
Detecção de falha em motores BLDC por meio
de sinais de áudio usando Rede Neural
Convolucional e SAC-DM

Yuri da Costa Gouveia



UNIVERSIDADE FEDERAL DA PARAÍBA
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA

João Pessoa
2022

Yuri da Costa Gouveia

**Detecção de falha em motores BLDC por meio
de sinais de áudio usando Rede Neural
Convolucional e SAC-DM**

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

Área de concentração: Sinais, Sistemas Digitais e Gráficos

Orientador: Alisson Vasconcelos de Brito

João Pessoa

2022

Catálogo na publicação
Seção de Catalogação e Classificação

G719d Gouveia, Yuri da Costa.

Detecção de falha em motores BLDC por meio de sinais de áudio usando Rede Neural Convolutiva e SAC-DM / Yuri da Costa Gouveia. - João Pessoa, 2022.

59 f. : il.

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

1. Sistema especialistas e diagnóstico. 2. VANTs. 3. Motores BLDC. 4. Espectrograma. 5. Rede Neural Convolutiva. I. Brito, Alisson Vasconcelos de. II. Título.

UFPB/BC

CDU 004.891.3(043)



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



Ata da Sessão Pública de Defesa de Dissertação de Mestrado de Yuri da Costa Gouveia, candidato ao título de Mestre em Informática na Área de Sistemas de Computação, realizada em 07 de julho de 2023.

Ao sétimo dia do mês de julho do ano de dois mil e vinte e três, às nove horas, no Centro de Informática da Universidade Federal da Paraíba, reuniram-se os membros da Banca Examinadora constituída para julgar o trabalho do sr. Yuri da Costa Gouveia, vinculado a esta Universidade sob a matrícula nº 20211000543, candidato ao grau de Mestre em Informática, na área de “Sistemas de Computação”, na linha de pesquisa “Sinais, Sistemas Digitais e Gráficos”, do Programa de Pós-Graduação em Informática, da Universidade Federal da Paraíba. A comissão examinadora foi composta pelos professores: Alisson Vasconcelos de Brito, Orientador e Presidente da banca; Tiago Pereira do Nascimento (PPGI), Examinador Interno, Abel Cavalcante Lima Filho (UFPB), Examinador Externo ao Programa, e Jorge Gabriel Gomes de Souza Ramos (UFPB), Examinador Externo ao Programa. Dando início aos trabalhos, a Presidente da Banca cumprimentou os presentes, comunicou aos mesmos a finalidade da reunião e passou a palavra ao candidato para que o mesmo fizesse a exposição oral do trabalho de dissertação intitulado: “Detecção de Falha em Motores BLDC por Meio de Sinais de Áudio Usando Rede Neural Convolutacional e SAC-DM”. Concluída a exposição, o candidato foi arguido pela Banca Examinadora que emitiu o seguinte parecer: “**aprovado**”. Do ocorrido, eu, Fernando Menezes Matos, Coordenador do Programa de Pós-Graduação em Informática, lavrei a presente ata que vai assinada por mim e pelos membros da banca examinadora. João Pessoa, 07 de julho de 2023.

Documento assinado digitalmente



FERNANDO MENEZES MATOS
Data: 05/10/2023 13:48:30-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Fernando Menezes Matos

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

Documento assinado digitalmente



TIAGO PEREIRA DO NASCIMENTO
Data: 22/09/2023 20:36:13-0300
Verifique em <https://validar.iti.gov.br>

Prof. Tiago Pereira do Nascimento
Examinador Interno (PPGI-UFPB)

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

Documento assinado digitalmente



ABEL CAVALCANTE LIMA FILHO
Data: 19/09/2023 09:58:34-0300
Verifique em <https://validar.iti.gov.br>

Prof. Jorge Gabriel Gomes de Souza Ramos
Examinador Externo ao Programa (UFPB)

Resumo

Veículos aéreos não tripulados (VANTs), comumente chamados por drones, vêm sendo utilizados cada vez mais para auxílio de tarefas humanas, com propósitos variados. Com o aumento no uso desse tipo de veículo, torna-se cada vez mais comum o acontecimento de falhas, o que pode causar danos a vida humana, danos materiais e também ambientais. Com isso, é proposto uma metodologia que tem como objetivo identificar falhas de balanceamento em hélices de motores BLDC, usados em VANTs. Neste trabalho é utilizado um método não invasivo, que adquire o sinal de áudio emitido pelo motor em rotação, realiza um pré-processamento, etapa a qual aplica-se o algoritmo SAC-DM (*Signal Analysis Based on Chaos Using Density of Maxima*), e em seguida obtém-se o espectrograma dos sinais pré-processados para aplicar em uma rede neural convolucional. Para validar a metodologia, foi realizado um experimento para realizar a comparação dos resultados obtidos, o qual não possui a etapa de aplicação do algoritmo SAC-DM. Também para validar, compara-se o resultado obtido com os resultados de trabalhos relacionados, afim de concluir o benefício do uso do SAC-DM. Com os experimentos executados, obtém-se os resultados de 71,43% de acurácia na classificação de sinais de áudio de um motor com hélice desbalanceada, para o experimento que utiliza o SAC-DM. Já para o experimento que não usa o SAC-DM, encontra-se uma acurácia de 98,21% de acertividade na classificação desses mesmos sinais.

Palavras-chave: VANTs, motores BLDC, espectrograma, Rede Neural Convolucional, SAC-DM.

Abstract

Unmanned aerial vehicles (UAVs), commonly called drones, have been increasingly used to aid human tasks, with many purposes. With the increase of its usage, failures become increasingly common, which can cause damage to human life, material damage, and environmental damage. With this knowledge, a methodology is proposed to identify balance failures in the propellers of BLDC motors used in UAVs. In this work, a non-invasive method is used, which acquires the audio signal emitted by the rotating motor, performs a pre-processing step in which the SAC-DM algorithm (*Signal Analysis Based on Chaos Using Density of Maxima*) is applied, and then the spectrogram of the pre-processed signals is obtained to apply in a convolutional neural network. To validate the methodology, an experiment was carried out to compare the results obtained, which does not have the step of applying the SAC-DM algorithm. Also, to validate, the result obtained is compared with the results of related works to conclude the benefit of using the SAC-DM. With the experiments carried out, the results of 71.43% accuracy in the classification of audio signals from a motor with an unbalanced propeller are obtained for the SAC-DM experiment. As for the experiment that does not use the SAC-DM, there is an accuracy of 98.21% of accuracy in the classification of these same signals.

Keywords: UAVs, BLDC motors, spectrogram, Convolutional Neural Network, SAC-DM.

Lista de ilustrações

Figura 1 – Crescimento da receita do mercado de VANTS, em bilhões de dólares. Fonte: MundoGEO (2021)	15
Figura 2 – Modelo de circuito elétrico de um motor BLDC de um VANT quadrotor. Fonte: Morbidi et al. (2016).	21
Figura 3 – Motor BLDC do tipo rotor externo. Fonte: Mohanraj et al. (2022). . .	21
Figura 4 – Tipos de motores BLDC e algoritmos de controle. Fonte: Mohanraj et al. (2022).	22
Figura 5 – Representação gráfica de sinal de tempo contínuo. Fonte: OPPENHEIM, A. et al. Sinais e Sistemas. 2. ed. São Paulo: Pearson, 2010. p. 2.	23
Figura 6 – Representação gráfica de sinal de tempo discreto. Fonte: OPPENHEIM, A. et al. Sinais e Sistemas. 2. ed. São Paulo: Pearson, 2010. p. 2. . . .	23
Figura 7 – Representação gráfica de sinal aperiódico $x(t)$ (a esquerda) e da sua representação como sinal periódico $\tilde{x}(t)$ (a direita). Fonte: OPPENHEIM, A. et al. Sinais e Sistemas. 2. ed. São Paulo: Pearson, 2010. p. 167.	24
Figura 8 – Representação do cálculo da STFT de um sinal com demonstração de duas funções em janela (retangular e Hanning). Fonte: Johnson, D. Fundamentals of Electrical Engineering I. University Press of Florida, 2008. p. 193.	25
Figura 9 – Comparativo de um sinal com o resultado de sua multiplicação por uma função Hanning em janela e sem sobreposição. Fonte: Johnson, D. Fundamentals of Electrical Engineering I. University Press of Florida, 2008. p. 194.	26
Figura 10 – Representação do cálculo das FFTs dos segmentos de um sinal multiplicado por um função Hanning em janela com sobreposição. Fonte: Johnson, D. Fundamentals of Electrical Engineering I. University Press of Florida, 2008. p. 195.	26

Figura 11 – Passo 1: Sinal de áudio $x(t)$ para gerar espectrograma, com um tempo $t_o \approx 6.24 * 10^{-2}s$. O eixo x apresenta o tempo, em segundos, e o eixo y apresenta a amplitude. Fonte: O autor.	27
Figura 12 – Passo 2: Sinal $x(t)$ segmentado em um total de 8 janelas, e cada uma delas com um tempo $t_s \approx 0.78 * 10^{-2}s$. O eixo x apresenta o número de amostras do sinais segmentados e o eixo y apresenta a amplitude. Fonte: O autor.	28
Figura 13 – Passo 3: Para exemplificar, utilizou-se a função Hanning. O eixo x apresenta o número de amostras, apresentando mesmo tempo que os sinais segmentados, e o eixo y apresenta a amplitude. Fonte: O autor.	28
Figura 14 – Passo 4: Resultado das convoluções entre os segmentos de $x(t)$ com o sinal $w(t)$. O eixo x apresenta o número de amostras após convolução e o eixo y apresenta a amplitude. Fonte: O autor.	29
Figura 15 – Passo 5: FFT dos resultados das convoluções. O eixo x apresenta as frequências após a FFT e o eixo y apresenta a magnitude das frequências. Fonte: O autor.	29
Figura 16 – Passo 6: Espectrograma resultante, com frequência no eixo y e o tempo no eixo x . Fonte: O autor.	30
Figura 17 – Representação da composição de camadas de uma rede neural convolucional. Fonte: O autor.	34
Figura 18 – Representação da convolução realizada na camada convolucional em uma CNN. Fonte: Goodfellow, Bengio e Courville. Deep Learning. MIT Press, 2016. p. 330.	35
Figura 19 – Representação das operações de uma camada convolucional. Fonte: O autor.	36
Figura 20 – Representação do <i>Max-Pooling</i> em uma CNN. Fonte: ALBAWI, S.; MOHAMMED, T. A.; AL-ZAWI, S. Understanding of a convolutional neural network. 2017 International Conference on Engineering and Technology (ICET), 2017.	36
Figura 21 – Circuito embarcado com componentes para geração dos sinais de áudio. Fonte: Veras et al. (2019)	39
Figura 22 – Fluxograma seguido. Fonte: O autor.	40
Figura 23 – Espectrograma gerado por meio do STFT. Fonte: O autor.	42
Figura 24 – Gráfico de uma função de janela <i>Hann</i> . Fonte: O autor.	43
Figura 25 – Arquitetura para o experimento da seção 4.2.1, que envolve os algoritmos SAC-DM e CNN. Fonte: O autor.	45
Figura 26 – Arquitetura para o experimento da seção 4.2.2, que envolve o algoritmo CNN. Fonte: O autor.	45
Figura 27 – Sinais de áudio segmentados e aplicados ao SAC-DM. Fonte: O autor.	48

Figura 28 – Espectrogramas gerados a partir dos áudios pré-processados. Fonte: O autor.	49
Figura 29 – Gráficos da acurária e perda para os <i>datasets</i> de treino e validação. Fonte: O autor.	49
Figura 30 – Matriz de confusão dos resultados do <i>dataset</i> de teste. Fonte: O autor.	50
Figura 31 – Sinais de áudio segmentados. Fonte: O autor.	51
Figura 32 – Espectrogramas gerados a partir dos áudios pré-processado. Fonte: O autor.	52
Figura 33 – Gráficos da acurária e perda para os <i>datasets</i> de treino e validação. Fonte: O autor.	52
Figura 34 – Matriz de confusão dos resultados do <i>dataset</i> de teste. Fonte: O autor.	53

Lista de tabelas

Tabela 1 – Trabalhos que envolvem detecção de falha em motores BLDC	19
Tabela 2 – Circuito embarcado para geração dos sinais de áudio	39
Tabela 3 – Classes resultantes da CNN	43
Tabela 4 – Áudios usados e características	47
Tabela 5 – Resultados dos experimentos	53
Tabela 6 – Trabalhos que envolvem detecção de falha em motores BLDC	54

