

Universidade Federal da Paraíba
Centro de Informática
Programa de Pós-Graduação em Informática

Uma abordagem baseada em densidade de máximos para
identificação de velocidade e possíveis falhas em motores DC
sem escova por meio de sinal de acelerômetro

Jefferson Silva de Souza

Dissertação submetida à Coordenação do Curso de Pós-Graduação em
Informática da Universidade Federal da Paraíba como parte dos requisi-
tos necessários para obtenção do Título de Mestre em Informática.

Área de Concentração: Ciência da Computação
Linha de Pesquisa: Sinais, Sistemas Digitais e Gráficos

Alisson Vasconcelos de Brito
(Orientador)

João Pessoa, Paraíba, Brasil

©Jefferson Silva de Souza, 09 de agosto de 2019

Uma abordagem baseada em densidade de máximos para
identificação de velocidade e possíveis falhas em motores DC
sem escova por meio de sinal de acelerômetro

Dissertação submetida à Coordenação do Curso de Pós-Graduação em
Informática da Universidade Federal da Paraíba como parte dos requisi-
tos necessários para obtenção do grau de Mestre em Informática.

Alisson Vasconcelo Brito (Orientador)

João Pessoa, Paraíba, Brasil

©Jefferson Silva de Souza, 09 de agosto de 2019

Ficha Catalográfica

Catálogo na publicação Seção de Catalogação e Classificação

S729a Souza, Jefferson Silva de.

Uma abordagem baseada em densidade de máximos para identificação de velocidade e possíveis falhas em motores DC sem escova por meio de sinal de acelerômetro / Jefferson Silva de Souza. - João Pessoa, 2019. 82 f.

Orientação: Alisson Vasconcelos Brito.
Dissertação (Mestrado) - UFPB/CI.

1. Teoria do Caos. 2. Análise de sinais. 3. Motores DC sem escovas. 4. BLDCs. 5. VANTs. I. Brito, Alisson Vasconcelos. II. Título.

UFPB/BC



UNIVERSIDADE FEDERAL DA PARAÍBA
CENTRO DE INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA



Ata da Sessão Pública de Defesa de Dissertação de Mestrado de Jefferson Silva de Souza, candidato ao título de Mestre em Informática na Área de Sistemas de Computação, realizada em 09 de agosto de 2019.

1 Aos nove dias do mês de agosto, do ano de dois mil e dezenove, às nove horas, no Centro
2 de Informática da Universidade Federal da Paraíba, em Mangabeira, reuniram-se os
3 membros da Banca Examinadora constituída para julgar o Trabalho Final do Sr. Jefferson
4 Silva de Souza, vinculado a esta Universidade sob a matrícula nº 20181000751, candidato
5 ao grau de Mestre em Informática, na área de "Sistemas de Computação", na linha de
6 pesquisa "Sinais, Sistemas Digitais e Gráficos", do Programa de Pós-Graduação em
7 Informática, da Universidade Federal da Paraíba. A comissão examinadora foi composta
8 pelos professores: Alisson Vasconcelos de Brito (PPGI-UFPB) Orientador e Presidente da
9 Banca, Ruy Alberto Pisani Altafim (PPGI-UFPB), Examinador Interno, Ewerton Monteiro
10 Salvador (UFPB), Examinador Externo ao Programa, Abel Cavalcante Lima Filho (UFPB),
11 Examinador Externo ao Programa, Frank Cesar Lopes Veras (UFPI), Examinador Externo à
12 Instituição. Dando início aos trabalhos, o Presidente da Banca cumprimentou os presentes,
13 comunicou aos mesmos a finalidade da reunião e passou a palavra ao candidato para que o
14 mesmo fizesse a exposição oral do trabalho de dissertação intitulado: "Uma Abordagem
15 Baseada no Caos para Identificação de Velocidade e Possíveis Falhas em Motores DC sem
16 Escova por Meio de Sinal de Acelerômetros". Concluída a exposição, o candidato foi arguido
17 pela Banca Examinadora que emitiu o seguinte parecer: "**aprovado**". Do ocorrido, eu,
18 Claurton de Albuquerque Siebra, Coordenador do Programa de Pós-Graduação em
19 Informática, lavrei a presente ata que vai assinada por mim e pelos membros da banca
20 examinadora. João Pessoa, 09 de agosto de 2019.


Prof. Dr. Claurton de Albuquerque Siebra




Prof. Dr. Alisson Vasconcelos de Brito
Orientador (PPGI-UFPB)


Prof. Dr. Ruy Alberto Pisani Altafim
Examinador Interno (PPGI-UFPB)

Prof. Dr. Ewerton Monteiro Salvador
Examinador Externo ao Programa (UFPB)

Prof. Dr. Abel Cavalcante Lima Filho
Examinador Externo ao Programa (UFPB)

Prof. Dr. Frank Cesar Lopes Veras
Examinador Externo à Instituição (UFPI)



Resumo

Este trabalho apresenta uma técnica denominada Análise de Sinais baseada no Caos, utilizando Densidade de Máxima (SAC-DM) para motores DC sem escovas usando o coeficiente de correlação obtido a partir da densidade máxima do sinal de vibração. Esta técnica demonstra o potencial para caracterizar motores com uma abordagem simples. A abordagem proposta é comparada com a tradicional Transformada Rápida de Fourier e a análise clássica do caos, com base no coeficiente de correlação obtido a partir do comprimento à meia altura da função de correlação. As experiências demonstram resultados semelhantes, mas mais simples e mais rápidos do que as duas abordagens comparadas.

Palavras-chave: Teoria do Caos, Análise de sinais, motores DC sem escovas, BLDCs, VANTs.

Abstract

This work presents a technique named Signal Analysis based on Chaos using Density of Maxima (SAC-DM) to analyze brushless DC motors using correlation coefficient obtained from density of maxima of the current signal. This technique demonstrates potential to characterize motors with a simple approach. The proposed approach is compared with the traditional FastFourier Transform and classical chaos analysis based on the correlation coefficient obtained from the length at half-height of the correlation function. The experiments demonstrates similar results but simpler and faster than the two compared approaches.

Keywords: Chaos, Signal analysis, Brushless DC Motor, BLDCs, VANTs.

Agradecimentos

Agradeço a Deus por estar sempre ao nosso lado, salvando, orientando, guardando, mostrando os caminhos, aliviando todas as preocupações e temores que surgiram ao longo desta e de todas as demais fases de minha vida.

Agradeço ao povo brasileiro, por ter financiado toda essa minha empreitada através dos impostos recolhidos, podendo assim financiar nossa Universidade pública, gratuita e de qualidade.

Aos meus amados pais, Paulo Francisco Barbosa de Souza e Josenice Francisca Silva de Souza, pela educação primorosa que dedicaram a cada um de seus filhos. Foi com este fraterno cuidado, os momentos de dúvidas foram muito mais suaves. Sou grato pelo amor e entrega ao longo de todos esses anos, por todo apoio, muitas vezes sem a mínima condição, mas que o fizeram com todo zelo.

Agradeço a minha esposa, Silvia Renata Ribeiro, pela sua paciência, dedicação e companheirismo, minha vida encontrou o caminho do amor verdadeiro. Dedico, igualmente, aos meus filhos, Levi, Gabriel e Isabela, por existirem e transformarem minha vida e a minha essência, como pessoa, homem, marido e pai. A chegada de cada um de vocês, esposa e filhos, guiou, guia e continuará guiando meus passos. Amo muito vocês!

Ao meu orientadores e amigo, Alisson Vasconcelos de Brito (LASER), bem como aos Professores Jorge Gabriel (Dep. Física), Abel Cavalcante Lima Filho (PPGEM) e Frank C. Lopes Vêras (UFPI), pela forma sutil, pontual e clara que me auxiliaram durante esses anos, enriquecendo meu conhecimento, minimizando minhas dúvidas e formando não só um profissional, como também um cidadão, mais apto a contribuir com a humanidade. Sem suas disponibilidades, inteligências e, principalmente, sem suas amizades, não seria possível chegar ao final dessa etapa.

Aos demais professores do curso que apresentaram e compartilharam seus conhecimentos, ajudando na montagem e evolução deste trabalho, bem como aos funcionários do PPGI, que dedicaram seu tempo auxiliando docentes e discentes do curso, em especial a mim, quando assim precisei. E as amizades estabelecidas ao longo do curso, a todos aqueles que contribuíram para que esse sonho fosse alcançado. O meu muito obrigado!

Sumário

1	Introdução	1
1.1	Motivação	3
1.2	Objetivos	4
1.2.1	Objetivo Geral	4
1.2.2	Objetivos Específicos	4
1.3	Estrutura do Trabalho	4
2	Fundamentação Teórica	5
2.1	VANTs	5
2.1.1	Tipos de VANTs	5
2.2	Motores de Corrente Contínua Sem Escovas (BLDCs)	7
2.3	Sistemas Caóticos	8
2.4	Coeficiente de Comprimento de Correlação (<i>Correlation Length Coefficient</i> - CLC)	11
2.5	Wavelet Multiresolution Analysis (WMA)	12
2.6	Análise de Sinal utilizando Caos baseado em Densidade de Máximos	13
2.7	Provando o Comportamento Caótico	16
2.8	Rede Neural Artificial	19
2.8.1	Aprendizagem	22
2.8.2	RNA Perceptron (Camada única)	25
2.8.3	RNA Perceptron Multicamadas	25
3	Trabalhos Relacionados	27
3.1	Técnicas Baseadas em Processamento Digital de Sinais	27

3.2	Abordagens Baseadas no Caos	28
3.3	Diagnósticos de Motores BLDCs	29
4	Metodologia e Materiais	31
4.1	Bancada de Ensaio	31
4.2	Acelerômetro Adafruit®ADXL345	33
4.3	Node MCU - ESP 8266 12F	35
4.4	MicroSD Card Adapter	36
4.5	Metodologia	36
4.5.1	Calculando SAC-DM	37
4.5.2	Aplicando Rede Neural de Alimentação para Frente <i>Feedforward</i> <i>Neural Network</i> (FNN)	39
5	Experimentos	40
5.1	Detecção de Velocidade utilizando SAC-DM (Experimentos I).	40
5.1.1	Aquisição dos Dados	41
5.1.2	Configurações do Acelerômetro	41
5.1.3	Configuração e treinamento da Rede Neural <i>Feedforward</i> (FNN) . .	42
5.1.4	Processando os Dados	42
5.2	Detecção de falhas utilizando SAC-DM (Experimentos II).	46
5.2.1	Aquisição dos Dados	46
5.2.2	Configurações do Acelerômetro	46
5.2.3	Processamento dos dados	47
5.3	Construção de Sistema Embarcado para Análise de SAC-DM em Voo. . . .	50
6	Conclusão	52
6.1	Considerações Finais	53
6.2	Atividades Futuras	54
	Referências Bibliográficas	58
A	Código da Bancada de Ensaio	59
B	Código do Sistema Embarcado para captura do Sinal em Tempo Real	64

Lista de Símbolos

BLDC : *Brushless Direct Current*

CLC : *Correlation Length Coefficient*

DC : *Direct Current*

DFT : *Discret Fourier Transform*

EKF : *Extend Kalman Filter*

ESC : *Electronic Speed Controller*

FNN : *Feedforward Neural Network*

FFT : *FastFourier Transform*

LPFT : *Local Polynomial FourierTransform*

MCSA : *Motor Current Signature Analysis*

MLP : *Multi-Layer Preceptron*

MRAC : *Model Reference Adaptive Control*

PMSM : *Permanent Magnet Synchronous Motor*

PWM : *Pulse Width Modulation*

RNA : *Redes Neuraais Artificiais*

SAC-DM : *Signal Analysisbased on Chaos using Density of Maxima*

SPI : *Serial Peripheral Interface*

SMO : *Sliding Mode Observer*

UAV : *Unmanned Aerial Vehicle*

VANT : *Veículo Aéreo Não Tripilado*

WDT : *Wavelet Discrete Transform*

SAC-DM : *Signal Analysis based on Chaos using Density of Maxima*

Lista de Figuras

2.1	Tipos de Vants Disponíveis comercialmente.	6
2.2	Motor Sem Escova de Corrente Contínua (BLDC)	7
2.3	Principais Componentes do Motor(BLDC)	7
2.4	Esquema Elétrico de Ligação do Motor BLDC	8
2.5	Algoritmo de Mallat para calcular o DWT.	13
2.6	Sinal do Acelerômetro para 70%, 80% e 90% da velocidade	16
2.7	Auto-Correlação sem filtro de Wavelet	17
2.8	Auto-Correlação com filtro de Wavelet	17
2.9	Coeficiente de Comprimento de Correlação após Wavelet - velocidade em 90% da capacidade do motor	18
2.10	Sinal de vibração em Zoom nos picos a 90% da velocidade	19
2.11	Neurônio Biológico	20
2.12	Modelo de Neurônio Biológico. Adaptado de (HAYKIN; NETWORK, 2004)	20
2.13	(a) Função Limiar, (b) Função Linear por Partes e (c) Função sigmóide com parâmetro de inclinação a variável.	23
2.14	Modelo de RNA perceptron multicamadas.	25
4.1	Bancada de Teste para coleta de dados de vibração.	32
4.2	Esquema elétrico da Bancada de Ensaio.	33
4.3	Acelerômetro Adafruit®ADXL345.	34
4.4	Node MCU ESP 8266 12F com sua pinagem.	35
4.5	MicroSD Card Adapter.	36
4.6	Metodologia para processamento do sinal usando densidade de máximos . .	37

4.7	Modelo de rede neural utilizada no experimento	39
5.1	Sinal do Acelerômetro - Velocidades de 70%, 80% e 90%	41
5.2	Porcentagem de erros na rede neural durante o processamento SAC-DM para medição de velocidade	43
5.3	Gráfico da amostra do vetor de aceleração do sinal para 70%, 80% e 90% da velocidade	45
5.4	Histograma do SAC-DM calculado a partir do sinal do vetor de aceleração para 70%, 80% and 90% da velocidade	45
5.5	Histogramas comparativos do SAC-DM em Função das velocidade	48
5.6	Histogramas comparativos do SAC-DM em Função do Desbalanceamento .	49
5.7	Protótipo de Sistema Embarcado para Análise de Vibração	51

Lista de Tabelas

2.1	Valores para CLC (após Wavelet) e SAC-DM (Sem Wavelet)	19
4.1	Especificação do Motor BLDC	32
4.2	Especificação do Chip ESP8266	36
5.1	Médias das Velocidades	41
5.2	Passos de treinamento da FNN Perceptron	43
5.3	Resultados Obtidos com a Rede Neural	44
5.4	Resultados Obtidos com a Rede Neural	47

Capítulo 1

Introdução

Os Veículos Aéreos não tripulados (VANTs), do inglês *Unmanned Aerial Vehicles* (UAVs), definido pela Agência Nacional de Aviação Civil (CIVIL, 2018), órgão responsável por regular a aviação no Brasil, é uma aeronave não tripulada, pilotada a partir de uma estação de pilotagem remota, com finalidade diversas de recreação, que deve ser chamada de Aeronave Remotamente Pilotada, do inglês *Remotely Piloted Aircrafts* (RPA). No meio acadêmico, muitas vezes é denominada como *Unmanned Aerial System* (UAS), *Unmanned Aircraft System* (UAS), *Unmanned Aerial Vehicle* (UAV) ou simplesmente Drones. (FUGGETTI et al., 2015); (LI et al., 2016); (MERHEB et al., 2014);(PANITSRISIT; RUANGWISET, 2011)

Os VANTs são uma realidade no espaço aéreo brasileiro e mundial. Eles vem sendo utilizados nas mais diversas atividades e propósitos, devido à acessibilidade e ao desenvolvimento tecnológico envolvido nesses dispositivos, permitindo o acesso a lugares e automatizando tarefas, tais como: entregas, jornalismo, monitoramento, entretenimento, atividades militares, entre outras (MOHAMMED et al., 2014). A Associação para Sistemas de Veículos Não Tripulados Internacional (AUVSI) espera que 100 mil empregos sejam criados até 2025 a partir do mercado em expansão para os pequenos VANTs. Os gastos em todas as categorias de VANTs deverão totalizar US \$ 100 bilhões até 2020 (HOWARD et al., 2018).

