

INSTITUTO FEDERAL DE EDUCAÇÃO,
CIÊNCIA E TECNOLOGIA DO CEARÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENERGIAS RENOVÁVEIS

Pedro Henrique Feijó de Sousa

Detecção e classificação de falhas em aerogeradores utilizando sistemas
embarcados

Maracanaú, Ceará

2019

Pedro Henrique Feijó de Sousa

Detecção e classificação de falhas em aerogeradores utilizando sistemas embarcados

Dissertação apresentada ao Programa de Pós-graduação em Energias Renováveis do Instituto Federal de Educação, Ciência e Tecnologia do Ceará como requisito parcial para a obtenção do título de Mestre em Energias Renováveis. Área de concentração: Energias Renováveis.

Prof. Dr. Pedro Pedrosa Rebouças Filho

Maracanaú, Ceará

2019

Dados Internacionais de Catalogação na Publicação (CIP)
Ficha catalográfica elaborada pelo Bibliotecário
Gláucio Barreto de Lima - CRB-3/995

S725 Sousa, Pedro Henrique Feijó de.
 Detecção e classificação de falhas em
 aerogeradores utilizando sistemas embarcados /
 Pedro Henrique Feijó de Sousa -- 2019.
 53 f.

 Dissertação (Mestrado em Energias Renováveis) -
 - Instituto Federal de Educação,
 Ciência e Tecnologia do Ceará, *Campus* Maracanaú,
 2019.
 Orientador: Prof. Dr. Pedro Pedrosa Rebouças
 Filho.

 1. ENERGIA EÓLICA. 2. AEROGERADOR.
 3. APRENDIZADO DE MÁQUINA. 4. SISTEMAS EMBARCADOS.
 I. Título.

CDD 333.92


PEDRO HENRIQUE FEIJÓ DE SOUSA

DETECÇÃO E CLASSIFICAÇÃO DE FALHAS EM AEROGERADORES UTILIZANDO
SISTEMAS EMBARCADOS


Dissertação submetida à Coordenação do Curso de Pós-graduação em Energias Renováveis do Instituto Federal de Educação, Ciência e Tecnologia do Ceará, como requisito parcial para a obtenção do título de Mestre em Energias Renováveis, área de concentração Energias Renováveis.

Aprovada em 29/07/2019.


BANCA EXAMINADORA



Prof. Dr. Pedro Pedrosa Rebouças Filho (Orientador)
Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE



Prof. Dr. Otávio Alcântara de Lima Júnior
Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE



Prof. Dr. Elias Teodoro da Silva Júnior
Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE

Resumo

O uso contínuo e demasiado de fontes de energia derivadas do petróleo resultou em impactos no ecossistema e um alerta surgiu na comunidade científica, gerando discussões e pesquisas neste campo. A geração de energia elétrica, a partir da força dos ventos, se destacou nas últimas três décadas, sua capacidade de geração instalada aumentou significativamente e se tornou uma alternativa viável. Devido à tendência mundial na geração de energia elétrica por meio de recursos energéticos renováveis, especialmente a partir da energia eólica, a confiabilidade de tais sistemas tornou-se uma prioridade para empresas e investidores do setor. Por isso, o monitoramento confiável da condição de funcionamento dos aerogeradores por meio de técnicas de aprendizado de máquinas, devem ser adotado para auxiliar na detecção e classificação de falhas incipientes a esse tipo de sistema, com o objetivo de evitar potenciais danos aos aerogeradores. Assim este trabalho objetivou o estudo de geradores elétricos, especificamente na detecção e classificação de falhas, usando fluxo magnético axial adquirido de um gerador de indução do tipo gaiola de esquilo. Foram comparados os desempenhos dos classificadores Bayesiano, Máquina de Vetores de Suporte (SVM), Floresta de Caminhos Ótimos (OPF), Perceptron Multicamadas (MLP) e k-Vizinhos Mais Próximo (KNN) em combinação com três métodos diferentes de extração de características, sendo eles: Estatística de Alta Ordem (HOS), Transformada de Fourier e Matriz de Co-ocorrência Estrutural (SCM). Após concluir a melhor combinação de extrator/classificador, o framework foi embarcado e métricas de tempo de processamento e acurácia foram utilizadas para avaliar qual o sistema embarcado mais adequado para a detecção e classificação de falhas em aerogeradores. Na primeira etapa do estudo para embarcar a melhor combinação de extrator-classificador, os resultados extraídos do banco de dados de fluxo magnético axial demonstraram que o classificador MLP identificou 80,31% dos casos quando combinado com extrator HOS e 74,80% com SCM. Os três melhores extratores e seus melhores classificadores foram selecionados para o sistema embarcado. Ao inserir os dados no framework desenvolvido, as taxas de acerto continuaram semelhantes ao teste no computador, comprovando a robustez do classificador. O extrator HOS, combinado com MLP, destacou-se com os melhores resultados nas três plataformas embarcadas com 80.21% de acerto na Nvidia Jetson AGX Xavier, 80.02% Jetson TX2 e 72.95% na Raspberry Pi3. Considerando o tempo total de processamento, a Nvidia Jetson AGX Xavier obteve o melhor desempenho com 11.99 milissegundos. Após todas as etapas da pesquisa, definimos que a plataforma indicada para embarcar o sistema de detecção e classificação de falhas em aerogeradores é a Nvidia Jetson AGX Xavier.

Palavras-chaves: Energia Eólica; Falhas em Aerogeradores; Fluxo Magnético Axial; Aprendizado de Máquinas; Sistemas Embarcados.

Abstract

Continued and overuse of oil-derived energy sources has resulted in impacts on the ecosystem, and an alert has emerged in the scientific community, generating discussions and research in this field. Electric power generation, from the strength of the winds, has stood out in the last three decades, its installed generation capacity increased significantly and has become a viable alternative. Due to the worldwide trend of increasing electricity through renewable energy resources, primarily from wind energy, the reliability of such systems has become a priority for companies and investors in the sector. Therefore, reliable monitoring of the condition of wind turbines using machine learning techniques should be adopted to assist in the detection and classification of incipient faults in this type of system, to avoid potential damages to wind turbines. Thus, this work aimed at the study of electric generators, specifically in the detection and classification of deflections, using axial magnetic flux acquired from a squirrel-type induction generator. We compared the performance of Bayesian classifiers, SVM, OPF, Multislice Perceptron (MLP), and KNN in combination with three different methods of feature extraction: High Order Statistics (HOS), Fourier Transform, and Structural Co-occurrence Matrix (SCM). After identifying the best combination of extractor/classifier, the framework was shipped with processing time and accuracy metrics to evaluate the most suitable embedded system for the detection and classification of failures in wind turbines. In the first stage of the study to collect the best combination of extractor-classifier, the results extracted from the bank of axial magnetic flux data showed that the MLP classifier identified 80.31% of the cases when combined with HOS extractor and 74.80% with SCM. The three best pullers and their best classifiers were selected for the embedded system. When entering the data into the framework developed, the hit rates remained similar to the computer test, proving the robustness of the sorter. The HOS puller, combined with MLP, stood out with the best results on three Nvidia Jetson hit 80.21% hit platforms. AGX Xavier, 80.02% Jetson TX2 and 72.95% on Raspberry Pi3. Considering the total processing time, NVidia Jetson AGX Xavier achieved the best performance with 11.99 milliseconds. After the research steps, we defined that the indicated platform to embark the wind turbine fault detection and classification system is Nvidia Jetson AGX Xavier.

Key-words: Wind Energy; Failures in Wind Turbines; Axial Magnetic Flux; Machine Learning; Embedded systems.

Lista de ilustrações

Figura 1 – Plataformas: Raspberry PI3(esquerda), Nvidia TX2 (centro) e Xavier (direita). Fonte: Autor	26
Figura 2 – Diagrama da metodologia proposta. Fonte: Autor	29
Figura 3 – Detalhe da inserção do curto-circuito entre espiras do bobinamento do estator. Fonte: Adaptado de Sousa et al. (2018)	31
Figura 4 – Diagrama do sistema de emulação do aerogerador. Fonte: Adaptado de (SOUSA et al., 2018)	32
Figura 5 – Instalação da bobina de fluxo axial. Fonte: Adaptado (SOUSA et al., 2018)	33
Figura 6 – Representação gráfica da Tab. 8.	40
Figura 7 – Representação gráfica da Tab. 9.	41
Figura 8 – Representação gráfica da Tab. 10.	43
Figura 9 – Representação gráfica com as melhores combinações extrator/classificador de cada plataforma.	43

Lista de tabelas

Tabela 1 – Dados da Energia Eólica no Brasil em 2017.Fonte: Adaptado de (COUNCIL, 2017)	12
Tabela 2 – Resumo dos trabalhos do estado da arte	22
Tabela 3 – Comparação entre as plataformas para sistema embarcado	25
Tabela 4 – Faixas de inserção dos curtos-circuitos no gerador de indução	30
Tabela 5 – Resumo dos passos dos experimentos, contemplando as condições normais e de falha, os passos em Fg para cada passo em Fb	32
Tabela 6 – Distribuição dos recurso e amostras aplicados no sinal de fluxo axial. .	35
Tabela 7 – Comparação da taxa de precisão média entre os classificadores considerados.	37
Tabela 8 – Matriz de confusão referente aos melhores resultados de cada extratores de características destacados na Tab. 7.	38
Tabela 9 – Valores de acurácia (acc) e tempo de processamento entre métodos de extração e classificação executados na Raspberry Pi 3	40
Tabela 10 – Valores de acurácia e tempo de processamento entre métodos de extração e classificação executados na NVIDIA Jetson TX2	41
Tabela 11 – Valores de acurácia (acc) e tempo de processamento entre métodos de extração e classificação executados na NVIDIA Jetson AGX Xavier . .	42

Sumário

1	INTRODUÇÃO	11
1.1	Justificativa	13
1.2	Objetivo	13
1.2.1	Objetivo específicos	14
1.3	Produção	14
1.4	Organização do texto	14
2	FUNDAMENTAÇÃO TEÓRICA	16
2.1	Geradores elétricos	16
2.2	Extratores de Características	17
2.2.1	Transformada de Fourier	17
2.2.2	Estatística de Alta Ordem (HOS)	18
2.2.3	Matriz de Co-ocorrência Estrutural	18
2.3	Técnicas de aprendizado de máquinas	18
2.3.1	Classificador Bayesiano	18
2.3.2	Perceptron Multicamadas	19
2.3.3	Máquina de vetores de suporte	19
2.3.4	Floresta de caminhos ótimos	20
2.3.5	Algoritmo de k-vizinhos mais próximos	20
2.4	Estado da Arte	20
2.4.1	Monitoramento e Detecção de Falhas em Aero geradores	21
2.4.2	Maximização de Geração	23
2.4.3	Sistema Embarcados	24
3	METODOLOGIA	29
3.0.1	Configuração do gerador	30
3.1	Descrição da base de dados	30
3.1.1	Sistema de aquisição de dados	31
3.1.2	Sinais de funcionamento do gerador	33
3.2	Configuração dos Extratores e Classificadores	33
3.2.1	Configuração dos Extratores	34
3.2.2	Configuração dos Classificadores	34
3.3	Sistema embarcado	35

4	RESULTADOS E DISCUSSÕES	37
5	CONCLUSÃO	45
	REFERÊNCIAS	46

1 Introdução

A disponibilidade de fontes de energia em profusão, historicamente, impulsionou o desenvolvimento tecnológico (KUMAR et al., 2019). Contudo, o uso contínuo e inconsequente de fontes de energia derivadas de combustíveis fósseis geraram impactos no ecossistema, resultando discussões e questionamentos pela sociedade científica. Assim, novos estudos surgiram sobre o uso de energias renováveis como alternativa em diversas áreas (YUAN; PENG, 2017). O declínio de investimento em combustíveis fósseis por investidores e a crescente queda nos preços de geração de energia eólica e solar criaram um cenário favorável na geração de energia limpa. Uma pesquisa publicada pela Agência Internacional de Energia analisou dados dos últimos 40 anos e evidenciou que a utilização de fontes renováveis para geração de energia cresceu 221%, enquanto o uso do petróleo e seus derivados reduziu 68% (INTERNATIONAL ENERGY AGENCY, 2017).

Algumas fontes de energia renovável, como energia eólica, energia solar e biocombustíveis, são exemplos de boas alternativas (RAHIMI et al., 2013). O primeiro parque eólico comercial começou a gerar eletricidade em Crotched Mountain no sudoeste de New Hampshire no final de 1980, após cerca de 100 anos de pesquisas, desenvolvimento e teste de protótipos, e assim a indústria eólica moderna surgiu. Desde então, a indústria tem estado em uma contínuo busca de novos mercados. Hoje as operações eólicas comerciais estão presentes em mais de 90 países, nove deles com capacidade de geração acima de 10 GW e 30 países com mais de 1 GW, localizados na Europa, Ásia, América do Norte, América Latina e África (COUNCIL, 2017). O mercado global de novas instalações de energia eólica manteve sua capacidade de geração acima de 50 GW em 2017. O total da capacidade de geração acumulada, semelhante aos anos anteriores, bateu recordes de geração atingindo 539,123 GW e a previsão do mercado é que em 2022 alcance 840.9 GW. Um destaque no último relatório do Conselho Global de Energia Eólica, do inglês, Global Wind Energy Council (GWEC), é o crescimento da capacidade de geração de energia em instalações *off-shore*, com um recorde de 4.33 GW de novas instalações, representando um aumento de 87% em relação ao ano de 2016 e atingindo uma geração global acumulada de 18.81 GW, representando um aumento 30%. Mesmo com números expressivos, a geração no segmento *off-shore* preenche apenas 3.4% da capacidade de geração acumulada. No geral, os preços para projetos *off-shore*, que serão concluídas nos próximos 5 anos ou mais, custam metade do que eram nos últimos cinco anos, e esta tendência é provável que continue (COUNCIL, 2017).

O Brasil é o líder na América Latina e ocupa a 8ª colocação com capacidade de geração instalada de 12.3 GW e números expressivos no cenário mundial, ilustrado na Tabela 1. Porém teve pouco investimento em novas instalações, que representaram um pouco mais

de 2 GW, em 2017. O secretário geral da GWEC, Steve Sawyer, aponta que a fase política e a crise econômica no país são as causas da queda das novas instalações (COUNCIL, 2017). Porém o Brasil possui recursos naturais e localização geográfica privilegiada proporcionando uma situação favorável que gera confiança nos investidores e minimiza os efeitos dessa fase política. Além disso, a criação de linhas de crédito pelo Banco Nacional de Desenvolvimento Econômico e Social (BNDES) e o Programa de Incentivo às Fontes Alternativa para fomentar investimento no setor de energias renováveis foram atrativos aos investidores. Assim, a matriz energética brasileira se tornou mais diversificada, criando um sistema de geração descentralizado, transmitindo confiabilidade e ampliando a capacidade de produção de energia elétrica (XAVIER et al., 2015).