Lista de algoritmos

1	SAC-DM	42
---	------------------	----

Lista de siglas

ADS *Air Data System*

BLDC *Brushless Direct Current*

CNN *Convolutional Neural Network*

ESC *Electronic Speed Controller*

GPS *Global Positioning System*

IMU *Inertial Measurement Unit*

LiPo *Lithium Polymer*

LSTM *Long Short-Term Memory*

RPAS *Remotely Piloted Aircrafts Systems*

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

STFT *Short-Time Fourier Transform*

UAV *Unmanned Aerial Vehicle*

VANT Veículo Aéreo Não Tripulado

Sumário

1	INTRODUÇÃO	15
1.1	Objetivos	17
1.1.1	Objetivo Geral	17
1.1.2	Objetivos Específicos	17
1.1.3	Outros Objetivos	17
1.2	Trabalhos Relacionados	18
1.3	Estrutura do Trabalho	19
2	REFERENCIAL TEÓRICO	20
2.1	Motores BLDC	20
2.2	Processamento de Sinais	22
2.2.1	Classificação de Sinais	22
2.3	Espectrograma	23
2.3.1	Transformada de Fourier	24
2.3.2	Geração do Espectrograma a partir do sinal	25
2.4	Comportamento Caótico	30
2.4.1	<i>Signal Analysis based on Chaos using Density of Maxima (SAC-DM)</i>	30
2.5	Redes Neurais Convolucionais	32
2.5.1	Camada Convolucional	34
2.5.2	Camada <i>Pooling</i>	36
2.5.3	Camada Totalmente Conectada	37

3	METODOLOGIA	38
3.1	Aquisição dos Dados	38
3.2	Fluxograma	39
3.3	Pré-Processamento	40
3.3.1	Segmentação	40
3.3.2	SAC-DM	41
3.4	Geração do Espectrograma	42
3.5	Rede Neural Convolutiva	43
3.5.1	Características dos Dados	44
3.5.2	Arquitetura da CNN	44
4	RESULTADOS	46
4.1	Dados utilizados	46
4.2	Divisão dos Experimentos	47
4.2.1	Aplicação do algoritmo de aprendizado de máquina sobre o sinal gerado pelo SAC-DM	47
4.2.1.1	Resultados da CNN sobre os espectrogramas dos sinais gerados pelo SAC-DM	49
4.2.2	Aplicação do algoritmo de aprendizado de máquina sobre o sinal de áudio	50
4.2.2.1	Resultados da aplicação da rede neural sobre os espectrogramas dos sinais de áudio	52
4.3	Comparação do Resultados	53
5	CONSIDERAÇÕES FINAIS	55
5.1	Conclusões	55
5.2	Trabalhos Futuros	56
	REFERÊNCIAS	58

Introdução

Veículos aéreos não tripulados (VANTs), popularmente conhecidos como drones, são aeronaves capazes de realizar vôos sem a presença de seres humanos dentro desse veículo. Na maioria das vezes, os VANTs são pilotados através de um controlador de radiofrequência, porém, existem aplicações onde esse veículo é automatizado para realizar suas missões sem interferência humana.

Os VANTs vêm sendo cada vez mais utilizados como ferramentas para auxiliar em atividades diárias. De acordo com uma matéria do MundoGEO (2021), a taxa anual de crescimento do mercado de drones será de 13,8% entre 2020 e 2025, partindo de uma receita de US\$ 22 bilhões e chegando a US\$ 43 bilhões. A Figura 1 mostra o crescimento da receita desse mercado desde o ano 2019 até o ano de 2025, e pode-se notar que os investimentos chegaram a dobrar nesse período.

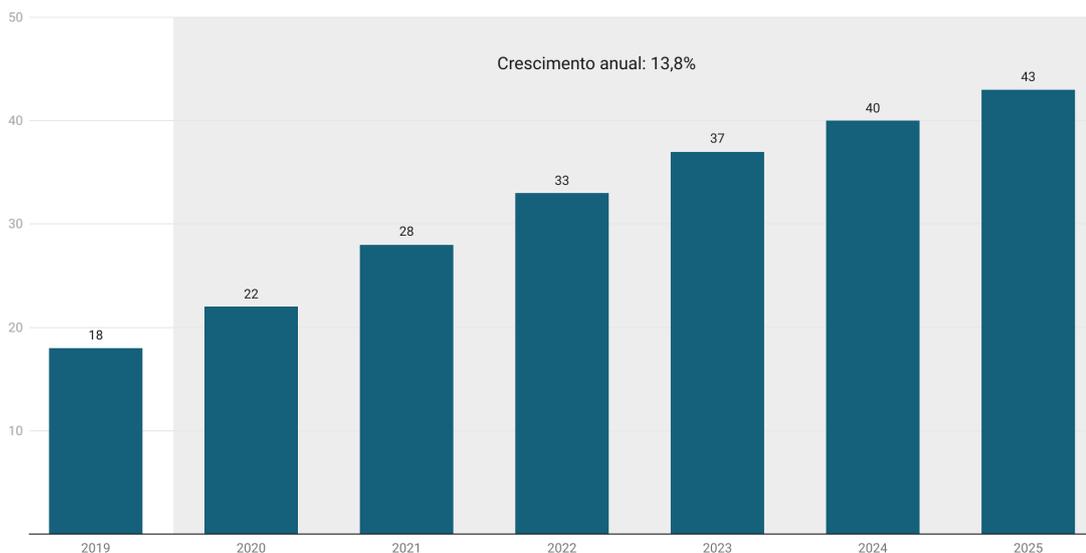


Figura 1 – Crescimento da receita do mercado de VANTS, em bilhões de dólares. Fonte: MundoGEO (2021)

O uso dessas aeronaves vêm se tornando cada vez mais extensivo, e varia desde

utilização na agricultura, busca e resgate, construção civil, entrega de mercadorias, recreativo, entre outros.

No ramo da agricultura os VANTs podem ser usados em aplicações distintas, desde monitoramento das plantações, até como ferramenta para espalhar pesticidas. Calou et al. (2020) propõe uma metodologia para detecção de um fungo em plantações de bananas. Ele realiza a coleta de imagens da plantação através de um VANT e aplica uma rede neural que classifica as imagens coletadas. Louargant et al. (2017) apresenta uma metodologia que faz a detecção de plantações de *cannabis sativa*. Em seu trabalho, utiliza-se um VANT para adquirir imagens de uma determinada área e aplica-se um algoritmo de classificação não-supervisionado para classificar as imagens obtidas e detectar as plantações.

Relativo ao tema busca e resgate os VANTs são ferramentas que funcionam como facilitadores e agilizadores, de forma que servem para localizar e permitir o resgate de seres vivos em situações extremas. Em (SILVAGNI et al., 2017) é relatado uma maneira de realizar a localização de pessoas que necessitam de resgate em situações de avalanche. Nesse artigo utiliza-se um VANT com uma câmera térmica/visual, o qual realiza missões em áreas de ocorrência de avalanche.

No setor da construção civil os VANTs podem ser utilizados para fazer o monitoramento da construção de grandes projetos, linhas de energia e gasodutos, e também para a inspeção da infraestrutura de gasodutos e torres GSM. Chen et al. (2014) menciona a possibilidade de usar veículos aéreos não tripulados para monitorar grandes obras, como rodovias, pontes e plantas de construção. Com o auxílio desses veículos ele prevê benefícios como maior visibilidade da do local da construção, melhor representação do modelo da área da construção pelo auxílio de imagens aéreas e um melhor gerenciamento de risco. Em Deng et al. (2014) é proposto uma maneira de realizar a inspeção cooperativa de linhas de energia utilizando um sistema multiplataforma de VANTs. Nesse trabalho, são usados mais de um modelo de VANT, onde cada um é responsável por uma tarefa específica na inspeção, com o auxílio de um sistema de controle e de comunicação que são integrados ao sistema cooperativo.

Com o extenso e crescente uso de VANTs torna-se cada vez mais comum observar defeitos nesses tipos de veículos, seja por mau uso ou por desgaste de seus componentes. Os defeitos nesses veículos podem causar danos às pessoas próximas ao local de vôo, danos materiais ou danos ambientais. Os VANTs se tornaram mais seguros com o passar dos anos, porém ainda existem componentes suscetíveis à falhas (PETRITOLI; LECCESE; CIANI, 2017), e muitas delas são difíceis de serem previstas.

Devido a existência dessas possíveis falhas, muitos estudos vêm sendo realizados com o intuito de identificar sinais que caracterizam algum tipo de problema e evitar que aconteçam. Segundo esses trabalhos, as principais fontes de problemas em VANTs são

relacionados aos motores e às hélices (FUGGETTI; GHETTI; ZANZI, 2015). Os trabalhos variam de acordo com a natureza da falha, onde algumas delas podem ser falha em hélices (POURPANAH et al., 2018), falha em motor (JAFARI; FAIZ; JARRAHI, 2021) e falha em atuador (servo) (JUNG; BANG, 2021).

1.1 Objetivos

1.1.1 Objetivo Geral

O objetivo deste trabalho é realizar uma análise comparativa entre duas metodologias que permitem a detecção de falhas de balanceamento de hélices em motores sem escova de corrente contínua (BLDC). Através de sinais de áudio coletados do motor, a primeira metodologia realiza a detecção de falhas de balanceamento com base na densidade de máximos e rede neural convolucional (CNN), e a segunda metodologia envolve apenas a rede neural convolucional.

1.1.2 Objetivos Específicos

Os objetivos específicos deste trabalho estão listados a seguir:

1. Implementação do SAC-DM para cálculo de densidade de máximos do sinais de áudios coletados;
2. Classificar os sinais de áudio coletados com base nos resultados do SAC-DM quanto à condição de balanceamento dos motores por meio do uso de uma CNN;
3. Classificar os sinais de áudio coletados quanto à condição de balanceamento dos motores, por meio do uso de uma CNN;
4. Realizar experimentos e simulações comparativas.

1.1.3 Outros Objetivos

Como o presente trabalho visa analisar a combinação das técnicas SAC-DM e CNN, considerando que não foi encontrada nenhuma pesquisa que utilizasse essa combinação de algoritmos, alguns questionamentos devem ser respondidos ao fim do presente trabalho. Os questionamentos a serem respondidos são:

- A técnica CNN pode ser mais vantajosa do que a SAC-DM?
- Quais os prós e contras em utilizar CNN ao invés de SAC-DM?
- A combinação de SAC-DM e CNN pode trazer melhores resultados?

1.2 Trabalhos Relacionados

Com relação à detecção de falhas em motores de VANTs é possível encontrar algumas bibliografias que alcaçam esse objetivo, utilizando metodologias distintas. É possível citar trabalhos com intuito de identificar defeitos nesses veículos, e agrupá-los de acordo com o tipo de falha a ser analisado e também aos métodos utilizado.

Levando em consideração o modo de identificação de falhas, são encontrados trabalhos que realizam a detecção de falhas através de sons emitidos pelos VANTs. Em Yaman, Yol e Altinors (2022), é proposto um método leve, o qual pode ser usado em sistemas embarcados para detecção de falhas em tempo real. Para testar esse método, foram criadas falhas de balanceamento, imã, hélice e rolamento em motores de VANT de 820KV. Foram utilizados diferentes modelos de VANTs, como helicóptero, duocóptero, tricóptero e quadcóptero. Foram obtidos conjuntos de dados sonoros com cinco classes para cada modelo de VANT analisado. A extração de características foi realizada utilizando o método de Coeficientes Cepstrais de Frequência de Mel (MFCC) nos sinais sonoros coletados. A classificação das falhas foi feita utilizando Máquinas de Vetores de Suporte (SVM) com as características selecionadas. Já Iannace, Ciaburro e Trematerra (2019), propõe-se um método de detecção de desbalanceamento das hélices do motor de um VANT através dos sinais sonoros emitidos. Para simular o desbalanceamento, foram acopladas fitas adesivas às hélices, causando uma mudança na sua aerodinâmica e consequentemente mudando o som emitido durante a rotação dos motores. Para a detecção da falha, foi realizada a análise de frequência dos sinais sonoros obtidos, em seguida é aplicado um filtro passa-banda e por criado um modelo de rede neural artificial de múltiplas camadas com propagação direta para classificar os dados que representam os sinais desbalanceados e os balanceados.

Também é possível citar trabalhos que realizam a detecção de falhas em VANTs por meio de redes neurais convolucionais. Na pesquisa realizado em Guo et al. (2018), realiza-se a detecção de falha de sensores de um VANT. Para o estudo, foram coletados dados do GPS, IMU e ADS. Após coletar os sinais residuais dos sensores, aplica-se a transformada de Fourier de tempo curto (STFT) e encontra-se o mapa do tempo-frequência, também chamado por espectrograma. Com esse mapa, utiliza-se uma CNN para extrair o mapa de características, ou *feature map*, possibilitando a realização do diagnóstico de falhas dos sensores do VANT. Em Sadhu, Zonouz e Pompili (2020), propõe-se uma nova arquitetura baseada em CNN e uma rede neural de memória longa de curto prazo, conhecida por LSTM, com a finalidade de detectar e classificar falhas na operação a partir de dados em tempo real originados de sensores. As arquiteturas propostas têm a capacidade de aprender de forma automática características de alto nível a partir dos dados brutos dos sensores, assim como compreender as dinâmicas espaciais e temporais presentes nesses dados.