Motores de corrente continua sem escovas, do inglês *Brushless Direct Current* - BLDC motor, são os mais utilizados em VANTs como afirma (TEFAY et al., 2011). Várias vantagens são associadas a esse tipo de motor, como projeto estrutural e de controle, bem como o tamanho compacto, fácil manutenção e baixo ruído, são ótimas características para o emprego de motores BLDCs na construção de VANTs.

A indústria vem aplicando motores BLDCs em diferentes áreas, como por exemplo nos setores de transportes, aeroespacial, equipamentos de informática, equipamentos eletromédicos, entre outros. (KUZMA et al., 2017); (MILLS, 2017); (PARK et al., 2011); (SOLOMON, 2007); (STÖCKER et al., 2017) (TEFAY et al., 2011) (ZERAOUlia et al., 2006). Podendo funcionar em condições estacionárias ou não-estacionárias, a utilização motores de BLDCs tende a aumentar substancialmente e com esse aumento, haverá também uma maior probabilidade de falhas durante a operação desses motores, podendo ocasionar prejuízos financeiros ou, até mesmo, de potenciais vítimas humanas.(RAJAGOPALAN, 2006); (SAMARA et al., 2008).

Considerando que uma falha é conceitualmente definida como um desvio não permitido ou previsto de pelo menos uma propriedade característica ou parâmetro do sistema a partir do estado aceitável/normal/padrão (GAO et al., 2015), é inevitável procurar aprimorar ou desenvolver técnicas para detectar falhas incipientes em motores BLDC, permitindo agir e/ou corrigir antes de sua avaria total em pleno funcionamento (XIAO; YIN, 2017); (YUAN et al., 2016).

Este contexto apresentado foi predominante para a observação e escolha do objeto de estudo desse trabalho. São vários os questionamento quanto à detecção de falhas em motores BLDCs utilizados em VANTs.O ponto central desse trabalho é como identificar velocidade e falhas de forma não intrusiva em motores do tipo BLDCs utilizados em VANTs?

Este trabalho apresenta a aplicação de uma técnica denominada Análise de Sinais baseada no Caos utilizando Densidade de Máximo (SAC-DM) para estimar a velocidade e detectar falhas de motores BLDC, com base no coeficiente de correlação obtido a partir da densidade de máximos do sinal atual. Essa técnica demonstrou potencial para caracterizar motores com abordagem computacional simples.

A abordagem proposta aplica ideias desenvolvidas em física nuclear, transporte quântico em nanoestruturas e sistemas biológicos (BAZEIA et al., 2017) para estudar as características de motores de corrente contínua sem escova (BLDC) usada em drones. Aplicações experimentais recentes do método incluem o estudo da dinâmica caótica em cavidades ressonantes eletromagnéticas que podem servir à criptografia, emulação de entrelaçamento quântico, etc. (DIETZ et al., 2015) e estudo do caos em sistemas biológicos (BAZEIA et al., 2017).

Essa é uma nova técnica para processamento de sinais, chamada SAC-DM (Análise de

Sinal baseada no Caos, usando Densidade do Máximo) que foi aplicada para obter o Coeficiente de Comprimento de Correlação (CLC). Foi demonstrado que com o SAC-DM também é possível identificar a velocidade na qual o motor está operando e detectar a presença de hélice desequilibrada analisando o sinal adquirido por meio do acelerômetro em motor BLDC. A partir dessas ações, foi possível analisar o sinal atual coletado diretamente do motor BLDC. Neste trabalho, propomos validar esta técnica, agora para um sinal diferente, utilizando uma abordagem não invasiva que analisa a vibração mecânica gerada pela rotação do motor.

1.1 Motivação

Nos muitos cenários em que os VANTs estão inseridos, há uma necessidade de tornar mais segura a operação desses dispositivos, podendo ser utilizados em diversas situações como filmagens, fotografias, mapeamento de imagens 3D, busca e salvamento, defesa civil e aérea, dentre outros usos não recreativos. Os veículos aéreos estão cada dia mais integrados à vida cotidiana das pessoas.

Seja para apenas um VANT ou para operação de multi-Vants, seja na detecção de falhas, o acompanhamento da missão ou no auxílio das atividades específicas em que o VANT esteja sendo utilizado é sempre necessária. Tendo em vista esses aspectos mencionados, é possível observar que o usuário de VANTs pode encontrar diversos problemas durante a execução de um voo. Seja ele diretamente por falhas no VANT, como problemas nos motores, falhas de comunicação, entre outros. Tais veículos são, em grande parte, impulsionados por motores de corrente contínua sem escovas ou BLDCs (*Brushless direct-current*), sendo assim, o diagnóstico de falhas é crucial para evitar a falha total do sistema, o que poderia ocasionar acidentes.

Levando-se em conta o aumento considerável de tais aeronaves, há de ser considerada a maior probabilidade de acidentes em tais veículos. O presente projeto tem como objetivo propor uma solução embarcada para diagnóstico de falhas em motores elétricos tipo BLDC, utilizando algoritmos de SAC-DM em conjunto com Redes Neurais Artificiais e visando um baixo acoplamento nas aeronaves e fácil adaptação e instalação, aumentando assim a segurança na utilização de tais dispositivos.

1.2 Objetivos

1.2.1 Objetivo Geral

O objetivo desse trabalho é propor uma abordagem baseada em densidade de máximos para identificação de velocidade e possíveis falhas em motores DC sem escova por meio de sinal de acelerômetro.

1.2.2 Objetivos Específicos

1. Validar a técnica do SAC-DM para detecção de velocidade em motor BLDC baseada sinais de acelerômetro;
2. Validar a técnica do SAC-DM para detecção de falhas em motor BLDC baseada sinais de acelerômetro;
3. Desenvolver um sistema embarcado para detecção de velocidade e falhas em motores BLDC usando a técnica do SAC-DM em sinais de acelerômetro.

1.3 Estrutura do Trabalho

Para uma melhor organização, este trabalho está dividido em capítulos, cada capítulo aborda um tema específico. O Capítulo 2 traz uma visão geral sobre os temas abordados descrevendo as tecnologias utilizadas, no Capítulo 3 é realizada uma análise dos trabalhos relacionados a este trabalho separando por grupos de temas, no Capítulo 4 é mostrado o método, quais tecnologias e quais equipamentos foram utilizadas para uma implementação de sistema e realização dos experimentos, no Capítulo 5 é apresentado como serão realizados os experimentos para validar técnica SAC-DM na detecção de velocidade e falha em motores BLDC de forma não intrusiva e por fim no Capítulo 6 temos a conclusão deste trabalho com uma discussão sobre as vantagens, contribuições e resultados globais alcançados e possibilidades futuras.

Capítulo 2

Fundamentação Teórica

Neste capítulo serão descritas as bases teóricas e tecnologias, bem como um arcabouço conceitual das teorias empregadas no desenvolvimento deste trabalho incluindo: Conceitos básicos sobre veículos aéreos não tripulados(VANTs), motores de corrente contínua sem escovas (BLDCs), Caos, Provando o Comportamento Caótico do Motor BLDC e Conceitos de Redes Neurais Artificiais.

2.1 VANTs

Os Veículos Aéreos não tripulados (VANTs) são definidos como uma aeronave não tripulada pilotada a partir de uma estação de pilotagem remota com finalidade diversas (CIVIL, 2018), para Klippstein et al. (2018) os VANTs são definidos como veículos aéreos genéricos capazes de trabalhar de forma autônoma sem um piloto a bordo. Autônomos ou remotamente pilotados o avanço desta tecnologia em tais aplicações foi possível por várias razões, tais como inovações em projetos estruturais e aerodinâmicos, introdução de novos materiais leves e tecnologias de fabricação, desenvolvimento de sensores e sistemas de diagnósticos.

2.1.1 Tipos de VANTs

Os VANTs vêm sendo modernizados a cada dia, surgindo novos formatos e tipos, para servir as mais diversas demandas de aplicações para atender a sociedade. Por isso, dependendo da aplicação cada VANTs pode ser mais indicado para determinada atividade. Na Figura 2.1

podemos ver os tipos de VANTs comerciais mais populares, em seguida vemos a descrição de cada um deles.




Figura 2.1: Tipos de Vants Disponíveis comercialmente.
Fonte: FLOREANO; WOOD

- a) **Modelos do tipo Asa-Fixa:** Esse tipo de VANT é mais indicado para voos com longo tempo de duração, esse dispositivo tem a capacidade de percorrer grandes áreas devido ao tamanho, por ter um número menor de motores em comparação ao quadricóptero e também provê uma visão na perspectiva de um passado, atualmente bastante utilizado para atividades na agricultura.
- b) **Modelos do tipo Quadricóptero:** Esse tipo de VANTs é o mais popular entre os VANTs, possuindo em vários tamanhos, é bastante utilizado para atividades domésticas e entretenimento, na realização de filmagens, devido ao numero de motores que consomem mais bateria, esse dispositivo possui um tempo reduzido de voo.
- c) **Modelos do tipo Enxames de VANTs:** Esse tipo de VANT é consideravelmente recente, e foi criado principalmente para realizar atividades de forma colaborativa, entre VANTs do mesmo tipo, possuindo um tamanho menor que os demais, assemelha-se a um inseto e realiza o voo batendo as asas.
- d) **Modelos do tipo Multi-modo:** Esse dispositivo é rodeado por uma jaula que pode fazê-lo rolar pelo chão e voar, é aplicado para atividades que necessitem realizar tarefas no ar e no chão.

2.2 Motores de Corrente Continua Sem Escovas (BLDCs)

De acordo com a *National Electrical Manufactures Associatoin* (NEMA), um motor de corrente continua sem escovas (BLDC) é uma máquina síncrona girante com ímãs permanentes e com a posição do rotor conhecida para possibilitar a comutação eletrônica. Uma das vantagens do motor BLDC em comparação com motores convencionais é a ausência de um comutador eletromecânico e de escovas, tornando os motores BLDCs mais eficientes, com menor ruído, menor relação entre suas dimensões e a potência que pode desenvolver (D'AVILA et al., 2011).



Figura 2.2: Motor Sem Escova de Corrente Continua (BLDC)

Também nessa linha (YILDIRIM et al., 2014) afirma que os motores BLDC (figura 2.2) têm uma série de vantagens, incluindo 1) o peso total e volume são significativamente reduzidos para uma determinada potência de saída (densidade de alta potência); 2) têm uma maior eficiência como mencionado acima; E 3) o calor é eficientemente dissipado para o ambiente.



Figura 2.3: Principais Componentes do Motor(BLDC)

Os principais componentes do motor BLDC exemplificado na figura 2.3, são o estator (parte fixa onde estão localizadas as bobinas) e o rotor (que é a parte que se movimenta durante a operação do motor, é a parte mais externa onde está localizado os ímãs permanentes). O acionamento se dá a partir de um fluxo elétrico convertido em fluxo eletromagnético a partir da corrente elétrica induzida no estator.




Figura 2.4: Esquema Elétrico de Ligação do Motor BLDC

A figura 2.4 apresenta o esquema elétrico de ligação do motor BLDC de forma simplificada. Esse sistema de propulsão elétrica converte energia elétrica em impulso mecânico e consiste em três elementos fundamentais para o acionamento do motor: uma fonte de energia elétrica de corrente contínua (DC), um controlador eletrônico de velocidade (*Electronic Speed Controller*), que faz o controle de velocidade do motor através do recebimento de sinal de modulação por largura de pulso (*Pulse Width Modulation* - PWM) e um motor BLDC que para a utilização em VANTs tem em seu eixo uma hélice acoplada.

2.3 Sistemas Caóticos

Sistemas caóticos, são sistemas que revelam um comportamento relativamente complexo através da dinâmica de um sistema não linear. Os sistemas caóticos são sistemas aparentemente aleatórios e dependem sensivelmente das condições iniciais. Além disso, eles são sensíveis a certos sinais e imune à ruídos de fundo. Por conta dessas propriedades dos sistemas caóticos, a Teoria do Caos é usada em muitas pesquisas científicas (GOKYILDIRIM et al., 2016).

Para (SILVA; YOUNG, 2000) o Caos ocorre em uma miríade de fenômeno de modelagem de sistemas dinâmicos, da astronomia à zoologia, e em diversas faixas de frequência, desde a banda de base até a óptica.

A importância de estudar comportamentos caóticos reside no fato de que o comportamento caótico é muito mais difundido, e pode até ser norma no mundo real (GHORBANI et al., 2017).

