou erosão. Os níveis de vibração do sistema balanceado deve ser próximo aos níveis de vibração usando-se apenas o eixo em rotação livre sem pás. Os dados gerados nessa etapa de testes servirão como referencial para indicar se em um conjunto de dados há ou não a presença de desbalanceamento. A Figura 9 demonstra as pás de massas de teste.

Figura 9 - Representação esquemática do ensaio livre de massas.



Fonte: Elaborado pelo autor.

Em cada procedimento do ensaio, foram capturados 50 sinais. A Tabela 1 representa de forma esquemática o número de sinais em cada tipo de procedimento do ensaio.

Tabela 1 – Representação da quantidade de sinais em cada procedimento.

Tipo do Ensaio	Rotação (rpm)		
	900	1200	1500
1 pá desbalanceada com 0,5 g	50	50	50
2 pás desbalanceadas com 0,5 g	50	50	50
1 pá desbalanceada com 1,0 g	50	50	50
2 pás desbalanceadas com 1,0 g	50	50	50
1 pá desbalanceada com 1,5 g	50	50	50
2 pás desbalanceadas com 1,5 g	50	50	50
Sem desbalanceamento	50	50	50
Total	350	350	350

Fonte: Elaborado pelo autor.

5.2 Aplicação da DFA

Após a coleta dos sinais de vibração, os dados precisaram ser processados antes de iniciar a classificação. Na primeira etapa, os sinais passaram pelo DFA, gerando vetores com várias componentes. A análise desses vetores torna-se extremamente complicada por conta da multidimensionalidade do problema. Assim, as técnicas de reconhecimento de padrões foram

utilizadas para realizar uma classificação adequada dos sinais. Os vetores gerados pela DFA passaram, então, pelos processos de classificação pelo método SVM.

5.3 Máquina de Vetores Suporte

Todos os vetores gerados pela DFA foram classificados utilizando o método SVM, a partir de uma abordagem Um-Contra-Um, onde cada classe é classificada contra cada uma das demais classes. Esta abordagem exige a construção de $K(K-1)/2$ classificadores, onde K é número de classes. Após o devido treinamento de cada um dos classificadores, a amostra de teste foi analisada e atribuída à classe que “recebeu mais votos” dos classificadores.

Para implementação da técnica de classificação SVM, o conjunto de sinais obtidos pela análise de flutuações destendenciadas precisou ser dividido em dois subconjuntos: treinamento e teste. 80% dos sinais foram utilizados para treinamento do classificador e os 20% restantes foram utilizados como teste para avaliar a taxa de acerto da classificação.

Todas as classificações utilizaram a função gaussiana (ou RBF) como função Kernel. O algoritmo SMO foi utilizado para resolução dos problemas de otimização (Problema Dual do SVM). Em todas as análises, os hiperparâmetros C (parâmetro de regularização) e σ (parâmetro do Kernel gaussiano) foram ajustados seguindo o seguinte procedimento:

1. Foi realizada uma busca em grade nos seguintes valores para ambos os hiperparâmetros: 1; 25; 50; 75; 100. (os limites 1 e 100 foram definidos após testes iniciais de classificação).
2. Após a seleção inicial, uma busca aleatória foi realizada nos intervalos que foram definidos pelos valores vizinhos do valor inicialmente escolhido.

O ajuste teve como objetivo a maximização do acerto obtido pela validação cruzada de 5-dobras realizada sobre o conjunto de treinamento. Os hiperparâmetros selecionados são justamente os que promoveram a maior taxa de acerto. Todo o processo de separação treino-teste e ajuste de hiperparâmetros foi repetido 100 vezes.

É necessário explicitar que o ajuste de hiperparâmetro foi realizado toda vez que um novo conjunto de treinamento foi apresentado aos classificadores. Em hipótese alguma os dados de teste foram utilizados de forma a interferir na seleção destes hiperparâmetros.

As classificações dos dados foram desenvolvidas em três níveis diferentes de

rotação (900, 1200 e 1500 rpm) para representar a variação dos ventos ao longo do dia, uma vez que o aerogerador não opera constantemente na velocidade de projeto. Em cada nível de rotação, foram utilizados dois conjuntos de classificação: utilizando três classes (CD1, CD2 e CB) e, em seguida, sete classe (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 CB). A Tabela 2 apresenta de forma esquemática como foram divididos os dois conjuntos de classes e o significado da representação de cada classe.

Tabela 2 – Representação dos dois conjuntos de classes e a definição das classes.

Conjunto com 3 classes	Definição da Classe	Conjunto com 7 classes	Definição da Classe
CD1	Classe com 1 pá desbalanceada	CD1-0,5 g	Classe com desbalanceamento de 0,5 g em 1 pá
		CD1-1,0 g	Classe com desbalanceamento de 1,0 g em 1 pá
		CD1-1,5 g	Classe com desbalanceamento de 1,5 g em 1 pá
CD2	Classe com 2 pá desbalanceada	CD2-0,5 g	Classe com desbalanceamento de 0,5 g em 2 pás
		CD2-1,0 g	Classe com desbalanceamento de 1,0 g em 2 pás
		CD2-1,5 g	Classe com desbalanceamento de 1,5 g em 2 pás
CB	Classe balanceada	CB	Classe balanceada

Fonte: Elaborado pelo autor.

Como saída do classificador SVM, é obtido uma matriz de confusão média em que cada classe apresentará sua classificação separado em etapa de treinamento e teste, em função das outras classes (abordagem um-contra-um). Foram realizadas classificações para cada um dos dois conjuntos de classificação, em cada um dos três níveis de rotação, totalizando seis matrizes de confusão média.