Tabela 1 – Dados da Energia Eólica no Brasil em 2017. Fonte: Adaptado de (COUNCIL, 2017)

Características	Dados
Capacidade Total Instalada	12.763 MW
Capacidade de Geração Aderida em 2017	2.022 MW
Energia Elétrica Produzida por meio do vento em 2017	42.253 GWh
Número de Turbinas	6.491 unidades
Participação da Eletricidade Gerada por meio do vento no Consumo Total de Eletricidade do Brasil	7.44%
Pessoas empregadas pela indústria eólica em 2017	190.000
Fornecedores líderes de turbinas eólicas em 2017	GE, Siemens Gamesa, Vestas

O plano de desenvolvimento energético do governo brasileiro prevê que o país atinja 28,5 GW de capacidade eólica até 2026. Para essa meta ser alcançada, atualmente já estão em andamento projetos que somarão mais de 5 GW (INTERNATIONAL ENERGY AGENCY, 2017).

Os números da energia eólica, no mundo, são expressivos e a torna uma das fontes de energia renováveis e limpa mais rentáveis e está em fase de ascensão. Porém o aumento no número de novas instalações cria algumas incertezas quanto à confiabilidade e a disponibilidade dos aerogeradores. A confiabilidade pode ser definida como a capacidade de executar o necessário, sem falha, por um determinado intervalo de tempo sob determinadas condições, enquanto a disponibilidade é definida como a capacidade de execução em um determinado estado, conforme exigido pelas normas da *International Electrotechnical Commission* (IEC) 60050 (OZTURK; FTHENAKIS; FAULSTICH, 2018). Ações como monitorar, detectar e classificar falhas, de acordo com o nível de dano ao aerogerador, são executadas com o propósito de fortalecer a confiança e disponibilidade dos aerogeradores.

Este estudo comparou o desempenho de três configurações de sistemas embarcados. Porém, antes de embarcar, foi realizado um estudo e então definida as melhores técnicas de extração e classificação no sinal de fluxo axial, aquistado de um motor de indução gaiola esquilo, do inglês, *Squirrel Cage Induction Generator* (SCIG),

1.1 Justificativa

As estruturas dos aerogeradores, de forma geral, são instaladas em locais de difícil acesso e, em sua maioria, em locais remotos. Esse cenário influência no custo de operação e manutenção desses sistemas de geração de energia eólica. Além disso, a baixa confiabilidade do sistema reduz diretamente a disponibilidade de geração de energia devido o tempo de inatividade de operação (LU et al., 2009).

O custo de manutenção de aerogeradores representa de 20% a 25% do rendimento total de um sistema eólico (BONNETT; SOUKUP, 1992). Além disso, a reparação e manutenção de turbinas eólicas exigem equipamentos de elevação, por exemplo, que geram aumento nos custos devido a atrasos causados pela disponibilidade dos equipamentos e condições climáticas ideais para a execução da manutenção.

O monitoramento das condições dos aerogeradores é o principal campo de estudos nos últimos anos, com o objetivo de aumentar a expectativa de vida útil dos componentes e, ao mesmo tempo, reduzir os custos de operação e manutenção (SALAMEH et al., 2018). A literatura (SALAMEH et al., 2018; DAO et al., 2018; OGIDI; BARENDSE; KHAN, 2016; QIAN; MA; CROSS, 2017) apresenta algumas pesquisas na área de monitoramento, detecção e classificação, por exemplo, (OZTURK; FTHENAKIS; FAULSTICH, 2018), (TAZI; CHÂTELET; BOUZIDI, 2017), que serão detalhados no estado da arte.

Com o desenvolvimento tecnológico e o interesse das indústrias e pesquisadores, a geração de energia eólica está evoluindo e pesquisas sobre metodologia de monitoramento, detecção e classificação de falhas estão sendo relatadas. Este trabalho se enquadra nesta linha de pesquisa e propõe uma metodologia para monitorar, detectar e classificar falhas em aerogeradores e assim tornar o sistema mais confiável, disponível por um maior intervalo de tempo e provido de menores custos para manutenção. Além disso, compartilhar conhecimento à sociedade científica.

1.2 Objetivo

O presente trabalho objetivou a utilização de um sistema embarcado para detectar e classificar falhas em aerogeradores aplicando técnicas de aprendizado de máquinas no sinal de fluxo magnético axial do aerogerador.

1.2.1 Objetivo específicos

Para atingir o objetivo geral, os seguintes objetivos específicos devem ser atingidos:

- Utilizar banco de dados de fluxo magnético axial de um gerador gaiola de esquilo
- Analisar qual extrator e classificador apresentam o melhor desempenho
- Avaliar plataformas de sistema embarcado mais adequado para o sistema de detecção e classificação de falhas
- Embarcar e simular o desempenho da melhor combinação de extrator/classificador

1.3 Produção

No decorrer do desenvolvimento dessa pesquisa os seguintes trabalhos científicos foram produzidos:

Artigos publicados:

Sousa, P. H. F.; Nascimento, N. M. M.; Almeida, J. S.; Rebouças Filho, P. P. and Albuquerque, V. H. C. (2019) Intelligent Incipient Fault Detection in Wind Turbines based on Industrial IoT Environment. *Journal of Artificial Intelligence and Systems*, 1, 1–19.

SANTOS FILHO, E.Q.; SOUSA, P. H. F.; ALMEIDA, J. S.; GURGEL, M. V.; REBOUÇAS FILHO, P. P.; BARRETO, G. A.; ALBUQUERQUE, V. H. C. Recognition of Quality Leather Goat via Computer Vision. *Science Journal of Circuits, Systems and Signal Processing (CSSP)*, 2019.

SOUSA, P. H. F.; NASCIMENTO, N. M. M.; REBOUÇAS FILHO, P. P.; MEDEIROS, C. M. S. Detection and classification of faults in induction generator applied into wind turbines through a machine learning approach. *International Joint Conference on Neural Networks (IJCNN)*, 2018.

1.4 Organização do texto

A organização do texto obedece a sequência cronológica de desenvolvimento da pesquisa. Então o texto está organizado da seguinte maneira: no Capítulo 2 são expostas as fundamentações teóricas necessárias para o desenvolvimento do trabalho; No Capítulo 3 é explorada a metodologia para execução dos experimentos e aquisição dos dados. No Capítulo 4 é apresentado e discutido quais combinações de extratores de atributos e classificadores obtiveram os melhores resultados nas simulações processadas nas plataformas de sistemas embarcados e por fim, no Capítulo 5, é exposta a conclusão, baseado nos

objetivos idealizados, de qual arquitetura embarcada é mais indicada para detectar e classificar falhas em aerogeradores.

2 Fundamentação teórica

Neste capítulo é abordada a fundamentação teórica breve, porém necessária para o melhor entendimento do presente estudo. O texto está organizado da seguinte maneira: na Secção 2.1 é apresentado uma explicação sobre geradores elétricos; na 2.2 apresenta os extratores de características aplicados no estudo, bem como suas especificações detalhadas em seus respectivos tópicos; na Secção 2.3 são abordados as técnicas de aprendizagem de máquinas executadas no trabalho e seus detalhes apresentados em seus respectivos tópicos e, por fim, na Secção 2.4 o estado da arte é apresentado, onde trabalhos são explorados e auxiliaram no escopo e conhecimento deste trabalho.

2.1 Geradores elétricos

Os geradores elétricos, aplicados na energia eólica, é responsável por converter a energia cinética dos ventos, captadas através das pás do rotor, em energia elétrica de forma controlada e eficiente (YARAMASU et al., 2015). Diferentes tipos de geradores elétricos são aplicados em sistemas de aerogeração. Entre eles, o SCIG se destaca dentre os outros geradores, como o Gerador de Indução Duplamente Alimentados, do inglês *Doubly Fed Induction Generator* (DFIG), Gerador Síncrono de Imã permanente, do inglês *Permanent Magnet Synchronous Generator* (PMSG) e ao Gerador de Indução de Rotor Bobinado, do inglês *Wound Rotor Induction Generator* (WRIG), por possuir um tamanho reduzido, não possuir anéis ou escovas e simples implementação contribuindo com o menor custo de manutenção e instalação (MESEMANOLIS; MADEMLIS; KIOSKERIDIS, 2013; ZOU; ELBULUK; SOZER, 2013). Francisco (2006) afirma que o motor de indução trifásico (MIT) com rotor do tipo gaiola de esquilo é o mais utilizado, por se tratar de uma máquina robusta e de simples construção, o que a torna menos onerosa que as demais. Apesar da versatilidade do SCIG, ele não é imune a falhas e possui limitações. Em termos gerais, as falhas neste tipo de equipamento estão associadas a diversos fatores em conjunto, dentre eles: sobreaquecimento, efeitos elétricos, dinâmicos e mecânicos (BONNETT; SOUKUP, 1992). Uma compilação de dados de falhas em motores de indução na indústria química e do petróleo em um período de 40 anos realizada por Bonnett (2010),exibe os tipos de falhas mais expressivas nesse tipo de máquina. Há um destaque para falhas em rolamentos, que representam 51% das falhas nos geradores de indução, em enrolamentos do estator, com 16%, enquanto que falhas de barras no rotor representam 5%.

O aumento no tamanho dos aerogeradores mostra um tendência natural, pois a quantidade de energia gerada é proporcional ao quadrado do diâmetro do rotor e ao cubo da velocidade do vento (PAO; JOHNSON, 2011). Com esse aumento, outros componentes

naturalmente também sofreram alterações, por exemplo, em um estudo realizado por [Yaramasu et al. \(2015\)](#), a dimensão do rotor dos aerogeradores subiu de 15 metros para 126 metros em 30 anos e sua potência de geração elétrica elevou de 50 kW para 7.5 MW no mesmo período. Devido ao aumento físico e maior desenvolvimento nos aparatos tecnológicos, alguns estudos sobre análise de falhas em aerogeradores foram propostos para o desenvolvimento de modelos mais eficientes na detecção e classificação de falhas a fim de se evitar prejuízos com paralisações não programadas e por longo tempo ([BELLINI et al., 2001](#)).

2.2 Extratores de Características

A etapa de pré-processamento de dados e extração de atributos é uma importante área de aprendizado de máquina, pois identifica informações presentes no sinal do aerogerador. Essas informações, chamadas de atributos, podem ser quaisquer uma que descrevam quantitativamente ou qualitativamente um problema. As técnicas de extração de atributos utilizadas nesse trabalho são:

2.2.1 Transformada de Fourier

[Penman et al. \(1994\)](#) estudou a ocorrência de curtos-circuitos entre espiras do bobinamento estatóricos de motores e desenvolveu uma modelagem matemática que relaciona a dispersão de fluxo magnético e as harmônicas mais importantes nos sinais de corrente. Porém a equação do modelo proposta depende do escorregamento do motor, que por sua vez, sua equação depende da rotação do motor. Para aplicações com motores de baixa potência, essa metodologia não é comum porque o valor do sensor de velocidade pode ultrapassar o valor da máquina elétrica. [Oliveira, Pontes e Medeiros \(2013\)](#) contornou esse problema em seu trabalho pressupondo que o motor trabalha com velocidade nominal, sem carga e estima os componentes de frequência da equação de ([PENMAN et al., 1994](#)), a partir dos dados fornecidos pelo fabricante da máquina. investigou as harmônicas no sinal de corrente elétrica do motor elétrico sob diversas falhas de curto-circuitos e concluiu que as frequências mais importantes são $0,5f_n$, $1,0f_n$, $1,5f_n$, $2,5f_n$, $3,0f_n$, $5,0f_n$ e $7f_n$, em que f_n é a frequência fundamental do estator. Os valores dessas frequências, normalizados por sua fundamental, serão utilizadas como recursos. O autor obteve êxito em identificar as falhas utilizando as harmônicas propostas por ([PENMAN et al., 1994](#)), validando a aplicação do método para detecção de curto-circuito entre espiras do bobinamento estatórico. Os autores [Filho et al. \(2018a\)](#), [Sousa et al. \(2017\)](#) também usaram esse método em seus trabalhos.

2.2.2 Estatística de Alta Ordem (HOS)

Dwyer foi o primeiro a propor o uso da Curtose como ferramenta estatística para indicar componentes não-Gaussianas em um sinal. E depois essa teoria foi reformulada por [Capdevielle, Serviere e Lacoume \(1996\)](#) sob a base de estatísticas de alta ordem e descrita a partir do momento estatístico normalizado de quarta ordem, aplicáveis apenas a sinais estacionários. Entretanto, proposições feitas por [Antoni \(2006\)](#) já preconizam eficácia do método e capacidade de caracterizar sinais não estacionários.

2.2.3 Matriz de Co-ocorrência Estrutural

A Matriz de Co-ocorrência Estrutural (SCM, do inglês *Structural Co-occurrence Matrix*) é direcionado para a análise estrutural de sinais discretos, admitindo conexões existentes entre estruturas de baixo nível de dois sinais discretos em n-dimensões ([RAMALHO et al., 2016](#)). Sua principal característica é introduzir um conhecimento dos sinais analisados, enfatizando a detecção de detalhes. Sua saída é um histograma bidimensional, onde o SCM fornece as co-ocorrências entre estruturas dos sinais de entrada ([RAMALHO et al., 2016](#)). O sinal de entrada representado será comparado com outro sinal, que corresponde à entrada sinal após a aplicação de um filtro pré-selecionado. Depois desta comparação, uma matriz com as diferenças estruturais entre os sinais são gerados. Então, um histograma bidimensional, obtém-se uma matriz e, portanto, dos atributos propostos por [Ramalho et al. \(2016\)](#) são extraídos. Na literatura, o uso de SCM tem sido relatado apenas em tarefas de classificação de imagens, como em [Marinho et al. \(2017\)](#). Em sinais no domínio do tempo, não há relatórios sobre o uso do SCM como técnica de extração de recursos. [Ramalho et al. \(2016\)](#) propuseram nove características a serem extraído de qualquer sinal e seus cálculos são mostrados em sua publicação.

2.3 Técnicas de aprendizado de máquinas

A capacidade computacional de resolver problemas a partir de um conhecimento prévio, ou seja, a partir de dados pode ilustrar a definição de aprendizado de máquina. Algumas técnicas de aprendizado de máquina, do inglês *machine learning*, são abordadas nessa seção com breve teorias necessárias para o entendimento do trabalho.

2.3.1 Classificador Bayesiano

O classificador Bayesiano é um método de aprendizagem de máquina, considerada uma técnica estatística, aplicado na classificação de amostras de acordo com a função de densidade de probabilidade de cada uma dessas amostras pertencente a uma determinada classe. Sua aprendizagem é supervisionada e baseada na Teoria da Decisão de

Bayes (FRIEDMAN; GEIGER; GOLDSZMIDT, 1997). O classificador bayesiano distribui as amostras de acordo com o valor da probabilidade posterior, calculado a partir dos valores das densidades condicionais e das probabilidades anteriores (THEODORIDIS; KOUTROUMBAS, 2008). O bayesiano usado neste trabalho será caracterizado como um discriminante quadrático, com matriz de co-variância independente para cada classe.