Por fim, são encontrados trabalhos que utilizam a detecção de falhas em VANTs por meio de características caóticas, em específico utilizando um algoritmo criado na Universidade Federal da Paraíba, o SAC-DM. Nesses trabalhos, foram feitos através da análise do som emitido pelo motor BLDC, e as principais diferenças são relativas à maneira como o áudio é processado e à identificação da falha. Em Medeiros et al. (2018) é utilizado uma extensão da abordagem desenvolvida para quantificar o comportamento caótico em sistemas biológicos (BAZEIA et al., 2017). A técnica de densidade de máximos é aplicada ao sinal de corrente elétrica do estator para detectar falha de excentricidade dinâmica em motores BLDC e também detectar a velocidade de rotação do motor. Essa técnica utiliza um algoritmo simples de contagem de picos no domínio do tempo para detectar falhas. Em Veras et al. (2019) o som emitido pelo motor é utilizado para o diagnóstico, onde é comprovado que o sinal sonoro emitido pelo motor BLDC possui características caóticas, as quais são extraídas por meio de uma abordagem Wavelet. A partir de detalhes gerados pela Análise de Multiresolução Wavelet, é demonstrado que é possível aplicar o SAC-DM para identificar a excentricidade dinâmica de um motor BLDC para diferentes cenários de velocidade.

A tabela 1 apresenta os trabalhos citados anteriormente de forma mais resumida. Ao final deste trabalho a tabela 6 é apresentada como uma releitura da citada anteriormente, apresentando os resultados encontrados de cada trabalho.

Tabela 1 – Trabalhos que envolvem detecção de falha em motores BLDC

Autor	Defeito analisado	Técnica utilizada
Yaman, Yol e Altinors (2022)	Desbalanceamento de hélices	MFCC, SVM
Iannace, Ciaburro e Trematerra (2019)	Desbalanceamento de hélices	Análise de frequência, Filtro passa-banda
Guo et al. (2018)	Sensores	STFT, CNN
Sadhu, Zonouz e Pompili (2020)	Sensores	CNN, LSTM
Véras et al. (2019)	Excentricidade	SAC-DM, Wavelet
Medeiros et al. (2018)	Desbalanceamento de hélices	SAC-DM

1.3 Estrutura do Trabalho

O presente documento possui cinco capítulos, e esses são divididos da seguinte forma: no Capítulo 2 os conceitos do referencial teórico são descritos; no Capítulo 3 é explicado a metodologia utilizada para a execução da pesquisa; no Capítulo 4 é mostrado como a metodologia desenvolvida foi aplicada, os resultados obtidos na sua execução e um comparativo entre os resultados obtidos e trabalhos relacionados; o Capítulo 5 apresenta as considerações finais do presente trabalho em conjunto com trabalhos futuros.

Referencial Teórico

Este capítulo descreve os conceitos básicos para o entendimento do trabalho desenvolvido. São descritos os princípios fundamentais sobre: motores elétricos, em particular os motores *brushless* de corrente contínua; processamento de sinais; teoria do caos; *Signal Analysis based on Chaos using Density of Maxima* e Redes Neurais Convolucionais.

2.1 Motores BLDC

Motores de corrente contínua sem escova, também conhecidos como BLDC (*Brushless direct current*), vêm ganhando uma grande popularidade de forma rápida. Esse tipo de motor é usado em diversas indústrias, como a automotiva, aeroespacial, automação industrial, medicinal e outras.

Como o próprio nome sugere, por não possuir escova em sua composição, esse tipo de motor realiza a comutação (troca de energia entre o rotor e o estator) de forma eletrônica, diferentemente do que ocorre em motores com escova (YEDAMALE, 2003). Conforme Yedamale (2003), os motores BLDC oferecem diversas vantagens em relação aos motores DC com escova. Segue alguns desses benefícios:

- ❑ Melhor velocidade versus característica de torque;
- ❑ Alta resposta dinâmica;
- ❑ Vida útil duradoura;
- ❑ Operação sem ruído;
- ❑ Maiores taxas de velocidade.

O autor também destaca que a relação entre o torque entregue e o tamanho do motor é maior, fazendo com que o motor seja útil para aplicações onde o tamanho e o peso são fatores extremamente importantes.

Em Morbidi et al. (2016) é apresentado a estrutura de funcionamento de um motor BLDC. Como este trabalho tem o propósito de apresentar uma solução para RPAS, é mostrada através da figura 2 essa estrutura na forma de um circuito elétrico. Um sistema de propulsão elétrica converte energia elétrica em impulso mecânico e consiste em quatro componentes principais: uma fonte de energia elétrica, nesse caso uma bateria do tipo LiPo; um controlador eletrônico de velocidade (ESC); um motor elétrico, nesse caso um motor BLDC; e uma hélice.

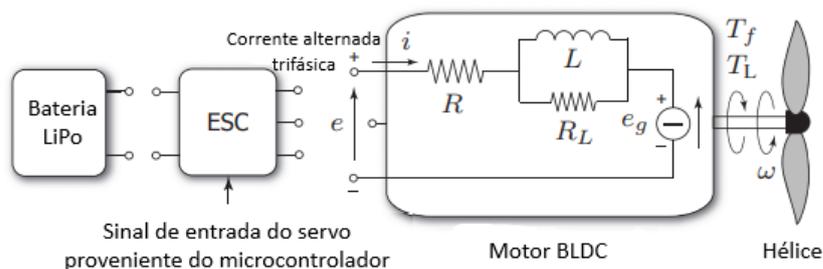


Figura 2 – Modelo de circuito elétrico de um motor BLDC de um VANT quadrotor. Fonte: Morbidi et al. (2016).

Em Mohanraj et al. (2022) é apresentada uma revisão sobre o estado da arte sobre motores BLDC. Também é mostrado a estrutura e os tipos de motores BLDC, as quais são retratadas pelas figuras 3 e 4, respectivamente.

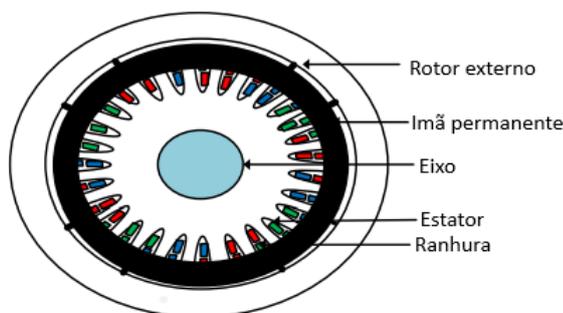


Figura 3 – Motor BLDC do tipo rotor externo. Fonte: Mohanraj et al. (2022).

Um motor BLDC é composto pelos seguintes componentes: rotor; superfície do ímã permanente; eixo central; estator; e ranhura (local onde posiciona-se as bobinas). O motor BLDC do tipo rotor externo é um motor que apresenta o estator na sua camada mais externa, em relação ao seu centro e é comumente utilizado em VANTS (MOHANRAJ et al., 2022). Devido às forças de atração e repulsão magnética é realizado a movimentação do rotor em relação ao estator. Essa movimentação é originada por meio de um ESC, o qual gera um campo magnético nas bobinas do estator, fazendo o rotor se movimentar por meio dessa comutação.

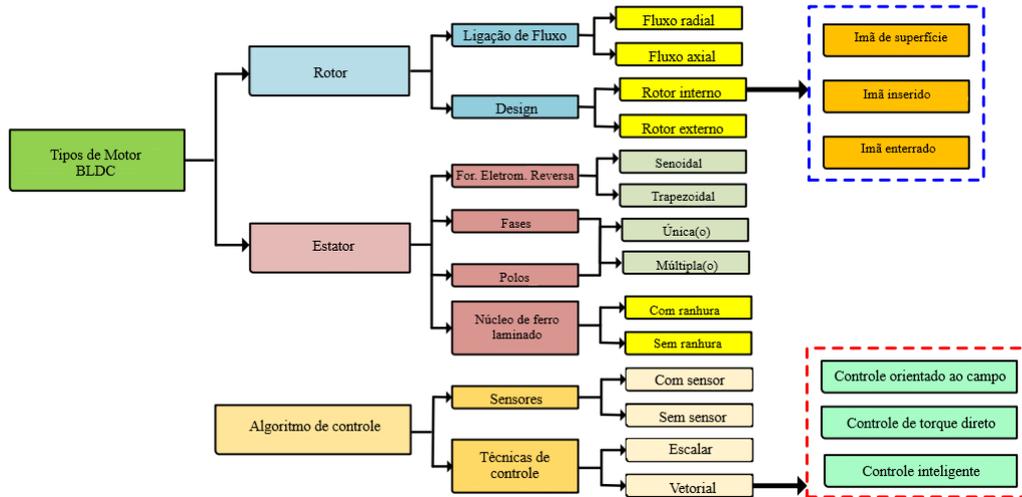


Figura 4 – Tipos de motores BLDC e algoritmos de controle. Fonte: Mohanraj et al. (2022).

2.2 Processamento de Sinais

Sinais são funções de uma ou mais variáveis independentes que transmitem informações sobre o comportamento ou natureza de um fenômeno físico (OPPENHEIM et al., 2010). A quantidade de variáveis independentes presentes no sinal define sua classificação com relação a sua dimensão. Ou seja, quando o sinal apresenta uma única variável independente é chamado de unidimensional. Já quando apresenta duas ou mais dimensões é chamado de multidimensional (HAYKIN; VEEN, 2001). Um sinal de áudio, por exemplo, é um sinal unidimensional pois depende apenas do tempo, já uma imagem é um sinal multidimensional (com duas dimensões) pois depende da altura e largura.

2.2.1 Classificação de Sinais

Segundo Oppenheim et al. (2010) os tipos básicos de sinais são os de tempo contínuo e de tempo discreto. No caso dos sinais de tempo contínuo, a variável independente é contínua e, portanto, esses sinais são definidos em um conjunto contínuo de valores da variável independente. Já os sinais de tempo discreto são definidos somente em instantes discretos, ou seja, a variável independente assume apenas um conjunto discreto de valores. As Figuras 5 e 6 mostra como são representados graficamente sinais de tempo contínuo e de tempo discreto.

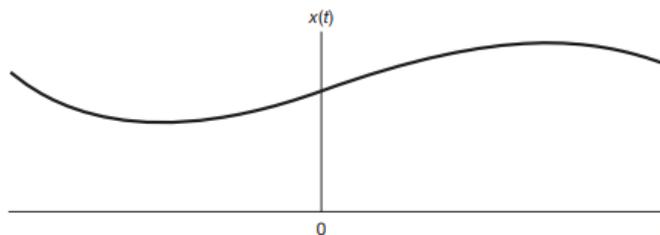


Figura 5 – Representação gráfica de sinal de tempo contínuo. Fonte: OPPENHEIM, A. et al. Sinais e Sistemas. 2. ed. São Paulo: Pearson, 2010. p. 2.

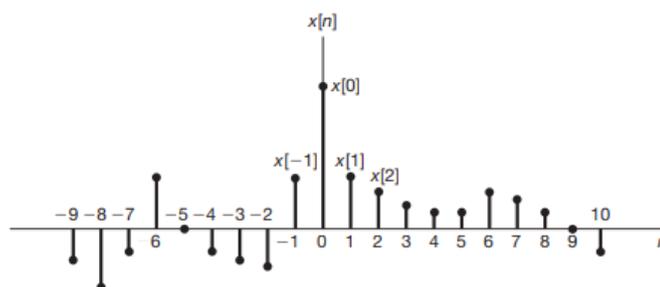


Figura 6 – Representação gráfica de sinal de tempo discreto. Fonte: OPPENHEIM, A. et al. Sinais e Sistemas. 2. ed. São Paulo: Pearson, 2010. p. 2.

Uma outra classificação de acordo com Oppenheim et al. (2010) é relativa a periodicidade de sinais. Um sinal de tempo contínuo $x(t)$ é dito periódico quando seu período T é um valor positivo e que satisfaça a Fórmula 2.1 para todos os valores de t .

$$x(t) = x(t + T) \quad (2.1)$$

Quando o sinal $x(t)$ não apresenta periodicidade, ele é chamado de aperiódico. Sinais de tempo discreto são classificados como periódicos de forma similar à sinais de tempo contínuo. Um sinal de tempo discreto $x[n]$ é dito periódico quando seu período N é um número inteiro positivo e que satisfaça a Fórmula 2.2 para todos os valores de n .

$$x[n] = x[n + N] \quad (2.2)$$

2.3 Espectrograma

O espectrograma nada mais é do que a representação visual das diferentes frequências de um sinal com o passar do tempo. Para gerar o espectrograma de um sinal utiliza-se uma variação da Transformada de Fourier, chamada Transformada de Fourier de Tempo Curto.