6 RESULTADOS E DISCUSSÕES

Nesta seção, são apresentados os resultados produzidos pela DFA e a classificação dos sinais de vibração utilizando o método de técnica de reconhecimento de padrões SVM, além de discutir as informações de saída obtidas pelo classificador.

6.1 Filtragem dos Dados e Processamento pelo Método DFA


A frequência dos sinais de vibração varia entre 15 Hz e 25 Hz. O amplificador que recebeu esses sinais foi programado para manter um filtro passa banda na faixa de 1 Hz a 100 Hz. Valores que extrapolam esses limites são descartados automaticamente.

Os sinais foram registrados obedecendo o teorema de Nyquist-Shannon, que afirma que os sinais devem ser registrados com uma taxa de amostragem maior ou igual ao dobro da sua frequência fundamental. Todos os sinais utilizados nesta dissertação foram registrados com uma taxa de amostragem de 250 Hz.

A implicação prática dessa taxa de amostragem é que, para as três rotações consideradas no experimento (900, 1200 e 1500 rpm) durante os dois segundos em que cada sinal foi registrado, o aerogerador em escala realizou 30, 40 e 50 rotações completas.

A Figura 10 mostra uma janela de dados de amplitude de vibração normalizado em função do tempo.


Figura 10 – Sinal de vibração normalizado obtido pela rotação de 900rpm com uma pá desbalanceada.



Fonte: Adaptado de MOURA et al. (2016)

A análise de flutuações destendenciadas visa melhorar a avaliação de correlações em uma série temporal, eliminando tendências nos dados. A partir dos valores logaritmo de base 10 da função $F(\tau)$, descrita pela Equação 3, podem ser definidos vetores cujos componentes correspondem à flutuação média associada aos tamanhos de intervalo escolhidos adequadamente. Nesse sentido, cada vetor tem 24 componentes e os valores de τ correspondiam aos valores em (5, 6, 7, 8, 9, 11, 13, 16, 19, 22, 26, 31, 37, 44, 53, 63, 74, 88, 105, 125, 149, 177, 210, 250). A Figura 11 demonstra a relação desses valores ajustados na base logarítmica.

Figura 11 – Curva DFA obtida dos sinais mostrados na Figura 10.



Fonte: Adaptado de MOURA et al. (2016)

6.2 Classificação dos Sinais

Após a geração dos vetores da DFA, a classificação foi realizada utilizando o classificador SVM, inicialmente, com três classes e em seguida com sete classes. As diagonais principais dessas matrizes indicam quantitativamente o percentual de acertos na classificação e a soma das linhas das matrizes de confusão média representam todas as classificações possíveis para cada classe e, portanto, sua soma será sempre 100%. As matrizes de confusão apresentam o percentual médio de dados de entrada de cada classe que foram corretamente classificados. As médias foram calculadas após 100 interações distintas de treinamento e teste. A Tabela 3 demonstra a matriz de confusão média para classificação de três classes de desbalanceamento no nível de rotação de 900 rpm, dividido em duas etapas, treinamento e teste.

Tabela 3 - Matriz de confusão média para classificação de três classes de desbalanceamento e nível de rotação de 900 rpm.

Matriz de Classificação Correta		CD1	CD2	CB	
Classificação Correta	Treinamento	CD1	100	0	0
		CD2	0	100	0
		CB	0	0	100
	Teste	CD1	99,89	0,11	0
		CD2	0	100	0
		CB	0	0,71	99,29

Fonte: Elaborado pelo autor.

Verifica-se, na matriz de confusão apresentada na Tabela 3, que as taxas de acerto na classificação de dados associados aos desbalanceamentos provocados por excesso de massa em uma pá, duas pás e sem desbalanceamento alcançaram uma taxa de acerto de 100% na etapa de treinamento. Os desempenhos alcançados nas etapas de testes foram ligeiramente diferentes, pois apenas a classe que apresenta desbalanceamento em duas pás alcançou o resultado de 100% de acertos, enquanto a classe CD1 alcançou 99,89% e a Classe CB, 99,29%.

Confrontando a matriz de confusão média com três classes (ver Tabela 3) e a matriz de confusão média com sete classes (ver Tabela 6), torna-se evidente que o método SVM teve melhor desempenho de classificação utilizando-se uma menor quantidade de classes.

Outro ponto interessante, ainda comparando-se a Tabela 3 e 6, é que a classificação do desbalanceamento produzido pelo acréscimo de massa em uma pá, possui maiores taxas acertos do que a classificação do desbalanceamento produzido pelo acréscimo de massas em duas pás classificando o problema em sete níveis de desbalanceamentos, o que é retratado de forma inversa na matriz com apenas três classes de desbalanceamentos. A Tabela 4 apresenta uma matriz de confusão média para a classificação de três classes de desbalanceamento em um maior nível rotação, agora de 1200 rpm.

Tabela 4 - Matriz de confusão média para classificação de três classes de desbalanceamento e nível de rotação de 1200 rpm.

Matriz de Classificação Correta		CD1	CD2	CB	
Classificação Correta	Treinamento	CD1	99,63	0,16	0,21
		CD2	0	100	0
		CB	0,01	0	99,99
	Teste	CD1	98,60	0,62	0,78
		CD2	0	100	0
		CB	1,07	0	98,93

Fonte: Elaborado pelo autor.