Existem algumas técnicas para a identificação do caos, em (BAZEIA et al., 2017) é apresentada uma técnica baseado no conceito de distância de Hamming (HAMMING, 2017), e na contagem da densidade de máximos (RAMOS et al., 2011) do sinal, é explorado a possibilidade de distinguir entre as evoluções temporais que partem de estados iniciais ligeiramente diferentes, guiados pela distância de Hamming, que desvenda heurísticamente o comportamento caótico. Em (MEDEIROS et al., 2018), foi aplicado essa técnica para demonstrar que o sinal de corrente de um motor BLDC é caótico, e o comprimento da correlação pode ser estimado a partir da densidade dos máximos.

Este trabalho apresenta a possibilidade de estimar o comprimento da correlação a estimar o comprimento de correlação do sinal de vibração emitido por um motor BLDC através de uma fórmula simples, que considera apenas a densidade máxima deste sinal. Ao analisar uma pequena quantidade de dados de um sinal $q(t)$, é possível caracterizar o caos neste tipo de motor. Este sinal oscila no tempo para produzir o máximo local no intervalo $[t, t + \delta t]$, para ser suficientemente pequeno δt , então temos $q'_i(t) > 0$ e $q'(t + \delta t) < 0$ onde o primeiro representa a derivada do tempo, tal que, $-q''(t)\delta t > q'(t) > 0$.

A probabilidade conjunta $P(q', q'')$ pode ser utilizada para calcular a média da Densidade de Máximos $\langle \rho_1 \rangle$ através de um caminho simples: a probabilidade de encontrar um máximo no intervalo $[t, t + \delta t]$ é proporcional à integral que abrange a região definida acima, de modo que:

$$\begin{aligned} \langle \rho_1 \rangle &\equiv \frac{1}{\delta t} \int_{-\infty}^0 dq'' \int_0^{-q''\delta t} dq' P(q', q'') \\ &= \int_{-\infty}^0 dq'' q'' P(0, q'') \end{aligned} \quad (2.1)$$

O fato de que as propriedades estatísticas do número médio de picos serem invariantes sob traduções temporais indica que q' e q'' tem valores médios de fuga. Além disso, as propriedades de $P(q', q'')$ pode ser obtido a partir do menor momento de q' e q'' , e da variância

de $P(q', q'')$ que estão diretamente relacionados para a função de auto-correlação.

$$C(\delta t) = \langle q(t + \delta t)q(t) \rangle. \quad (2.2)$$

Podemos então obter os vários momentos, em particular

$$\langle q'^2 \rangle = - \left. \frac{d^2 C(\delta t)}{d(\delta t)^2} \right|_{\delta t=0} ; \langle q''^2 \rangle = - \left. \frac{d^4 C(\delta t)}{d(\delta t)^4} \right|_{\delta t=0}. \quad (2.3)$$

O princípio da entropia máxima pode ser usado para construir a distribuição de probabilidade conjunta para $q(t)$ e seus derivados das equações anteriores. Depois de implementar os cálculos algébricos, a integração $q(t)$ leva a $P(q', q'')$ que resulta em

$$P(0, q'') = \frac{1}{2\pi} \frac{1}{\sqrt{\langle q'^2 \rangle \langle q''^2 \rangle}} \exp\left(-\frac{1}{2} \frac{q''^2}{\langle q'^2 \rangle}\right) \quad (2.4)$$

A equação 2.5 é aplicado para analisar amostras de sinal não periódicos, onde $\langle \rho_1 \rangle$ é teórico e " C " é calculado pela segunda e quarta derivadas, respectivamente, representadas como $\frac{d^2 C}{dt^2}$ e $\frac{d^4 C}{dt^4}$, da função de auto-correlação em zero, conforme definido em outros trabalhos anteriores (BAZEIA et al., 2017) e (MEDEIROS et al., 2018).

$$\langle \rho_1 \rangle = \frac{1}{2\pi} \sqrt{-\frac{\frac{d^4 C}{dt^4}(0)}{\frac{d^2 C}{dt^2}(0)}} = \frac{1}{2\pi} \sqrt{-\frac{\langle q''^2 \rangle}{\langle q'^2 \rangle}} \quad (2.5)$$

Pelo princípio da entropia máxima, para séries temporais periódicas e homogêneas, é possível escrever a função de correlação normalizada, a partir de uma função cosseno, reduzindo a equação anterior à Equação 2.6, onde τ é o comprimento de correlação e ρ é a densidade de máximos encontrada experimentalmente.

$$\langle \tau \rangle = \frac{1}{6\langle \rho \rangle} \quad (2.6)$$

O comportamento caótico presente nos sistemas estocásticos é apresentado no resultado encontrado na Equação 2.6. Usando esse método, é possível estimar as características de um sistema através da análise de uma série temporal curta e estimar o coeficiente de correlação, com base na média da densidade máxima adquirida a partir do sinal de vibração.

2.4 Coeficiente de Comprimento de Correlação (*Correlation Length Coefficient* - CLC)

Para um determinado sinal de vibração X_t , as amostras são organizadas em uma matriz M (equação 2.7) (MEDEIROS et al., 2018). As linhas de M variam de t to s , iniciando em $t_0 = 1$. As colunas variam de 1 a k e representa o número de amostras em cada fração do tempo. O Sinal X_t representa o processo estacionário, com média μ , variância σ^2 e covariância $Cov(X_t, X_s)$ dependendo apenas da variação de tempo $|t - s|$. Para este caso, a covariância está entre X_t e X_{t+k} .

$$M = \begin{vmatrix} X_{t,1} & X_{t,2} & X_{t,3} & \cdots & X_{t,k} \\ X_{t+1,1} & X_{t+1,2} & X_{t+1,3} & \cdots & X_{t+1,k} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ X_{s,1} & X_{s,2} & X_{s,3} & \cdots & X_{s,k} \end{vmatrix} \quad (2.7)$$

Para M , é calculado a Função de Auto-Correlação (*Auto-correlation Function*) - ACF, baseado em (MEDEIROS et al., 2018) e (WEI, 2006), representado na Equação 2.8.

$$\langle \rho_k \rangle = \frac{Cov(X_t, X_{t+k})}{\sqrt{Var(X_t)}\sqrt{Var(X_{t+k})}}, k = 1, 2, 3, \dots \quad (2.8)$$

Portando, a matriz de Auto Correlação é organizada em função de $\langle \rho_k \rangle$, aplicado a Matriz M . No entanto, é necessário calcular a função de Auto Correlação Parcial (*Partial Auto-correlation Function*) - PAF, para calcular o coeficiente de comprimento de correlação descrito a seguir.

Essa técnica baseia-se no fato de que sistemas caóticos se auto-correlacionam ao longo do tempo, diferentes de sistemas aleatórios, cuja ACF tende a não convergir.

Para encontrar o PAF, é necessário calcular $\hat{X}_{t+k}$ (Equação 2.9) como a melhor estimativa linear no sentido quadrado médio de X_{t+k} (WEI, 2006; MEDEIROS et al., 2018).

$$\hat{X}_{t+k} = \alpha_1 X_{t+k-1} + \alpha_2 X_{t+k-2} + \cdots + \alpha_{k-1} X_{t+1} \quad (2.9)$$

Considerando α_i como o coeficiente de regressão linear da raiz quadrada média, nós temos que a condição de correlação $Corr(X_t, X_{t+k} | X_{t+1}, \dots, X_{t+k-1})$ é geralmente referido

como o PAF para análise de séries temporais, com $(1 \leq i \leq k-1)$. Esta função pode ser expressa por P_k (Equação 2.10).

$$P_k = \begin{vmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_{k-1} \end{vmatrix} = \begin{vmatrix} 1 & \rho_1 & \cdots & \rho_{k-2} \\ \rho_1 & 1 & \cdots & \rho_{k-3} \\ \vdots & \vdots & & \vdots \\ \rho_{k-2} & \rho_{k-3} & \cdots & 1 \end{vmatrix} \begin{vmatrix} \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_{k-1} \end{vmatrix} \quad (2.10)$$

Assim, o PAF faz parte do cálculo do coeficiente de comprimento a meia altura, calculado em P_k , e chamado de Coeficiente de comprimento de Correlação (*Correlation Length Coefficient- CLC*) .

2.5 Wavelet Multiresolution Analysis (WMA)

Para Cruz et al. (2017), uma ferramenta poderosa no processamento de sinais estacionários ou dinâmicos é a Análise Multirresolução Wavelet (WMA), onde o sinal é subdividido em vários níveis de resolução. Baseada no algoritmo de Mallat (2008), no primeiro nível da WMA, o sinal original amostrado $c[k]$ é convolucionado com um filtro passa baixa, originando a aproximação A1, e por um filtro passa altas, originando o detalhe D1, conforme a Equação 2.11

$$\begin{aligned} A_1[n] &= \sum_k h[k-2n]c[k] \\ D_1[n] &= \sum_k g[k-2n]c[k] \end{aligned} \quad (2.11)$$

Neste caso, h e g são filtros da família de *Wavelets Daubechies*, passa-baixas e passa-altas, respectivamente.

A partir do nível 2, os filtros passa-altas e passa-baixas são submetidos às aproximações do subnível anterior, conforme a Equação 2.12, formando uma estrutura de decomposição em cascata conforme ilustrado por Mallat (2008) - Figura 2.5.

$$\begin{aligned} A_m[n] &= \sum_k h[k-2n]A_{m-1}[k] \\ D_m[n] &= \sum_k g[k-2n]A_{m-1}[k] \end{aligned} \quad (2.12)$$

A largura de banda de cada sinal é definida pela estrutura dos filtros utilizados na de-

composição. A aplicação desses filtros resulta em uma subamostragem do sinal pela metade, fazendo com que a largura de banda seja reduzida na mesma proporção.




Figura 2.5: Algoritmo de Mallat para calcular o DWT.

Devido ao processo de decomposição apresentado na Figura 2.5, a banda passante das aproximações e dos detalhes obedece a relação da Equação 2.13.

$$\begin{aligned} AC_L &= \left[0, \frac{f_s}{2^{L+1}} \right] \\ DC_L &= \left[\frac{f_s}{2^{L+1}}, \frac{f_s}{2^L} \right] \end{aligned} \quad (2.13)$$

A técnica de WMA foi utilizada em razão de sua abordagem simultânea no tempo e na frequência. Porém, aspectos discutidos na Seção 2.7, são apresentados e tratados como dificuldades ou problemas que podem surgir quando se trabalha com sinais de vibração, justificando a utilização da WMA em nosso trabalho, por ser uma técnica que reduz, sensivelmente, os ruídos presentes nas amostras, possibilitando a análise do sinal após a sua aplicação.

2.6 Análise de Sinal utilizando Caos baseado em Densidade de Máximos

Observando o princípio da Entropia (princípio da termodinâmica que mede a desordem das partículas de um sistema físico, e de extensões da Teoria do Caos (RAMOS et al., 2011), é proposto o procedimento para caracterização de comportamento caótico em motores BLDC.

Este método é chamado de Análise de Sinais Baseada no Caos usando Densidade de Máximo, termo em inglês *Signal Analysis using Chaos based of Density of Maxima* (SAC-DM), consiste na análise de uma quantidade genérica de amostras $q(t)$. Este propõe resolver o problema de como caracterizar com uma pequena quantidade de dados e identificar a presença de comportamento caótico em séries de informação aparentemente aleatórias em $q(t)$ (MEDEIROS et al., 2018).

A constante a ser estimada e apresentada na Seção 2.4 é chamada de coeficiente de comprimento de correlação (CLC). A técnica de contagem de pico é denominada Análise de Sinal baseada no Caos usando Densidade dos Máximos (SAC-DM).

Por esse conceito, medimos a diferença entre dois estados, que é uma maneira simples e apropriada de distinguir quantidades como vetores e matrizes, e pode ser modelada com vetores binários.

Devido às propriedades caóticas dos sistemas estocásticos, a abordagem foi reduzida (conforme seção 2.4) para obter o comprimento de correlação como uma fórmula simples que considerava apenas a densidade de máximos do sinal original. Assim, o valor do SAC-DM pode ser obtido da seguinte forma:

$$SAC_DM = \langle \tau \rangle = \frac{1}{6\langle \rho \rangle} \quad (2.14)$$

O algoritmo para cálculo do SAC-DM é demonstrado em 1, o valor do SAC-DM é calculado para cada bloco de sinais de tamanho *Sample Size*. Para cada três valores consecutivos, o algoritmo checa se o valor intermediário é maior do que o valor anterior e o seguinte. Se isso acontece, a quantidade de picos é incrementada com o valor do elemento intermediário. Ao final, as amplitudes dos picos é dividida pelo tamanho do bloco e é formado um vetor com todos os valores das densidades de máximo (SAC-DM).

A tarefa principal do algoritmo é detectar e contar os picos no conjunto de amostras coletados no período de tempo t . Pois para calcular o SAC-DM para o sinal inteiro, é necessária uma interação única no sinal, isso significa uma complexidade assintótica de $O(n)$. Assim, em comparação com FFT que a complexidade assintótica de $O(n^2)$, a complexidade computacional do SAC-DM é baixa (MEDEIROS et al., 2018). Em sua versão computacionalmente melhorada do algoritmo FFT, que foi denominada Transformada Discreta de Fourier (*Discret Fourier Transform* - DFT) ainda possui uma complexidade $O(n_{log}n)$, complexidade

Algorithm 1 SAC-DM (signal, sampleSize) (MEDEIROS et al., 2018)

```

1: function SAC-DM (signal, int sampleSize)
2: peaks = 0, i = 0, j = 0
3: n = sampleSize
4: while i < lenght(signal)-2 do
5:   a = signal[i]
6:   b = signal[i+1]
7:   c = signal[i+2]
8:   if b > a and b > c then
9:     peaks = peaks + b
10:    if i == n then
11:      rho = peaks/sampleSize
12:      if rho != 0 then
13:        sacdm[j] = rho
14:      else
15:        sacdm[j] = 0
16:      end if
17:      j = j + 1
18:      n = n + sampleSize
19:      peaks = 0
20:    end if
21:    i = i+1
22:  end if
23: end while
24: return sacdm

```

superior ao demonstrado no algoritmo 1.

2.7 Provando o Comportamento Caótico

A figura 2.6 representa graficamente os dados de vibração de um motor BLDC coletados por meio de um acelerômetro em uma bancada de teste em três velocidades distintas, a bancada será detalhada posteriormente, nesse momento o foco será concentrado nos dados dessa coleta que serão utilizados para provar o comportamento caótico do motor BLDC.