2.3.1 Transformada de Fourier

A série de Fourier é uma expansão de uma função usada para representar sinais harmônicos utilizando funções de seno e cosseno. Em geral utiliza-se a série de Fourier para representar sinais periódicos, porém pode-se descrever um sinal aperiódico como o limite de um sinal periódico com período T se aproximando do infinito. A Figura 7 mostra que um sinal aperiódico $x(t)$ converge para $\tilde{x}(t)$ quando T converge para ∞ .

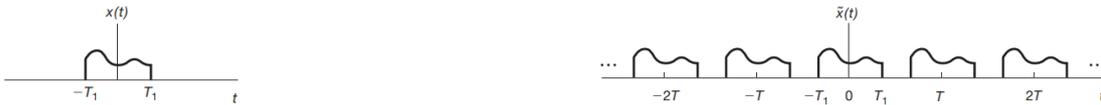


Figura 7 – Representação gráfica de sinal aperiódico $x(t)$ (a esquerda) e da sua representação como sinal periódico $\tilde{x}(t)$ (a direita). Fonte: OPPENHEIM, A. et al. Sinais e Sistemas. 2. ed. São Paulo: Pearson, 2010. p. 167.

A transformada de Fourier permite analisar adequadamente sinais não periódicos. A seguir são apresentadas as fórmulas referentes a transformada de Fourier (2.3) e a transformada inversa de Fourier (2.4) para esses tipos de sinais, onde essa última tem a finalidade de recuperar o sinal original após aplicar a função $X(jw)$.

$$X(jw) = \int_{-\infty}^{\infty} x(t)e^{-jwt} dt \quad (2.3)$$

$$x(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} X(jw)e^{jwt} dw \quad (2.4)$$

Para uma melhor adequação à aplicações digitais realizadas em computador, deriva-se as equações 2.3 e 2.4 para que sejam representadas em tempo discreto. As Fórmulas 2.5 e 2.6 representam a transformada de Fourier e transformada inversa de Fourier para tempos discretos, respectivamente.

$$X(e^{jw}) = \sum_{n=-\infty}^{\infty} x[n]e^{-jwn} \quad (2.5)$$

$$x[n] = \frac{1}{2\pi} \int_{2\pi} X(e^{jw})e^{jwn} dw \quad (2.6)$$

Uma outra extensão da transformada de Fourier é a transformada de Fourier de tempo curto, ou, *Short-Time Fourier Transform*, a qual tem a finalidade de facilitar a análise de sinais que possuem uma variação de frequência durante sua duração. Segundo Kehtarnavaz (2011), a STFT funciona como uma sequência de transformadas de Fourier rápidas, também chamadas de FFT, em janelas deslizantes. A STFT fornece a informação da frequência localizada em um determinado tempo para situações onde a frequência do sinal variam de acordo com o tempo, enquanto a transformada de Fourier padrão fornece

uma média da informação da frequência relativa a toda a duração do sinal. As Fórmulas 2.7 e 2.8 representam a STFT de tempo contínuo e de tempo discreto, respectivamente.

$$X(\tau, w) = \int_{-\infty}^{\infty} x(t)w(t - \tau)e^{-j\omega t} dt \quad (2.7)$$

$$X(n, w) = \sum_{m=-\infty}^{\infty} x[m]w[m - n]e^{-j\omega m} \quad (2.8)$$

onde, $w(t)$ e $w[m]$ é o sinal da janela deslizante.

2.3.2 Geração do Espectrograma a partir do sinal

Para gerar um espectrograma precisa-se ter, inicialmente, um sinal $x(t)$, com variável independente sendo o tempo. Em seguida, aplica-se a STFT no sinal em questão, onde nesse processo o sinal é dividido em pedaços. Ao dividir o sinal em segmentos, é possível que a oscilação presente em suas bordas seja muito brusca, característica essa que não é presente no sinal original. Devido à esse comportamento e com o objetivo de suavizar o sinal nas bordas dos segmentos, de maneira sequencial multiplica-se esses pedaços de $x(t)$ por uma função $w(t)$ chamada *window*, ou janela.

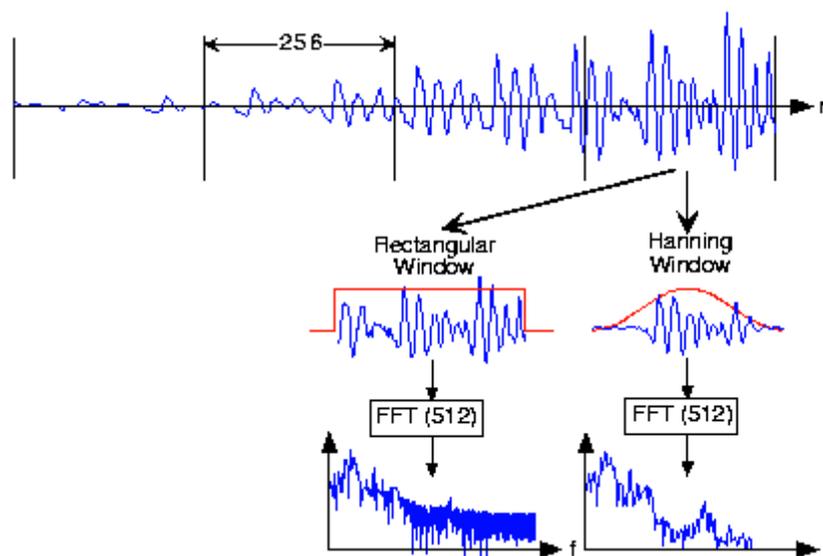


Figura 8 – Representação do cálculo da STFT de um sinal com demonstração de duas funções em janela (retangular e Hanning). Fonte: Johnson, D. Fundamentals of Electrical Engineering I. University Press of Florida, 2008. p. 193.

A Figura 8 representa o processo do cálculo da STFT a partir de um sinal no domínio do tempo. Nela, pode-se observar o resultado da FFT de dois sinais, resultantes da multiplicação de um segmento do sinal original e de duas funções em janela, retangular e Hanning, respectivamente. A resultado da FFT do segmento de sinal multiplicado por uma função retangular enaltece as oscilações de frequência de forma não genuína. Já o

resultado obtido da multiplicação do segmento pela função Hanning mostra oscilações mais próximas da realidade, pois gera um sinal que é estreito nas bordas (JOHNSON, 2008).

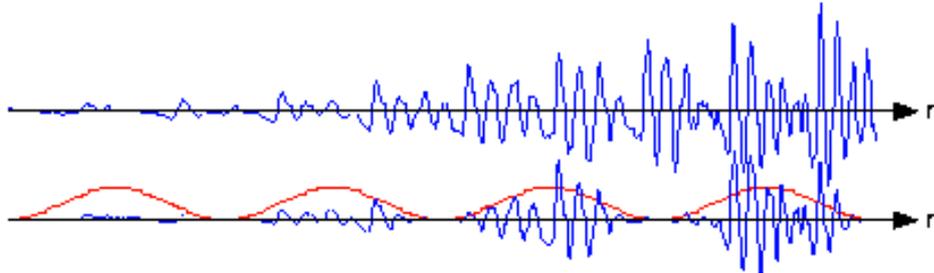


Figura 9 – Comparativo de um sinal com o resultado de sua multiplicação por uma função Hanning em janela e sem sobreposição. Fonte: Johnson, D. Fundamentals of Electrical Engineering I. University Press of Florida, 2008. p. 194.

Através da Figura 9, observa-se que ao multiplicar um sinal por uma função Hanning em janela e sem sobreposição, perde-se trechos de informação nas bordas dos segmentos. Para amenizar essa característica, os segmentos são sobrepostos, tornando necessário uma quantidade maior de cálculos de FFT em comparação com a janela retangular. Apesar disso, as mudanças de frequência são muito melhor capturadas, tornando o resultado mais próximo da realidade. Para a sobreposição os sinais são alinhados e deslocados de modo que, a quantidade de amostras entre duas janelas é igual, exceto para a primeira e última janela que são mais alongadas. A Figura 10 ilustra o resultado desse processo.

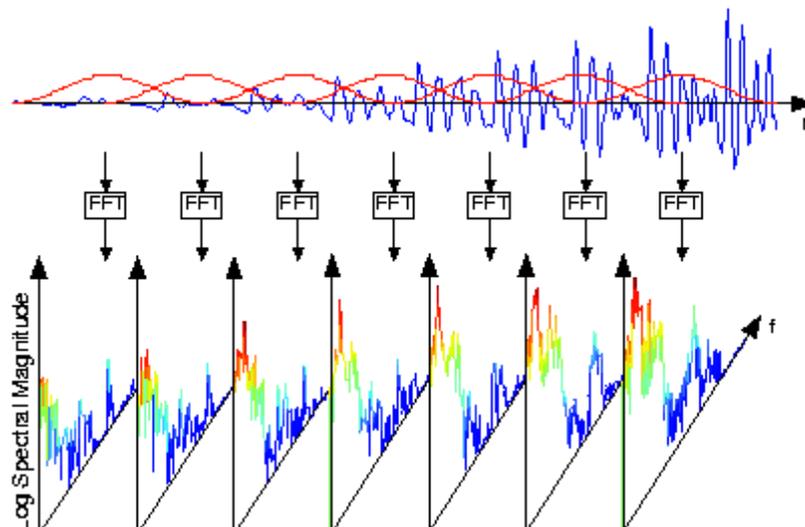


Figura 10 – Representação do cálculo das FFTs dos segmentos de um sinal multiplicado por um função Hanning em janela com sobreposição. Fonte: Johnson, D. Fundamentals of Electrical Engineering I. University Press of Florida, 2008. p. 195.

Para gerar o espectrograma, primeiramente pega-se o resultado da STFT (o mesmo que pegar o resultado de cada FFT), onde cada sinal representa a variação da

frequência em um determinado tempo t , ou m , segundo as Fórmulas 2.7 e 2.8. Em seguida, para gerar a imagem, cada sinal é rotacionado de modo que o eixo Y contém a alteração da frequência para aquele determinado tempo, que estará definido no eixo X. A magnitude da frequência é representada por cores, que variam de acordo com a amplitude da frequência. Ou seja, cada cálculo da FFT é responsável por gerar uma coluna no espectrograma. De forma simplificada, para gerar o espectrograma a partir de um sinal $x(t)$, segue-se os passos descritos abaixo e juntamente com exemplos associados por imagens.

1. Considere um sinal $x(t)$, no domínio do tempo.

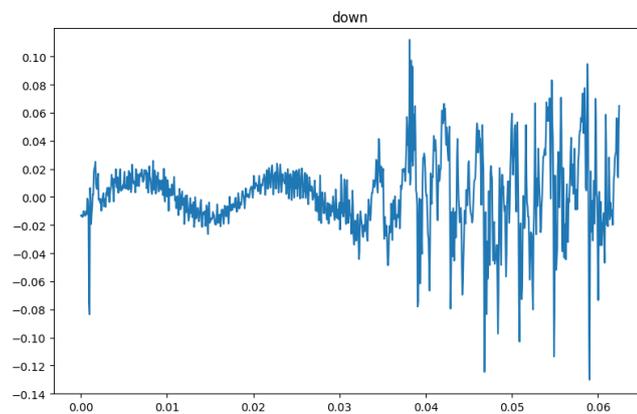


Figura 11 – Passo 1: Sinal de áudio $x(t)$ para gerar espectrograma, com um tempo $t_o \approx 6.24 * 10^{-2}s$. O eixo x apresenta o tempo, em segundos, e o eixo y apresenta a amplitude. Fonte: O autor.