Verifica-se, na matriz de confusão apresentada na Tabela 4, que as taxas de acerto para a etapa de treinamento, 99,63% e 99,99%, classe CD1 e CB respectivamente, apresentaram uma pequena queda em relação ao nível de rotação de 900 rpm. Já no caso do desbalanceamento provocado por excesso de massa em duas pás (classe CD2), foi alcançado uma taxa de acerto de 100% em ambas etapas.

Os desempenhos alcançados nas etapas de testes foram ligeiramente diferentes para as classes CD1 e CB, já que foram reduzidos para os valores de 98,60% e 98,93%, respectivamente. Já a classe CD2 continua com uma taxa de acerto máxima em ambas etapas de treinamento e de teste.

Confrontando a matriz de confusão média com três classes (ver Tabela 4) e a matriz de confusão média com sete classes (ver Tabela 7), torna-se evidente que o método SVM teve novamente melhores desempenhos de classificação utilizando-se uma menor quantidade de classes, contudo, diferentemente da Tabela 3, a taxa de acertos da Tabela 4 não atingiram, na etapa de treinamento, valores máximos em duas das três classes. A Tabela 5 apresenta uma matriz de confusão média para a classificação de três classes de desbalanceamento no maior nível de rotação, 1500 rpm.

Tabela 5 - Matriz de confusão média para classificação de três classes de desbalanceamento e nível rotação de 1500 rpm.

Matriz de Classificação Correta		CD1	CD2	CB	
Classificação Correta	Treinamento	CD1	99,68	0,02	0,31
		CD2	1,20	98,80	0
		CB	0,01	0	99,99
	Teste	CD1	98,95	0,27	0,78
		CD2	2,13	97,54	0,34
		CB	0	0,31	99,69

Fonte: Elaborado pelo autor.

Verifica-se, na matriz de confusão apresentada na Tabela 5, que as taxas de acerto nas três classes não atingiram o valor máximo, chegando próximo apenas a classe CB, com um valor de 99,99% de acerto. Já os desempenhos alcançados na etapa de teste foram ligeiramente inferiores para todas as três classes, como esperado.

Confrontando a matriz de confusão média com três classes (ver Tabela 5) e a matriz de confusão média com sete classes (ver Tabela 8), torna-se evidente que o método SVM teve novamente melhores desempenhos de classificação utilizando-se uma menor quantidade de classes, contudo, diferentemente da Tabela 3 e 4, a taxa de acertos da Tabela 5 não atingiu, na etapa de treinamento, valores máximos em nenhuma das três classes. Isso representa uma tendência de queda na taxa de acerto nas matrizes de confusão média em função do aumento da rotação do sistema.

Há também uma tendência de queda na taxa de acerto na etapa de teste quando há aumento da rotação de 900 rpm até 1500 rpm. Isso representa uma relação inversamente proporcional entre o aumento da rotação com o aumento da taxa de acertos para a classificação com apenas três classes. Para o conjunto com três classes, a menor taxa de acerto na etapa de treinamento foi de 98,80%, enquanto na etapa de teste, 97,54%.

Decompondo as três classes de desbalanceamento nos níveis de rotação de 900 rpm, 1200 rpm e 1500 rpm, anteriormente analisadas, em sete classes de desbalanceamento nos mesmos níveis de rotações, o enfoque dos resultados deixa de ser apenas a quantidade de pás com desbalanceamento, e passar a ser a quantidade de pás desbalanceadas simultaneamente com o grau desse desbalanceamento (0,5 g, 1,0 g ou 1,5 g). A Tabela 6 mostra a primeira matriz de confusão média com sete classes de desbalanceamento no nível de rotação de 900 rpm.

Tabela 6 – Matriz de confusão média para classificação de sete classes de desbalanceamento e nível de rotação de 900 rpm.

Matriz de Classificação Correta		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	CB	
Classificação Correta	Treinamento	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	100	0	0	0	0
		CD2-0,5 g	0	0	0	96,74	3,26	0	0
		CD2-1,0 g	0	0	0	3,42	96,58	0	0
		CD2-1,5 g	0	0	0	0	0	100	0
		CB	0	0	0	0	0,06	0	99,94
	Teste	CD1-0,5 g	100	0	0	0	0	0	0
		CD1-1,0 g	0,92	99,08	0	0	0	0	0
		CD1-1,5 g	0	0	99,92	0	0	0,08	0
		CD2-0,5 g	0	0	0	93,66	6,34	0	0
		CD2-1,0 g	0	0	0	3,25	96,75	0	0
		CD2-1,5 g	0	0	0	0	0	100	0
		CB	0	0	0	0,4	0,84	0	98,76

Fonte: Elaborado pelo autor.

Verifica-se que as taxas de acerto na classificação de dados associados aos desbalanceamentos, provocados por excesso de massa em uma única pá são maiores que para as classes associadas aos desbalanceamentos produzidos pela adição de massa em duas pás, como visualiza-se nas colunas de 1 a 6.

Taxas de acerto acima de 96,58% foram alcançadas na classificação dos dados obtidos a 900 rpm na etapa de treinamento (ver Tabela 6). O desempenho nas etapas de treinamento e de teste são ligeiramente diferentes. A classe associada aos sinais capturados com adição de 0,5 g em duas pás (CD2-0,5 g) foi a que apresentou relativamente a menor taxa de acerto, com 93,66% para a etapa de teste. Seguindo o mesmo procedimento de análise, a Tabela 7 apresenta a matriz de confusão média com sete classes no nível de rotação de 1200 rpm.

Tabela 7 - Matriz de confusão média para classificação de sete classes de desbalanceamento e nível de rotação de 1200 rpm.