Figura 2.6: Sinal do Acelerômetro para 70%, 80% e 90% da velocidade

A figura 2.7 representa a auto-correlação para o exemplo da figura 2.6. Nesse caso, a função tende a convergir e amortecer. No entanto, o ruído presente na coleção, ou as impurezas no circuito de medição, não permitem que esse amortecimento seja o esperado.

Desta forma, a *Wavelet Discrete Transform* (WDT) foi aplicada no sinal de vibração para que os parâmetros de ganho do sinal fossem ajustados, melhorando as condições dos experimentos e aumentando a tendência da função de convergir e amortecer. Essa técnica de WDT é utilizada exclusivamente para provar que o sinal é caótico.

Observando a autocorrelação discutida na Seção 2.4, os sinais coletados nas taxas de 70%, 80% e 90% foram processados usando a Wavelet Discrete Transform (DWT) e decom-




Figura 2.7: Auto-Correlação sem filtro de Wavelet

postos em vários níveis de detalhe (D). Dentre os níveis de decomposição do sinal, o que apresentou melhor convergência e amortecimento para as velocidades em questão foi o nível de detalhamento D5.

O comportamento do sinal de autocorrelação Wavelet D5 aplicado ao sinal de vibração nas velocidades 70%, 80% e 90% é mostrado na Figura 2.8. Após a aplicação do filtro é possível observar a redução de ruído, melhorando a convergência dos sinais de autocorrelação.




Figura 2.8: Auto-Correlação com filtro de Wavelet

Na Figura 2.9 mostra o Coeficiente de Comprimento de Correlação (CLC), representado por (τ_{HH}) , que é o valor de x , quando y atinge o valor de 0,5 (meia altura) . No caso apresentado, o comprimento de correlação a meia altura obtido com uma velocidade de 90% do motor é de 6,759, conforme expresso pela Equação 2.15.

$$\tau_{HH} = X_B - X_A = 7,759 - 1 = 6.759 \quad (2.15)$$




Figura 2.9: Coeficiente de Comprimento de Correlação após Wavelet - velocidade em 90% da capacidade do motor

Assim, o CLC foi estimado utilizando a abordagem do SAC-DM. Neste caso, a densidade dos máximos foi obtida e aplicada à Equação 2.14.

A figura 2.10 apresenta parte do sinal da figura 2.6. A partir disso, é possível contar com 25.697 picos, totalizando 999.999 amostras. Calculando o valor do SAC-DM pela equação 2.14, temos:

$$SACDM = \frac{1}{6 \frac{25697}{999999}} = 6.4858 \quad (2.16)$$

O erro percentual relativo encontrado entre o CLC mostrado na Figura 2.9 e o resultado na Equação 2.16 é 6.485%. Quando o SAC-DM é calculado para o sinal inteiro, há um erro relativo de 4.0542%.

Considerando que os valores do Erro Relativo Percentual em todas as medições são menores que 7%, pode-se afirmar que o sinal de vibração analisado e discutido aqui tem um




Figura 2.10: Sinal de vibração em Zoom nos picos a 90% da velocidade

Tabela 2.1: Valores para CLC (após Wavelet) e SAC-DM (Sem Wavelet)

% ESC	CLC	SAC-DM	ERRO REL.PERC.
70	6.7215	6.4526	3.9992%
80	6.8880	6.4634	6.1636%
90	6.7599	6.4858	4.0542%

comportamento caótico e pode ser guiado por cálculos envolvendo a equação 2.14.

Este resultado oferece uma nova dimensão que surge do comportamento caótico impresso nos dados estocásticos. Este método calcula a média da densidade dos máximos das amostras. Permite-nos estimar as propriedades de um sistema mesmo quando uma série temporal única e curta está disponível e para estimar o coeficiente de comprimento de correlação (CLC).

2.8 Rede Neural Artificial

A capacidade de implementar computacionalmente versões simplificadas de neurônio biológicos deu origem a uma sub especialidade da inteligência artificial, conhecida como Redes Neurais Artificiais (RNAs), que podem ser definidas como sistemas paralelos compostos por unidades de processamento simples, dispostas em camadas e altamente interligadas, inspiradas no cérebro humano (HAYKIN; NETWORK, 2004). A origem da teoria de RNAs

remonta aos modelos matemáticos e aos modelos de engenharia de neurônios biológicos. Os neurônios biológicos podem ser divididos em três seções principais: O corpo celular (soma), os dendritos e o axônio, como mostra a figura 2.11 (BRAGA, 2000).




Figura 2.11: Neurônio Biológico

Werren McCulloch e Walter Pitts propuseram o primeiro modelo artificial de um neurônio biológico (MCCULLOCH; PITTS, 1943). O neurônio proposto por McCullonch era um dispositivo binário, sendo que sua saída poderia ser pulso ou não pulso, e suas entradas tinham ganhos arbitrários, podendo ser excitatórias ou inibitórias. A figura 2.12 mostra o neurônio artificial proposto.




Figura 2.12: Modelo de Neurônio Biológico. Adaptado de (HAYKIN; NETWORK, 2004)

O processamento efetuado por esse tipo de neurônio, para o cálculo do seu sinal de saída (Y) pode ser expresso pela equação matemática 2.19:

$$u_j = \sum_{i=1}^n w_i \cdot x_i + b_j \quad (2.17)$$

$$Y_j = f(u_j) \quad (2.18)$$

$$Y_j = f\left(\sum_{i=1}^n w_i \cdot x_i + b_j\right) \quad (2.19)$$

Onde n é o número total de sinais de entrada que chegam até o neurônio que está sendo calculado; (x_i) é um valor de entrada para esse neurônio (que pode tanto ser originário de outro neurônio ou da própria entrada da rede); e (w_i) é um peso associado a essa conexão (que pode caracterizar maior ou menor significância para a conexão). Matematicamente, o resultado da somatória das componentes do produto interno entre o vetor de entrada (x) e o vetor de pesos (w) do neurônio é mapeado através de uma função de ativação (f) , produzindo um valor de saída (Y) de (j) .

Para as funções de ativação, são três os tipos de função de ativação mais utilizados (HAYKIN; NETWORK, 2004):

- Função de Limiar ou Degrau: a saída do neurônio é igual a zero, quando seu valor for negativo e 1, quando seu valor for positivo, matematicamente demonstrado na equação 2.20;

$$\Theta(v) = \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{se } v < 0 \end{cases} \quad (2.20)$$

- Função Linear por Partes: Esse tipo de função pode ser visto como uma aproximação de um amplificador não linear, matematicamente demonstrado na equação 2.21;

$$\Theta(v) = \begin{cases} 1, & \text{se } v \geq 0,5 \\ v, & \text{se } 0,5 > v > -0,5 \\ 0, & \text{se } v \leq -0,5 \end{cases} \quad (2.21)$$

- Função Sigmóide: Esse tipo de função de ativação é mais utilizado em redes neurais artificiais. É definido como uma função extremamente crescente. Um exemplo de

função sigmóide é expresso na equação 2.22

$$\Theta(v) = \frac{1}{1 + e^{-av}} \quad (2.22)$$

onde a é o parâmetro de inclinação da função (Quanto maior o valor de a , mais inclinada se torna a curva).

A figura 2.13 exemplifica graficamente cada uma das principais função de ativação:

2.8.1 Aprendizagem

Uma das habilidades dos seres humanos que tem sido alvo de indagações e pesquisas ao longo dos séculos é a capacidade de aprender. Esta capacidade recebe o nome técnico de protopeiria. Os homens e alguns animais superiores possuem a protopeiria muito desenvolvida. Eles aprendem com a experiência, aprendizagem ouvindo o que lhes é dito e aprendem ampliando o alcance do conhecimento que já possuem, através de reordenações sucessivas.

Em (SIMON, 1983) aprendizado é definido como "o processo através do qual um sistema melhora o seu desempenho". Esta definição parte do pressuposto que o sistema esta tentando realizar uma tarefa. A melhoria no desempenho pode se dar através da aplicação de novos métodos e conhecimentos existentes, de maneira a torná-los mais rápidos e precisos.

Com uma visão mais voltada para a teoria conexionista das redes neurais. Aprendizagem é um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre (HAYKIN; NETWORK, 2004).

A forma básica de aprendizagem de uma RNA se dá através de um processo iterativo de correções e ajustes de pesos associados a suas conexões e ao bias, ou seja, a RNA aprende um pouco mais a cada iteração.

De acordo com (HAYKIN; NETWORK, 2004), as cinco principais regras básicas de aprendizagem são:

- Aprendizagem por correção de erro, fundamentada na filtragem ótima;




Figura 2.13: (a) Função Limiar, (b) Função Linear por Partes e (c) Função sigmóide com parâmetro de inclinação a variável.

- Aprendizagem baseada em memória, que trabalha com a memorização direta dos dados de treinamento;
- Aprendizagem hebbiana, baseada na teoria de Hebb, que descreve o funcionamento quantitativo da sinapse e do processo de treinamento humano no reconhecimento de padrões;
- Aprendizagem competitiva, também inspirada na neurobiologia;
- Aprendizagem de Boltzmann, baseada em ideias da mecânica estatística.

Dependendo da finalidade e aplicação a RNA, uma regra se adaptar melhor que a outra.

No que diz respeito ao treinamento de uma RNA é realizado por aplicações sequenciais dos vetores de entradas (e em alguns casos também de saída), enquanto os pesos da rede são ajustados de acordo com um procedimento de treinamento pré-determinado. Durante o treinamento os pesos da RNA gradualmente convergem para determinados valores, de maneira tal que a aplicação dos vetores de entrada produzam as saídas necessárias. Os procedimentos de treinamento das RNAs podem ser classificados em duas classes:

- Supervisionado: Necessita de um vetor de entrada e um vetor de saída, conhecido como vetor alvo. Esses dois vetores são então utilizados para o treinamento da RNA. O vetor de entrada é aplicado, a saída de rede é calculada e comparada com o correspondente vetor alvo. O erro encontrado é então realimentado através da rede e os pesos são atualizados de acordo com um algoritmo determinado a fim de minimizar este erro. Este processo de treinamento é repetido até que o erro para os vetores de treinamento alcance os valores pré-determinado;
- Não Supervisionado: Este por sua vez, não requer vetor alvo para saídas e, obviamente, não faz comparações para determinar a resposta ideal. O conjunto de treinamento modifica os pesos da rede de forma a produzir saídas que sejam consistentes. O processo de treinamento extrai as propriedades estatísticas do conjunto de treinamento e agrupa os vetores similares em classes, onde a aplicação de um vetor de uma determinada classe à entrada da rede produzirá um vetor de saída específico

2.8.2 RNA Perceptron (Camada única)

As RNAs do tipo *perceptron* de uma única camada são úteis na solução de problemas que admitem separação de classes por hiperplanos, ou seja, padrões linearmente separáveis. Rosenblatt demonstrou que sempre que um *perceptron* for treinado com padrões retirados de duas classes linearmente separáveis, será capaz de convergir para uma superfície de decisão formada por um hiperplano entre essas duas classes (ROSENBLATT, 1958).

Quando o *perceptron* é construído com um único neurônio, esse somente será capaz de classificar padrões entre duas classes apenas. Porém, com o aumento do número de neurônios, o número de classes separáveis aumentará proporcionalmente.

2.8.3 RNA Perceptron Multicamadas

Redes *perceptron* de camada única só são capazes de classificar padrões linearmente separáveis. Quando o problema a ser processado não admite uma separação linear exata como acontece na maioria dos problemas práticos, torna-se necessário o uso de um *perceptron* multicamadas.

A rede *perceptron* multicamadas é o modelo mais frequente na literatura. Esta rede é composta de neurônios e eles são divididos em camadas (Entrada, Oculto e Saída), como exemplificado na figura 2.14.




Figura 2.14: Modelo de RNA perceptron multicamadas.

O poder computacional de uma rede *perceptron* multicamadas é derivado da capacidade de manipular dados não linearmente separáveis e da capacidade de aprender com a experiência através de treinamento supervisionado. Neste modelo de aprendizagem, normalmente

os padrões de entrada são associados à saída e os algoritmos de treinamento usam essa referência para corresponder aos valores dos pesos de RNA (HAYKIN, 1994).

Neste trabalho, um modelo de RNA será usado para o processamento do sinal de aceleração, verificar a velocidade e possíveis falhas em um motor BLDC.

Capítulo 3

Trabalhos Relacionados

Diante do crescimento no uso dos VANTs há diversos trabalhos a cerca do tema, abordando diferentes dimensões sobre o uso dos VANTs e/ou determinados dispositivos que compõe o mesmo, até mesmo técnicas e abordagens para estudo de seu comportamentos. Alguns trabalhos focam em apresentar modelos matemáticos, outros buscam apresentar protótipos de soluções, e ainda trabalhos que tem sua atuação em detecção e diagnóstico de falhas em motores BLDCs.

3.1 Técnicas Baseadas em Processamento Digital de Sinais

Com o prévio conhecimento de como se comporta o sistema em situação considerada normal (saudável), ou seja, com os padrões dos sinais para comportamento padrão do sistema com suas características devidamente mapeados e catalogados é possível detectar anomalias que podem ser ou não classificadas como falhas. Com base nesses dados é possível realizar um diagnóstico, este pode ser caracterizado no domínio do tempo, no domínio da frequência ou em ambos.

Alguns métodos de análise de tempo-frequência têm sido propostos e aplicados para tentar diagnosticar falhas em máquinas. Sendo *Fast Fourier Transform* (FFT), *Short-Time Fourier Transform* (STFT), *Wavelet Transforms* (WT) e *Wigner-Ville Distribution*

Zhang et al. (2012) o autor afirma que o método STFT permite a determinação do conteúdo da frequência de um sinal em seções locais com o tempo, o que tem sido amplamente aplicada para detecção de falhas do estator e rotor em motores de indução. No entanto, o

método sofre com o alto custo computacional, se for necessário obter uma boa resolução do sinal.

Hou et al. (2015) propõe um método de detecção de falhas introduzindo uma das representações de tempo/frequência - TRF (*Time-frequency representation*), de acordo com o autor, essa técnica é mais eficiente que a Transformada de Fourier Poligonal Local - LPFT. Realizando a Análise de Assinatura de Corrente de Motor - MCSA (*Motor Current Signature Analysis*), com o LPFT para distinguir os sinais de falhas coletados dos motores BLDCs. Um dos pontos relevantes desse trabalho é que o autor indica que, ao coletar o sinal de corrente do estator, é interessante usar o Adaptive Tracking Filter (ATF) para filtrar o sinal original. O ATF pode eliminar a frequência fundamental e alguns harmônicos do inversor, e ajudar a evitar termos cruzados.