2.3.2 Perceptron Multicamadas

O perceptron multicamadas, do inglês *Multi-layer perceptron* (MLP) é uma combinação de perceptron para resolver problemas multi-classe (HAYKIN, 2008). Sua arquitetura é composta de camadas de neurônios, de modo que cada camada está totalmente conectada ao próximo. A MLP tem uma ou mais camadas ocultas, que são formadas por neurônios ocultos. De acordo com (HAYKIN, 2008), os neurônios ocultos intervêm entre as camadas de entrada e saída, permitindo que a rede extraia estatísticas de alto nível. Os pesos de conexão na rede mensuram o grau de correlação entre os níveis de atividade dos neurônios que eles conectam. Além disso, um algoritmo de treinamento deve ser aplicado para ajustar os pesos (AZEVEDO; BRASIL; OLIVEIRA, 2000; HAYKIN, 2008). O algoritmo de treinamento mais conhecido da MLP, proposto por (MOZER, 1995), é conhecido como *Backpropagation*.

2.3.3 Máquina de vetores de suporte

A máquina de vetores de suporte, do inglês *Support Vector Machine* (SVM) possui uma teoria matemática bem fundamentada usada para a análise da classificação e de regressão. Entre as vantagens da SVM está a indução de um hiperplano de decisão que pode ser descrito em termos de uma quantidade relativamente pequena de amostras de entrada. Em outras palavras, soluções esparsas são desenvolvidas. Esses padrões de entrada são chamados Vetores de Suporte, em geral, eles permanecem próximos à margem de separação. O problema forma dual que surge na formulação do SVM é normalmente resolvido pela programação quadrática (VAPNIK, 1998). Outra característica comum na SVM é a formulação que visa resolver um problema binário. Existem formulações SVM para problemas multiclasse (CRAMMER et al., 2001), no entanto, devido à sua complexidade, uma combinação de saída de classificador binário pode ser usada. A abordagem um-contra-um (DUAN; KEERTHI, 2005), um-contra-todos (DUAN; KEERTHI, 2005), DAGSVM (PLATT; CRISTIANINI; SHAW-TAYLOR, 2000) e o código de correção de erros (DIETTERICH; BAKIRI, 1995) são mais as mais comumente usados. O artifício do *kernel* é usado para criar versões não-lineares, já que sua versão padrão é linear. Os *kernel* utilizados foram o linear, polynomial e o *Radial Basis Function*(RBF).

2.3.4 Floresta de caminhos ótimos

O classificador floresta de caminhos ótimos (*Optimum Path Forest*, OPF) é um classificador não paramétrico, multi-classe, de baixo custo computacional, que utiliza uma abordagem matemática simples e baseia-se na teoria dos grafos (PAPA; FALCAO; SUZUKI, 2009). A técnica do OPF conecta amostras que são modelados como um gráfico completo. Amostras de treinamento são nós cujos arcos são ponderados pelas distâncias entre os vetores de recurso dos nós. Os protótipos são identificados em todas as classes e a minimização da função de conectividade para programação dinâmica atribui a cada amostra de treinamento um caminho de custo mínimo do protótipo mais fortemente conectado. Os protótipos participam de um processo de concorrência, que tenta oferecer caminhos de maiores custos para as outras amostras do banco de dados. Na parte final deste processo é obtido um conjunto particionado de treinamento com uma coleção de árvores, a união dessas árvores é chamada de floresta, que nomeia o classificador (PAPA et al., 2012). A distância euclidiana foi usada para o classificador OPF nesta pesquisa.

2.3.5 Algoritmo de k-vizinhos mais próximos

A regra dos k -vizinhos mais próximos *K-Nearest Neighbors algorithm* (kNN) é um dos métodos simples e antigos para o padrão de classificação. Esse método classifica cada amostra não rotulada de acordo com o rótulo majoritário entre os seus k vizinhos mais próximos no conjunto de treinamento. Por isso, sua performance está relacionada a métrica de distância utilizada para identificar seus vizinhos mais próximos. Geralmente produz resultados competitivos, porém quando combinados em certos domínios e com conhecimento prévio (COVER; HART, 1967). Na ausência de conhecimento prévio, a maioria dos classificadores kNN utilizam distâncias euclidianas simples para medir as diferenças entre os exemplos representados como entradas de vetores. Na literatura, alguns autores, por exemplo, Chopra, Hadsell e LeCun (2005), Goldberger et al. (2005), Shalev-Shwartz, Singer e Ng (2004) demonstram que o classificador KNN apresenta melhores resultados quando aprende métricas de distância a partir de amostras rotuladas. Nesta pesquisa estas situações foram avaliadas, bem como a variação do número de vizinhos.

2.4 Estado da Arte

Nesta Seção serão apresentados estudos que auxiliaram no desenvolvimento e escopo desta pesquisa. De maneira a delimitar as áreas de atuação dos autores, foram criadas três subseções com temas distintos. Na subseção 2.4.1, trabalhos sobre monitoramento e detecção de falhas em aerogeradores são apresentados, na subseção 2.4.2 autores exploram técnicas que maximizam a geração de energia em aerogeradores e por fim, na subseção 2.4.3 pesquisas sobre sistemas embarcados.

2.4.1 Monitoramento e Detecção de Falhas em Aerogeradores

Na análise de falhas em máquinas elétricas, há métodos relevantes como a análise por assinatura de corrente do motor (ROYO; ARCEGA, 2007; MOORTHY; CHANDRAN; RISHIDAS, 2011), análise de vibração (CLIMENTE-ALARCON et al., 2013; OGIDI; BARENDSE; KHAN, 2016; SOUSA P. H. F.; NASCIMENTO; ALBUQUERQUE, 2019) e fluxo magnético axial (CEBAN; PUSCA; ROMARY, 2011; MIRIMANI et al., 2012; MESHGIN-KELK; MILIMONFARED; TOLIYAT, 2004; ASSAF; HENAO; CAPOLINO, 2004; PARK et al., 2018; OGIDI; BARENDSE; KHAN, 2015). Ambos métodos são aplicados à detecção de falha em rolamentos de motores de indução (MARTIN; HONARVAR, 1995; WANG; TAMILSELVAN; HU, 2014; EL-THALJI; JANTUNEN, 2015; CHANDRA; SEKHAR, 2016), em enrolamentos do estator (ASFANI; PURNOMO; SAWITRI, 2013; JIN et al., 2015) e outros trabalhos abordam às quebras de barras do circuito do rotor (KIM et al., 2013; MARTINEZ; BELAHÇEN; ARKKIO, 2013). O uso de sinais de vibração tem sido largamente empregada para análise de falhas em máquinas rotativas (GELMAN et al., 2013a; LIN et al., 2013; GELMAN et al., 2013b), pois há características presentes nesses sinais que estão associadas às condições do equipamento, por exemplo, desalinhamento, desbalanceamento, lubrificações deficientes, sobrecarga e fadiga dos elementos. Em específico, para motores de indução trifásicos do tipo gaiola de esquilo, os estudos relacionam as análises vibracionais e a quebra de barras do rotor.

Em sua revisão (LU et al., 2009), listou os sinais dos geradores utilizados para diagnosticar falhas, entre eles, temperatura, corrente elétrica no estator, emissões acústica, análise de óleo e detritos, torque e vibração, porém, não listou a corrente de curto circuito gerada pelo fluxo axial, o qual consistirá o sinal avaliado no presente estudo. Em outro estudo realizado por Salameh et al. (2018) analisam as condições da caixa de redução em aerogeradores e também apresentam uma revisão sobre diferentes métodos e técnicas de monitoramento das condições das caixas de redução em aerogeradores. Os dados de vibração e assinatura da corrente elétrica de um gerador de ímã permanente foi abordado no estudo de Ogidi, Barendse e Khan (2016), nesse aplicou-se técnicas de processamento de sinal para detectar e discriminar falhas de curto-circuito e excentricidades estáticas, que segundo ele, são as duas falhas mais comuns em geradores de ímãs permanentes. No entanto, o autor cita que a capacidade discriminatória das falha do modelo proposto é ineficaz. Tazi, Châtelet e Bouzidi (2017) analisou o modo de falha e análise de seus efeitos integrando os custos para avaliar a criticidade da falha. Os custos oscilam desde a substituição de componentes até os custos das falhas esperados. Um estudo quantitativo e comparativo também foi realizado com a taxa média das falhas, as principais causas de falha, custos esperados das falhas e técnicas de detecção das falhas e, por fim, concluiu que o desgaste é o principal e mais comum causa de falha em aerogeradores e o ambiente em que está instalado é o principal motivo desse desgaste. Esse desgaste causa problemas

de desalinhamento, vibração e corrosão, este último citado é o desgaste mais frequente, segundo o autor.

Tabela 2 – Resumo dos trabalhos do estado da arte

Sinal	Tipo de falhas	Autores
Assinatura da Corrente Elétrica	Curto Circuito	(ROYO; ARCEGA, 2007; SALAMEH et al., 2018)
	Quebra de barra	(ROYO; ARCEGA, 2007; MOORTHY; CHANDRAN; RISHIDAS, 2011)
	Excentricidade Estática	(ROYO; ARCEGA, 2007; SALAMEH et al., 2018)
Vibração	Curto Circuito	(SOUSA P. H. F.; NASCIMENTO; ALBUQUERQUE, 2019), (OGIDI; BARENDSE; KHAN, 2016; SALAMEH et al., 2018)
	Quebra de Barra	(CLIMENTE-ALARCON et al., 2013)
	Excentricidade Estática	(SALAMEH et al., 2018)
Fluxo Magnético Axial	Excentricidade Estática	(CEBAN; PUSCA; ROMARY, 2011)(MIRIMANI et al., 2012), (OGIDI; BARENDSE; KHAN, 2016)
	Quebra de Barra	(CEBAN; PUSCA; ROMARY, 2011) (MESHGIN-KELK; MILIMONFARED; TOLİYAT, 2004)
	Curto Circuito	(ASSAF; HENAO; CAPOLINO, 2004) (OGIDI; BARENDSE; KHAN, 2015)
	Falha no Rotor	(PARK et al., 2018)
Assinatura da Corrente Elétrica, Vibração, Fluxo Magnético Axial	Desgaste	(TAZI; CHÂTELET; BOUZIDI, 2017)

Estudos existentes sobre o estado de saúde das turbinas eólicas tendem a se concentrar em técnicas de monitoramento (ZHOU et al., 2014), (TCHAKOUA et al., 2014), (YANG; SUN, 2013), (AMIRAT et al., 2009), (CIANG; LEE; BANG, 2008). (WYMORE et al., 2015) contextualiza o monitoramento de saúde dos aerogeradores e os desafios enfrentados pela indústria e pelos pesquisadores. A pesquisa de (QIAN; MA; CROSS, 2017) monitora o funcionamento de um aerogerador, por meio do sinal da caixa de velocidade a partir de um sistema de supervisão e controle de dados (SCADA) e apresenta um método de treinamento que identifica falhas e estado de saúde da caixa de velocidade com maior rapidez, porém o autor não apresenta a taxa de acerto e nem uma matriz confusão dos resultados do seu método, causando assim possíveis falsos positivos e falso negativos. Em outro estudo, realizado por (SANTOS et al., 2015), foi abordado um sistema multissensorial para diagnóstico de falhas em turbinas eólicas, combinado com uma solução de mineração de dados para a classificação do estado operacional do aerogerador. O autor usou sinal de vibração, gerado de um acelerômetro, e sinais elétricos de torque e velocidade. Para classificar as falhas de desalinhamento e desequilíbrio o autor aplica o classificador SVM nos dados adquiridos de um banco de teste que simula as condições reais dos aerogeradores. O autor afirma que o classificador SVM linear teve melhores resultados, porém o banco de dados é bem restrito quanto ao número de condições de cargas e velocidades da máquina emulada. E quanto aos extratores de características de sinais, o autor não aplica em seus dados.

Uma abordagem emergente para reduzir os custos da energia eólica é tornar os aerogeradores mais inteligentes. Sensores instalados nos sistemas de aerogeração monitoram

e coletam dados para serem usados com diversas finalidades a fim de manter o bom funcionamento do aerogerador. Alguns desses sistemas já são realidade e fornecem benefícios, como monitoramento de integridade online e redução de custo com paradas desnecessárias. Outro ponto favorável para tais sistemas inteligentes é que os dados fornecidos aos processos de controle do aerogeradores possam maximizar a eficiência de parques eólicos. Por isso, espera-se que sistemas de monitoramento e coleta de dados desempenhem um papel importante no futuro da energia eólica (WYMORE et al., 2015). De fato, com o passar do tempo, o monitoramento da saúde dos aerogerador se torna mais importante e mais atraente. Aerogeradores cresceram rapidamente em tamanho físico e, conseqüentemente, em geração de energia. Isso significa que cada aerogerador está se tornando uma fonte maior de receita e reduzindo seu tempo de inatividade está se tornando mais crítico. Além disso, componentes maiores são geralmente mais caros de manter e substituir. Cada vez mais parques eólicos estão sendo instalados em alto mar, onde o monitoramento remoto é particularmente útil. E, finalmente, a energia eólica está preenchendo uma parte maior do portfólio de geração de energia elétrica do mundo, de modo que os aerogeradores necessitam cada vez mais de uma operação consistente. Portanto, é esperado um aumento do interesse em sistemas para aerogeradores inteligentes.

Para classificar de forma mais clara, os autores abordam o tema relacionando à uma forma de medida, por exemplo, (RIGONI et al., 2012) utilizaram a temperatura para detecção de falhas, vibração mecânica (RODRÍGUEZ et al., 2007), corrente de partida (SUPANGAT et al., 2005), análise da assinatura da corrente (AHMED; ERTUGRUL; SO-ONG, 2005). Este estudo utiliza dados de fluxo magnético axial adquiridos de um Gerador de Indução Gaiola Esquilo exposto a situações de falhas de acordo com (YARAMASU et al., 2015).

2.4.2 Maximização de Geração

Ao revisar a literatura, diferentes técnicas para maximizar a produção de energia em parque eólicos são apresentadas. Existem métodos que pesquisam otimização de layout, porém, é restrito a parques em fase de projetos, e não pode ser aplicado a parques já em operação (PARADA et al., 2017; FENG; SHEN, 2017). No entanto, em outra abordagem, o autor reconhece que para atingir a potência máxima em um parque eólico, não significa, necessariamente, que todas as turbinas eólicas devem operar em uma taxa nominal, pois a busca pela máxima potência inicia-se desde as interações aerodinâmicas entre os aerogeradores do parque eólico. (GONZÁLEZ et al., 2015).

Afanasyeva et al. (2016) concluíram que entre as incertezas que permeiam a predição de energia de aerogerador, a velocidade do vento e a curva de potência de uma aerogerador são os mais importantes, pois apresentam um alto impacto no projeto. Quando Rolik (2017) baseou-se na análise de risco destinadas a investimentos, destacou que é necessário

entender o comportamento do vento na região proposta para instalação do parque eólico, através do monitoramento de no mínimo um ano. Os autores também sugerem que a escolha da turbina eólica deve ser realizada após a análise da capacidade eólica da região.