Matriz de Classificação Correta		Saída do Classificador						CB	
		CD1-0,5 g	CD1-1,0 g	CD1-1,5 g	CD2-0,5 g	CD2-1,0 g	CD2-1,5 g		
Classificação Correta	Treinamento								
		CD1-0,5 g	99,88	0	0	0	0	0	0,12
		CD1-1,0 g	0	80,31	19,69	0	0	0	0
		CD1-1,5 g	0	3,97	96,03	0	0	0	0
		CD2-0,5 g	0	0	0	99,92	0	0,08	0
		CD2-1,0 g	0	0	0	0	100	0	0
		CD2-1,5 g	0	0	0	0	0	100	0
		CB	0	0	0	0	0	0	100
		Teste							
		CD1-0,5 g	97,83	0	0	0	0	0	2,17
		CD1-1,0 g	0	77,27	22,73	0	0	0	0
		CD1-1,5 g	0,33	7,92	89,92	0,22	0	0,16	1,45
		CD2-0,5 g	0	0	0	99,03	0	0,88	0,09
		CD2-1,0 g	0	0	0	0,47	99,28	0	0,25
	CD2-1,5 g	0	0	0	1,87	0	98,13	0	
	CB	0,6	0	0	0	0	0	99,4	

Fonte: Elaborado pelo autor.

Verifica-se que na etapa de treinamento da matriz de confusão média com sete níveis de desbalanceamento e rotação de 1200 rpm, as taxas de acerto na classificação de dados associados aos desbalanceamentos, provocados por excesso de massa em uma única pá são menores que para as classes associadas aos desbalanceamentos produzidos pela adição de massa em duas pás, como visualiza-se nas colunas 1, 2 e 3. Esse resultado é diferente do obtido na Tabela 6, uma vez que os desbalanceamentos provocados por excesso de massa em duas pás atingiram taxas de acertos elevadas de 99,92%, 100% e 100%.

O desempenho nas etapas de treinamento e de teste apresentaram resultados ligeiramente diferentes em algumas classes, no entanto todas as três classes com excesso de massa em apenas uma pá apresentaram resultados com maior desnível entre as etapas de treinamento e teste. A classe associada aos sinais capturados com adição de 1,0 g em uma pá (CD1-1,0 g) foi a que apresentou a menor taxa de acerto, com 80,31% e 77,27% para conjuntos de treinamento e teste, respectivamente. Seguindo para última análise, a Tabela 8 apresenta a matriz de confusão média com sete classes e nível de rotação de 1500 rpm.

Tabela 8 – Matriz de confusão média para classificação de sete classes de desbalanceamento e nível de rotação de 1500 rpm.

Matriz de Classificação Correta		Saída do Classificador						CB	
		CD1-0,5 g	CD1-1,0 g	CD1-1,5 g	CD2-0,5 g	CD2-1,0 g	CD2-1,5 g		
Classificação Correta	Treinamento								
		CD1-0,5 g	94,66	4,12	0	0	0	0	1,23
		CD1-1,0 g	1,18	98,82	0	0	0	0	0
		CD1-1,5 g	0	0	100	0	0	0	0
		CD2-0,5 g	0	0	0	100	0	0	0
		CD2-1,0 g	0,95	0	2,32	0	96,74	0	0
		CD2-1,5 g	0	0	0	0	0	100	0
		CB	0	0	0	0	0	0	100
		Teste							
		CD1-0,5 g	92,54	4,92	0	0	0	0	2,54
		CD1-1,0 g	1,88	98,12	0	0	0	0	0
		CD1-1,5 g	0	0	99,89	0	0,11	0	0
		CD2-0,5 g	0	0,18	0	98,93	0	0	0,88
		CD2-1,0 g	4,15	0	3,45	0	92,32	0	0,08
	CD2-1,5 g	0	0	0	0	0	100	0	
	CB	0,1	0	0	0	0	0	99,9	

Fonte: Elaborado pelo autor.

Verifica-se que na etapa de treinamento da Tabela 8, as taxas de acertos na classificação de dados associados aos desbalanceamentos, provocados por excesso de massa em uma única pá são menores que para as classes associadas aos desbalanceamentos produzidos pela adição de massa em duas pás, como visualiza-se nas colunas 1 e 2, com exceção da coluna 3 que apresentou um resultado de 100%. Fato esse que se assemelhou em parte com a Tabela 7, em que os desbalanceamentos provocados por excesso de massa em duas pás atingiram taxas de acertos elevadas de 99,92%, 100% e 100%, consecutivamente.

O desempenho nas etapas de treinamento e de teste apresentaram resultados ligeiramente diferentes na maioria das classes, com exceção das classes CD1-0,5 g e CD2-1,0 g, que mostraram uma queda na diferença de taxa de acertos mais significativa, de 2,12% e 4,42%, respectivamente. O melhor desempenho ficou com a classe CD2-1,5 g, que conseguiu manter uma taxa de acerto de 100% em ambas as etapas.

O fenômeno do decréscimo da taxa de acerto em função do aumento do nível de rotação visto nas matrizes com três classes de desbalanceamento não foi observado para o conjunto com sete classes de desbalanceamento. Observa-se que houve uma redução do número de acertos em várias classes quando aumentou-se o nível de rotação de 900 rpm para 1200 rpm, porém, em média, algumas classes tiveram um pequeno aumento na taxa de acertos quando o nível de rotação passou de 1200 rpm para 1500 rpm. Essa elevação não era esperada, uma vez

que o aumento da rotação ocasiona um aumento no nível de vibração sistêmica. Esse fenômeno pode ter ocorrido devido a frequência de 1200 rpm ter se aproximado da frequência natural de algum componente ou equipamento do sistema. Um estudo sobre a frequência natural não foi levado em consideração nessa dissertação.