Bianchini et al. (2010) realiza a análise teórica da ligação física entre falhas e componentes do espectro de vibração, além do desenvolvimento de um modelo cinemático para prever as frequências dos rolamentos de lineares. Foram realizados vários experimentos para avaliar o modelo e verificar as frequências de falhas previamente identificadas. Algumas técnicas de processamento de sinal foram aplicadas ao sinal de vibração, dentre essas técnicas foi aplicada a *Short-Time Fourier Transform* - STFT. Mesmo as quantidades escalares não foram determinantes para identificar o rolamento com defeito. Os resultados obtidos demonstram que é muito difícil encontrar uma única quantidade de características que indique o estado do rolamento. E os resultados obtidos utilizando a técnica *Fast Fourier Transform* - FFT foram os mais relevantes.

3.2 Abordagens Baseadas no Caos

Uma introdução ao campo da dinâmica não linear e do caos, juntamente com um conjunto de aplicativos representativos que servem para ilustrar o impacto potencial do caos no processamento de sinais e transferência de informação. Silva e Young (2000) chamam a atenção para o fato de que a popularidade do caos é simultaneamente um benefício e um prejuízo para que se torne um tema reconhecidamente estabelecido no meio. Por outro lado, essa popularidade traz uma apreciação e interesse do público geral por um assunto matemático que normalmente seria ignorado.

Gokyildirim et al. (2016) destaca que muitas pesquisas tem sido realizadas para o desenvolvimento de aplicações de detecção de sinais fracos (*weak signal*) encobertos por fortes ruídos.

Bazeia et al. (2017) demonstra a presença do caos em simulações estocásticas que são amplamente utilizadas para estudar a biodiversidade na natureza. Este trabalho apresenta a possibilidade de distinguir entre evoluções de tempo que começam a partir de estados iniciais ligeiramente diferentes. A descoberta abre uma abordagem quantitativa que relaciona o comprimento de correlação com a densidade média de máximos de uma espécie típica, e um conjunto de simulações estocásticas é implementado para apoiar o procedimento. O principal resultado do trabalho demonstra como uma realização experimental única e simples que conta a densidade de máximos associados à evolução caótica da espécie serve para inferir seu comprimento de correlação.

3.3 Diagnósticos de Motores BLDCs

Com o crescente uso de redes neurais artificiais (RNAs) adaptativas para aplicação em sistemas não lineares, Samy et al. (2010) apresenta uma abordagem baseada em modelo denominado *sensor fault detection, isolation and accommodation* (SFDIA). Desenvolvida sob o conceito de redes neurais artificiais para analisar falhas em vários sensores simultaneamente. O Autor afirma que um grupo de sensores podem falhar simultaneamente ou consecutivamente. Considerando esse cenário e assumindo um atraso de 1s entre as falhas, foram introduzidas falhas nos sensores de *pitch gyro*, *angle of attack sensor*, e *normal accelerometer*. Após treinar a RNA *offline*, cada sensor é relacionado e utilizado pelo SFDIA online.

Para Turk et al. (2018), o motor BLDC, seu estator, rotor e enrolamentos são projetados usando um método de *Finite Element Analysis* - FEA. As mudanças no fluxo magnético de cada elemento no motor são monitorado, caso ocorra alguma mudança no espaço de ar entre o rotor e o estator. As correntes de fluxo magnéticos são analisadas usando modelos de motores saudáveis e defeituosos com falhas de excentricidade estática e dinâmica. Os resultados demonstram a possibilidade de detecção de falhas em estágio bastante iniciais, possibilitando uma correção precoce evitando desgastes desnecessários ou até mesmo uma parada completa do motor BLDC.

Em Merheb et al. (2014) tem como objetivo lidar com falhas severas em VANTs do tipo quadrirotor, desenvolvendo um controlador de emergência para esse tipo de dispositivo. Sempre que uma falha ocorre, o controlador aplica modificações para que os três motores restantes possam ser utilizados para controlar o VANT como um trirotor. O autor alerta para o fato de que estratégias antigas de controle ou técnicas convencionais de controle tolerante a falha não funcionam neste caso. Bem como, que o controlador desenvolvido não deve ser utilizado em condições normais de voo, mas sim apenas em emergência, fim para o qual foi desenvolvido. O controlador usa *nonlinear sliding mode observer* como ferramenta para o Diagnóstico de falhas e *Sliding mode control* como núcleo do controlador.

Para Fuggetti et al. (2015) apresenta conceitos interessantes como *failure modes and effects analysis (FMEA)* e *fault tree analysis (FTA)*. Também apresenta uma solução para VANT asa-fixa com redundância em hardware. Contudo, apenas trabalha com sensor de corrente associado a um servo motor que, diferente de um BLDC, apresenta uma conexão *ground*.

Capítulo 4

Metodologia e Materiais

Nesse capítulo apresentaremos a definição de todos os materiais utilizados na pesquisa, bem como explicar a metodologia utilizada.

4.1 Bancada de Ensaio

Para realização dos experimento, foi construído uma bancada de ensaio para instalação do motor BLDC trifásico. A bancada foi projetada para aplicação em ciclo de motor elétrico usado como um motor prático de teste. Uma configuração experimental do motor BLDC foi usada para validar o modelo de simulação, com a bancada mostrada na figura 4.1. O modelo foi desenvolvido baseado na especificação do motor que é dado na Tabela 4.2.

A bancada é formada por:

- (1) Motor de corrente contínua sem escovas (BLDC) de 1400 kv;
- (2) Acelerômetro Adafruit®XL345;
- (3) Node MCU ESP 8266 12F - Baseado em Arduíno para controle e processamento das informações
- Controlador Eletrônico de Velocidade *Eletronic Speed Controller*- (ESC) de 30 Amperes;
- (4) Electronic Speed Controller (ESC) - 30A;




Figura 4.1: Bancada de Teste para coleta de dados de vibração.

- (5) Hélice de 10.4 polegadas de vinil.
- (6) Fita isolante de PVC com 18mm (usado para desbalanceamento da hélice)

Tabela 4.1: Especificação do Motor BLDC

Descrição	Valor	Unidade
Tensão DC	12	Volt
Velocidade Nominal	930	RPM
Peso	59	Gram
Potência	270	Watt

A figura 4.2 apresenta o esquema elétrico da Bancada de Ensaio. Com as ligações do circuito de força, ligando a fonte de alimentação externa, o ESC e o Motor BLDC. E com o circuito de controle entre o Esp8266, que faz o controle do ESC e as ligação para a aquisição dos dados do acelerômetro.

A banca de testes dispões ainda de uma camada de EVA entre o suporte do motor BLDC e o corpo da bancada, esse camada se faz necessário para permitir uma certa flexibilidade, simulando as condições ao qual o motor BLDC é submetido quando instalado no corpo de um VANT, geralmente de isopor, deprom ou outro material leve.




Figura 4.2: Esquema elétrico da Bancada de Ensaio.

4.2 Acelerômetro Adafruit®ADXL345

O acelerômetro é um dispositivo usado para medir a aceleração própria de um sistema. O conceito de aceleração própria surgiu em 1915 com os trabalhos de Albert Einstein sobre a Teoria da Relatividade Geral. A aceleração própria de um sistema é medida em relação a outro sistema em queda livre, de modo que esta está atrelada à sua sensação de peso. Portanto, um acelerômetro em repouso sobre a superfície da Terra indicará uma aceleração g ($9,81 \text{ m/s}^2$) para cima, pois, em relação a um objeto em queda livre, o acelerômetro está acelerado a $9,81 \text{ m/s}^2$ para cima. Por outro lado, quando em queda livre, seja na Terra ou na Lua, um acelerômetro indicará aceleração nula, embora a aceleração de coordenadas (isto é, a aceleração em seu sentido convencional), seja bastante diferente em cada um dos casos (HEWITT, 2000).

Esses sensores são largamente aplicados na indústria e na ciência. Eles são usados para detectar e monitorar vibrações em sistemas mecânicos, tais como mancais de elementos rotativos, caixas de engrenagem e componentes estruturais em geral. No setor da saúde, são usados para caracterizar a inclinação de membros e para medir a transmissibilidade de vibra-

ções de máquinas e ferramentas para o corpo humano. Acelerômetros altamente sensíveis são usados como componentes de sistemas de navegação de aeronaves e mísseis. Em alguns aparelhos eletrônicos portáteis, como *tablets* e *smartphones*, acelerômetros são usados de maneira a manter as imagens exibidas na tela sempre na posição vertical. Eles são, ainda, utilizados em VANTs para estabilização de voo (ACELERÔMETRO, 2019).

O ADXL345, apresentado da figura 4.3, é um pequeno acelerômetro, fino e de baixa consumo, com três eixos. Acelerômetro com medição de alta resolução (13 bits) até $\pm 16g$. Dados de saída digital são formatados como pares de 16 bits complementar e é acessível através de um *Serial Peripheral Interface* (SPI) ou interface digital I2C.




Figura 4.3: Acelerômetro Adafruit®ADXL345.

O ADXL345 é adequado para aplicativos de dispositivos móveis. Ele é capaz de medir a aceleração estática da gravidade em sensor de inclinação, bem como a aceleração dinâmica resultante movimento ou choque. Sua alta resolução (4mg / LSB) permite a solução de mudanças de inclinação de apenas 0, 25°. Esse acelerômetro é um sistema completo de medição de aceleração de três eixos com uma faixa de medição selecionável ou $\pm 2g$, $\pm 4g$, $\pm 8g$ ou $\pm 16g$. Ele mede tanto a aceleração dinâmica resultante de movimento ou choque quanto a aceleração estática, como a gravidade, que permite que ela seja usada como um sensor de inclinação. O sensor é uma estrutura micro-usinada de polissilício construída em cima de uma pastilha de silício. As molas polissiliconadas suspendem a estrutura sobre a superfície da pastilha e proporcionam uma resistência contra as forças de aceleração. A deflexão da estrutura é medida usando capacitores diferenciais que consistem em placas e placas fixas independentes fixadas à massa móvel. A aceleração desvia o feixe e desequilibra o capacitor diferencial, resultando em uma saída do sensor cuja amplitude é proporcional à aceleração. A demodulação sensível à fase é usada para determinar a magnitude e a polaridade da acele-

ração.

4.3 Node MCU - ESP 8266 12F

O módulo Node MCU ESP 8266 12F é uma placa de desenvolvimento produzido pela empresa chinesa Espressif Systems®, que combina o chip ESP8266 e uma interface usb-serial e um regulador de tensão 3.3V. A programação pode ser feita usando LUA ou a IDE do Arduino, utilizando a comunicação via cabo micro-usb. A figura 4.4 mostra o módulo ESP8266 Node MCU e suas respectiva pinagem.




Figura 4.4: Node MCU ESP 8266 12F com sua pinagem.

O Node MCU possui antena embutida e conector micro-usb para conexão ao computador, além de 11 pinos de I/O e conversor analógico-digital, a tabela 4.3 mostra maiores detalhes da especificação técnica do Chip ESP8266.

Um dispositivo bastante versátil que pode ser utilizados nas mais diversos aplicações como internet das coisas, controle automatizados de lampadas e dispositivos elétricos em geral entre outros. Nesse trabalho a placa Node MCU ESP 8266 12F foi utilizada para controle do motor BLDC, aquisição dos dados do acelerômetro e processamento dos dados.

Tabela 4.2: Especificação do Chip ESP8266

Tensão DC	3,3v
Consumo de Corrente	10 μA
Memória Flash	16MB max (512k normal)
Processador	Tensilica L106 32 bit
Velocidade do processador	80-160MHz
Memória RAM	32K + 80K
GPIOs	17(multiplexada com outras funções)
Analógico para digital	1 entrada com 1024 de resolução
Suporte 802.11	b/g/n/d/e/i/k/r
Máxima conexões Concorrentes de TCP	5

4.4 MicroSD Card Adapter

Este Módulo Cartão SD permite a leitura e escrita em cartão SD, com fácil ligação ao Arduino e outros microcontroladores. Todos os pinos de ligação estão identificados no módulo, que suporta formatos de arquivo FAT16 e FAT32, e alimentação de 3.3V ou 5V.




Figura 4.5: MicroSD Card Adapter.

A comunicação é feita pela interface SPI (pinos MOSI, SCK, MISO e CS), e o nível de sinal é de 3.3V, exigindo um divisor de tensão para ligação à microcontroladores que trabalhem com 5V, como o Arduino.

4.5 Metodologia

Para validar o SAC-DM 2.6 foi realizado uma investigação experimental, afim de provar o uso desta abordagem para aferição da velocidade do motor BLDC de forma não invasiva, e posteriormente a detecção de falhas, realizando os seguintes passos:

1. Projetar e construir bancada de testes capaz de prover o uso do motor BLDC em um VANT;
2. Realizar coletas de dados simulando alterações de velocidade e passíveis falhas no motor BLDC;
3. Utilizar método para análise de sinais baseado em Caos utilizando Densidade de Máximo em sinais de vibração;
4. Implementar sistema de coleta e processamento de dados baseado no Caos, capaz de ser embarcado em um VANT;
5. Demonstrar a viabilidade do sistema em simulações de bancada.

A abordagem proposta neste trabalho é apresentada na Figura 4.6. Primeiro, o sinal de vibração é coletado por um acelerômetro conectado a uma placa ESP 8266. Então, a soma vetorial é calculada ($\vec{x} + \vec{y}$). O resultado é usado para calcular o SAC-DM da Equação 2.16. O valor do SAC-DM é submetido a uma Rede Neural Artificial (RNA) que detecta a velocidade de operação do motor BLDC.




Figura 4.6: Metodologia para processamento do sinal usando densidade de máximos

4.5.1 Calculando SAC-DM

Com a soma resultante dos vetores de aceleração ($\vec{x} + \vec{y}$), a densidade dos máximos de um grupo predefinido de amostras é calculada. Para isso a Equação 2.16 é aplicada e o SAC-

DM é obtido. O SAC-DM é calculado para cada subconjunto do sinal de vibração filtrada de acordo com a Equação 2.14, em que ρ é o número de picos dividido pelo número de amostras, ou seja, a densidade dos máximos. Após o cálculo para cada subconjunto, verifica-se o valor do SAC-DM está dentro da faixa esperada para determinada faixa de velocidade, podendo assim estimar a velocidade do motor a partir do SAC-DM.