2. Divida o sinal $x(t)$ em pequenas janelas de tempo de tamanho fixo, ou seja, todas as janelas terão a mesma duração.

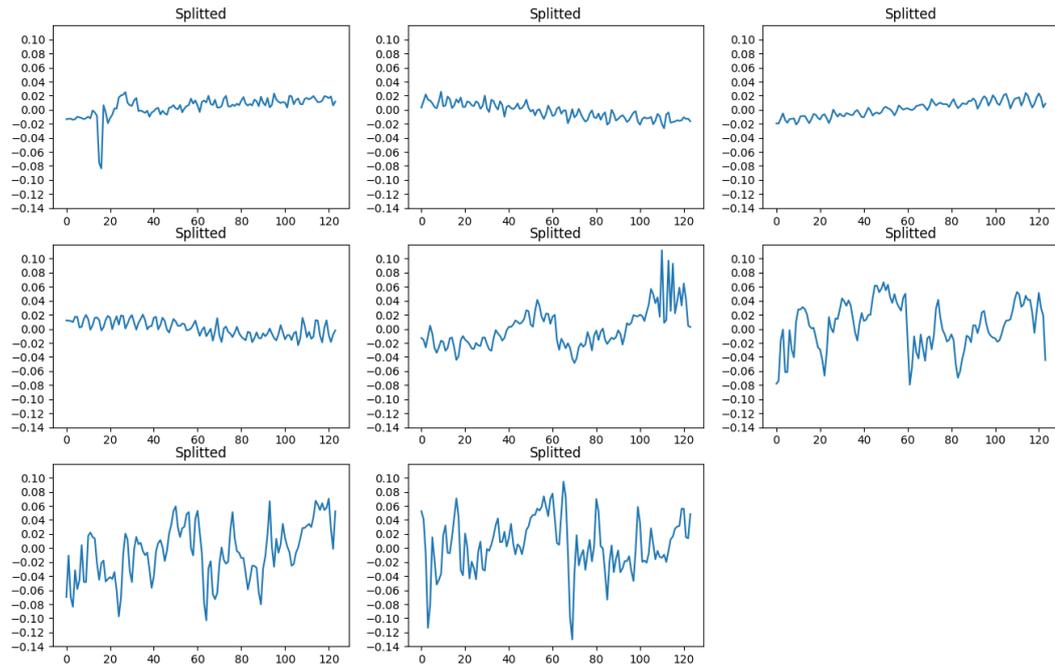


Figura 12 – Passo 2: Sinal $x(t)$ segmentado em um total de 8 janelas, e cada uma delas com um tempo $t_s \approx 0.78 * 10^{-2}s$. O eixo x apresenta o número de amostras dos sinais segmentados e o eixo y apresenta a amplitude. Fonte: O autor.

3. Escolha uma função $w(t)$ para que seja utilizada como a função *window*, ou seja, ela será a janela deslizante.

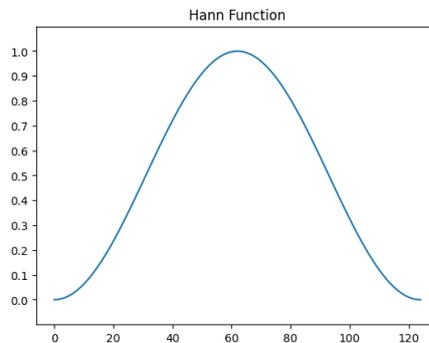


Figura 13 – Passo 3: Para exemplificar, utilizou-se a função Hanning. O eixo x apresenta o número de amostras, apresentando mesmo tempo que os sinais segmentados, e o eixo y apresenta a amplitude. Fonte: O autor.

4. Para cada sinal segmentado de $x(t)$, calcule a convolução dele com o sinal da janela deslizante escolhida.

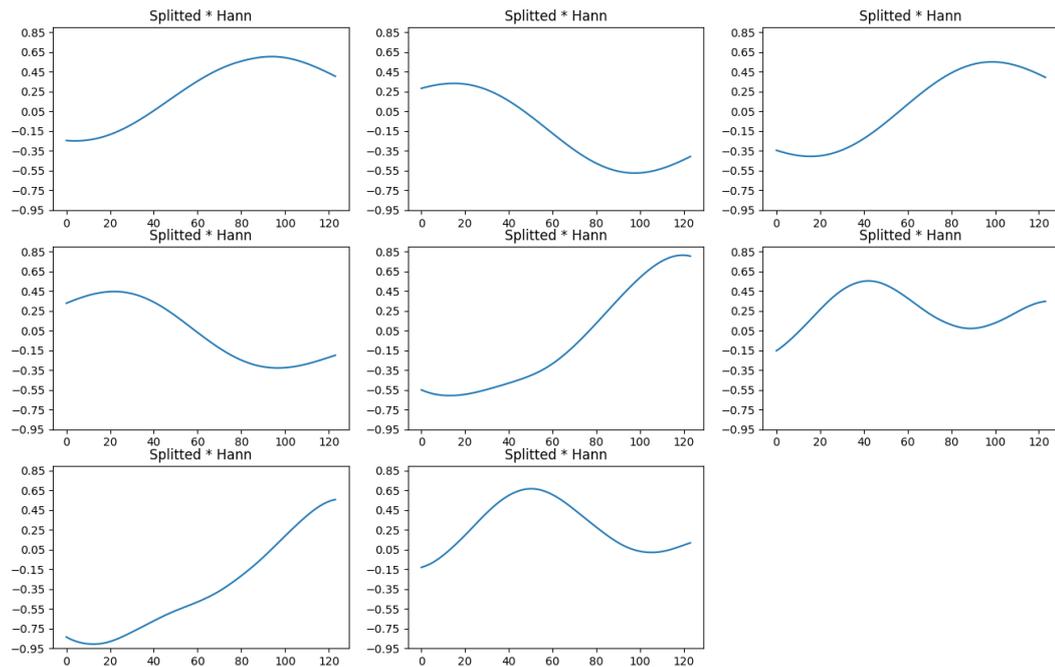


Figura 14 – Passo 4: Resultado das convoluções entre os segmentos de $x(t)$ com o sinal $w(t)$. O eixo x apresenta o número de amostras após convolução e o eixo y apresenta a amplitude. Fonte: O autor.

5. Faça o cálculo da FFT para cada um dos resultados obtidos no passo anterior.

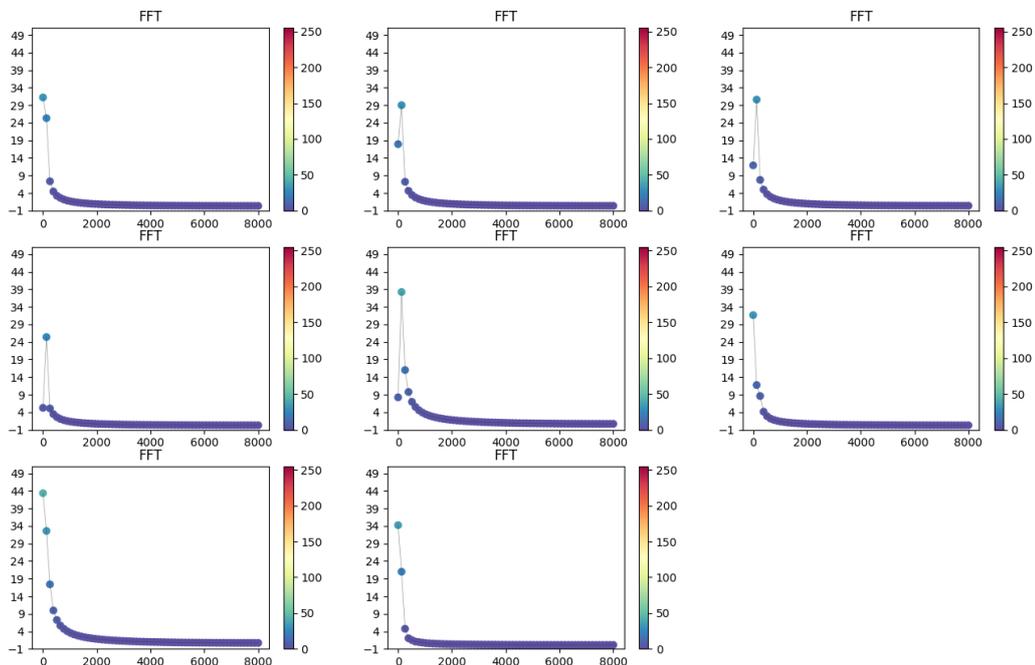


Figura 15 – Passo 5: FFT dos resultados das convoluções. O eixo x apresenta as frequências após a FFT e o eixo y apresenta a magnitude das frequências. Fonte: O autor.

6. Utilize os resultados das FFTs para plotar um gráfico 2D com a frequência no eixo vertical e o tempo no eixo horizontal. Cada resultado de uma FFT irá gerar

uma coluna no gráfico 2D, onde a frequência será disposta no eixo Y, onde suas intensidades serão representadas por cores, e o tempo será disposto no eixo X e será igual para cada resultado da FFT, com o valor de t igual ao tempo de cada janela, descrita no Passo 2.

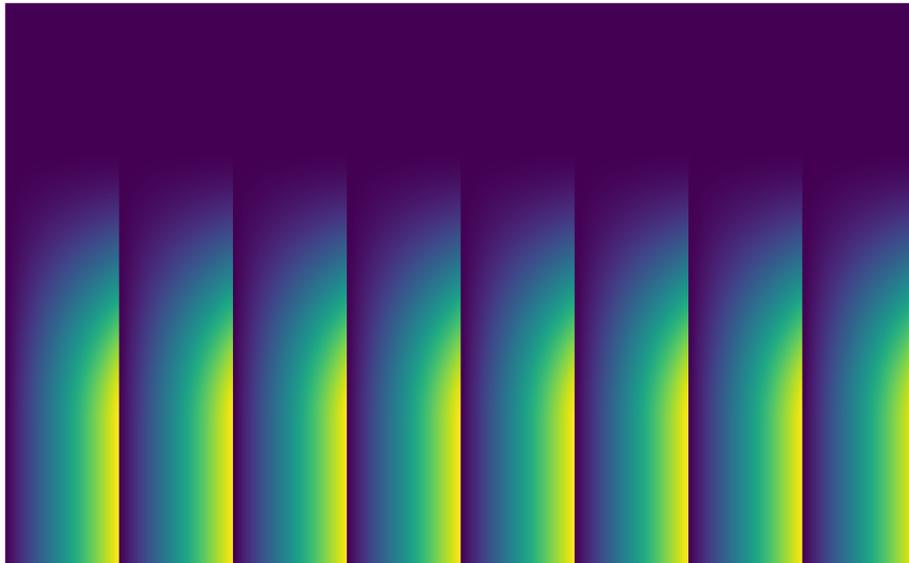


Figura 16 – Passo 6: Espectrograma resultante, com frequência no eixo y e o tempo no eixo x .
Fonte: O autor.

As imagens representadas pela Figura 16 mostram de forma visual as etapas descritas pelos passos no parágrafo anterior.

2.4 Comportamento Caótico

Muitos sistemas apresentam comportamentos irregulares e imprevisíveis a exemplo do clima, reações químicas e circuitos eletrônicos. Sistemas caóticos são aparentemente incertos e qualquer alteração às suas condições iniciais podem resultar em alterações ao sistema, caracterizando sua grande sensibilidade ao estado original (GOKYILDIRIM; UYAROGLU; PEHLIVAN, 2016). Segundo Bix e Pipenberg (1992), apesar de apresentar essa sensibilidade a pequenos sinais, sistemas caóticos são imunes à ruídos externos.

2.4.1 *Signal Analysis based on Chaos using Density of Maxima* (SAC-DM)

O método *Signal Analysis based on Chaos using Density of Maxima* compreende na análise de uma quantidade genérica de amostras $q(t)$ de um sinal $x(t)$. O SAC-DM oferece uma possibilidade de resolução de problemas com uma baixa quantidade de dados e confirma o comportamento caótico em séries aparentemente aleatórias.

Analisando uma pequena quantidade de dados de um sinal $q(t)$, nota-se que ele varia no tempo e produz o máximo local no intervalo $[t, t + \delta t]$, para um δt suficientemente pequeno, onde $q'(t) > 0$ e $q'(t + \delta t) < 0$, e de tal forma que $-q''(t)\delta t > q'(t) > 0$.