6.3 Comparações com Outros Métodos na Literatura

Moura et al. (2016) desenvolveram um artigo com uma mesma coleção de dados, mas utilizando três classificadores distintos: Discriminador Gaussiano (DG), Transformada de Karhunen-Loève (KLT) e Redes Neurais Artificiais (RNA). Comparou-se apenas o conjunto de dados com sete classes distintas nos três níveis de rotação, nas etapas de treinamento e de teste. Para comparar os dados utilizou-se a taxa média de acertos (TMA), pois a quantidade de sinais em cada classe são as mesmas para cada classificador (ver Tabela 1). A TMA pode ser obtida somando as taxas de acertos (diagonal principal das matrizes de confusão média) divididas pelo número total de classes.

A Tabela 9 demonstra a comparação das TMA entre quatro classificadores para o conjunto com sete classes em três níveis de rotação nas etapas de treinamento e teste.

Tabela 9: Comparação das TMA entre os classificadores: DG, KLT RNA e SVM.

Ranking dos classificadores		900 rpm		1200 rpm		1500 rpm	
Treinamento	1º Colocado	DG	100%	DG	99,83%	DG	100%
	2º Colocado	KLT	100%	KLT	96,79%	RNA	99,10%
	3º Colocado	RNA	99,96%	SVM	96,59%	SVM	98,60%
	4º Colocado	SVM	99,03%	RNA	96,57%	KLT	98,59%
Teste	1º Colocado	KLT	99,88%	KLT	94,91%	KLT	97,79%
	2º Colocado	DG	99,31%	SVM	94,40%	DG	97,38%
	3º Colocado	RNA	98,67%	RNA	93,99%	SVM	97,37%
	4º Colocado	SVM	98,31%	DG	93,41%	RNA	97,37%

Fonte: Elaborado pelo autor.

Nota-se que o classificador SVM obteve uma baixa TMA no nível de rotação de 900 rpm se comparado com os outros classificadores, em ambas as etapas (treinamento e teste). No nível de rotação de 1200 rpm, o SVM conseguiu passar, sensivelmente, do RNA na etapa de treinamento, e dos classificadores RNA e DG na etapa de testes, uma melhora comparativa em relação ao nível de rotação menor. Já no nível de rotação de 1500 rpm, o SVM ficou na terceira posição na etapa de treinamento, ficando atrás dos classificadores DG e RNA, e na etapa de

testes, atrás dos KLT e DG. O método SVM obteve vantagens e desvantagens dependendo do nível de rotação e da etapa em que foi avaliado, mostrando ser um método de classificação simples e robusto.

7 CONCLUSÃO

Observa-se que nas etapas de treinamento dos ensaios divididos em três classes, há uma taxa de acertos decrescente quando aumenta-se as velocidades de rotações de 900 rpm para 1500 rpm, enquanto na menor rotação o treinamento conseguiu gerar taxas de acertos com 100% de acurácia, na maior rotação, os acertos foram entre 98,80% até 99,99%, uma redução sensível.

Observou-se que utilizando esse método, a classe sem desbalanceamento nas pás ou eixo sem pás (CB), apresentou acerto entre 99,94% até 100%, como visto nas 6 matrizes de confusão. Isso garante que o sistema possui desbalanceamento interno irrisório. Assim, o erro sistemático de vibração não interferiu na qualidade do classificador.

Ainda nos ensaios com três classes, mas analisando a etapa de testes, a tendência na redução da taxa de acertos também foi inversamente proporcional ao aumento da rotação. No nível de rotação a 900 rpm, a taxa de acertos foi entre 99,29% até 100%, enquanto a faixa de acerto a 1500 rpm, foi entre 97,54% até 99,69%. Essa diferença sensível na diminuição da taxa de acertos, quando se aumenta a rotação do sistema, pode ter sido ocasionada pelo leve aumento do erro sistemático de vibração com o aumento da rotação.

Avaliando-se a matriz com sete classes em 900 rpm, a etapa de treinamento alcançou uma taxa de acerto de 100% em quatro classes, exceto as classes CD2-0,5 g, CD2-1,0 g e CB não alcançaram o valor máximo. Já na etapa de testes, com exceção das classes CD1-0,5 g e CD2-1,5 g que mantiveram a taxa de acerto em 100%, as taxas de acertos diminuíram.

Analisando no nível de rotação de 1200 rpm na matriz de sete classes, a taxa de acertos de 100% na etapa de treinamento foi apenas em três classes, uma a menos que na rotação de 900 rpm. Na etapa de testes, todas as taxas de acertos caíram. Na matriz de sete classes com rotação a 1500 rpm, a etapa de treinamento voltou a ter quatro classes com taxa de acertos em 100%, mas na etapa de testes todas as classes tiveram suas taxas diminuídas como era esperado.

Essa diferença entre taxas de acertos entre as etapas de treinamento e de testes foram significativas em poucas classes de estudo, mas sempre obtiveram taxas de acerto acima de 90%, com exceção das classes CD1 - 1,0 g e CD2 - 1,5 g na rotação de 1200 rpm. De forma geral, os resultados foram promissores para identificação de problemas de desbalanceamento em aerogeradores em escala com condições ambientais controladas, principalmente quando se divide os problemas de classificação em uma menor quantidade de classes.