4.5.2 Aplicando Rede Neural de Alimentação para Frente *Feedforward Neural Network* (FNN)

A rede neural *feedforward* foi o primeiro e mais simples tipo de rede neural artificial criada (SCHMIDHUBER, 2015). Nesta rede, a informação move-se em apenas uma direção, para frente dos nós de entrada, através dos nós ocultos (se houver) e para os nós de saída. Não há ciclos ou *loops* na rede. (ZELL, 1994), a figura 4.7 apresenta como foi implementada da rede neural.




Figura 4.7: Modelo de rede neural utilizada no experimento

Para avaliar a possibilidade de distinguir a velocidade de um motor BLDC com o SAC-DM como parâmetro de entrada, foi implementada uma rede neural artificial (RNA) do tipo perceptron multicamada. Dados os parâmetros de entrada (SAC-DM e Speed), o RNA deve avaliar a tupla como positiva ou negativa. Caso a velocidade seja conhecida, isso pode ser usado para detectar um mau funcionamento do sistema. Da mesma forma, se o sistema está funcionando regularmente, a saída da RNA pode ser usada para detectar a velocidade. k

Capítulo 5

Experimentos

Nesse capítulo apresentaremos como foi realizado o experimento para detecção da velocidade do motor BLDC a partir do SAC-DM e um segundo experimento para detecção de possíveis falhas de utilizando SAC-DM.

5.1 Detecção de Velocidade utilizando SAC-DM (Experimentos I).

Após a coleta dos dados, foram definidos quinze cenários experimentais para avaliação do sistema, com diferentes quantidades de amostras por grupo para o cálculo do SAC-DM:

- Grupo 1: SAC-DM calculado para cada 200 amostras;
- Grupo 2: SAC-DM calculado para cada 400 amostras
- Grupo 3: SAC-DM calculado para cada 600 amostras
- Grupo 4: SAC-DM calculado para cada 800 amostras
- Grupo 5: SAC-DM calculado para cada 1.000 amostras

Para cada grupo, três diferentes níveis de velocidade do motor BLDC (70%, 80% e 90%) foram avaliados, como mostrado na Tabela 5.3, mostrando nas colunas "Amostras / SAC" e "Velocidade", que correspondem respectivamente aos grupos e velocidade. A Figura 5.1

apresenta como um exemplo de um sinal de aceleração (sem filtros) capturado na bancada de testes à velocidades de 70%, 80% e 90%.




Figura 5.1: Sinal do Acelerômetro - Velocidades de 70%, 80% e 90%

5.1.1 Aquisição dos Dados

Do ambiente de teste foram coletadas um milhão e oitocentas mil amostras para cada velocidade (70 %, 80 % e 90 %), com uma frequência de amostragem de 520 Hertz, totalizando cinco milhões e quatrocentas mil amostras.

A tabela 5.1 apresenta a relação entre o percentual de potência aplicada e a velocidade atingida pelo motor.

Tabela 5.1: Médias das Velocidades

Unidade	70%	80%	90%
RPM	3525	3985,2	4373
Hz	58,75	66,42	72,88

5.1.2 Configurações do Acelerômetro

Usando o acelerômetro ADXL345, é possível coletar dados sob três eixos de atuação (X, Y e Z), como mencionado na seção 4.2. Considerando que o eixo Z foi direcionado para

a dimensão de profundidade da bancada, este foi ignorado para os cálculos do SAC-DM. Assim, a soma dos vetores $(\vec{x} + \vec{y})$ é usada para calcular o SAC-DM.

Outras condições importantes para o cenário do experimento são as taxas de aquisição e a sensibilidade do acelerômetro. O acelerômetro funciona na faixa entre 1 Hz e 3.2 kHz e sensibilidade de 2 G a 16 G. Para o experimento foi utilizada a taxa de aquisição de 1,6 kHz e sensibilidade de 16G.

5.1.3 Configuração e treinamento da Rede Neural *Feedforward* (FNN)

Uma Rede Neural *Feedforward* foi implementada para processar os valores SAC-DM, a fim de estimar a velocidade do motor BLDC ou para detectar possíveis falha do motor. O FNN foi configurado para receber dois parâmetros de entrada, o primeiro é o SAC-DM e o segundo é a velocidade possível, então o FNN determina se a tupla é considerada verdadeira ou falsa. A FNN é composta por dez neurônios na camada oculta, um neurônio na camada de saída e usa o algoritmo de retropropagação para treinamento e aprendizado. Para o treinamento da FNN, um conjunto de 900 valores de SAC-DM, com suas velocidades conhecidas. Em um segundo momento, para avaliar a eficácia da rede, foram processados 3.000 valores de SAC-DM seguindo os passos da tabela 5.1.3.

5.1.4 Processando os Dados

Na Tabela 5.3 são apresentados os resultados após processamento dos dados pela FNN. As colunas Amostras e Velocidade são os dados usados para calcular o SAC-DM para cada cenário. A coluna Ident(+) mostra o número de resultados positivos apontados pela FNN e a coluna Ident(-) mostra o número de resultados negativos, seguidos por duas colunas que apresentam a porcentagem de saídas positivas e negativas da FNN. Neste caso, apenas tuplas corretas (SAC-DM e Speed) foram passadas para o FNN. Em outras palavras, os resultados positivos da FNN significam que a velocidade foi estimada corretamente e a saída negativa significa erro na identificação da velocidade.

As taxas de acerto e erro são apresentadas na Figura 5.2, conforme aumenta a quantidade de amostras por SAC-DM. Então, é possível extrair duas informações importantes. A primeira que é possível estimar a velocidade de um motor BLDC, e a segunda que quanto

Tabela 5.2: Passos de treinamento da FNN Perceptron

Passo 1	Definição de conjunto de dados conhecidos, dispostos em forma de matriz. Entrar com um conjunto de saídas com a entrada
Passo 2	Iniciar de forma aleatória um conjunto de pesos, que deve ser iniciado com valores pequenos e dispostos em forma de matriz. Definir um número máximo de épocas a ser utilizado no treinamento
Passo 3	Efetuar uma multiplicação ponto a ponto entre pesos e entradas a fim de que o valor desejado seja igual a saída
Passo 4	Repetir o procedimento do passo 3 até que o número de épocas predefinido seja atingido ou o erro seja inexistente. Este procedimento gerará uma saída (u_j) da equação 2.17
Passo 5	Gerar a saída da função que será $f(u_j)$, Equação 2.18. Comparar Y_j a saída desejada
Passo 6	Caso a saída da função seja diferente da saída desejada os pesos serão recalculados. O novo valor de pesos se dará pela diferença entre a função Y_j e a saída desejada, multiplicado pela entrada proposta e pela taxa de aprendizagem. Isso será somado ao valor anterior de peso para definir qual será o peso utilizado no próximo treinamento da rede
Passo 7	A cada cálculo de pesos, será incrementado no valor de 1 ao contador de épocas
Passo 8	Verificar o limite de épocas e caso possível, reiniciar o treinamento

maior o número de amostras processadas para o cálculo do SAC-DM, maior a precisão da estimativa.




Figura 5.2: Porcentagem de erros na rede neural durante o processamento SAC-DM para medição de velocidade

No experimento onde o SAC-DM é calculado para cada 1000 amostras do vetor de aceleração, foi possível identificar uma precisão maior que 97% em todos os cenários.

Tabela 5.3: Resultados Obtidos com a Rede Neural

Amostras	Velocidade	Ident.(+)	Ident.(-)	%Positivo	%Negativo
200	70	953	47	95,3	4,7
	80	694	306	69,4	30,6
	90	833	167	83,3	16,7
400	70	980	20	98,0	2,0
	80	850	150	85,0	15,0
	90	854	146	85,4	14,6
600	70	990	10	99	3,7
	80	964	36	96,4	4,4
	90	869	130	86,9	13,1
800	70	998	2	99,8	0,2
	80	942	58	94,2	5,8
	90	978	22	97,8	2,2
1000	70	1000	0	100,0	0
	80	974	26	97,4	2,6
	90	973	27	97,3	2,7

Na Figura 5.3, os valores de SAC-DM para cada grupo de 1000 amostras são mostrados para as velocidades 70%, 80% e 90%. Nesta figura é possível monitorar a aproximação entre os valores, observando os pontos de intersecção entre eles. Essas aproximações e interseções são pontos onde a FNN tem maior dificuldade em identificar com precisão uma determinada velocidade.




Figura 5.3: Gráfico da amostra do vetor de aceleração do sinal para 70%, 80% e 90% da velocidade

A figura 5.4 mostra o histograma da distribuição dos valores SAC-DM para cada 1000 amostras. A área de intersecção entre os histogramas apresentados refere-se a casos em que a detecção de velocidade seria menos precisa, correspondendo a 0,3% entre as velocidades de 70% e 80% e de 4,1% entre 80% e 90%. Estes valores coincidem com os resultados da análise da FNN.




Figura 5.4: Histograma do SAC-DM calculado a partir do sinal do vetor de aceleração para 70%, 80% and 90% da velocidade

5.2 Detecção de falhas utilizando SAC-DM (Experimentos II).

O segundo experimento está focado na detecção de falhas de excentricidade através da técnica do SAC-DM. Foram definidos três (3) grupos com diferentes níveis de balanceamento e executando nos três níveis de velocidade testado anteriormente 70% 80% e 90% da potência do motor.

- Grupo 1: Hélice balanceada com velocidade a 70% 80% e 90% da potência ;
- Grupo 2: Hélice desbalanceada a 0,5239g com velocidade a 70% 80% e 90% da potência ;
- Grupo 3: Hélice desbalanceada a 0,8196g com velocidade a 70% 80% e 90% da potência.

O Grupo 1 compreende os dados com a hélice balanceada, no Grupo 2 foi adicionado um peso extra de 0,5239g e o Grupo 3 foi adicionado 0,8196g, esse desbalanceamento foi gerado adicionando fita adesiva em uma extremidade da hélice. O peso de 0,5239g corresponde ao 14cm de fita adesiva e o 0,8196g corresponde a 22cm de fita adesiva.

5.2.1 Aquisição dos Dados

Do ambiente de teste foram coletadas 150 mil amostras para cada velocidade (70%, 80% e 90%), com uma frequência de amostragem de 520 Hertz, totalizando um milhão trezentos e cinquenta mil amostras.

A tabela 5.4 apresenta a relação entre o percentual de potência aplicada e a velocidade atingida pelo motor considerando o desbalanceamento provocado pela fita adesiva.

O desbalanceamento do motor foi provocado posicionando uma fita adesiva a 10 cm do eixo central do motor.

5.2.2 Configurações do Acelerômetro

As configurações do acelerômetro foram as mesmas do experimento anterior.

Tabela 5.4: Resultados Obtidos com a Rede Neural

Situação da Hélice	70%	80%	90%	Unidade
Balanceada	3525	3985,2	4373	RMP
	58,75	66,42	70,78	Hz
Desb. Fita 14 cm	3528,8	4001,6	4304,2	RMP
	48,28	66,7	71,74	Hz
Desb. Fita 22 cm	3526,8	4001,6	4337	RMP
	48,3	66,7	72,3	Hz

5.2.3 Processamento dos dados

Considerando o que foi observado no experimento 5.1, após a realização da captura dos dados em bancada e realizado o cálculo do SAC-DM para cada grupo de 1000 amostras, em cada Grupo de dados previamente definido, seguiu-se a análise dos dados deste segundo experimento.

Como o objetivo deste experimento é avaliar objetivamente a possibilidade de detecção da falha de excentricidade propositalmente inserida no cenário de testes, foi realizada a plotagem lado a lado dos dados disposto em formato de histograma dos valores de SAC-DM obtidos.

Para o primeiro grupo comparativo de histogramas, são dispostos os dados do SAC-DM para as velocidades de 70%, 80% e 90% da potência do motor e com um mesmo nível de desbalanceamento da hélice.

- O item (a) da figura 5.5, apresenta o comparativo dos valores de SAC-DM para as velocidades de 70%, 80% e 90% com a hélice balanceada;
- O item (b) da figura 5.5, apresenta o comparativo dos valores de SAC-DM para as velocidades de 70%, 80% e 90% com a hélice desbalanceada em 0,5239g ;
- O item (c) da figura 5.5, apresenta o comparativo dos valores de SAC-DM para as velocidades de 70%, 80% e 90% com a hélice desbalanceada em 0,8196g.

Para o segundo grupo comparativo de histogramas, são dispostos os dados do SAC-DM para a mesma velocidade do motor e acentuando o nível de desbalanceamento da hélice.




Figura 5.5: Histogramas comparativos do SAC-DM em Função das velocidade




Figura 5.6: Histogramas comparativos do SAC-DM em Função do Desbalanceamento

- O item (a) da figura 5.6, apresenta o comparativo dos valores de SAC-DM para o cenário de hélice balanceada, com desbalanceamento de 0,5239g, e com desbalanceamento de 0,8196g com uma velocidade fixa de 80% da potência do motor;
- O item (a) da figura 5.6, apresenta o comparativo dos valores de SAC-DM para o cenário de hélice balanceada, com desbalanceamento de 0,5239g, e com desbalanceamento de 0,8196g o com uma velocidade fixa de 70% da potência do motor;
- O item (a) da figura 5.6, apresenta o comparativo dos valores de SAC-DM para o cenário de hélice balanceada, com desbalanceamento de 0,5239g, e com desbalanceamento de 0,8196g o para uma velocidade fixa de 90% da potência do motor;

Analisando visualmente cada grupo de histograma, é possível afirmar que é possível identificar falhas de excentricidade em motores BLDC utilizando a técnica de SAC-DM, também é possível avaliar como factível a modelagem de uma rede neural capaz de identificar tais falhas em motores BLDC utilizando como técnica o SAC-DM.

5.3 Construção de Sistema Embarcado para Análise de SAC-DM em Voo.

O desenvolvimento e construção de um sistema embarcado para utilização nos VANTs para análises dos dados e possíveis diagnóstico em tempo real segue como uma evolução para os testes realizados na bancada em ambiente controlado.

Com o desenvolvimento e utilização desse dispositivo será possível realizar testes em ambiente *outdoors* com diversos tipos de VANTs, possibilitando o aprimoramento dos algoritmos e da rede neural.