A função de probabilidade conjunta $P(q', q'')$ pode ser usada para calcular a densidade de máximos $\langle \rho \rangle$, de modo que a probabilidade de encontrar um máximo no intervalo $[t, t + \delta t]$ é proporcional à integral que abrange a região definida acima, conforme a Fórmula 2.9.

$$\langle \rho \rangle \equiv \frac{1}{\delta t} \int_{-\infty}^0 dq'' \int_0^{-q''\delta t} dq' P(q', q'') = \int_{-\infty}^0 dq'' q'' P(0, q'') \quad (2.9)$$

A quantidade média de picos é invariante sob intervalos de tempo, devido a propriedades estatísticas, e isso significa que q' e q'' possuem valores médios próximos de zero. Além disso, as propriedades de $P(q', q'')$ podem ser obtidas a partir do menor momento q' e q'' , e as variâncias de $P(q', q'')$ estão diretamente ligadas com função de correlação explicitada pela Fórmula 2.10.

$$C(\delta t) = \langle q(t + \delta t)q(t) \rangle \quad (2.10)$$

Da Fórmula 2.10 podemos obter os vários momentos, em especial:

$$\langle q'^2 \rangle = - \left. \frac{d^2 C(\delta t)}{d(\delta t)^2} \right|_{\delta t=0} \quad (2.11)$$

$$\langle q''^2 \rangle = \left. \frac{d^4 C(\delta t)}{d(\delta t)^4} \right|_{\delta t=0} \quad (2.12)$$

O princípio da máxima entropia pode ser usado para construir a função de distribuição de probabilidade para q e suas derivadas. Após efetuar os cálculos algébricos, a integração em $q(t)$ leva a $P(q', q'')$, gerando a Fórmula 2.13.

$$P(q', q'') = \frac{1}{2\pi} \frac{1}{\sqrt{\langle q'^2 \rangle \langle q''^2 \rangle}} \exp \left(-\frac{1}{2} \frac{q'^2}{\langle q'^2 \rangle} \right) \quad (2.13)$$

A Fórmula 2.14 é aplicada para analisar amostras de sinais aperiódicos, em que $\langle \rho \rangle$ é teórico e C é calculado pelas derivadas segunda e quarta (Fórmulas 2.11 e 2.12) da função de correlação automática em zero, conforme mostrado em trabalhos anteriores, como Bazeia et al. (2017), Medeiros et al. (2018) e Veras et al. (2019).

$$\langle \rho \rangle = \frac{1}{2\pi} \sqrt{\frac{\langle q''^2 \rangle}{\langle q'^2 \rangle}} = \frac{1}{2\pi} \sqrt{\frac{\frac{d^4 C}{dt^4}(0)}{-\frac{d^2 C}{dt^2}(0)}} \quad (2.14)$$

Pelo princípio da máxima entropia, para séries temporais periódicas e homogêneas, é possível escrever a função de correlação normalizada, a partir de uma função cosseno, reduzindo-se a equação anterior para a Fórmula 2.15, onde τ é o comprimento de correlação e ρ é a densidade de máximos.

Em trabalhos realizados por Bazeia et al. (2017), Medeiros et al. (2018) e Veras et al. (2019), foi encontrado a Fórmula 2.15, a qual foi originada a partir de equações de probabilidade, função de correlação e funções algébricas que envolvem integrais que determinam a área em um determinado intervalo $[t, t + \delta t]$. Nela τ representa o comprimento de correlação e ρ é a densidade de máximos.

$$\tau = \frac{1}{6\langle\rho\rangle} \quad (2.15)$$

Este trabalho utiliza uma abordagem diferente dos outros citados anteriormente, porém de forma mais simplificada e com mesma finalidade. Um sinal $x(t)$ é fragmentado em relação à uma quantidade de amostras i especificada, gerando as amostras $q(t)$, e é realizado uma busca pelos picos em cada uma delas. Com os picos de $q(t)$ encontrados, e com sua quantidade de elementos k conhecida, aplica-se a Fórmula 2.16 para encontrar o valor da densidade de máximos ρ_y da amostra $q(t)$.

$$\rho_y = \frac{\sum_{n=1}^k 1}{i} \quad (2.16)$$

2.5 Redes Neurais Convolucionais

Rede Neural Convolutiva, ou CNN, é um dos tipos de redes neurais mais populares para resolução de problemas envolvendo imagens. Essa técnica visa resolver casos ligados a detecção de padrões, desde processamento de imagens até reconhecimento de voz (ALBAWI; MOHAMMED; AL-ZAWI, 2017). A principal diferença de uma CNN para outros tipos de redes neurais é a capacidade de lidar com dados com mais de uma dimensão, ou seja, ela consegue aprender diretamente a partir desses tipos de dados. A CNN não necessita que seja extraído manualmente as características dos dados analisados, isso ocorre graças à sua arquitetura de camadas convolucionais, que é capaz de extrair automaticamente recursos relevantes a partir dos dados de entrada.

De acordo com Chollet (2021), pode-se dizer que existem seis etapas para construir uma rede neural convolutiva, e são elas:

1. Preparação dos dados: É necessário preparar os dados de treinamento, validação e teste para a rede neural. Isso inclui carregar os dados, separar em conjuntos de

treinamento e validação, realizar pré-processamento, como normalização e aumento de dados, e transformar os dados em tensores para serem usados pela rede.

2. Definição da arquitetura: É necessário definir a arquitetura da CNN, que inclui o número e tamanho das camadas convolucionais, de pooling e totalmente conectadas, bem como a função de ativação e outras configurações.
3. Compilação: É necessário compilar a CNN, definindo a função de perda, o otimizador e as métricas de avaliação para serem usados durante o treinamento.
4. Treinamento: A CNN é treinada em dados de treinamento, iterativamente ajustando os pesos da rede para minimizar a perda, usando o otimizador definido na etapa anterior. Durante o treinamento, a rede é avaliada usando os dados de validação para monitorar o desempenho e evitar overfitting.
5. Avaliação: Após o treinamento, a CNN é avaliada usando dados de teste, que não foram usados no treinamento, para avaliar o desempenho final da rede.
6. Ajuste fino: Se necessário, a CNN pode ser submetida a um ajuste fino, onde a rede é novamente treinada com uma taxa de aprendizado mais baixa e em dados mais específicos para melhorar ainda mais o desempenho em tarefas específicas.

Esses tipos de redes neurais são compostos por várias camadas, as quais possuem funções específicas na análise dos dados. A CNN possui uma camada de entrada, uma camada de saída e várias camadas ocultas, onde essas são compostas pelas camadas convolucional, *pooling*, totalmente conectada e várias camadas de normalização (DHILLON; VERMA, 2020). A Figura 17 representa a arquitetura de uma rede neural convolucional, contemplando as camadas convolucional, *pooling* e totalmente conectada. A camada de entrada tem a função de receber os dados de entrada na forma de imagem ou outro tipo de dado, devido a isso o maior foco será na outras camadas da CNN.

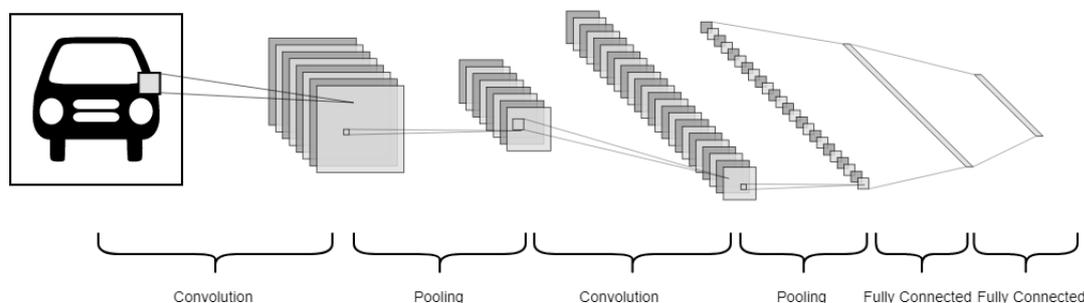


Figura 17 – Representação da composição de camadas de uma rede neural convolucional. Fonte: O autor.

2.5.1 Camada Convolutiva

Segundo Kattenborn et al. (2021), as camadas convolucionais da rede possuem filtros de otimização que transformam os dados de entrada ou camadas ocultas anteriores, ou seja, os filtros dessa camada são responsáveis por extrair informações da imagem. A quantidade desses filtros representam a profundidade da rede neural. Kattenborn et al. (2021) também diz que as transformações resultantes buscam revelar padrões que são decisivos para o problema em análise e que são aprendidos de forma iterativa através da convolução, que é essencialmente o deslizamento do filtro sobre a camada e o cálculo do produto escalar entre o filtro e os valores da camada. Segundo LeCun, Bengio e Hinton (2015), as camadas convolucionais aplicam filtros à imagem de entrada para extrair recursos ou características importantes. Cada filtro é um conjunto de pesos que é ajustado durante o treinamento para capturar diferentes padrões na imagem.

O processo de convolução consiste no produto escalar entre duas matrizes, onde uma matriz é referente aos dados de entrada da camada e a outra é referente à um filtro usado para extrair informações da imagem, também conhecido por kernel (ALBAWI; MOHAMMED; AL-ZAWI, 2017). Durante esse processo, o kernel desliza pela altura e largura da imagem, realizando o produto escalar, produzindo uma representação dos dados de entrada referentes à imagem. Isso resulta em uma matriz conhecida por mapa de ativação. O mapa de ativação é usado para entender quais as características a CNN está aprendendo. Essas informações podem ser usadas para identificar se a CNN está aprendendo características relevantes para a tarefa em questão e para ajustar os hiperparâmetros da rede. A Figura 20 ilustra o processo de realizado na camada convolutiva de uma CNN.

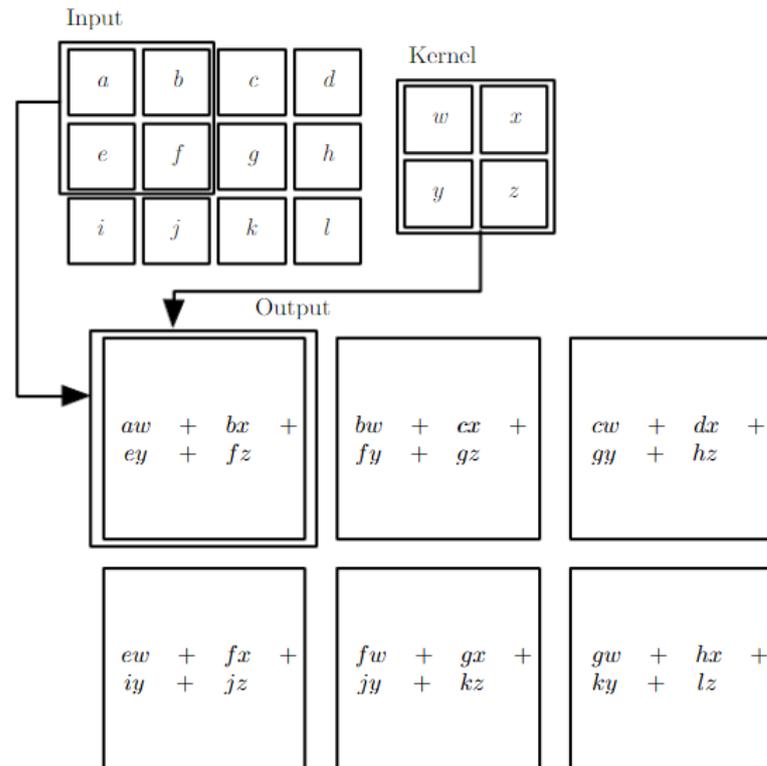


Figura 18 – Representação da convolução realizada na camada convolucional em uma CNN.
 Fonte: Goodfellow, Bengio e Courville. Deep Learning. MIT Press, 2016. p. 330.

Para evitar um grande custo computacional, gerando muitos parâmetros de aprendizagem, costuma-se escolher uma matriz para os filtros da camada convolucional menor que o tamanho da imagem. Utiliza-se filtros de tamanho $k \times k \times d$, onde k é a dimensão espacial do filtro e d é o número de canais (RGB) da imagem original. Por exemplo, digamos que tenhamos uma imagem de tamanho $140 \times 140 \times 3$, o que implicaria em um número total de 58.800 pesos, caso fosse escolhido um filtro de mesmo tamanho da imagem de entrada. Ao invés disso, pode-se definir que o valor de $k = 3$, logo, o número total de pesos seria $3 \times 3 \times 3$ (a imagem original possui 3 canais, logo $d = 3$), resultando em um total de 27 pesos. A Figura 19 representa a operação de uma camada convolucional, com mesmo parâmetros citados no exemplo anterior.

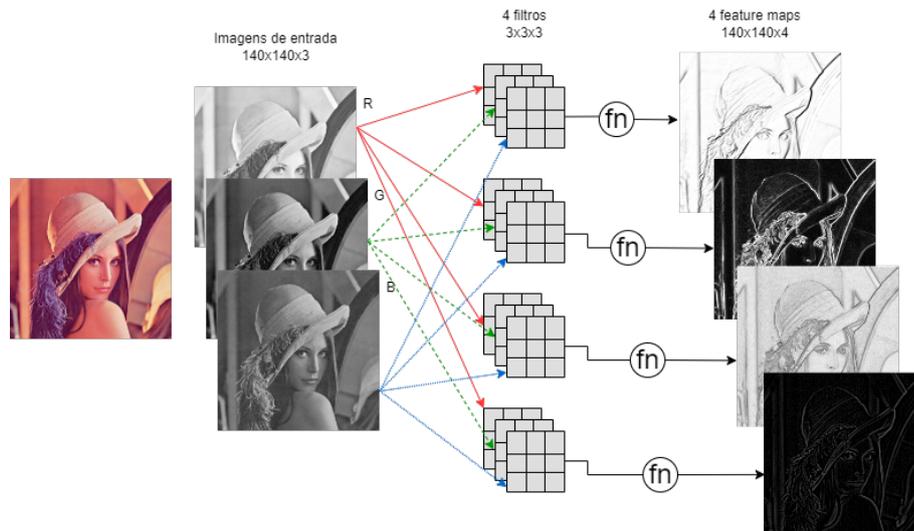


Figura 19 – Representação das operações de uma camada convolucional. Fonte: O autor.