REFERÊNCIAS

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (ANEEL). Resultados de Leilões. Brasília: [s.i], 2018

AL-KHARBOSY, Mohamed Ebeed Hussein. Enhancement Protection and Operation of The Doubly Fed Induction Generator During Grid Fault. 2012. Tese de Doutorado. South Valley University.

ALMEIDA, M. S. de. Implementação computacional para desenvolvimento de pás de turbinas eólicas de eixo horizontal. 2013. 125 f. Dissertação (Mestrado em Engenharia Mecânica) - Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2013

ALPAYDIN, E. Introduction to machine learning. Massachusetts: MIT press, 2009.

AMARANTE, O. A. C.; ZACK, M. B. J.; SA, A. L. Atlas of Brazilian Wind Potential. MME, Brasilia, p. 44. 2011. 131f. Tese (Doutorado em Engenharia e Ciências de Materias). Departamento de Engenharia Metalúrgica e de Materiais, Universidade Federal do Ceará. Fortaleza, 2011.

ASSOCIAÇÃO BRASILEIRA DE ENERGIA EÓLICA (ABEEólica) (Org.). Boletim Anual de Geração Eólica 2019. São Paulo: [S.I.], 2018.

BRYCE, R.M. SPRAGUE, K.B. Revisiting detrended fluctuation analysis. Sci Rep, 2 (2012), p. 315

CÂMARA DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA (Brasil) (Ed.). Geração eólica representa 14,7% do total de energia produzido em agosto de 2020.2020. Disponível em: <https://www.cee.org.br/portal/faces/pages_publico/noticias-opinio/noticias/noticia leitura?contentid=CCEE_656811&_adf.ctrl-state=288uggj8v_1&_afLoop=40072947512351#!%40%40%3Fcontentid%3DCCEE_656811%26_afLoop%3D40072947512351%26_adf.ctrl-state%3D288uggj8v_5>. Acesso em: 20 dez. 2020.

CHANG, Chih-Chung; LIN, Chih-Jen. LIBSVM: A library for support vector machines. *ACM transactions on intelligent systems and technology (TIST)*, v. 2, n. 3, p. 1-27, 2011.

CHRISTOPHER, S G; SIMON, J W. Physics of failure approach to wind turbine condition based maintenance. *Wind Energy*, [s.l.], v. 5, n. 13, p.395-405, maio 2010.

CIANG, Chia Chen; LEE, Jung-ryul; BANG, Hyung-joon. Structural health monitoring for a wind turbine system: a review of damage detection methods. *Measurement Science And Technology*, [s.l.], v. 19, n. 12, p.122001-122008, 13 out. 2008. IOP Publishing. <http://dx.doi.org/10.1088/0957-0233/19/12/122001>

CLARK, Ruth Colvin; MAYER, Richard. *E-Learning and the Science of Instruction: Proven Guidelines for Consumers and Designers of Multimedia Learning*. 3. ed. Pfeiffer: John Wiley & Sons, 2011. 528 p.

CORTES, Corinna; VAPNIK, Vladimir. Support-vector networks. *Machine learning*, v. 20, n. 3, p. 273-297, 1995.

DELIGNIÈRES, Didier. Correlation Properties of (Discrete) Fractional Gaussian Noise and Fractional Brownian Motion. *Mathematical Problems In Engineering*, [s.l.], v. 2015, p.1-7, 2015. Hindawi Limited. <http://dx.doi.org/10.1155/2015/485623>.

DIÓGENES, Jamil Ramsi Farkat et al. Overcoming barriers to onshore wind farm implementation in Brazil. *Energy Policy*, [s.l.], p.111165-111179, jan. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.enpol.2019.111165>.

DOUGLAS WESTWOOD. *Offshore Wind Assessment For Norway*, 2010

DU, Ying et al. Damage detection techniques for wind turbine blades: A review. *Mechanical Systems And Signal Processing*, [s.l.], p.106445-10653, out. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.ymsp.2019.106445>.

EICHMAN, Joshua D. et al. Exploration of the integration of renewable resources into California's electric system using the Holistic Grid Resource Integration and Deployment

(HiGRID) tool. *Energy*, [s.l.], v. 50, p.353-363, fev. 2013. Elsevier BV. <http://dx.doi.org/10.1016/j.energy.2012.11.024>.

EMPRESA DE PESQUISAS ENERGÉTICAS (EPE) (Org). *Energy Balance: Year 2019*. Rio de Janeiro: [s.i.], 2020.

FENG, Zhipeng et al. Fault Diagnosis For Wind Turbine Planetary Gearboxes Via Demodulation Analysis Based On Ensemble Empirical Mode Decomposition And Energy Separation. *Renewable Energy*, [s.l.], v. 47, p.112-126, nov. 2012. Elsevier BV. <http://dx.doi.org/10.1016/j.renene.2012.04.019>.

FENG, Zhipeng; CHEN, Xiaowang; LIANG, Ming. Iterative generalized synchrosqueezing transform for fault diagnosis of wind turbine planetary gearbox under nonstationary conditions. *Mechanical Systems And Signal Processing*, [s.l.], v. 52-53, p.360-375, fev. 2015. Elsevier BV. <http://dx.doi.org/10.1016/j.ymsp.2014.07.009>.

FLEMMING, Manfred; ROTH, Siegfried. *Einführung. weisen Eigenschaften*, [s.l.], p.1-10, 2003. Springer Berlin Heidelberg. http://dx.doi.org/10.1007/978-3-642-55468-1_1.

FORSTHOFFER, Michael S.. *Predictive and Preventive Maintenance. Forsthoffer's More Best Practices For Rotating Equipment*, [s.l.], p.501-546, 2017. Elsevier. <http://dx.doi.org/10.1016/b978-0-12-809277-4.00011-5>.