A figura 5.7 é apresentado o esquema elétrico e lógico do protótipo do dispositivo que é composto por um Esp 8266 12F, responsável pelo controle e processamento das informações, um acelerômetro ADXL345, para fornecer os dados de vibração e um Modulo MicroSD Adapter para armazenamento dos dados coletados do sistema. O dispositivo pesa 23 gramas, peso que possibilita que seja transportado por inúmeros tipo de VANTs, e o único meio de acoplagem entre o protótipo e o VANT se faz por meio da conexão da alimentação, em todo




Figura 5.7: Protótipo de Sistema Embarcado para Análise de Vibração

processo o dispositivo proposto é auto-suficiente para aquisição, captura e processamento dos dados.

Capítulo 6

Conclusão

Este trabalho apresenta a aplicação de uma técnica denominada Análise de Sinais baseada no Caos utilizando Densidade de Máxima (SAC-DM) para estimar a velocidade e detectar falhas em motores BLDC com base no coeficiente de correlação obtido a partir da densidade de máximos do sinal de vibração mecânica capturada por meio de acelerômetro. Essa técnica demonstrou potencial para caracterizar motores com abordagem computacional simples.

Duas contribuições foram apresentadas neste trabalho: i) demonstrar que o mesmo comportamento caótico detectado a partir do sinal atual de corrente contínua sem escova (BDLC) (MEDEIROS et al., 2018; Medeiros et al., 2018) também é apresentado em sinais capturados externamente (não invasivos) usando um acelerômetro ; ii) propor uma técnica utilizando Rede Neural Artificial para detectar a velocidade do motor a partir do coeficiente de correlação estimado usando-se a densidade dos máximos.

Após a análise dos dados foi possível calcular que a média de SAC-DM é de 0,4470 para velocidade a 70% da potência máxima, 0,4989 para 80% e 0,5565 para 90%. Embora as médias sejam diferentes, é possível ver que há uma faixa curta de valores onde o SAC-DM é o mesmo para 80% e 90%. Mesmo assim, esse resultado comprova a possibilidade de aplicar a técnica apresentada para estimar a velocidade do motor utilizando uma abordagem computacionalmente simples, contando apenas a densidade de picos no sinal bruto, sem nenhum tipo de filtragem.

Após a realização do experimento 5.1 , foi possível estimar a velocidade aplicada ao ESC a partir do SAC-DM, com um grau de precisão de cerca de 97%. A relação entre o SAC-DM e o nível de precisão do sistema também foi apresentada: quanto maior o número

de amostras para o cálculo do SAC-DM, maior a precisão que a rede neural pode medir a velocidade aplicada pelo motor BLDC.

Já no experimento 5.2, foi feita a caracterização do espectro do sinal e um motor BLDC em funcionamento normal e após o desbalanceamento da hélice foi percebida a alteração dos padrões do SAC-DM para caga perfil de velocidade previamente estudado, culminando no desenvolvimento do dispositivo capaz de ser embarcado em VANTs para estudar o comportamento do SAC-DM em voos reais.

6.1 Considerações Finais

Com SAC-DM é possível detectar a variação de velocidade e realizar a detecção de falhas em motores BLDCs e de maneira não intrusiva. Os experimentos aqui relatados já nos dão a certeza da eficácia da técnica e do que ela é capaz de diferenciar unicamente cada componente de velocidade e falhas fazendo a comparação do espectro do sinal do SAC-DM em um motor BLDC saudável e com alguma falha de excentricidade.

A técnica ainda precisa ser mais estudada e melhorada, precisamos fazer mais experimentos, que serão realizados e demonstrados em trabalhos posteriores.

Para os próximos experimentos queremos realizar simulações de falhas nos motores, coletar os dados e aplicar a técnica do SAC-DM, apresentar o experimento e também um dispositivo capaz de ser embarcado em um VANT ou outro dispositivo que faça uso de motores BLDC para que possa ser acompanhado sua vibração e realizar possíveis diagnósticos em tempo real evitando prejuízos com equipamentos ou acidentes de maior gravidade.

6.2 Atividades Futuras

Sugestão para trabalhos futuros é a realização de testes simulando diferentes tipos de defeitos no motor BLDC, observando o comportamento do SAC-DM para verificar a possibilidade de identificar especificamente o problema e não apenas detectar a existência do mesmo utilizando o SAC-DM como técnica. A expectativa é aumentar o leque de possibilidades de utilização desta técnica, dado o baixo custo computacional, para que ela possa ser utilizada em outros cenários, incluindo previsão de falhas, evitando a ocorrência de acidentes. A abaixo são elencadas as proposta para atividades:

- Realizar testes simulando falhas nos motores BLDCs em situação real de voo em VANTs.
- Aprimorar os algoritmos de processamento de análise do SAC-DM afim de obter a detecção da falha da forma mais performática e precisa possível.
- Realizar voos simulando falha para servir de parâmetros para treinamento da rede neural que ira identificar os desvios de comportamento do sinal por meio da análise do SAC-DM.
- Criar mecanismos para notificação em tempo real do piloto do VANT para que o mesmo possa tomar as medidas necessárias para evitar danos ao patrimônio e/ou potenciais vítimas humanas.

Referências Bibliográficas

ACELERÔMETRO. In: ARTIGO sobre Acelerômetro. Wikimedia, 2019. Disponível em: <<https://pt.wikipedia.org/wiki/Aceler%C3%B4metro>>. Acesso em: 05 mai. 2019.

BAZEIA, D. et al. A novel procedure for the identification of chaos in complex biological systems. *Scientific Reports*, Nature Publishing Group, v. 7, 2017.

BIANCHINI, C. et al. Fault detection of linear bearings in brushless ac linear motors by vibration analysis. *IEEE Transactions on Industrial Electronics*, IEEE, v. 58, n. 5, p. 1684–1694, 2010.

BRAGA, A. d. P. *Redes neurais artificiais: teoria e aplicações*. [S.l.]: Livros Técnicos e Científicos, 2000.

CIVIL, A. R. B. de A. Especial–rbac–e nº 94. *Requisitos Gerais para Aeronaves Não Tripuladas de Uso Civil. Resolução*, n. 419, 2018.

CRUZ, A. et al. A hybrid system based on fuzzy logic to failure diagnosis in induction motors. *IEEE Latin America Transactions*, IEEE, v. 15, n. 8, p. 1480 – 1489, 2017.

DIETZ, B.; RICHTER, A.; SAMAJDAR, R. Cross-section fluctuations in open microwave billiards and quantum graphs: The counting-of-maxima method revisited. *Physical Review E*, APS, v. 92, n. 2, p. 022904, 2015.

D’AVILA, C. et al. Estudo de um motor cc brushless aplicado no acionamento de um carro elétrico de pequeno porte. *Revista Liberato, Novo Hamburgo*, v. 12, n. 18, p. 107–206, 2011.

FLOREANO, D.; WOOD, R. J. Science, technology and the future of small autonomous drones. *Nature*, Nature Publishing Group, v. 521, n. 7553, p. 460, 2015.

FUGGETTI, G.; GHETTI, A.; ZANZI, M. Safety improvement of fixed wing mini-uav based on handy fdi current sensor and a failsafe configuration of control surface actuators. In: IEEE. *2015 IEEE Metrology for Aerospace (MetroAeroSpace)*. [S.l.], 2015. p. 356–361.

GAO, Z.; CECATI, C.; DING, S. X. A survey of fault diagnosis and fault-tolerant techniques—part i: Fault diagnosis with model-based and signal-based approaches. *IEEE Transactions on Industrial Electronics*, IEEE, v. 62, n. 6, p. 3757–3767, 2015.

GHORBANI, M. et al. Augmented chaos-multiple linear regression approach for prediction of wave parameters. *Engineering science and technology, an international journal*, Elsevier, v. 20, n. 3, p. 1180–1191, 2017.

GOKYILDIRIM, A.; UYAROGLU, Y.; PEHLIVAN, I. A novel chaotic attractor and its weak signal detection application. *Optik*, Elsevier, v. 127, n. 19, p. 7889–7895, 2016.

HAMMING, R. Error detecting and error correcting codes. *IEEE Latin America Transactions*, IEEE Latin America Transactions, v. 15, n. 8, p. 1480 – 1489, 2017.

HAYKIN, S. *Neural networks: a comprehensive foundation*. [S.l.]: Prentice Hall PTR, 1994.

HAYKIN, S.; NETWORK, N. A comprehensive foundation. *Neural networks*, v. 2, n. 2004, p. 41, 2004.

HEWITT, P. G. *Fundamentos de física conceitual*. [S.l.]: Bookman, 2000.

HOU, W.; ZHANG, Y.; SUN, J. A fault detection method for motors based on local polynomial fourier transform. In: *2015 Prognostics and System Health Management Conference (PHM)*. [S.l.: s.n.], 2015. p. 1–5.

HOWARD, J.; MURASHOV, V.; BRANCHE, C. M. Unmanned aerial vehicles in construction and worker safety. *American journal of industrial medicine*, Wiley Online Library, v. 61, n. 1, p. 3–10, 2018.

KLIPPSTEIN, H. et al. Fused deposition modeling for unmanned aerial vehicles (uavs): A review. *Advanced Engineering Materials*, Wiley Online Library, v. 20, n. 2, p. 1700552, 2018.

KUZMA, J. et al. Commercialization strategy in managing online presence in the unmanned aerial vehicle industry. *International Journal of Business Strategy*, International Academy of Business and Economics., v. 17, n. 1, p. 59–68, 2017. Disponível em: <<http://eprints.worc.ac.uk/5436/>>.

LI, K. et al. Improved efficiency electronic speed controller development for 3-phase brushless dc motor in unmanned aerial systems. In: *Int. Micro Air Vehicle Competition and Conf.* [S.l.: s.n.], 2016. p. 167–172.

MALLAT, S. *A Wavelet Tour of Signal Processing*. [S.l.]: Third Edition: The Sparse Way, Academic Press, 2008. ISBN 978-0-12-374370-1.

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

Medeiros, R. et al. A novel approach for speed and failure detection in brushless dc motors based on chaos. *IEEE Transactions on Industrial Electronics*, p. 1–1, 2018. ISSN 0278-0046.

MEDEIROS, R. L. V. et al. A novel approach for brushless dc motors characterization in drones based on chaos. *Drones*, v. 2, n. 2, 2018. ISSN 2504-446X. Disponível em: <<http://www.mdpi.com/2504-446X/2/2/14>>.

MERHEB, A.-R.; NOURA, H.; BATEMAN, F. A novel emergency controller for quadrotor uavs. In: IEEE. *2014 IEEE Conference on Control Applications (CCA)*. [S.l.], 2014. p. 747–752.

- MILLS, M. P. *Drone Disruption: The Stakes, The Players, And The Opportunities*. 2017. <https://www.forbes.com>. Access date: 20 Mar. 2017.
- MOHAMMED, F. et al. Uavs for smart cities: Opportunities and challenges. In: IEEE. *Unmanned Aircraft Systems (ICUAS), 2014 International Conference on*. [S.l.], 2014. p. 267–273.
- PANITSRISIT, P.; RUANGWISSET, A. Sensor system for fault detection identification and accommodation of elevator of uav. In: IEEE. *SICE Annual Conference 2011*. [S.l.], 2011. p. 1035–1040.
- PARK, B. G. et al. Simple fault diagnosis based on operating characteristic of brushless direct-current motor drives. *IEEE Transactions on Industrial Electronics*, v. 58, n. 5, p. 1586–1593, May 2011. ISSN 0278-0046.
- RAJAGOPALAN, S. *Detection of Rotor and Load Faults in BLDC Motors Operating Under Stationary and Non-Stationary Conditions*. Tese (Doutorado) — Georgia Institute of Technology, 2006.
- RAMOS, J. et al. Conductance peaks in open quantum dots. *Physical review letters*, APS, v. 107, n. 17, p. 176807, 2011.
- ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, American Psychological Association, v. 65, n. 6, p. 386, 1958.
- SAMARA, P. A. et al. A statistical method for the detection of sensor abrupt faults in aircraft control systems. *IEEE Transactions on Control Systems Technology*, IEEE, v. 16, n. 4, p. 789–798, 2008.
- SAMY, I. et al. Detection of multiple sensor faults using neural networks-demonstrated on an unmanned air vehicle (uav) model. IET, 2010.
- SCHMIDHUBER, J. Deep learning in neural networks: An overview. *Neural networks*, Elsevier, v. 61, p. 85–117, 2015.
- SILVA, C. P.; YOUNG, A. M. Introduction to chaos-based communications and signal processing. In: IEEE. *2000 IEEE Aerospace Conference. Proceedings (Cat. No. 00TH8484)*. [S.l.], 2000. v. 1, p. 279–299.
- SIMON, H. A. Why should machines learn? In: *Machine learning*. [S.l.]: Elsevier, 1983. p. 25–37.
- SOLOMON, O. Model reference adaptive control of a permanent magnet brushless dc motor for uav electric propulsion system. In: *IECON 2007 - 33rd Annual Conference of the IEEE Industrial Electronics Society*. [S.l.: s.n.], 2007. p. 1186–1191. ISSN 1553-572X.
- STÖCKER, C. et al. Review of the current state of uav regulations. *Remote Sensing*, Multidisciplinary Digital Publishing Institute, v. 9, n. 5, p. 459, 2017. Disponível em: <<http://www.mdpi.com/2072-4292/9/5/459/htm>>.

TEFAY, B. et al. Design of an integrated electronic speed controller for agile robotic vehicles. In: *Australasian Conference on Robotics and Automation (ACRA 2011) Proceedings*. [S.l.: s.n.], 2011.

TURK, N.; DESWAL, S. et al. Detection of air gap eccentricity faults using finite element analysis (fea) in bldc motors. *Trends in Mechanical Engineering & Technology*, v. 8, n. 2, p. 1–5, 2018.

WEI, W. W. S. *Time Series Analysis: univariate and multivariate methods*. [S.l.]: Pearson, 2006. ISBN 0321322169.

XIAO, B.; YIN, S. A new disturbance attenuation control scheme for quadrotor unmanned aerial vehicles. *IEEE Transactions on Industrial Informatics*, PP, n. 99, p. 1–1, 2017. ISSN 1551-3203.

YILDIRIM, M.; POLAT, M.; KÜRÜM, H. A survey on comparison of electric motor types and drives used for electric vehicles. In: *IEEE. 2014 16th International Power Electronics and Motion Control Conference and Exposition*. [S.l.], 2014. p. 218–223.

YUAN, Y. et al. Resilient control of networked control system under dos attacks: A unified game approach. *IEEE Transactions on Industrial Informatics*, v. 12, n. 5, p. 1786–1794, Oct 2016. ISSN 1551-3203.