2.4.3 Sistema Embarcados

No Reino Unido, foi desenvolvido a Raspberry Pi, por Eben Upton, Rob Mullins, Jack Lang e Alan Mycroft, com o objetivo de auxiliar no ensino de ciências da computação para alunos do ensino fundamental (PI, 2013). Existem diversos modelos de Raspberry Pi, porém neste estudo selecionamos a Raspberry Pi 3 Modelo B+, ilustrado na 1. A escolha deste modelo foi simples, é o mais atual e ele possui a melhor arquitetura. Com um processador Broadcom BCM2837B0 ARMv8 quad-core de 1,4 GHz, memória RAM de 1 GB, 4 entradas USB, conexão Wi-Fi dual band (2,4 GHz e 5 GHz), Ethernet, Bluetooth 4.2 e HDMI. E seu grande diferencial, considerando projetos futuros, é o *Power over Ethernet*, ou seja, permite que o cabo Ethernet possa ser fonte de energia. Entre os sistemas operacionais mais relevantes (Raspbian, Pidora e RISC OS) escolhemos o Raspbian devido ao suporte do sistema operacional Linux com licença livre e por possui diversas informações compartilhadas por comunidades relacionadas. No último mês de junho, a fundação Raspberry Pi iniciou a venda da Raspberry Pi 4 modelo B, com novo processador Broadcom de quatro núcleos de 1.5 GHz, RAM 4Gb e com exibição 4K. Devido ao seu alto consumo energético, estudos futuros devem ser considerados para avaliar seu custo/benefício (RASPBERRY PI FOUNDATION,).

Em sua pesquisa, (SIEGEL et al., 2018) avaliaram métodos para detectar e intervir em falhas de arco elétrico com uma placa Raspberry Pi 3 fazendo as leituras do sinal. Suresh et al. (2014) também utilizou uma Raspberry e propôs um sistema para monitorar e controlar o fluxo de líquido em um sistema industrial, através da internet por meio de um *smartphone* ou computador. Tcherniak e Mølgaard (2017) apresentaram um sistema embarcado, com um algoritmo de aprendizado semi-supervisionado, para monitorar a saúde estrutural de uma turbina eólica, modelo Vestas V27, identificando defeitos estruturais nas pás das turbinas eólicas, a partir do sinal de vibração mecânica captadas por um acelerômetro. Nesse estudo foi introduzido, artificialmente, um defeito e o sistema conseguiu detectar a menor quantidade de danos nas pás da turbina eólica e acompanhar uma abertura de 15 para 45 cm durante o processo da pesquisa. Garcia, Sanz-Bobi e Pico (2006) propuseram um sistema inteligente para manutenção preditiva (SIMAP), orientada para o diagnóstico e manutenção de processos industriais. Em seu estudo, Garcia, Sanz-Bobi e Pico (2006) aplicaram o SIMAP para monitorar as condições de funcionamento de uma caixa de engrenagem de uma turbina eólica. A partir do conjunto de sensores já existentes na turbina, informações são analisadas diariamente e o calendário de manutenção é ajustado de acordo com as necessidades reais e vida útil da turbina. O processo é realizado de forma

online, segundo o autor, com diferentes módulos interligados a uma rede de computadores trocando informações atuais e do histórico da carga de trabalho, possibilitando assim o sistema avaliar, a partir de modelos de rede neural baseados no perceptron multicamadas, o estado de saúde da turbina eólica e adaptar diariamente sua rotina de manutenção.

Em um túnel de vento construído para simular condições reais, [Myrent et al. \(2015\)](#) inseriu aerogeradores com trincas nas pás e desenvolveu um algoritmo de detecção dessas trincas. O sistema de aquisição de dados possui uma Raspberry Pi Sound Card 12, para captar o sinal de entrada e o algoritmo de detecção é embarcado na Raspberry Pi, que se comunica remotamente com o computador, através de uma conexão sem fio. [Currie et al. \(2015\)](#) também utilizaram uma Raspberry Pi 3 para monitorar a integridade estrutural de fundações de concreto de aerogeradores terrestres. Sensores de deslocamento sem fio foram anexados na parte inferior do aerogerador. O sistema proposto identificou que o anel embutido apresentou movimentação vertical expressiva, principalmente em situações de partida, desligamento e em momentos de turbulências causadas pela força do vento.

Uma arquitetura com Raspberry Pi e um Arduino Uno foi proposta por [León et al. \(2017\)](#) como uma estação meteorológica. A Raspberry é configurada para receber dados Arduino, via USB, e transmite essas informações para uma página web. Por meio do sistema operacional Raspbian, que possui diversas bibliotecas, por exemplo Apache Web Server, que permitem essa hospedagem na web. Parâmetros como umidade, temperatura, velocidade, direção dos ventos e radiação solar estão presentes na página web, em virtude das informações coletadas pelos *shields* (placas de hardware) do Arduino. O autor apresenta uma arquitetura versátil e programável, permitindo ser aplicada em outros contextos, inclusive desta pesquisa. Outra aplicação dessa arquitetura foi proposta para ser um nó Web Sensor para automação residencial ([VUJOVIĆ; MAKSIMOVIC, 2015](#)).

Tabela 3 – Comparação entre as plataformas para sistema embarcado

Característica / Plataforma	Raspberry	Jetson TX2	AGX Xavier
CPU	Broadcom BCM2837B0 ARM Cortex-A53 @1.4GHz	ARM Cortex-A57(quad-core) @2GHz + NVIDIA Denver2 (dual-core) @2GHz	8 core Carmel ARM CPU @2.26GHz (4x) 2MB L2 + 4MB L3
GPU	-	256 Core Pascal @1.3GHz	512 Core Volta @1.37GHz 64 Tensor Cores
Memória	1GB	8GB 128-Bit 58.4 GB/s	16GB 256-bit LPDDR4x @2133MHz 137 GB/s
Acelerador	-	-	(2x) NVDLA
Armazenamento	1GB	32GB	32GB
Potência	2.5W	7.5W / 15W	10W / 15W / 30W
Preço	\$ 40	\$ 399	\$ 699.00

Outra importante plataforma para sistemas embarcados, e utilizada neste estudo, é a Nvidia Jetson Tx 2, com duas CPUs Denver de 64 bits e Complexo Quad-Core A57, uma GPU NVIDIA PascalTM de 256 núcleos, 8 GB de memória LPDDR4 de 128 bits, 32 GB de armazenamento flash eMMC 5.1 e consumo de 7.5W/15W, de acordo com o uso do

recurso de processamento. Possui um ambiente de desenvolvimento Linux pré instalado. Suporta bibliotecas de deep learning, visão computacional, processamento por GPU e outras vantagens que proporciona um desenvolvimento de hardware e software rápido e robusto (NVIDIA, 2019). O framework desenvolvido também foi executado na Nvidia Jetson AGX Xavier, com CPU 8-core ARM v8.2 64-bit CPU, 8MB L2 + 4MB L3, GPU 512-core Volta GPU with Tensor Cores, memória de 16GB 256-Bit LPDDR4x | 137GB/s, armazenamento de 32GB eMMC 5.1, processador de visão VLIW 7 vias e fornecendo o recurso da GPU mantém o consumo abaixo de 30W. Mais característica dos kit de desenvolvimentos da Nvidia podem ser consultadas em Nvidia (2019) e ambas plataformas estão ilustradas na Fig. 1.




Figura 1 – Plataformas: Raspberry PI3(esquerda), Nvidia TX2 (centro) e Xavier (direita).
Fonte: Autor

Atualmente, as unidades de processamento gráfico(GPU),também presente na Jetson TX2 e Xavier, aplicada nesta pesquisa, é uma tecnologia que impulsiona aplicações em sistemas embarcadas.(TIJTGAT et al., 2017) avaliou um método para detectar objetos em tempo real, usando o algoritmo YOLOv2. O algoritmo, baseado em Redes Neurais Convolucionais, foi embarcado na NVIDIA Jetson TX2 e executada a bordo de um veículo aéreo não tripulado (VANT). A versão anterior, NVIDIA Jetson TX1, foi utilizada por Lee et al. (2017) para embarcar uma rede neural convolucional chamada AlexNet, para reconhecer os números das placas de veículos sem a presença de uma linha de detecção. A Jetson TX1, equipada com uma câmera CCTV, foi instalada em uma estradas e 500 imagens foram aquisitadas. O autor concluiu que o sistema com a Jetson TX1 pode ser efetivamente aplicada para esse problema.

Em sua pesquisa, Amert et al. (2017) avaliou aspectos do comportamento de agendamento da GPU da Jetson TX2, aplicados na área de sistemas autônomos e observou que a ferramenta de agendamento da GPU possui propriedades orientadas do algoritmo de escalonamento FIFO. Na área da saúde Attaran et al. (2018) propôs um sistema de monitoramento de estresse utilizando sinais fisiológicos, por exemplo, frequência cardíaca e comparou métricas de desempenho. Após concluir que os classificadores KNN e SVM obtiveram os melhores resultados, 95,8% e 96,7%, respectivamente, o autor embarcou o framework em diferentes plataformas, entre elas, Raspberry Pi 3, NVIDIA Jetson TX1 e TX2. Um estudo compilou trabalhos que avaliaram e otimizaram aplicações com rede

neural nas plataformas da Nvidia, entre elas a Jetson TX2 e Xavier, e apresentaram o progresso da capacidade de executar algoritmos de inteligência artificial com baixo custo e consumo energético (MITTAL, 2019).

Os Processadores digitais de sinais, do inglês *Digital Signal Processors* (DSPs) são indicados para solução específicas com processamento de sinais, tornando assim o custo mais barato, consumo de energético baixo e suporta sinal com 16 bits. Porém quando aplicada em sistemas mais complexos que envolve um maior transito de informações de diferentes sensores, sua programação se torna complexa e a limitada comunidade que compartilha informações é limitada. Além disso, a pequena disposição de periféricos, comunicação bibliotecas e kit de desenvolvimento pago dificulta a utilização dessa plataforma (LEÓN et al., 2017).

Outra plataforma disponível no mercado para sistemas embarcado são os circuitos integrados para uma aplicação específica, do inglês *Application-specific integrated circuit* (ASIC). É um dispositivo (chip) analógico ou digital, predominantemente digital, desenvolvido para executar uma tarefa específica. São dispositivos que necessitam de tempo e muitos recursos para desenvolvimento que deixa seu custo alto. Porém proporciona um alto desempenho e um baixo consumo de energia. Os circuitos integrados para uma aplicação específica padrão, do inglês *Application-specific standard parts* (ASSPs) também são desenvolvidos para executar uma tarefa específica e possuem um alto desempenho como os ASIC, porém os ASSPs podem ser aplicados em diferentes projetos, por exemplo a interface HDMI utilizada em diversos dispositivos mas que executa apenas uma tarefa (CHINNERY; KEUTZER, 2008). A matriz de portas lógicas programáveis, do inglês *Field Programmable Gate Array* (FPGA) possui blocos programáveis ligados por uma conexão programável, destacando assim a sua capacidade de configuração do hardware para executar variadas combinações de funções digitais. Essa flexibilidade exemplifica a vantagem que a FPGA possuem em relação às ASIC e ASSPs, que são plataformas rígidas. Porém a desvantagem é o alto consumo de energia e a menor eficiência de desempenho porém essas desvantagens podem ser solucionados com algoritmos paralelos (FUNK; LUO, 2015). No presente trabalho serão utilizadas três arquiteturas de sistema embarcado, Raspberry Pi 3 Modelo B+, Nvidia Jetson TX 2 e Nvidia Jetson AGX Xavier, para executar o framework de detecção e classificação de falhas em aerogeradores. Por serem plataformas com baixo consumo energético, compactas e de vasta rede de usuários elas foram escolhidas. Além de serem as disponíveis para testes, até o momento.

Outra área de pesquisa com sistema embarcados é a otimização do seu consumo energético. A limitada disponibilidade de energia para manter o bom funcionamento dos dispositivos embarcados é um grande desafio e a captura de energia para sistemas embarcados, a partir de recursos do meio ambiente, surge como alternativa, evitando assim o uso de bateria ou supercapacitores que torna o sistema oneroso e até inviável devido

ao peso ou tamanho do dispositivo embarcado (LIU et al., 2011). Fonte de energia como a energia solar é a mais comum, porém deve ser considerado a potência de energética que o dispositivo embarcado consumirá (HABIBZADEH et al., 2017a). Na escala de 1 nW - 10 mW, as fontes de energia coletadas do meio ambiente de origem térmica (ASHRAF; MASOUMI, 2015; RAMADASS; CHANDRAKASAN, 2010), vibração (ZHU et al., 2015), radiofrequência (RF)(SOYATA; COPELAND; HEINZELMAN, 2016; PIÑUELA; MITCHESON; LUCYSZYN, 2013), microbianas (MEEHAN; GAO; LEWANDOWSKI, 2010) e piezoelétricos (KONG; HA, 2011) são viáveis. Quando o dispositivo necessita de uma faixa de potência entre 1W - 10 W, a fonte de energia solar (ALIPPI; GALPERTI, 2008) e eólica (RAMASUR; HANCKE, 2012) são indicadas, inclusive sistemas híbridos que utilizam as duas fontes (HABIBZADEH et al., 2017b; HABIBZADEH et al., 2017a). Após definir a melhor forma de alimentar o dispositivo, técnicas como *Dynamic Power Management* (DPM), e *Dynamic Voltage Frequency Scaling* (DVFS) podem ser aplicadas com o objetivo de gerenciar o consumo de energia dos dispositivos, proporcionando maior vida útil e robustez ao sistema embarcado. Na execução deste trabalho não será necessário aplicar técnicas de captação e gerenciamento de energia, pois o ambiente será controlado permitindo que os dispositivos do sistema embarcado possam executar suas tarefas nas melhores condições de funcionamento proporcionando resultados de acurácia e tempo de processamento assertivos na detecção e classificação de falhas em aerogerador.

3 Metodologia

Este capítulo apresenta a metodologia seguida neste trabalho. Na Secção 3.1 detalha-se como é feita a descrição da base de dados e artigos que também foram usados na construção dessa base de dados. Na Secção 3.0.1, é explicada a configuração do gerador emulado na pesquisa. Na Secção 3.1.1 o preparo da máquina elétrica e a metodologia do circuito emulado é explicado, bem como as faixas de estado normal e de falhas do aerogerador. A forma que o sinal de fluxo axial foi aqusitado é demonstrado na Secção 3.1.2, na Secção 3.2 os parâmetros dos classificadores, escolhidos após um estudo prévio, é apresentado. E por fim, na seção 3.3 é apresentado as métodos do sistema embarcado. A Fig. 3 ilustra, de forma breve, as etapas da metodologia do trabalho que serão explicadas no decorrer deste capítulo.