GONZALEZ-CARRATO, R R D L H. Sound and vibration-based pattern recognition for wind turbines driving mechanisms. *Renewable Energy*, [s.i.], n. 109, p.262-274, maio 2017.

GUNTUR, Srinivas et al. Modeling Dynamic Stall On Wind Turbine Blades Under Rotationally Augmented Flow Fields. *Wind Energy*, v. 19, n. 3, p. 383-397, 2016.

HAHN, B; DURSTEWITZ, M; ROHRIG, K. Reliability of wind turbines—Experience of 15 years with 1500 WTs. *Wind Energy*, [s.i.], v. 62, n. 8, p.329-332, jan. 2015.

HAMEED, Z. et al. Condition monitoring and fault detection of wind turbines and related algorithms: A review. *Renewable And Sustainable Energy Reviews*, [s.l.], v. 13, n. 1, p.1-39,

jan. 2009. Elsevier BV. <http://dx.doi.org/10.1016/j.rser.2007.05.008>.

HAYKIN, S. S. Neural networks and learning machines. New York: Prentice Hall, 2009.

HERP, Jürgen et al. Bayesian state prediction of wind turbine bearing failure. *Renewable Energy*, [s.l.], v. 116, p.164-172, fev. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.renene.2017.02.069>.

IGBA, Joel et al. Effect of preventive maintenance intervals on reliability and maintenance costs of wind turbine gearboxes. *Wind Energy*, v. 18, n. 11, p. 2013-2024, 2015.

INTERNATIONAL RENEWABLE ENERGY AGENCY (IRENA) (Org.). Renewable Power Generation Costs in 2014. Abu Dhabi, UAE (2015), p. 164

INTERNATIONAL RENEWABLE ENERGY AGENCY (IRENA) (Org.). Global renewable energy levelised costs of electricity (LCOE) in the time period from 2010 until 2019. 2020. Disponível em: <<https://www.irena.org/publications/2020/Mar/Renewable-Capacity-Statistics-2020>>. Acesso em: 20 dez. 2020.

JAMES, Gareth. Statistical Learning. In: JAMES, Gareth; WITTEN, Daniela; HASTIE, Trevor. *An Introduction to Statistical Learning: with application in R*. 7. ed. New York: Springer, 2013. Cap. 2, p. 26

JOKAR, H.; MAHZOON, M.; VATANKHAH, R.. Dynamic modeling and free vibration analysis of horizontal axis wind turbine blades in the flap-wise direction. *Renewable Energy*, [s.l.], v. 146, p.1818-1832, fev. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.renene.2019.07.131>

JONG, Pieter de et al. Forecasting high proportions of wind energy supplying the Brazilian Northeast electricity grid. *Applied Energy*, [s.l.], v. 195, p.538-555, jun. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.apenergy.2017.03.058>.

JONG, Pieter de et al. Integrating large scale wind power into the electricity grid in the Northeast of Brazil. *Energy*, [s.l.], v. 100, p.401-415, abr. 2016. Elsevier BV.

<http://dx.doi.org/10.1016/j.energy.2015.12.026>.

JOSHUVA, A.; SUGUMARAN, V. A lazy learning approach for condition monitoring of wind turbine blade using vibration signals and histogram features. *Measurement*, [s.l.], v. 152, p.107295-107301, fev. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.measurement.2019.107295>.

HU, K. P.C. IVANOV, Z. CHEN, P. CARPENA, H.E. STANLEY. Effect of trends on detrended fluctuation analysis. *Phys Rev E*, 64 (2001), p. 011114.

KHADKA, Ashim et al. Non-contact vibration monitoring of rotating wind turbines using a semi-autonomous UAV. *Mechanical Systems And Signal Processing*, [s.l.], v. 138, p.106446-106452, abr. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.ymsp.2019.106446>.

LEE, Jay et al. Intelligent prognostics tools and e-maintenance. *Computers In Industry*, [s.l.], v. 57, n. 6, p.476-489, ago. 2006. Elsevier BV. <http://dx.doi.org/10.1016/j.compind.2006.02.014>.

LI, Qing'an et al. Experimental investigations of airfoil surface flow of a horizontal axis wind turbine with LDV measurements. *Energy*, [s.l.], v. 191, p.116558-116578, jan. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.energy.2019.116558>.

MAIA, Pedro Paulo Nunes. Discontinuity classification in welded joints using trained support vector machines from numerically simulated ultrasound signals. 2019. 80 f. TCC (Graduação) - Curso de Engenharia Metalúrgica e de Materiais, Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2019. Disponível em: <http://www.repositorio.ufc.br/handle/riufc/49249>. Acesso em: 03 set. 2020.

MASON, I.g.; PAGE, S.c.; WILLIAMSON, A.g.. A 100% renewable electricity generation system for New Zealand utilising hydro, wind, geothermal and biomass resources. *Energy Policy*, [s.l.], v. 38, n. 8, p.3973-3984, ago. 2010. Elsevier BV. <http://dx.doi.org/10.1016/j.enpol.2010.03.022>.

MENDEZ, Martin O. et al. Power-law scaling behavior of A-phase events during sleep: Normal and pathologic conditions. *Biomedical Signal Processing And Control*, [s.l.], v. 57, p.101757-101766, mar. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.bspc.2019.101757>.