2.5.2 Camada *Pooling*

A camada de *pooling*, segundo Dhillon e Verma (2020), serve para diminuir o número das dimensões, ou seja, ela funciona reduzindo ou agrupando pixels de uma região da imagem. Essa camada é responsável por reduzir o número de parâmetro a serem aprendidos e também os cálculos computacionais realizados na rede. De acordo com Albawi, Mohammed e Al-Zawi (2017), no domínio de processamento de imagem *Pooling* é considerado similar à redução da resolução. Ele também diz que uma das técnicas mais utilizadas de *Pooling* é o *Max-Pooling*, onde a imagem é particionada em sub-regiões retangulares e os maiores valores de cada região são selecionados.

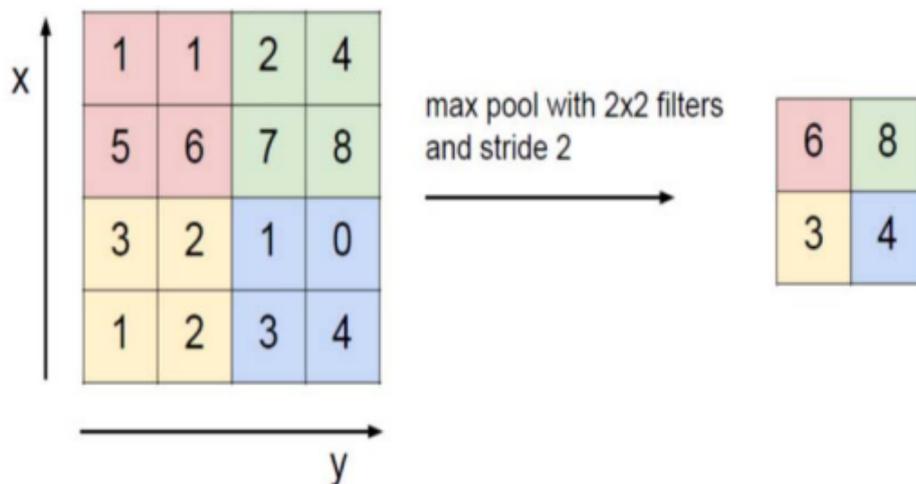


Figura 20 – Representação do *Max-Pooling* em uma CNN. Fonte: ALBAWI, S.; MOHAMMED, T. A.; AL-ZAWI, S. Understanding of a convolutional neural network. 2017 International Conference on Engineering and Technology (ICET), 2017.

2.5.3 Camada Totalmente Conectada

De acordo com Liu et al. (2018), em uma rede neural comum, cada neurônio em uma camada é ligado a um outro na camada seguinte, caracterizando a camada totalmente conectada. Nessa perspectiva em uma CNN, cada pixel seria processado por um neurônio, e isso resultaria em um grande desperdício de recursos. Graças às camadas anteriores (convolucional e *pooling*) a redução no número de parâmetros ajuda no processamento desse tipo de rede neural. Em redes neurais convolucionais, a camada totalmente conectada recebe os resultados do processamento das camadas convolucionais e *pooling*, e chegam a uma decisão de classificação. Segundo LeCun, Bengio e Hinton (2015), a camada totalmente conectada transforma os recursos extraídos pelas camadas anteriores em uma saída final, a qual pode ser usada para classificação, detecção de objetos, segmentação de imagem, entre outras tarefas. Esse resultado da camada totalmente conectada exige que o resultado das camadas anteriores seja vetorizado, ou seja, para um resultado com dimensões $6 \times 6 \times 4$, é necessário redimensioná-lo para $1 \times (6 \times 6 \times 4) = 1 \times 144$.

Metodologia

Neste capítulo são descritas as etapas da metodologia adotada neste trabalho, onde por meio de uma rede neural convolucional é realizada a classificação de espectrogramas de sinais gerados pelo algoritmo SAC-DM a partir de áudios de um motor BLDC. Nesta metodologia, escolhe-se trabalhar a detecção do desbalanceamento da hélice por meio de sinal sonoro, pois é um procedimento simples de ser implementado e não-invasivo, visto que muitas aplicações de VANTs necessitam de pouco peso acoplado ao seu sistema.

A Seção 3.1 descreve a maneira que os dados foram adquiridos. A Seção 3.2 apresenta o fluxograma seguido para a realização do trabalho. A Seção 3.3 é relativa ao pré-processamento nos quais os dados são submetidos. Em 3.4 explica-se o porquê de se utilizar o espectrograma. Por fim, expõe-se a forma como é construída a rede neural utilizada para classificar as imagens dos espectrogramas na seção 3.5.

3.1 Aquisição dos Dados

Para executar a metodologia adotada no presente trabalho, o primeiro passo a ser realizado é a aquisição dos dados. Esses elementos tratam-se de sinais de áudio emitidos por um motor BLDC em funcionamento. Os sinais de áudio utilizados fazem parte de uma parcela dos que foram utilizados no trabalho de Veras et al. (2019), onde ele os coletou a partir de um circuito eletrônico composto por um Arduino com um microfone acoplado. A Figura 21 mostra o circuito utilizado para emitir os sinais de áudio que foram coletados.

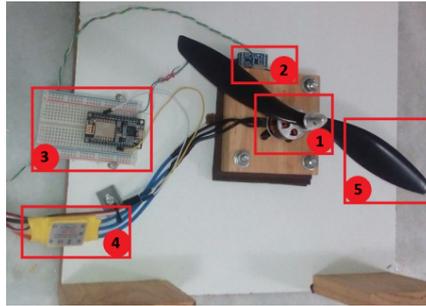


Figura 21 – Circuito embarcado com componentes para geração dos sinais de áudio. Fonte: Veras et al. (2019)

A tabela 2 lista os componentes utilizados na Figura 21, para geração dos sinais de áudio.

Tabela 2 – Circuito embarcado para geração dos sinais de áudio

Número na Figura	Componente
1	Brushless DC Motor 1400 Kv
2	Accelerometer Adafruit XL345
3	Node MCU ESP8266 12F
4	Electronic Speed Controller (ESC) de 30 A
5	Hélice de 10.4 polegadas

3.2 Fluxograma

Os procedimentos seguidos nesta pesquisa estão dispostos em formato de fluxograma pela Figura 22, mostrando os passos executados. Com posse dos sinais, segue-se para a etapa do pré-processamento, onde eles são tratados para estarem adequados aos processos os quais serão submetidos em etapas posteriores. Essa fase consiste na segmentação e aplicação do SAC-DM. Em seguida, gera-se os espectrogramas dos sinais pré-processados, obtendo-se imagens que serão utilizadas para alimentar uma CNN, a qual irá passar pelas etapas de treinamento, validação e teste. Com esses passos finalizados, realiza-se a análise dos resultados (Capítulo 4) obtidos através do percentual de acurácia encontrado.

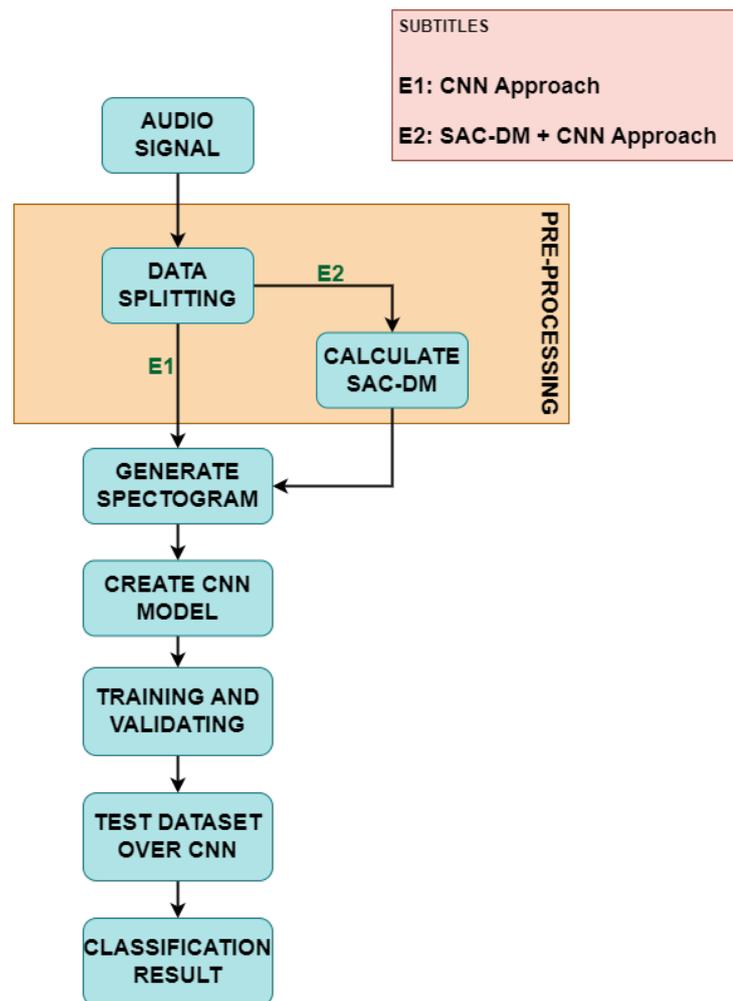


Figura 22 – Fluxograma seguido. Fonte: O autor.

3.3 Pré-Processamento

Para a elaboração deste trabalho, foi realizada uma etapa de pré-processamento dos dados, viabilizando seu uso em uma CNN. Esse procedimento foi realizado em dois passos diferentes, além da leitura dos áudios, e são eles: *segmentação* e aplicação do *SAC-DM*.

3.3.1 Segmentação

Esta etapa se dá devido a baixa quantidade de áudios disponibilizados para a realização deste trabalho. O critério usado para a divisão dos áudios foi equalizar o tamanho de todos eles, ou seja, deixá-los com a mesma duração. Para isso, tomou-se o tempo de duração de todos os sinais e encontrou-se o menor deles com a intenção de dividi-los em sinais menores utilizando um parâmetro t , que é a variável que corresponde ao tempo de duração dos novos segmentos de áudio. Ou seja, após este processo, todos

os segmentos de áudio terão t segundos de duração, e a soma dos tempos dos áudios segmentados é igual à duração do áudio de menor período encontrado.

As fórmulas a seguir contribuirão para a realização correta da segmentação:

$$T = \frac{N}{f} \quad (3.1)$$

onde, T representa o período de duração do áudio completo, N o número de amostras do áudio ($y = [x_1, x_2, x_3, \dots, x_N]$) e f a taxa de amostragem do áudio, a qual possui um valor de 44.100 *hertz* (VERAS et al., 2019).

$$N_s = \lceil \frac{N \times t}{T} \rceil \quad (3.2)$$

$$A_s = \lceil \frac{T}{t} \rceil \quad (3.3)$$

onde, N_s representa o número de amostras de um segmento do sinal de áudio e A_s o número de novos segmentados de áudio gerados.

Com os valores de T , N_s e A_s é possível dividir o sinal do áudio y com as Fórmulas 3.4 e 3.5.

$$F(i) = i \times N_s + 1 \quad (3.4)$$

$$L(i) = N_s \times (i + 1) + 1 \quad (3.5)$$

onde, F_i e L_i são funções que definem o índice do primeiro e último elemento, respectivamente, de cada sinal dividido, e i é um valor inteiro dentro do intervalo $[1, A_s]$ que representa o número de dados divididos específicos. Assim, a Fórmula 3.6 representa um segmento de sinal.

$$Y_i = \{y_{F(i)}, y_{F(i)+1}, \dots, y_{L(i)-1}, y_{L(i)}\} \quad (3.6)$$

onde, Y_i representa um sinal de áudio dividido e $Y_i \in [y_1, \dots, y_N]$, portanto, $Y_i \in y$.

3.3.2 SAC-DM

Com a finalidade de identificar o comportamento caótico do sinal sonoro gerado por um motor BLDC, mesmo com uma única amostra de sinal e com curto período de tempo, faz-se a análise do comportamento do equilíbrio cíclico (BAZEIA et al., 2017).

Em trabalhos previamente realizados, já foram provados o comportamento caótico de motores BLDC (MEDEIROS et al., 2018). Partindo para sua aplicação, o Algoritmo 1 é utilizado para o cálculo do SAC-DM do sinal. Neste trabalho, a cada 10 amostras de sinal ($tamanhoAmostra = 10$) são encontrados os picos e é calculado a densidade de máximos.