Figura 2 – Diagrama da metodologia proposta. Fonte: Autor

3.0.1 Configuração do gerador

3.1 Descrição da base de dados

A base de dados utilizado nesta pesquisa foi desenvolvida por (NASCIMENTO, 2018), e pode ser consultada para mais detalhes dos procedimentos experimentais. Outros estudos como (NASCIMENTO; MEDEIROS; FILHO, 2017) e (SOUSA et al., 2018), também utilizaram a mesma base de dados para desenvolver suas pesquisa. De forma geral, o sistema de emulação de falhas utiliza dois motores de indução do tipo gaiola esquilo e seus eixos são acoplados mecanicamente. Um motor é energizado e simula a força do vento e o outro desempenha o papel de gerador, na Seção 3.1.1 esse sistema é descrito. O gerador sofreu alterações para que curtos-circuitos fossem inseridos, na Seção 3.0.1 é detalhado esse preparo. A configuração de aquisição de dados de fluxo magnético axial é abordada na Seção 3.1.2. E por fim, na Seção 3.2 são detalhados os parâmetros de configuração para o treinamento dos classificadores.

Para que se possa inserir curtos-circuitos, emulando diferentes níveis de falhas no gerador elétrico, e conseguir acompanhar a evolução dos curtos-circuitos emulados, a máquina elétrica sofreu um processo de rebobinamento no circuito estatórico executado por uma empresa especializada. Esse processo permitiu o acesso às ramificações das bobinas através de terminais elétricos. A mesma máquina elétrica também foi utilizado por (OLIVEIRA; PONTES; MEDEIROS, 2013) e (FILHO et al., 2018b) em suas pesquisas de detecção de falhas em motores elétrico, respeitando as mesmas especificações de emulação das falhas.

Tabela 4 – Faixas de inserção dos curtos-circuitos no gerador de indução

Tipos de curto	% de espiras	Graus de severidade
A1	1.41	1
	4.81	2
	9.26	3
B1	1.41	4
	4.81	5
	9.26	6

As ramificações da bobina na fase R do gerador elétrico preparado, disponibiliza inserir falhas de curto circuito entre 1.41% (Nível 1), 4.81% (Nível 2) e 9.26% (Nível 3) da quantidade total de espiras, ilustrada na Tab. 4. Estabelece-se, também, dois tipos de curto circuito, o curto de baixa impedância (BI) e alta impedância (AI), ambos representam respectivamente o inicio e fim da aparição do curto circuito. A corrente de curto circuito é limitada por uma resistência ajustável ao valor da corrente nominal da máquina elétrica. Um visão geral do processo de simulação da falha é exibido na Fig. 3.




Figura 3 – Detalhe da inserção do curto-circuito entre espiras do bobinamento do estator.
Fonte: Adaptado de [Sousa et al. \(2018\)](#)

3.1.1 Sistema de aquisição de dados

O aerogerador simulado neste estudo foi baseado na configuração descrita por ([YARAMASU et al., 2015](#)), que consiste em um gerador de indução gaiola de esquilo, do tipo Full-scale e Full-Variable-Speed, ou seja, a máquina elétrica está apta a gerar energia elétrica em toda a faixa de operação de velocidade. Na Fig. 4 é exibido o diagrama do sistema de emulação do aerogerador.

Para realizar experimentos, utilizou-se um gerador de indução do tipo gaiola de esquilo (SCIG) com as seguintes características: 4 polos, potência mecânica de 1 CV, eletricamente ligado em configuração de delta para tensão de alimentação de 220 V, com corrente nominal de 3 A. As bobinas estatóricas são alimentadas por um conversor de frequência trifásico com alimentação monofásica, CFW-08 da marca WEG. Como Máquina Primária (MP), acoplada mecanicamente ao gerador, utilizou-se um motor de indução com as mesmas características e ligações, e acionado por conversor de frequência.

O conversor de frequência que aciona a MP faz o papel do vento e irá propiciar velocidade variáveis a MP, lado marcado em azul na Fig. 4. A máquina primária faz o papel das pás da turbina eólica, provendo movimento rotativo ao eixo do gerador, que é marcado pelo lado verde na mesma figura.

O SCIG utilizado no sistema de aerogeração emulado foi devidamente modificado para facilitar a inserção de curto-circuito entre as espiras. Os experimentos são comandados por um Painel de Teste de Curto-Circuito (PTCC), com a função de realizar ligações elétricas emulam o processo de curto-circuito entre espiras do bobinamento estatórico.

Com a bancada para emulação finalizada, foi possível coletar dados de corrente elétrica, fluxo axial e vibração mecânica, utilizando, que respectivamente, sensores de corrente elétrica, fluxo magnético e acelerômetro. Uma interface gráfica para realizar as

aquisições será desenvolvida no software LabVIEW® da *National Instruments*.




Figura 4 – Diagrama do sistema de emulação do aerogerador. Fonte: Adaptado de (SOUSA et al., 2018)

Os experimentos foram realizados no sistema exibido na Fig.4. Convencionou-se como frequência de base (F_b) o valor comandado no conversor de frequência da máquina primária, e como frequência do gerador (F_g) o valor atribuído na alimentação estatórica do gerador de indução.

Os ensaios foram realizados da seguinte forma: há sete estados primários de funcionamento, a condição normal e as seis de falhas desde o curto circuito de menor até o de maior intensidade, combinados com sete condições secundárias de frequências de base, entre 45 e 60 Hz , e derivados em situações individuais, por cada F_b , varia-se a frequência do gerador, em passos de 0,02 Hz entre os ensaios, partindo de 210 V no barramento CC (V_{cc}) até que: o gerador atinja a corrente nominal (I_g) ou a tensão do barramento CC atinja o valor nominal de 380 V , ou ainda que, seja atingida a corrente nominal na máquina primária (I_{mp}). Na Tab. 5 está resumido esse procedimento, que totalizou 1357 aquisições de dados, sendo 248 de condições normais do gerador e 1109 de condições de falha.

Tabela 5 – Resumo dos passos dos experimentos, contemplando as condições normais e de falha, os passos em F_g para cada passo em F_b

Estados	F_b	F_g
Normal	45 a 60 Hz , passos de 2,5 Hz	$f_1 (V_{cc} = 210 V)$ até $f_n (V_{cc} = 380 V$ ou $I_g = 3 A$ ou $I_{mp} = 3 A)$, com passos de 0,02 Hz
Falha AI-1		
Falha AI-2		
Falha AI-3		
Falha BI-1		
Falha BI-2		
Falha BI-3		

3.1.2 Sinais de funcionamento do gerador

O fluxo axial que percorre uma máquina elétrica é uma característica natural do equipamento, gerado pelo acoplamento magnético entre o circuito do estator e do rotor (YARAMASU et al., 2015), devido a imprecisões físicas normais durante a construção do gerador. Contudo, (YARAMASU et al., 2015) exhibe matematicamente que esse efeito pode ser influenciado por assimetrias entre o eixo do rotor e do campo gerado no estator. Além disso, o fluxo disperso em uma máquina de indução é um efeito indesejável, que não gera conjugado de trabalho útil, e (HENAO; DEMIAN; CAPOLINO, 2003) exhibe uma análise no domínio da frequência para detecção de falhas no bobinamento estatórico de um motor submetido a curto-circuito entre espiras. O autor afirma que a utilização de um sensor de fluxo é mais eficiente que a abordagem clássica pela análise da assinatura de corrente do motor (MCSA, do inglês). Os resultados de (HENAO; DEMIAN; CAPOLINO, 2003) exibiram que o espectro de frequência de fluxo magnético é tão conclusivo quanto a corrente elétrica para a detecção de falhas no motor elétrico. O presente trabalho escolhe esse método para monitorar as condições de funcionamento do gerador. Como proposto por (SOUSA; SÁ, 2017), utilizou-se uma bobina constituída de 100 espiras de fio de cobre 24 AWG, posicionada entre o eixo da máquina, como exibido na Fig.5. Pelo fato de a bobina está imersa no fluxo magnético produzido pelo gerador haverá uma tensão induzida, de acordo com a segunda lei de Faraday, porém não haverá corrente elétrica circulando pela mesma, visto que seus terminais permanecerão em aberto.




Figura 5 – Instalação da bobina de fluxo axial. Fonte: Adaptado (SOUSA et al., 2018)

Para as aquisições de dados do sistema escolheu-se o sistema de aquisição de dados NI-USB6009 da *National Instruments*, com resolução de 10 bits, à uma taxa de amostragem de 5 kHz durante 10 segundos de aquisição.

3.2 Configuração dos Extratores e Classificadores

A base de dados separada para treinamento possui quantidades de amostras balanceada por classes, ou seja, a quantidade de amostras é a mesma para todas as classes, como ilustra a Tab. 6. Em todos os experimentos serão realizados 50 treinamentos independentes. A partir destes foram gerados valores de acurácia e matrizes de confusão

média. Os métodos de aplicados foram realizados em um PC Intel i7 rodando a 3.6GHz e 8Gb de memória RAM com um sistema operacional Linux Ubuntu.

3.2.1 Configuração dos Extratores

As configurações dos extratores são: em Fourier as características são encontradas a partir das hamônicas $0.5 f_n$, $1.5 f_n$, $2.5 f_n$, $3.0 f_n$, $5.0 f_n$ e $7 f_n$, onde a frequência fundamental do estator é encontrada. O conjunto de atributos de Fourier é expresso com o vetor expresso na equação 3.1.

$$\vec{x}_{FOR} = \left[\frac{0.5f_n}{f_n} \quad \frac{1.5f_n}{f_n} \quad \frac{2.5f_n}{f_n} \quad \frac{3f_n}{f_n} \quad \frac{5f_n}{f_n} \quad \frac{7f_n}{f_n} \right], \quad (3.1)$$

Os características extraída em HOS são Skewness (s), Kurtosis (k), Variance (σ^2) juntamente com os valores de variância e rms (FILHO et al., 2018a), expressos na equação 3.2.

$$\vec{x}_{HOS} = \left[s \quad k \quad \sigma^2 \quad rms \right] \quad (3.2)$$

No SCM a característica calculada a partir da matriz de co-ocorrência são Correlação (c), Momento de diferença inversa (i), Qui-quadrado (cs), Razão de diferença absoluta média (m), Entropia (e) e diferença absoluta absoluta (p) (RAMALHO et al., 2016), expresso na equação 3.3.

$$\vec{x}_{SCM} = \left[c \quad i \quad cs \quad m \quad e \quad p \right] \quad (3.3)$$

3.2.2 Configuração dos Classificadores

Similar aos extratores de características, utilizou-se diferentes tipos de classificadores com o objetivo de encontrar a melhor configuração para a tarefa de detectar falhas em aerogeradores, usando sinal de fluxo axial. Para comparar o desempenho dos classificadores, todos os experimentos seguem os mesmos procedimentos em comum. A normalização utilizada em todos as bases de dados será a estatística. A qual é feita a subtração da média e divisão pelo desvio padrão em cada um dos vetores de atributos; a separação dos dados utilizou a técnica *hold out*, que consiste em utilizar 80% das amostras para criar uma base de treinamento e 20% para uma base de teste, separadas aleatoriamente.

Os quatro classificadores, combinados com os três métodos de extração de atributos, são usados para avaliar o sinal. Nos classificadores, KNN, SVM e MLP é realizado um *tunned* antes do desenvolvimento do modelo. Com o objetivo de avaliar as configurações adequadas dos hiperparâmetros, é usada validação cruzada com 10 *folds* com *grid search*. O intervalo de busca dos hiperparâmetros dos classificadores são:

Tabela 6 – Distribuição dos recurso e amostras aplicados no sinal de fluxo axial.

Sensor	Nº de atributos			Nº de amostras		
	Fourier	HOS	SCM	Fourier	HOS	SCM
Fluxo Magnético Axial	8	7	9	1356	1356	1356

- MLP: *Cross-Validation* com 10 *folds*; Função de ativação: *tanh* para camada oculta e *softmax* para camada de saída; $\eta_0 = 0.001$; error tolerance: 10^{-5} ; Método de treinamento: Levenberg-Marquardt (BROWN; DENNIS, 1971); Variação no número de neurônios de 2 a 1000; número de camadas ocultas: 1 a 2;
- SVM: γ : $[2^{-15}, 2^{33}]$; C $[2^{-5}, 2^{15}]$; *kernels*: Linear, Polinomial e *Radial Basis Kernel* (RBF).
- KNN: Métrica de distância: Euclidiana; Número de vizinhos: 1, 3 e 5.
- Naive-Bayes: Gaussian probability density function;

Junto com esses métodos, Filho et al. (2018a) usa três condições operacionais no geradores. A tensão no barramento CC do conversor de frequência no lado do gerador (V_{cc}), a frequência aplicada no estator do gerador (f_g) e o valor efetivo de cada corrente de linha (I_{rms}). No fim, o vetor de atributo x construído está ilustrado na equação 3.4.

$$\vec{x} = \begin{bmatrix} x_F & V_{dc} & f_g & I_{rms} \end{bmatrix}. \quad (3.4)$$

3.3 Sistema embarcado

O *scikit-learn* é uma biblioteca de aprendizado de máquina escrita na linguagem de programação Python, versão Python3.6, e sua licença é gratuita. Diversos algoritmos de classificação, *clustering* e regressão, são suportadas. Para aplicar o aprendizado de máquina utilizando o *scikit-learn*, ou até mesmo outro, é necessário que a base de dados que foi realizado o treinamento, e gerado o conhecimento, deva ter o mesmo formato e até nomenclaturas de colunas e linhas iguais a base de teste. Então ao dividir a base de dados em um base de treino e teste é necessário aplicar as mesmas transformações nas duas. Então para facilitar essa tarefa, e evitar problemas na leitura do bando de dados, utilizamos uma Pipeline, pois o mesmo algoritmo será reproduzido em três sistemas embarcados. Com a pipeline padrão, outro desafio ao embarcar são as bibliotecas que interoperam com o *scikit-learn*, por exemplo, *scipy* que é uma biblioteca dedicada a computação e possui módulos para álgebra linear, processamento de sinais e outros. Já o *scipy* fundamenta-se em objetos da matriz *numpy*, que é um biblioteca de suporte para matrizes. Configurar todo o ambiente para executar o framework é um grande desafio. Para minimizar esses

problemas potenciais, foi criada um ambiente com as bibliotecas, modelos e banco de dados e executado em cada plataforma. Para evitar problemas com as versões das bibliotecas já existentes nos sistemas operacionais das plataformas, foi criado envs dentro da pasta do nosso ambiente. Nas plataformas da Nvidia não houve problemas ao gerar os modelos, treinar e testar, porém na Raspberry Pi 3 a versão do scikit-learn disponível era a 0.19.2 e a configuração utilizada necessita da versão 0.21.2. Esse problema foi superado com ajustes nas versões das demais bibliotecas. O sistema operacional Linux e o suporte da comunidade relacionada são fatores importantes que auxiliaram no desenvolvimento e na escolha das plataformas Nvidia. Outro ponto que merece destaque é que a biblioteca scikit-learn não utiliza recurso de GPU, porém é *multi thread*, ou seja, permite que cada processador ou núcleo execute tarefas em paralelo ([INRIA, 2019](#)).