MOURA, Elineudo Pinho de; MELO JUNIOR, Francisco Erivan de Abreu; DAMASCENO, Filipe Francisco Rocha; FIGUEIREDO, Luis Câmara Campos; ANDRADE, Carla Freitas de; Almeida, Maurício Soares de; ROCHA, Paulo Alexandre Costa. Classification of imbalance levels in a scaled wind turbine through detrended fluctuation analysis of vibration signals. *Renewable Energy*, [s.l.], v. 96, p.993-1002, out. 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.renene.2016.05.005>.

NIVEDH, B. S. Major failures in the wind turbine components and the importance of periodic inspections. *Wind Sider, Mumbai*, v. 33855, n. 142, p.32-36, jan. 2014.

PAINEL GOVERNAMENTAL SOBRE MUDANÇA DO CLIMA (IPCC, sigla em inglês). Relatórios. Disponível em:<<https://www.ipcc.ch/site/assets/uploads/2019/07/SPM-Portuguese-version.pdf>>. Último acesso em: 10 de dezembro de 2020.

PENG, C.K. S. HAVLIN, H.E. STANLEY, A.L. GOLDBERGER. Quantification of scaling exponents and crossover phenomena in nonstationary heartbeat time series. *Chaos*, 5 (1995), pp. 82-87

PURVINS, Arturs et al. Effects of variable renewable power on a country-scale electricity system: High penetration of hydro power plants and wind farms in electricity generation. *Energy*, [s.l.], v. 43, n. 1, p.225-236, jul. 2012. Elsevier BV. <http://dx.doi.org/10.1016/j.energy.2012.04.038>.

RAO, S. *Vibrações Mecânicas*. 4. ed. São Paulo: Pearson Prentice Hall, 2009.

RIBEIRO, Tiago et al. A comprehensive method for fatigue life evaluation and extension in the context of predictive maintenance for fixed ocean structures. *Applied Ocean Research*, [s.l.], v. 95, p.102050-102060, fev. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.apor.2020.102050>.

ROCHA NETO, Ajalmar. Máquinas de vetores suporte: uma revisão. *Learning And Nonlinear Models*, [S.L.], v. 15, n. 1, p. 16-44, 30 jun. 2017. Associação Brasileira de Inteligência Computacional - ABRICOM. <http://dx.doi.org/10.21528/lnlm-vol15-no1-art2>.

SCHUBERT, C. *Atlas Eólico/Wind Power Atlas: Bahia*. Salvador: Secti/seinfra Cimatec/senai,

2013

SILVA, Francisco Estênio da. Reconhecimento De Padrões Através De Análises Estatísticas E Fractais Aplicadas A Dados De Ensaio Não-Destrutivos. 2011. 131 f. Tese (Doutorado) - Curso de Engenharia Metalúrgica e de Materiais, Universidade Federal do Ceará, Fortaleza, 2011.

SHENG, Shuangwen. Wind turbine gearbox reliability database, condition monitoring, and operation and maintenance research update. National Renewable Energy Lab.(NREL), Golden, CO (United States), 2016.

SORNETTE, D. Critical phenomena in natural sciences(2nd ed), Springer, Berlin (2004).

TENG, Wei et al. Multi-fault detection and failure analysis of wind turbine gearbox using complex wavelet transform. *Renewable Energy*, [s.l.], v. 93, p.591-598, ago. 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.renene.2016.03.025>.

TENG, Wei et al. Pitting Fault Detection of a Wind Turbine Gearbox Using Empirical Mode Decomposition. *Strojniški Vestnik – Journal Of Mechanical Engineering*, [s.l.], v. 60, n. 1, p.12-20, 15 jan. 2014. Faculty of Mechanical Engineering. <http://dx.doi.org/10.5545/sv-jme.2013.1295>.

THÉ, Jesse; YU, Hesheng. A critical review on the simulations of wind turbine aerodynamics focusing on hybrid RANS-LES methods. *Energy*, [s.l.], v. 138, p.257-289, nov. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.energy.2017.07.028>.

WANG, Jianzhou; HU, Jianming. A robust combination approach for short-term wind speed forecasting and analysis–Combination of the ARIMA (Autoregressive Integrated Moving Average), ELM (Extreme Learning Machine), SVM (Support Vector Machine) and LSSVM (Least Square SVM) forecasts using a GPR (Gaussian Process Regression) model. *Energy*, v. 93, p. 41-56, 2015.

WANG, Jinjiang et al. An integrated fault diagnosis and prognosis approach for predictive maintenance of wind turbine bearing with limited samples. *Renewable Energy*, [s.l.], v. 145, p.642-650, jan. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.renene.2019.06.103>.

WEBB, A. R. Statistical pattern recognition. Chichester: John Wiley & Sons, 2003.

WIENER, N. Generalized harmonic analysis. *Acta Math*, 55 (1990), pp. 117-258

National Renewable Energy Laboratory (NREL). Gearbox Reliability Database. 2015. Disponível em: <<https://grd.nrel.gov/#/>>. Acesso em: 26 fev. 2020.

WU, Qing; FAN, Jiu-lun. Smooth support vector machine based on piecewise function. *The Journal Of China Universities Of Posts And Telecommunications*, [s.l.], v. 20, n. 5, p. 122-128, out. 2013. Elsevier BV. [http://dx.doi.org/10.1016/s1005-8885\(13\)60100-4](http://dx.doi.org/10.1016/s1005-8885(13)60100-4).

ZUO, Haoran; BI, Kaiming; HAO, Hong. A state-of-the-art review on the vibration mitigation of wind turbines. *Renewable And Sustainable Energy Reviews*, [s.l.], v. 121, n. 8, p.109710-109720, abr. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.rser.2020.109710>.