ZELL, A. *Simulation neuronaler netze*. [S.l.]: Addison-Wesley Bonn, 1994. v. 1.

ZERAOULIA, M.; BENBOUZID, M. E. H.; DIALLO, D. Electric motor drive selection issues for hev propulsion systems: A comparative study. *IEEE Transactions on Vehicular technology*, IEEE, v. 55, n. 6, p. 1756–1764, 2006.

ZHANG, X.; TANG, L.; DECASTRO, J. Robust fault diagnosis of aircraft engines: A nonlinear adaptive estimation-based approach. *IEEE Transactions on Control Systems Technology*, IEEE, v. 21, n. 3, p. 861–868, 2012.

Apêndice A

Código da Bancada de Ensaio

Código utilizado na banda de ensaio para controlar o motor BLDC e capturar os dados do acelerômetro via interface serial.

```
1  #include <Wire.h>
2  #include <Adafruit_Sensor.h>
3  #include <Adafruit_ADXL345_U.h>
4  #include <Servo.h>
5
6  /* Assign a unique ID to this sensor at the same time */
7  Adafruit_ADXL345_Unified accel = Adafruit_ADXL345_Unified(12345);
8
9  /* Set BLDC Motor */
10 Servo ServoMotor;
11
12 /* Set PWM pin for BLDC Motor */
13 #define servo1Pin D3
14
15 /* Set Serial Interface */
16 #define USE_SERIAL Serial
17
18 /* Motor power value */
19 int potServor;
20
21 void displaySensorDetails(void)
22 {
23     sensor_t sensor;
24     accel.getSensor(&sensor);
25     Serial.println("-----");
26     Serial.print ("Sensor: "); Serial.println(sensor.name);
27     Serial.print ("Driver Ver: "); Serial.println(sensor.version);
28     Serial.print ("Unique ID: "); Serial.println(sensor.sensor_id);
29     Serial.print ("Max Value: "); Serial.print(sensor.max_value); Serial.println(" m/s^2");
```

```
30     Serial.print ("Min Value: "); Serial.print(sensor.min_value); Serial.println(" m/s^2");
31     Serial.print ("Resolution: "); Serial.print(sensor.resolution); Serial.println(" m/s^2")
        ;
32     Serial.println("-----");
33     Serial.println("");
34     delay(500);
35 }
36
37 void displayDataRate(void)
38 {
39     Serial.print ("Data Rate: ");
40
41     switch(accel.getDataRate())
42     {
43         case ADXL345_DATARATE_3200_HZ:
44             Serial.print ("3200 ");
45             break;
46         case ADXL345_DATARATE_1600_HZ:
47             Serial.print ("1600 ");
48             break;
49         case ADXL345_DATARATE_800_HZ:
50             Serial.print ("800 ");
51             break;
52         case ADXL345_DATARATE_400_HZ:
53             Serial.print ("400 ");
54             break;
55         case ADXL345_DATARATE_200_HZ:
56             Serial.print ("200 ");
57             break;
58         case ADXL345_DATARATE_100_HZ:
59             Serial.print ("100 ");
60             break;
61         case ADXL345_DATARATE_50_HZ:
62             Serial.print ("50 ");
63             break;
64         case ADXL345_DATARATE_25_HZ:
65             Serial.print ("25 ");
66             break;
67         case ADXL345_DATARATE_12_5_HZ:
68             Serial.print ("12.5 ");
69             break;
70         case ADXL345_DATARATE_6_25HZ:
71             Serial.print ("6.25 ");
72             break;
73         case ADXL345_DATARATE_3_13_HZ:
74             Serial.print ("3.13 ");
75             break;
```

```
76     case ADXL345_DATARATE_1_56_HZ:
77         Serial.print ("1.56 ");
78         break;
79     case ADXL345_DATARATE_0_78_HZ:
80         Serial.print ("0.78 ");
81         break;
82     case ADXL345_DATARATE_0_39_HZ:
83         Serial.print ("0.39 ");
84         break;
85     case ADXL345_DATARATE_0_20_HZ:
86         Serial.print ("0.20 ");
87         break;
88     case ADXL345_DATARATE_0_10_HZ:
89         Serial.print ("0.10 ");
90         break;
91     default:
92         Serial.print ("???? ");
93         break;
94 }
95     Serial.println(" Hz");
96 }
97
98 void displayRange(void)
99 {
100     Serial.print ("Range: +/- ");
101
102     switch(accel.getRange())
103     {
104         case ADXL345_RANGE_16_G:
105             Serial.print ("16 ");
106             break;
107         case ADXL345_RANGE_8_G:
108             Serial.print ("8 ");
109             break;
110         case ADXL345_RANGE_4_G:
111             Serial.print ("4 ");
112             break;
113         case ADXL345_RANGE_2_G:
114             Serial.print ("2 ");
115             break;
116         default:
117             Serial.print ("?? ");
118             break;
119     }
120     Serial.println(" g");
121 }
122
```

```
123 void setup(void)
124 {
125
126   Serial.begin(460800);
127   Serial.println("Accelerometer Test"); Serial.println("");
128
129   /* Initialise the sensor */
130   if(!accel.begin())
131   {
132     /* There was a problem detecting the ADXL345 ... check your connections */
133     Serial.println("Ooops, no ADXL345 detected ... Check your wiring!");
134     while(1);
135   }
136
137   /* Set the range to whatever is appropriate for your project */
138   accel.setRange(ADXL345_RANGE_8_G);
139   // displaySetRange(ADXL345_RANGE_16_G);
140   // displaySetRange(ADXL345_RANGE_8_G);
141   // displaySetRange(ADXL345_RANGE_4_G);
142   // displaySetRange(ADXL345_RANGE_2_G);
143
144   accel.setDataRate(ADXL345_DATARATE_3200_HZ);
145
146   /* Display some basic information on this sensor */
147   displaySensorDetails();
148
149   /* Display additional settings (outside the scope of sensor_t) */
150   displayDataRate();
151   displayRange();
152   Serial.println("");
153
154   // Servo
155   ServoMotor.attach(servo1Pin);
156
157   Serial.println("Waiting to command turn the engine on!");
158
159   while (USE_SERIAL.available() <= 0) {
160     delay(1000);
161     ServoMotor.write(0);
162     Serial.println("Aguardando potencia:");
163   }
164
165   potServor = USE_SERIAL.parseInt();
166
167   USE_SERIAL.println("Turning engine on ...");
168   ServoMotor.write(0); delay(10000);
169   ServoMotor.write(20); delay(2000);
```

```
170   ServoMotor.write(0);   delay(5000);
171   ServoMotor.write(potServor);
172
173 }
174
175 void loop(void)
176 {
177   /* Get a new sensor event */
178   sensors_event_t event;
179   char cMsg[254];
180   accel.getEvent(&event);
181
182   sprintf(cMsg,"%0.2f  , %0.2f, %0.2f, %d, %d", event.acceleration.x, event.acceleration.y,
           event.acceleration.z, potServor, millis() );
183   Serial.println(cMsg);
184
185   if(USE_SERIAL.available() > 0) {
186     potServor = USE_SERIAL.parseInt();
187     ServoMotor.write(potServor);
188   }
189 }
```

Apêndice B

Código do Sistema Embarcado para captura do Sinal em Tempo Real

Código utilizado dispositivo a ser embarcado no VANT capaz de capturar e armazenar os dados de vibração e calcular e armazenar os valores do SAC-DM *on board*.

```
1  #include <Wire.h>
2  #include <Adafruit_Sensor.h>
3  #include <Adafruit_ADXL345_U.h>
4  #include <SD.h>
5
6  /* Assign a unique ID to this sensor at the same time */
7  Adafruit_ADXL345_Unified accel = Adafruit_ADXL345_Unified(12345);
8
9  #define USE_SERIAL Serial
10
11 /* SD pin read/write */
12 #define CS_PIN D8
13
14 int sampleSize = 1000;
15
16 void displaySensorDetails(void)
17 {
18     sensor_t sensor;
19     accel.getSensor(&sensor);
20     Serial.println("_____");
21     Serial.print (" Sensor: "); Serial.println(sensor.name);
22     Serial.print (" Driver Ver: "); Serial.println(sensor.version);
23     Serial.print (" Unique ID: "); Serial.println(sensor.sensor_id);
24     Serial.print (" Max Value: "); Serial.print(sensor.max_value); Serial.println(" m/s^2");
25     Serial.print (" Min Value: "); Serial.print(sensor.min_value); Serial.println(" m/s^2");
```

```
26     Serial.print ("Resolution: "); Serial.print(sensor.resolution); Serial.println(" m/s^2")
27     ;
28     Serial.println("-----");
29     Serial.println("");
30     delay(500);
31 }
32 void displayDataRate(void)
33 {
34     Serial.print ("Data Rate: ");
35
36     switch(accel.getDataRate())
37     {
38         case ADXL345_DATARATE_3200_HZ:
39             Serial.print ("3200 ");
40             break;
41         case ADXL345_DATARATE_1600_HZ:
42             Serial.print ("1600 ");
43             break;
44         case ADXL345_DATARATE_800_HZ:
45             Serial.print ("800 ");
46             break;
47         case ADXL345_DATARATE_400_HZ:
48             Serial.print ("400 ");
49             break;
50         case ADXL345_DATARATE_200_HZ:
51             Serial.print ("200 ");
52             break;
53         case ADXL345_DATARATE_100_HZ:
54             Serial.print ("100 ");
55             break;
56         case ADXL345_DATARATE_50_HZ:
57             Serial.print ("50 ");
58             break;
59         case ADXL345_DATARATE_25_HZ:
60             Serial.print ("25 ");
61             break;
62         case ADXL345_DATARATE_12_5_HZ:
63             Serial.print ("12.5 ");
64             break;
65         case ADXL345_DATARATE_6_25HZ:
66             Serial.print ("6.25 ");
67             break;
68         case ADXL345_DATARATE_3_13_HZ:
69             Serial.print ("3.13 ");
70             break;
71         case ADXL345_DATARATE_1_56_HZ:
```

```
72     Serial.print ("1.56 ");
73     break;
74     case ADXL345_DATARATE_0_78_HZ:
75     Serial.print ("0.78 ");
76     break;
77     case ADXL345_DATARATE_0_39_HZ:
78     Serial.print ("0.39 ");
79     break;
80     case ADXL345_DATARATE_0_20_HZ:
81     Serial.print ("0.20 ");
82     break;
83     case ADXL345_DATARATE_0_10_HZ:
84     Serial.print ("0.10 ");
85     break;
86     default:
87     Serial.print ("???? ");
88     break;
89 }
90 Serial.println(" Hz");
91 }
92
93 void displayRange(void)
94 {
95     Serial.print ("Range: +/- ");
96
97     switch(accel.getRange())
98     {
99     case ADXL345_RANGE_16_G:
100     Serial.print ("16 ");
101     break;
102     case ADXL345_RANGE_8_G:
103     Serial.print ("8 ");
104     break;
105     case ADXL345_RANGE_4_G:
106     Serial.print ("4 ");
107     break;
108     case ADXL345_RANGE_2_G:
109     Serial.print ("2 ");
110     break;
111     default:
112     Serial.print ("?? ");
113     break;
114 }
115     Serial.println(" g");
116 }
117
118
```

```

119 void setup(void)
120 {
121
122     Serial.begin(460800);
123     Serial.println("Accelerometer Test"); Serial.println("");
124
125     /* Initialise the sensor */
126     if(!accel.begin())
127     {
128         /* There was a problem detecting the ADXL345 ... check your connections */
129         Serial.println("Ooops, no ADXL345 detected ... Check your wiring!");
130         while(1);
131     }
132
133     /* Set the range to whatever is appropriate for your project */
134     accel.setRange(ADXL345_RANGE_8_G);
135     // displaySetRange(ADXL345_RANGE_16_G);
136     // displaySetRange(ADXL345_RANGE_8_G);
137     // displaySetRange(ADXL345_RANGE_4_G);
138     // displaySetRange(ADXL345_RANGE_2_G);
139
140
141     accel.setDataRate(ADXL345_DATARATE_3200_HZ);
142
143     /* Display some basic information on this sensor */
144     displaySensorDetails();
145
146     /* Display additional settings (outside the scope of sensor_t) */
147     displayDataRate();
148     displayRange();
149     Serial.println("");
150
151     // verify if SD starter
152     if (!SD.begin(CS_PIN)) {
153         Serial.println("SD failure.");
154         //close program
155         return;
156     }
157
158     Serial.println(" Starter SD.");
159
160
161 }
162
163 int peaks = 0;
164 int posiSample = 0;
165 float signal_ [3]= {0,0,0} ;

```

```

166 float rho = 0;
167
168 void loop(void)
169 {
170     /* Get a new sensor event */
171     sensors_event_t event;
172     char cMsg[254];
173     float SAC_DM = 0;
174
175     File dataFile = SD.open("LOG.txt", FILE_WRITE);
176     accel.getEvent(&event);
177
178
179     if (dataFile) {
180         if (posiSample == 0) {
181             dataFile.println("=====");
182         }
183         Serial.println(" File is opened.");
184         sprintf(cMsg,"%0.2f , %0.2f, %0.2f, %d", event.acceleration.x, event.acceleration.y,
            event.acceleration.z, millis() );
185         Serial.println(cMsg);
186         dataFile.println(cMsg);
187         dataFile.close();
188     }
189     else {
190         Serial.println(" Failure to open LOG.txt");
191     }
192     posiSample ++;
193
194     // SAC-DM Calculate
195     signal_ [0] = signal_ [1];
196     signal_ [1] = signal_ [2];
197     signal_ [2] = event.acceleration.x + event.acceleration.y;
198
199     if (posiSample > 2){
200         if (signal_ [0] > signal_ [1] && signal_ [1] > signal_ [2]){
201             peaks = peaks + 1;
202             if (posiSample == sampleSize){
203                 rho = peaks / sampleSize;
204                 if (rho != 0){
205                     SAC_DM = 1/(6*rho);
206                 }
207                 else {
208                     SAC_DM = 0;
209                 }
210                 peaks = 0;
211                 posiSample = 1;

```

```
212     File dataFile = SD.open("SAC_DM.txt", FILE_WRITE);
213     if (dataFile) {
214         Serial.println("File is Openet.");
215         Serial.println(SAC_DM);
216         dataFile.println(SAC_DM);
217         dataFile.close();
218     }
219     else {
220         Serial.println("Failure to open SAC_DM.txt");
221     }
222 }
223 }
224 }
225 }
```