4 Resultados e Discussões

Neste capítulo, os resultados das ações executadas seguindo a metodologia citada no Capítulo 3, são expostos e discutido.

Na Tab. 7 são exibidos os resultados gerais após 50 treinamentos de todas as combinações extrator-classificador, nas bases de treinamento e de teste no sinal de fluxo axial.

Tabela 7 – Comparação da taxa de precisão média entre os classificadores considerados.

Classificador	Extratores - Acc(%)		
	Fourier	HOS	SCM
Bayes	26,79±0,49	37,84±0,36	30,98±0,15
K1 (k=1)	48,69±0,07	66,03±0,27	64,10±0,23
K3 (k=3)	48,00±0,49	63,25±0,21	63,33±0,44
K5 (k=5)	48,09±0,54	62,83±0,39	63,09±0,47
M (MLP)	69,89±1,44	80,31±1,84	74,80±1,63
OB (OPF Bray-Curtis)	25,48±0,36	24,88±0,56	30,04±0,53
OC (OPF Canberra)	28,61±0,60	36,17±0,64	35,44±0,43
OCS (Chi-Square)	25,64±0,42	26,25±0,39	26,78±0,52
OE (OPF Euclidean)	28,65±0,50	36,74±0,63	36,89±0,50
OG Gaussian	28,77±0,38	36,56±0,37	37,16±0,63
OMN Manhattan	28,87±0,58	37,38±0,34	36,22±0,59
OCSC Squared Chi Squared	28,56±0,46	37,45±0,70	36,36±0,44
OSC Squared Chord	25,23±0,51	25,58±0,32	24,21±0,58
SL Linear	40,88±0,11	63,91±0,51	53,00±0,63
SP Plynomial	41,08±0,71	64,72±0,51	54,09±0,79
SR Radial Basic Functions	42,96±0,69	64,96±0,49	55,42± 0,52

As melhores acurácias de cada classificador foram destacadas em verde e evidenciou o bom desempenho do extrator HOS. Utilizando as características do HOS, o classificador MLP atingiu o melhor resultado com 80,31% de acurácia. Além do extrator HOS, a MLP também obteve valores expressivos de acurácia com os extratores Fourier e SCM com 69,89 e 74,80%, respectivamente. De forma geral, o classificador MLP obteve os melhores valores entre os três classificadores.

O extrator SCM obteve números próximos e em alguns classificadores foi até superior ao extrator HOS. Seu melhor desempenho foi quando combinado com o classificador KNN, porém não atingiu a acurácia se considerarmos todas as configurações. No entanto, o extrator SCM foi superior ao extrator Fourier em todas as configurações dos classificadores.

O extrator Fourier foi um destaque negativo nesta primeira etapa, pois apenas

quando combinado com MLP atingiu acurácia superior a 60%, nos demais os valores ficaram abaixo de 50%. Outro destaque negativo foi o classificador OPF e Bayes, pois em todas as suas configurações os valores de acurácia oscilaram entre 25 e 37%. Assim, nesta primeira etapa, fica evidente que para esta solução os classificadores OPF e Bayes não são indicados e não serão utilizados nas etapas seguintes.

Para explorar e identificar os equívocos na classificação do estado de saúde da máquina elétrica, a Tab. 8 foi gerada, já que a Tab. 7 apresenta a média da taxa de acerto nos 7 estados do aerogerador. Na Tab. 8 é apresentada as matrizes de confusão das melhores combinações de cada extrator, destacadas em verde na Tab. 7, e assim evidenciar quais estados de saúde do gerador o classificador se equivocou. Diferente do estudo de Qian, Ma e Cross (2017) que não apresentou taxa de acerto e a matriz confusão dos resultados.

Tabela 8 – Matriz de confusão referente aos melhores resultados de cada extratores de características destacados na Tab. 7.

Predição/Rótulo	HOS - SVM						
	Normal	AI-1	AI-2	AI-3	BI-1	BI-2	BI-3
Normal	99,19%	0,0%	0,0%	0,0%	0,0%	0,0 %	0,81%
AI-1	0,0 %	49,75%	0,99%	0,0%	11,33%	37,93%	0,0 %
AI-2	0,0%	29,61%	37,99%	0,0%	6,7%	25,7%	0,0%
AI-3	1,09 %	3,28%	0,0%	88,52%	0,0%	0,0%	7,1%
BI-1	1,13%	35,03%	2,26%	0,0%	32,2%	29,38%	0,0 %
BI-2	0,0%	22,60%	0,48%	0,48%	0,96%	75,48%	0,0 %
BI-3	2,36 %	1,57 %	0,79	48,03%	0,0%	3,15%	44,09%
Predição/Rótulo	HOS - MLP						
	Normal	AI-1	AI-2	AI-3	BI-1	BI-2	BI-3
Normal	100,0%	0,0%	0,0%	0,0%	0,0%	0,0 %	0,0%
AI-1	0,0	62,56%	4,93 %	0,49%	19,21%	12,81 %	0,0%
AI-2	0,0 %	14,53%	73,18%	0,0%	2,23 %	10,06%	0,0%
AI-3	0,0%	0,55%	0,0 %	91,28%	0,0%	0,0%	0,0 %
BI-1	0,0%	18,08%	1,13%	0,0%	71,75%	9,04%	0,0 %
BI-2	0,0 %	14,42 %	3,37%	0,0%	6,25%	75,96%	0,0 %
BI-3	0,0 %	0,79 %	0,0 %	16,54%	0,0 %	0,0%	82,68%
Predição/Rótulo	HOS - KNN						
	Normal	AI-1	AI-2	AI-3	BI-1	BI-2	BI-3
Normal	95,16%	0,0 %	0,0%	2,02%	0,0%	0,0%	2,82%
AI-1	0,0 %	71,43%	7,88%	0,0%	10,34%	10,34%	0,0%
AI-2	1,12%	32,96%	47,49%	0,56 %	6,70%	10,61%	0,56%
AI-3	1,64 %	3,83 %	3,28%	76,50%	0,55%	0,55%	13,66 %
BI-1	1,13 %	25,99%	12,43%	,56 0%	47,46%	11,86 %	0,56%
BI-2	0,0 %	21,15%	11,54 %	0,0%	14,90 %	52,40%	000%
BI-3	3,15 %	3,94%	1,57 %	31,50%	0,0 %	0,0%	59,84%

Após analisar o valor médio de acurácia de cada combinação na Tab. 7, a matriz confusão das melhores acurácias dos três melhores classificadores e apresenta na Tab. 8. Os valores destacados na diagonal verde é a taxa de acerto de cada estado do gerador. A

coluna vertical apresenta a predição e a linha horizontal apresenta o rótulo dos estados do gerador. Quando é cruzado uma linha imaginária entre a predição e rótulo a taxa de acerto do classificador é encontrada. Analisando o estado normal, a taxa de acerto alcançou 100% com a combinação HOS-MLP, 99,19% com HOS-SVM e a menor taxa com HOS-KNN no valor de 95,16%. São acurácias que demonstram uma confiança na classificação do estado normal de funcionamento do gerador. Quando a análise parte para os outros estados do gerador, os seis tipos de falhas, alguns pontos devem ser destacados. Em alguns momentos o classificador confundiu apenas a impedância do estado de falha do gerador, por exemplo, na combinação HOS-SVM o classificador indicou, em 35,03%, que a falha era BI-1 porém a falha era AI-1. O mesmo aconteceu no HOS-MLP e HOS-KNN em 18,08% e 25,99%, respectivamente. Outros valores destacados em vermelho requer uma maior preocupação, por exemplo, na combinação HOS-SVM o classificador indicou falha AI-1, em 37,93%, porém a falha era BI-2 que é uma falha mais perigosa para o funcionamento do gerador. O mesmo aconteceu no HOS-KNN, porém o classificador indicou uma falha mais grave e na verdade era uma falha com estágio de gravidade menor. Em geral, o classificador apresentou bom desempenho e conseguiu executar a tarefa de detectar e classificar falhas no gerador e, em alguns casos, com taxa de 100% de acerto.

Na segunda etapa, o framework desenvolvido em python, com a biblioteca scikit-learn, é embarcada e executada nas plataformas Nvidia Jetson TX2, Nvidia Jetson AGX Xavier e na Raspberry Pi 3. Com a rede treinada e o conhecimento prévio gerado, foi executado, em cada arquitetura, o treinamento e teste utilizando as métricas de acurácia e tempo de processamento. De modo que o passo a passo da execução do framework seja igual para todas as plataformas, tornando os resultados válidos e confiáveis.

Ao embarcar o framework em cada plataforma, as taxas de acerto foram bem próximas dos valores executado no computador, exceto na raspberry pi 3 devido suas configurações de hardware, porém isso já era esperado devido a execução da mesma metodologia. Na Tab. 9, são apresentados os valores das métricas de acurácia e tempo de processamento embarcado na Raspberry Pi 3.

O extrator de atributos que se destacou entre os três foi o HOS, combinado com o classificador MLP atingiu 72.95% de acerto em 21.98 milissegundos. Diferenças nos tempos de processamento são esperadas pois é derivada do fórmula do cálculo do classificador, por exemplo, o classificador MLP é baseado na multiplicação de matrizes, já o SVM aplica uma transformada e classifica por meio de hiperplanos, necessitando um pouco mais de tempo de processamento. O extrator Fourier apresentou o menor valor de acurácia, com 55.45%, entre os três, representado na Fig. 6. Outro destaque é o classificador KNN que ficou 2 unidade acima do classificar MLP e obteve o melhor resultado com as características do extrator SCM.

Por possuir um melhor configuração de hardware do que a Raspberry, as métri-

Tabela 9 – Valores de acurácia (acc) e tempo de processamento entre métodos de extração e classificação executados na Raspberry Pi 3

Classif/Extrator	Fourier			
	Acc(%)	Extração (ms)	Classificação(ms)	Total(ms)
MLP	55.45±3.85	16.71±0.27	5.32±0.14	22.03±0.20
SVM	43.01±3.93	16.91±0.45	50.90±0.87	67.81±0.66
KNN	48.65±3.07	16.83±0.30	11.20±0.52	28.03±0.41
Classif/Extrator	HOS			
	Acc(%)	Extração (ms)	Classificação(ms)	Total(ms)
MLP	72.95±2.17	16.73±0.34	5.25±0.13	21.98±0.22
SVM	63.91±2.69	16.91±0.30	41.88±0.72	58.79±0.51
KNN	66.02±4.64	16.44±0.09	10.06±0.32	26.05±0.20
Classif/Extrator	SCM			
	Acc(%)	Extração (ms)	Classificação(ms)	Total(ms)
MLP	62.60±4.03	16.95±0.42	5.16±0.09	22.11±0.25
SVM	55.40±3.38	16.75±0.24	43.49±0.76	60.24±0.55
KNN	64.22±2.21	16.92±0.13	11.02±0.28	27.94±0.23




Figura 6 – Representação gráfica da Tab. 8.

cas da Nvidia Jetson TX 2 foram melhores e apresentadas na Tab.10. Em seu melhor resultado, a combinação HOS-MLP obteve 80% de acerto, oito unidades a mais que a Raspberry e o tempo de processamento reduziu 8.38 milissegundos, com tempo total de 13.60 milissegundos. Na Raspberry o extrator SCM obteve seu melhor resultado com o classificador KNN, porém na Jetson Tx 2 o melhor resultado foi com o classificador MLP, 74.90%. E mais uma vez o extrator Fourier confirma não ser o mais indicado para esta

solução embarcada, como ilustra a Fig. 7.

Tabela 10 – Valores de acurácia e tempo de processamento entre métodos de extração e classificação executados na NVIDIA Jetson TX2

Classif/Extrator	Fourier			
	Acc(%)	Extração (ms)	Classificação(ms)	Total(ms)
MLP	69.57±2.87	11.24±0.22	2.57±0.20	13.81±0.20
SVM	43.02±2.27	11.37±0.41	5.27±0.45	16.64±0.44
KNN	48.56±3.10	11.35±0.35	7.20±0.31	18.55±0.33
Classif/Extrator	HOS			
	Acc(%)	Extração (ms)	Classificação(ms)	Total(ms)
MLP	80.04±3.22	11.10±0.17	2.50±0.17	13.60±0.22
SVM	63.82±2.63	11.19±0.19	4.71±0.19	15.90±0.81
KNN	65.96±4.79	11.27±0.31	6.46±0.21	17.73±0.29
Classif/Extrator	SCM			
	Acc(%)	Extração (ms)	Classificação(ms)	Total(ms)
MLP	74.90±3.11	11.20±0.16	2.53±0.22	13.73±0.29
SVM	55.41±3.25	11.30±0.40	4.89±0.48	16.19±0.53
KNN	64.33±2.51	11.39±0.31	6.60±0.33	17.99±0.34




Figura 7 – Representação gráfica da Tab. 9.

Os resultados apresentados na Nvidia Jetson AGX Xavier foram ilustrados na Tab. 10. A combinação HOS-MLP, novamente destacou-se com as melhores métricas, de acurácia, 80.21%, e tempo de processamento, 11.99 milissegundos. Ao comparar com as demais plataforma, a Xavier apresenta o melhor tempo de processamento e acurácia tecnicamente igual a da Jetson TX2. Outro destaque está presente no extrator SCM, pois

na Raspberry o melhor foi o classificador KNN e nas plataformas Nvidia foi o MLP. E mais uma vez, o extrator Fourier obteve os menos valores. Um fato deve ser destacado e motivo para futuras pesquisas desta aplicação. No trabalho de [Oliveira, Pontes e Medeiros \(2013\)](#), a investigação das frequências das harmônicas para extração de características do sinal com Fourier utilizou um sinal de corrente elétrica da máquina elétrica. Nesta pesquisa adotamos frequências iguais, no entanto aplicamos no sinal de fluxo axial. Então esse pode ser motivo do baixo desempenho do extrator de Fourier e trabalhos futuros investigarão as frequência mais importantes para o sinal de fluxo magnético axial da máquina elétrica.

Tabela 11 – Valores de acurácia (acc) e tempo de processamento entre métodos de extração e classificação executados na NVIDIA Jetson AGX Xavier

Classif/Extrator	Fourier			
	Acc(%)	Extração (ms)	Classificação(ms)	Total(ms)
MLP	70.07±3.55	9.76±1.22	2.20±0.39	11.96±0.80
SVM	42.99±3.93	9.29±2.55	4.90±0.90	14.19±1.72
KNN	48.68±3.07	9.30±1.08	6.20±2.37	15.50±1,75
Classif/Extrator	HOS			
	Acc(%)	Extração (ms)	Classificação(ms)	Total(ms)
MLP	80.21±3.18	9.29±1.07	2.70±0.31	11.99±0.68
SVM	63.92±3.93	9.87±1.38	3.90±0.48	13.77±0.93
KNN	66.01±3.07	9.05±1.72	5.20±1.16	14.25±1.44
Classif/Extrator	SCM			
	Acc(%)	Extração (ms)	Classificação(ms)	Total(ms)
MLP	74.84±3.29	9.54±1.82	2.38±0.25	11.92±1.03
SVM	55.40±3.93	9.59±0.97	5.96±0.38	15.55±0.67
KNN	64.24±3.07	9.72±1.20	6.19±2.05	15.92±1.62

Entre as três melhores combinações, destacada na Fig. 8, a combinação HOS-MLP atingiu acurácia de 80% e assim configura na melhor solução para embarcar utilizando a Nvidia Jetson AGX Xavier.

Após análise dos resultados de cada plataforma para sistemas embarcados, na última etapa da pesquisa, o último item dos objetivos específicos é alcançado. São selecionadas as melhores combinações extrator/classificados de cada plataforma, ilustrada na Fig. 9. A Raspberry Pi 3 apresenta as métricas mais baixas das três arquiteturas, porém vale salientar que uma acurácia de 72.95% não é um mau resultado. Se avaliarmos o preço de cada dispositivo e avaliar outro cenário de aplicação a Raspberry pode ser um alternativa mais indicada. Porém pra nossa aplicação de detecção e classificação de falhas em aerogeradores, é necessário uma sistema embarcado de alta performance e que proporcione confiança e segurança. Percebe-se que as plataformas Nvidia Jetson possuem desempenhos bem próximos de acurácia e tempo de processamento. Mas o objetivo desta pesquisa é definir uma configuração e a Nvidia Jetson AGX Xavier obteve uma taxa de acerto de 80.21% e tempo de processamento de 11.99 milissegundo. A Nvidia Jetson TX2 também apresentou bom desempenho com taxa de acerto tecnicamente igual a Xavier, porém obteve 1.61





Figura 8 – Representação gráfica da Tab. 10.

Figura 9 – Representação gráfica com as melhores combinações extrator/classificador de cada plataforma.



milissegundos a mais. E se analisarmos num contexto com grande volume de dados e com vários encadeamento de tarefas em paralelo essa diferença representa um aumento significativo no tempo de processamento.

5 Conclusão

Após utilizar banco de dados de fluxo magnético axial de um gerador gaiola de esquilo e realizar uma revisão sobre os métodos de extração de atributos e classificação, selecionamos alguns métodos para a primeira etapa de implementação. Ficou evidente que o extrator de Fourier não é o mais adequado para o problema, pois em apenas um caso atingiu 69% e nos demais ficou abaixo de 50% de acerto. Ao contrário de Fourier, o extrator HOS obteve acurácia superior a 80% e o SCM 74%. Porém, na continuidade da pesquisa o extrator de Fourier foi mantido, pois 90% de acurácia é um valor considerado bom.

Na segunda etapa da pesquisa, um estudo sobre plataformas para sistemas embarcados foi realizado e foram selecionadas Raspberry Pi3, Nvidia Jetson TX2 e AGX Xavier, de acordo com suas configurações de hardware e disponibilidade para o estudo. Após embarcar o framework em cada plataforma e em condições iguais de treino e teste, o melhor desempenho registrado foi da Nvidia Jetson AGX Xaveir com acurácia de 80.21% e 11.99 milisegundos de tempo de processamento total com o extrator HOS e o classificador MLP. A plataforma Nvidia Jetson TX2 também obteve uma acurácia de 80%, porém o tempo de processamento foi superior, com quase 2 milisegundos. De acordo com volume de dados e teste de uma aplicação, essa pequena diferença de tempo pode ser um grande diferencial para o sistema embarcado. Após o estudo, plataforma indicada para embarcar o sistema de detecção e classificação de falhas em aerogeradores é a Nvidia Jetson AGX Xavier. Porém alguns fatores devem ser considerados, por exemplo, a forma de alimentação do sistema embarcado, local em que o aerogerador está instalado e se existe algum acesso a internet, possibilitando assim envio de dados e/ou processamento em nuvem. Esses desafios presentes em aplicações com sistemas embarcados serão abordados em trabalhos futuros.

Referências

- AFANASYEVA, S. et al. Technical, economic and uncertainty modelling of a wind farm project. **Energy Conversion and Management**, Elsevier, v. 107, p. 22–33, 2016.
- AHMED, I.; ERTUGRUL, N.; SOONG, W. A study on the detection of fault frequencies for condition monitoring of induction machines. **School of Electrical and Electronics Engineering University of Adelaide, Australia**, 2005.
- ALIPPI, C.; GALPERTI, C. An adaptive system for optimal solar energy harvesting in wireless sensor network nodes. **IEEE Transactions on Circuits and Systems I: Regular Papers**, IEEE, v. 55, n. 6, p. 1742–1750, 2008.
- AMERT, T. et al. Gpu scheduling on the nvidia tx2: Hidden details revealed. In: IEEE. **2017 IEEE Real-Time Systems Symposium (RTSS)**. [S.l.], 2017. p. 104–115.
- AMIRAT, Y. et al. A brief status on condition monitoring and fault diagnosis in wind energy conversion systems. **Renewable and sustainable energy reviews**, Elsevier, v. 13, n. 9, p. 2629–2636, 2009.
- ANTONI, J. The spectral kurtosis: a useful tool for characterising non-stationary signals. **Mechanical systems and signal processing**, Elsevier, v. 20, n. 2, p. 282–307, 2006.
- ASFANI, D.; PURNOMO, M.; SAWITRI, D. Naïve bayes classifier for temporary short circuit fault detection in stator winding. In: IEEE. **2013 9th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives (SDEMPED)**. [S.l.], 2013. p. 288–294.
- ASHRAF, M.; MASOUMI, N. A thermal energy harvesting power supply with an internal startup circuit for pacemakers. **IEEE Transactions on Very Large Scale Integration (VLSI) Systems**, IEEE, v. 24, n. 1, p. 26–37, 2015.
- ASSAF, T.; HENAO, H.; CAPOLINO, G.-A. Simplified axial flux spectrum method to detect incipient stator inter-turn short-circuits in induction machine. In: IEEE. **2004 IEEE International Symposium on Industrial Electronics**. [S.l.], 2004. v. 2, p. 815–819.
- ATTARAN, N. et al. Embedded low-power processor for personalized stress detection. **IEEE Transactions on Circuits and Systems II: Express Briefs**, IEEE, v. 65, n. 12, p. 2032–2036, 2018.
- AZEVEDO, F. M. de; BRASIL, L. M.; OLIVEIRA, R. C. L. ao de. **Redes Neurais com aplicações em Controle e em Sistemas Especialistas**. [S.l.]: Visual Books, 2000.
- BELLINI, A. et al. Quantitative evaluation of induction motor broken bars by means of electrical signature analysis. **IEEE Transactions on industry applications**, IEEE, v. 37, n. 5, p. 1248–1255, 2001.
- BONNETT, A. H. Root cause failure analysis for ac induction motors in the petroleum and chemical industry. In: IEEE. **2010 record of conference papers industry**

applications society 57th annual Petroleum and Chemical Industry conference (PCIC). [S.l.], 2010. p. 1–13.

BONNETT, A. H.; SOUKUP, G. C. Cause and analysis of stator and rotor failures in three-phase squirrel-cage induction motors. **IEEE Transactions on Industry applications**, IEEE, v. 28, n. 4, p. 921–937, 1992.

BROWN, K. M.; DENNIS, J. Derivative free analogues of the levenberg-marquardt and gauss algorithms for nonlinear least squares approximation. **Numerische Mathematik**, Springer, v. 18, n. 4, p. 289–297, 1971.

CAPDEVIELLE, V.; SERVIERE, C.; LACOUME, J.-L. Blind separation of wide-band sources: Application to rotating machine signals. In: IEEE. **1996 8th European Signal Processing Conference (EUSIPCO 1996)**. [S.l.], 1996. p. 1–4.

CEBAN, A.; PUSCA, R.; ROMARY, R. Study of rotor faults in induction motors using external magnetic field analysis. **IEEE Transactions on Industrial Electronics**, IEEE, v. 59, n. 5, p. 2082–2093, 2011.

CHANDRA, N. H.; SEKHAR, A. Fault detection in rotor bearing systems using time frequency techniques. **Mechanical Systems and Signal Processing**, Elsevier, v. 72, p. 105–133, 2016.

CHINNERY, D.; KEUTZER, K. **Closing the power gap between ASIC & custom: tools and techniques for low power design**. [S.l.]: Springer Science & Business Media, 2008.

CHOPRA, S.; HADSELL, R.; LECUN, Y. Learning a similarity metric discriminatively, with application to face verification. In: IEEE. **Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on**. [S.l.], 2005. v. 1, p. 539–546.

CIANG, C. C.; LEE, J.-R.; BANG, H.-J. Structural health monitoring for a wind turbine system: a review of damage detection methods. **Measurement science and technology**, IOP publishing, v. 19, n. 12, p. 122001, 2008.

CLIMENTE-ALARCON, V. et al. Vibration transient detection of broken rotor bars by psh sidebands. **IEEE Transactions on Industry Applications**, IEEE, v. 49, n. 6, p. 2576–2582, 2013.

COUNCIL, G. W. E. Global wind report: Annual market update 2010; 2011. **Relatório Anual de Energia Eólica**, 2017.

COVER, T.; HART, P. Nearest neighbor pattern classification. **IEEE transactions on information theory**, IEEE, v. 13, n. 1, p. 21–27, 1967.

CRAMMER, K. et al. On the algorithmic implementation of multiclass kernel-based vector machines. **Journal of Machine Learning Research**, v. 2, p. 2001, 2001.

CURRIE, M. et al. Structural integrity monitoring of onshore wind turbine concrete foundations. **Renewable energy**, Elsevier, v. 83, p. 1131–1138, 2015.

- DAO, P. B. et al. Condition monitoring and fault detection in wind turbines based on cointegration analysis of scada data. **Renewable Energy**, Elsevier, v. 116, p. 107–122, 2018.
- DIETTERICH, T. G.; BAKIRI, G. Solving multiclass learning problems via error-correcting output codes. **J. Artif. Int. Res.**, AI Access Foundation, USA, v. 2, n. 1, p. 263–286, jan. 1995. ISSN 1076-9757.
- DUAN, K.-B.; KEERTHI, S. Which is the best multiclass svm method? an empirical study. In: OZA, N. et al. (Ed.). **Multiple Classifier Systems**. [S.l.]: Springer Berlin Heidelberg, 2005, (Lecture Notes in Computer Science, v. 3541). p. 278–285. ISBN 978-3-540-26306-7.
- EL-THALJI, I.; JANTUNEN, E. A summary of fault modelling and predictive health monitoring of rolling element bearings. **Mechanical systems and signal processing**, Elsevier, v. 60, p. 252–272, 2015.
- FENG, J.; SHEN, W. Z. Wind farm power production in the changing wind: Robustness quantification and layout optimization. **Energy Conversion and Management**, Elsevier, v. 148, p. 905–914, 2017.
- FILHO, P. P. R. et al. A reliable approach for detection of incipient faults of short-circuits in induction generators using machine learning. **Computers & Electrical Engineering**, Elsevier, v. 71, p. 440–451, 2018.
- FILHO, P. P. R. et al. A reliable approach for detection of incipient faults of short-circuits in induction generators using machine learning. **Computers & Electrical Engineering**, Elsevier, v. 71, p. 440–451, 2018.
- FRANCISCO, A. M. **MOTORES DE INDUÇÃO TRIFÊSICOS**. [S.l.]: Versão 0. Material de Estudo à disciplina Máquinas Elétricas, Departamento ... , 2006.
- FRIEDMAN, N.; GEIGER, D.; GOLDSZMIDT, M. Bayesian network classifiers. **Machine learning**, Springer, v. 29, n. 2-3, p. 131–163, 1997.
- FUNK, J. L.; LUO, J. Open standards, vertical disintegration and entrepreneurial opportunities: How vertically-specialized firms entered the us semiconductor industry. **Technovation**, Elsevier, v. 45, p. 52–62, 2015.
- GARCIA, M. C.; SANZ-BOBI, M. A.; PICO, J. D. Simap: Intelligent system for predictive maintenance: Application to the health condition monitoring of a windturbine gearbox. **Computers in Industry**, Elsevier, v. 57, n. 6, p. 552–568, 2006.
- GELMAN, L. et al. Rolling bearing diagnosis based on the higher order spectra. **International Journal of Prognostics and Health Management**, ISSN, p. 2153–2648, 2013.
- GELMAN, L. et al. Novel technology based on the spectral kurtosis and wavelet transform for rolling bearing diagnosis. **International Journal of Prognostics and Health Management**, ISSN, p. 2153–2648, 2013.
- GOLDBERGER, J. et al. Neighbourhood components analysis. In: **Advances in neural information processing systems**. [S.l.: s.n.], 2005. p. 513–520.

- GONZÁLEZ, J. S. et al. Maximizing the overall production of wind farms by setting the individual operating point of wind turbines. **Renewable Energy**, Elsevier, v. 80, p. 219–229, 2015.
- HABIBZADEH, M. et al. Solar/wind hybrid energy harvesting for supercapacitor-based embedded systems. In: IEEE. **2017 IEEE 60th International Midwest Symposium on Circuits and Systems (MWSCAS)**. [S.l.], 2017. p. 329–332.
- HABIBZADEH, M. et al. Supercapacitor-based embedded hybrid solar/wind harvesting system architectures. In: IEEE. **2017 30th IEEE International System-on-Chip Conference (SOCC)**. [S.l.], 2017. p. 215–220.
- HAYKIN, S. O. **Neural Networks and Learning Machines**. [S.l.]: Pearson Prentice Hall, 2008.
- HENAO, H.; DEMIAN, C.; CAPOLINO, G. A. A frequency-domain detection of stator winding faults in induction machines using an external flux sensor. **IEEE Transactions on Industry Applications**, v. 39, n. 5, p. 1272–1279, 2003. ISSN 00939994.
- INRIA. **Scikit-learn: Machine Learning in Python**. 2019. Disponível em: <<https://scikit-learn.org/stable/>>. Acesso em: 01 jul. 2019.
- INTERNATIONAL ENERGY AGENCY. **Key world energy statistics**. 2017. Disponível em: <<https://www.iea.org/publications/freepublications/publication/KeyWorld2017.pdf>>.
- JIN, C. et al. Envelope analysis on vibration signals for stator winding fault early detection in 3-phase induction motors. **International Journal of Prognostics and Health Management**, v. 6, n. 1, p. 003, 2015.
- KIM, Y.-H. et al. High-resolution parameter estimation method to identify broken rotor bar faults in induction motors. **IEEE Transactions on Industrial Electronics**, IEEE, v. 60, n. 9, p. 4103–4117, 2013.
- KONG, N.; HA, D. S. Low-power design of a self-powered piezoelectric energy harvesting system with maximum power point tracking. **IEEE Transactions on power electronics**, IEEE, v. 27, n. 5, p. 2298–2308, 2011.
- KUMAR, A. et al. Solar energy for all? understanding the successes and shortfalls through a critical comparative assessment of bangladesh, brazil, india, mozambique, sri lanka and south africa. **Energy Research & Social Science**, Elsevier, v. 48, p. 166–176, 2019.
- LEE, S. et al. Car plate recognition based on cnn using embedded system with gpu. In: IEEE. **2017 10th International Conference on Human System Interactions (HSI)**. [S.l.], 2017. p. 239–241.
- LEÓN, J. R. C. et al. Raspberry pi and arduino uno working together as a basic meteorological station. **arXiv preprint arXiv:1711.09750**, 2017.
- LIN, F.-J. et al. Intelligent controlled three-phase squirrel-cage induction generator system using wavelet fuzzy neural network for wind power. **IET Renewable Power Generation**, IET, v. 7, n. 5, p. 552–564, 2013.

- LIU, S. et al. Harvesting-aware power management for real-time systems with renewable energy. **IEEE transactions on very large scale integration (VLSI) systems**, IEEE, v. 20, n. 8, p. 1473–1486, 2011.
- LU, B. et al. A review of recent advances in wind turbine condition monitoring and fault diagnosis. In: IEEE. **Power Electronics and Machines in Wind Applications, 2009. PEMWA 2009. IEEE**. [S.l.], 2009. p. 1–7.
- MARINHO, L. B. et al. A novel mobile robot localization approach based on topological maps using classification with reject option in omnidirectional images. **Expert Systems with Applications**, Elsevier, v. 72, p. 1–17, 2017.
- MARTIN, H.; HONARVAR, F. Application of statistical moments to bearing failure detection. **Applied acoustics**, Elsevier, v. 44, n. 1, p. 67–77, 1995.
- MARTINEZ, J.; BELAHCEN, A.; ARKKIO, A. Broken bar indicators for cage induction motors and their relationship with the number of consecutive broken bars. **IET Electric Power Applications**, IET, v. 7, n. 8, p. 633–642, 2013.
- MEEHAN, A.; GAO, H.; LEWANDOWSKI, Z. Energy harvesting with microbial fuel cell and power management system. **IEEE Transactions on power electronics**, IEEE, v. 26, n. 1, p. 176–181, 2010.
- MESEMANOLIS, A.; MADEMLIS, C.; KIOSKERIDIS, I. Optimal Efficiency Control Strategy in Wind Energy Conversion System With Induction Generator. **IEEE Journal of Emerging and Selected Topics in Power Electronics**, v. 1, n. 4, p. 238–246, 2013. ISSN 2168-6777. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6620967>>.
- MESHGIN-KELK, H.; MILIMONFARED, J.; TOLİYAT, H. A. Interbar currents and axial fluxes in healthy and faulty induction motors. **IEEE Transactions on Industry Applications**, IEEE, v. 40, n. 1, p. 128–134, 2004.
- MIRIMANI, S. M. et al. Static eccentricity fault detection in single-stator–single-rotor axial-flux permanent-magnet machines. **IEEE Transactions on Industry Applications**, IEEE, v. 48, n. 6, p. 1838–1845, 2012.
- MITTAL, S. A survey on optimized implementation of deep learning models on the nvidia jetson platform. **Journal of Systems Architecture**, Elsevier, 2019.
- MOORTHY, Y. K.; CHANDRAN, P. S.; RISHIDAS, S. Motor current signature analysis by multi-resolution methods using support vector machine. In: IEEE. **2011 IEEE Recent Advances in Intelligent Computational Systems**. [S.l.], 2011. p. 096–101.
- MOZER, M. C. A focused backpropagation algorithm for temporal. **Backpropagation: Theory, architectures, and applications**, v. 137, 1995.
- MYRENT, N. J. et al. A robust algorithm to detecting wind turbine blade health using vibro-acoustic modulation and sideband spectral analysis. In: **33rd Wind Energy Symposium**. [S.l.: s.n.], 2015. p. 1001.

- NASCIMENTO, N. d. M. M. e; MEDEIROS, C. M. de S.; FILHO, P. P. R. A comparison of machine learning methods to identify broken bar failures in induction motors using statistical moments. In: SPRINGER. **International Conference on Intelligent Systems Design and Applications**. [S.l.], 2017. p. 124–133.
- NASCIMENTO, N. de Medeiros Mendonça e. **Deteção e classificação de falhas de curto-circuito em geradores de indução aplicados em geração eólica utilizando aprendizado de máquina**. 137 p. Dissertação (Mestrado) — INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO CEARÁ, Fortaleza-Ce, 2018.
- NVIDIA. **Harness AI at the Edge with the Jetson TX2 Developer Kit**. 2019. Disponível em: <<https://developer.nvidia.com/embedded-computing>>. Acesso em: 02 jul. 2019.
- OGIDI, O. O.; BARENDSE, P. S.; KHAN, M. A. The detection of interturn short circuit faults in axial-flux permanent magnet machine with concentrated windings. In: IEEE. **2015 IEEE Energy Conversion Congress and Exposition (ECCE)**. [S.l.], 2015. p. 1810–1817.
- OGIDI, O. O.; BARENDSE, P. S.; KHAN, M. A. Fault diagnosis and condition monitoring of axial-flux permanent magnet wind generators. **Electric Power Systems Research**, Elsevier, v. 136, p. 1–7, 2016.
- OLIVEIRA, Á. G. de; PONTES, R. S. T.; MEDEIROS, C. M. de S. Neural network used to stator winding interturn short-circuit fault detection in an induction motor driven by frequency converter. In: IEEE. **2013 BRICS Congress on Computational Intelligence and 11th Brazilian Congress on Computational Intelligence**. [S.l.], 2013. p. 459–464.
- OZTURK, S.; FTHENAKIS, V.; FAULSTICH, S. Failure modes, effects and criticality analysis for wind turbines considering climatic regions and comparing geared and direct drive wind turbines. **Energies**, Multidisciplinary Digital Publishing Institute, v. 11, n. 9, p. 2317, 2018.
- PAO, L. Y.; JOHNSON, K. E. Control of Wind Turbines. **IEEE Control Systems**, v. 31, n. 2, p. 44–62, 2011. ISSN 1066-033X.
- PAPA, J. P. et al. Efficient supervised optimum-path forest classification for large datasets. **Pattern Recognition**, Elsevier, v. 45, n. 1, p. 512–520, 2012.
- PAPA, J. P.; FALCAO, A. X.; SUZUKI, C. T. Supervised pattern classification based on optimum-path forest. **International Journal of Imaging Systems and Technology**, Wiley Online Library, v. 19, n. 2, p. 120–131, 2009.
- PARADA, L. et al. Wind farm layout optimization using a gaussian-based wake model. **Renewable Energy**, Elsevier, v. 107, p. 531–541, 2017.
- PARK, Y. et al. Stray flux monitoring for reliable detection of rotor faults under the influence of rotor axial air ducts. **IEEE Transactions on Industrial Electronics**, IEEE, v. 66, n. 10, p. 7561–7570, 2018.
- PENMAN, J. et al. Detection and location of interturn short circuits in the stator windings of operating motors. **IEEE transactions on Energy conversion**, IEEE, v. 9, n. 4, p. 652–658, 1994.

- PI, R. Raspberry pi. **Raspberry Pi**, v. 1, n. 1, 2013.
- PIÑUELA, M.; MITCHESON, P. D.; LUCYSZYN, S. Ambient rf energy harvesting in urban and semi-urban environments. **IEEE Transactions on microwave theory and techniques**, IEEE, v. 61, n. 7, p. 2715–2726, 2013.
- PLATT, J. C.; CRISTIANINI, N.; SHAW-TAYLOR, J. Large margin dags for multiclass classification. In: **Advances in Neural Information Processing Systems**. [S.l.]: MIT Press, 2000. p. 547–553.
- QIAN, P.; MA, X.; CROSS, P. Integrated data-driven model-based approach to condition monitoring of the wind turbine gearbox. **IET Renewable Power Generation**, IET, v. 11, n. 9, p. 1177–1185, 2017.
- RAHIMI, E. et al. On the management of wind power intermittency. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 28, p. 643–653, 2013.
- RAMADASS, Y. K.; CHANDRAKASAN, A. P. A battery-less thermoelectric energy harvesting interface circuit with 35 mv startup voltage. **IEEE Journal of Solid-State Circuits**, IEEE, v. 46, n. 1, p. 333–341, 2010.
- RAMALHO, G. L. B. et al. Rotation-invariant feature extraction using a structural co-occurrence matrix. **Measurement**, Elsevier, v. 94, p. 406–415, 2016.
- RAMASUR, D.; HANCKE, G. P. A wind energy harvester for low power wireless sensor networks. In: IEEE. **2012 IEEE International Instrumentation and Measurement Technology Conference Proceedings**. [S.l.], 2012. p. 2623–2627.
- RASPBERRY PI FOUNDATION. **Raspberry Pi 4**. Disponível em: <<https://www.raspberrypi.org/products/raspberry-pi-4-model-b/>>. Acesso em: 01 jul. 2019.
- RIGONI, M. et al. Detection and analysis of rotor faults in induction motors by the measurement of the stray magnetic flux. **Journal of Microwaves, Optoelectronics and Electromagnetic Applications**, SciELO Brasil, v. 11, n. 1, p. 68–80, 2012.
- RODRÍGUEZ, P. V. J. et al. **Current-, force-, and vibration-based techniques for induction motor condition monitoring**. [S.l.]: Helsinki University of Technology, 2007.
- ROLIK, Y. Risk management in implementing wind energy project. **Procedia Engineering**, Elsevier, v. 178, p. 278–288, 2017.
- ROYO, J.; ARCEGA, F. Machine current signature analysis as a way for fault detection in squirrel cage wind generators. In: IEEE. **2007 IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives**. [S.l.], 2007. p. 383–387.
- SALAMEH, J. P. et al. Gearbox condition monitoring in wind turbines: A review. **Mechanical Systems and Signal Processing**, Elsevier, v. 111, p. 251–264, 2018.
- SANTOS, P. et al. An svm-based solution for fault detection in wind turbines. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 15, n. 3, p. 5627–5648, 2015.

- SHALEV-SHWARTZ, S.; SINGER, Y.; NG, A. Y. Online and batch learning of pseudo-metrics. In: ACM. **Proceedings of the twenty-first international conference on Machine learning**. [S.l.], 2004. p. 94.
- SIEGEL, J. E. et al. Real-time deep neural networks for internet-enabled arc-fault detection. **Engineering Applications of Artificial Intelligence**, Elsevier, v. 74, p. 35–42, 2018.
- SOUSA, I. R. de; SÁ, C. M. d. M. APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA A DETECÇÃO DE FALHAS EM BARRAS ROTÓRICAS DE MOTORES DE INDUÇÃO. In: **XIII Simpósio Brasileiro de Automação Inteligente**. [S.l.: s.n.], 2017.
- SOUSA, P. H. F. de et al. Detection and classification of faults in induction generator applied into wind turbines through a machine learning approach. In: IEEE. **2018 International Joint Conference on Neural Networks (IJCNN)**. [S.l.], 2018. p. 1–7.
- SOUSA, P. H. F. de et al. A Fourier Characterization of Manetic Flux in Stator Winding Interturn Short-Circuit of an Wind Turbine Induction Generator. **IEEE Latin America**, 2017.
- SOUSA P. H. F.; NASCIMENTO, N. M. M. A. J. S. R. F. P. P.; ALBUQUERQUE, V. C. Intelligent incipient fault detection in wind turbines based on industrial iot environment. **Journal of Artificial Intelligence and Systems**, IEC, p. 1–19, 2019.
- SOYATA, T.; COPELAND, L.; HEINZELMAN, W. Rf energy harvesting for embedded systems: A survey of tradeoffs and methodology. **IEEE Circuits and Systems Magazine**, IEEE, v. 16, n. 1, p. 22–57, 2016.
- SUPANGAT, R. et al. Broken rotor bar fault detection in induction motors using starting current analysis. In: IEEE. **Power Electronics and Applications, 2005 European Conference on**. [S.l.], 2005. p. 10–pp.
- SURESH, N. et al. Raspberry pi based liquid flow monitoring and control. **International Journal of Research in Engineering and Technology**, v. 3, n. 07, p. 122–125, 2014.
- TAZI, N.; CHÂTELET, E.; BOUZIDI, Y. Using a hybrid cost-fmea analysis for wind turbine reliability analysis. **Energies**, Multidisciplinary Digital Publishing Institute, v. 10, n. 3, p. 276, 2017.
- TCHAKOUA, P. et al. Wind turbine condition monitoring: State-of-the-art review, new trends, and future challenges. **Energies**, Multidisciplinary Digital Publishing Institute, v. 7, n. 4, p. 2595–2630, 2014.
- TCHERNIAK, D.; MØLGAARD, L. L. Active vibration-based structural health monitoring system for wind turbine blade: Demonstration on an operating vestas v27 wind turbine. **Structural Health Monitoring**, SAGE Publications Sage UK: London, England, v. 16, n. 5, p. 536–550, 2017.
- THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern recognition**. 4. ed. San Diego, Califórnia, USA: Academic Press, 2008. ISBN 978-1-59749-272-0.

- TIJTGAT, N. et al. Embedded real-time object detection for a uav warning system. In: **Proceedings of the IEEE International Conference on Computer Vision**. [S.l.: s.n.], 2017. p. 2110–2118.
- VAPNIK, V. N. **Statistical Learning Theory**. [S.l.]: John Wiley & Sons, Inc., 1998.
- VUJOVIĆ, V.; MAKSIMOVIĆ, M. Raspberry pi as a sensor web node for home automation. **Computers & Electrical Engineering**, Elsevier, v. 44, p. 153–171, 2015.
- WANG, P.; TAMILSELVAN, P.; HU, C. Health diagnostics using multi-attribute classification fusion. **Engineering Applications of Artificial Intelligence**, Elsevier, v. 32, p. 192–202, 2014.
- WYMORE, M. L. et al. A survey of health monitoring systems for wind turbines. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 52, p. 976–990, 2015.
- XAVIER, G. A. et al. Simulation of distributed generation with photovoltaic microgrids—case study in brazil. **Energies**, Multidisciplinary Digital Publishing Institute, v. 8, n. 5, p. 4003–4023, 2015.
- YANG, B.; SUN, D. Testing, inspecting and monitoring technologies for wind turbine blades: A survey. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 22, p. 515–526, 2013.
- YARAMASU, V. et al. High-power wind energy conversion systems: State-of-the-art and emerging technologies. **Proceedings of the IEEE**, v. 103, n. 5, 2015.
- YUAN, S.; PENG, S. Trends in the economic return on energy use and energy use efficiency in china’s crop production. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 70, p. 836–844, 2017.
- ZHOU, H. et al. A review of full-scale structural testing of wind turbine blades. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 33, p. 177–187, 2014.
- ZHU, Y. et al. An energy autonomous 400 mhz active wireless saw temperature sensor powered by vibration energy harvesting. **IEEE Transactions on Circuits and Systems I: Regular Papers**, IEEE, v. 62, n. 4, p. 976–985, 2015.
- ZOU, Y.; ELBULUK, M. E.; SOZER, Y. Simulation comparisons and implementation of induction generator wind power systems. **IEEE Transactions on Industry Applications**, v. 49, n. 3, p. 1119–1128, 2013. ISSN 00939994.