Algoritmo 1 SAC-DM

Input: $sinal, tamanhoAmostra$
 $m \leftarrow length(sinal)$
 $tamanho \leftarrow 1 + \lceil m/tamanhoAmostra \rceil$
 $sacdm \leftarrow [0.0] \times tamanho$
 $inicio \leftarrow 0$
 $fim \leftarrow tamanhoAmostra$
para $k \leftarrow 0$ ATÉ $tamanho$ **faça**
 $picos \leftarrow encontraPicos(sinal[inicio : fim])$
 $sacdm[k] \leftarrow 1.0 \times length(picos)/tamanhoAmostra$
 $inicio \leftarrow fim$
 $fim \leftarrow fim + tamanhoAmostra$
fim para

3.4 Geração do Espectrograma

Seguindo os passos do fluxograma desta pesquisa, realiza-se a geração dos espectrogramas dos sinais de áudio pré-processados. Devido a dificuldade de realizar a classificação de sinais e ao fato de estarem retratados apenas no domínio do tempo, ocultando informações relevantes sobre a sua frequência, é gerado o espectrograma do sinal.

Isso torna explícito suas características nos domínios do tempo e da frequência, configurando o mapa de energia do sinal de áudio (LIU; CHEN; ZHENG, 2020). O seu resultado é uma imagem, que facilita o uso de redes neurais, pois é mais simples para um algoritmo de aprendizado de máquina extrair informações de uma imagem do que em um sinal puro. A Figura 23 mostra um dos espectrogramas gerados nos experimentos realizados.

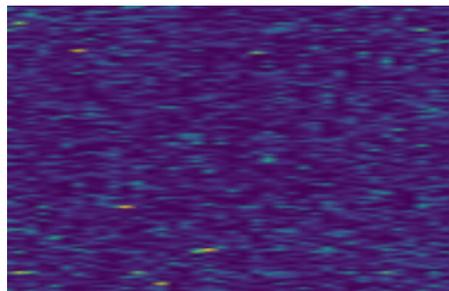


Figura 23 – Espectrograma gerado por meio do STFT. Fonte: O autor.

Para a realização do cálculo dos valores do espectrograma, como indicado na

Seção 2.3, precisa-se do sinal de entrada e de uma função de janela. Para os valores do sinal de entrada, utiliza-se os sinais obtidos na etapa de pré-processamento. Já para a função de janela, decide-se por utilizar a função de janela *Hann*. Utilizou-se essa função pois ela é simétrica e suave, o que permite uma transição suave nas bordas da janela, durante o cálculo da STFT. Uma outra vantagem da função *Hann* é que ela reduz o vazamento espectral (LYON, 2009). O vazamento espectral é uma mudança no espectro original, causado pela convolução de um sinal por uma janela, ou seja, é quando uma componente de frequência presente no sinal de entrada é espalhada em outras frequências adjacentes na saída da transformada.

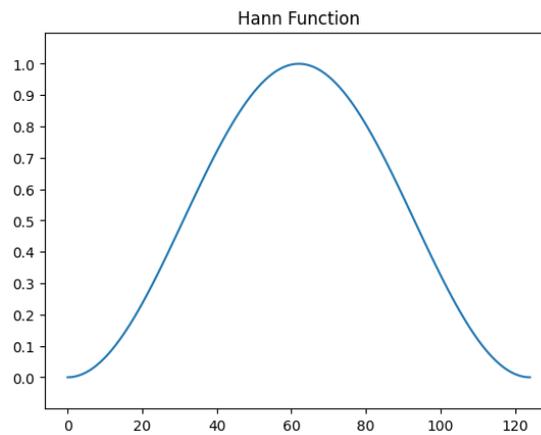


Figura 24 – Gráfico de uma função de janela *Hann*. Fonte: O autor.

3.5 Rede Neural Convolutacional

A etapa final da metodologia aplicada consiste em implementar uma rede neural convolutacional que deverá receber as imagens dos espectrogramas e distinguir entre as que apresentam algum tipo de desbalanceamento das que possuem hélices balanceadas. Realiza-se esta etapa pois os seres humanos necessitam de um método automatizado que nos ajudem a diferenciar as imagens geradas pelos espectrogramas (LIU; CHEN; ZHENG, 2020). Elas podem ser classificadas entre as classes 0, 1 e 2, e podem ser entendidas através da Tabela 3.

Tabela 3 – Classes resultantes da CNN

Classe	Descrição	Característica
0	<i>no-strip</i>	Hélice balanceada
1	<i>6-cm-strip</i>	Hélice desbalanceada com fita de 6 <i>cm</i>
2	<i>14-cm-strip</i>	Hélice desbalanceada com fita de 14 <i>cm</i>

3.5.1 Características dos Dados

Antes de criar os modelos das redes neurais, faz-se a preparação dos dados, os quais são os mesmos para os experimentos realizados no presente trabalho. Nesta etapa, 80% de todas as imagens são separadas para a etapa de treinamento, 10% para a etapa de validação e os 10% restantes são usadas para o teste da CNN. Os dados de treino fazem parte da entrada da rede neural, já os dados de validação são usados para avaliar o desempenho do modelo durante o treinamento, e com base nisso, permitir que os hiperparâmetros da CNN sejam ajustados. No entanto, é importante garantir que o modelo não esteja superajustando (*overfitting*) aos dados de treinamento, ou seja, não esteja memorizando os dados de treinamento em vez de aprender a generalizar para novos dados. Os dados utilizados para a etapa de teste não fazem parte do processo de treinamento do modelo, por esse motivo, são usados para avaliar o seu desempenho final.

Com a construção gradual do modelo da rede neural convolucional, definiu-se o número de épocas e o critério de parada para cada um dos experimentos realizados. Para o experimento que engloba os algoritmos SAC-DM e CNN (seção 4.2.1), o número de épocas usadas foi 50 e o critério de parada utilizado foi o *Early Stopping*, finalizando o treinamento do modelo quando o valor da perda (*loss*) não diminui em 5 épocas consecutivas. Já para o experimento que envolve apenas a CNN (seção 4.2.2), o número de épocas usadas foi 16 e o critério de parada utilizado foi o *Early Stopping*, idêntico ao anterior. Os valores usados para o número de épocas das CNNs foram escolhidos por meio de testes, ou seja, foram escolhidos após analisar os resultados usando outros valores, com isso identificou-se que os mencionados anteriormente foram os melhores.

3.5.2 Arquitetura da CNN

Devido à realização de dois experimentos, foram desenvolvidas duas arquiteturas, uma para cada CNN. Foram testados vários modelos de arquitetura, inclusive alguns conhecidos popularmente, como a LetNet (KAYED; ANTER; MOHAMED, 2020), porém os mostrados abaixo obtiveram os melhores resultados para a classificação.

O experimento que envolve os algoritmos SAC-DM e CNN (seção 4.2.1) apresenta uma arquitetura com 11 camadas. A primeira se trata de uma camada de *Rescaling*, pois as imagens que são utilizadas possuem três canais (RGB) digitais, e cada um de seus pixels são representados por um valor pertencente ao intervalo $[0, 255]$, o que não é ideal. Essa camada inicial, irá normalizar esses valores para que pertençam ao intervalo $[0, 1]$. Em sequência, existem cinco camadas definidas, onde são intercaladas entre uma camada convolucional, com função de ativação Relu, e uma de *pooling*. As últimas quatro camadas se tratam das camadas totalmente conectadas, onde ocorrerá a classificação das imagens processadas nas camadas anteriores. A figura 25 mostra a arquitetura utilizada para esse experimento.

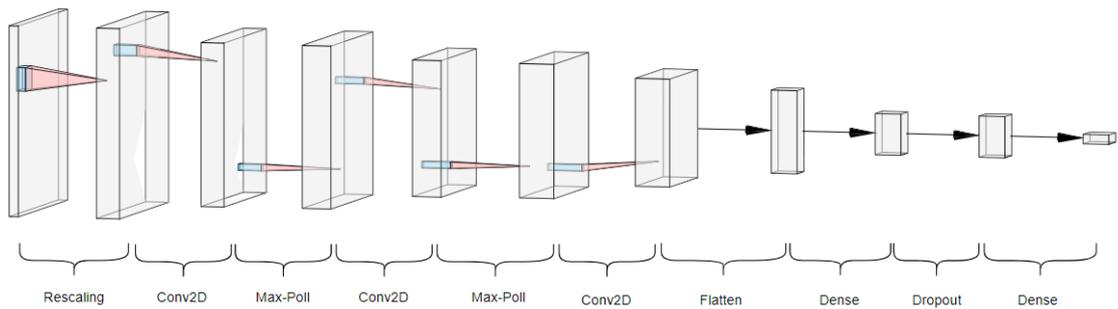


Figura 25 – Arquitetura para o experimento da seção 4.2.1, que envolve os algoritmos SAC-DM e CNN. Fonte: O autor.

O experimento que envolve o algoritmo CNN (seção 4.2.2) apresenta uma arquitetura com 12 camadas. A primeira se trata de uma camada de *Rescaling*, idêntica à mencionada anteriormente. Em sequência, existem sete camadas definidas, onde são intercaladas entre uma camada convolucional, com função de ativação Relu, e uma de *pooling*. As últimas quatro camadas se tratam das camadas totalmente conectadas, onde ocorrerá a classificação das imagens processadas nas camadas anteriores. A figura 26 mostra a arquitetura utilizada para esse experimento.

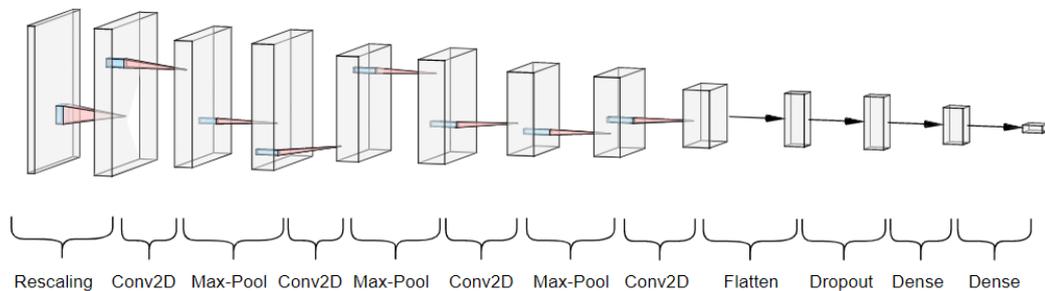


Figura 26 – Arquitetura para o experimento da seção 4.2.2, que envolve o algoritmo CNN. Fonte: O autor.

Resultados

Este capítulo destina-se à apresentação dos experimentos e dos resultados encontrados. Cada um dos experimentos tiveram suas particularidades para que fosse possível se obter resultados satisfatórios. Foram utilizados sinais de áudio de um motor BLDC com uma hélice, onde esses sinais foram os mesmos utilizados em Vérias et al. (2019). Graças à isso, também é realizado um comparativo dos resultados encontrados por ele e toma-se as conclusões do poder de performance do uso do algoritmo SAC-DM no presente trabalho.

Na Seção 4.1 é realizada uma breve descrição da origem dos dados usados. Na seção 4.2 é explicado como foi feito a divisão dos experimentos, assim como os critérios adotados para a execução de cada um deles e seus resultados. Na seção 4.3 é apresentado o comparativo entre os resultados encontrados nesta pesquisa e os resultados achados em outros trabalhos.

4.1 Dados utilizados

Os sinais usados formam uma parte dos dados utilizados no trabalho de Vérias et al. (2019). Enquanto ele faz seu estudo com velocidades do ESC em 50%, 60%, 70%, 80% e 90% da velocidade máxima, os testes envolveram apenas áudios de motores com velocidades do ESC em 70%, 80% e 90% da velocidade máxima. Outro diferencial dos dados usados entre as pesquisas foram os tamanhos de fitas presas às hélices. Vérias et al. (2019) utiliza fitas de 6 cm, 14 cm e 22 cm, enquanto nesta pesquisa foram utilizadas apenas áudios sem fitas presas à hélice, com fitas de 6 cm e 14 cm. A Tabela 4 mostra especificamente os áudios usados no trabalho e suas características.

Tabela 4 – Áudios usados e características

Arquivo	Fita	Velocidade (%)
no_strip_70_0.WAV	no-strip	70
no_strip_80_0.WAV	no-strip	80
no_strip_90_0.WAV	no-strip	90
strip6_70_0.WAV	6-cm-strip	70
strip6_80_0.WAV	6-cm-strip	80
strip6_90_0.WAV	6-cm-strip	90
strip14_70_0.WAV	14-cm-strip	70
strip14_80_0.WAV	14-cm-strip	80
strip14_90_0.WAV	14-cm-strip	90

4.2 Divisão dos Experimentos

Neste trabalho os experimentos foram separados em dois. O primeiro, apresentado em 4.2.1, possui o objetivo de aplicar um algoritmo de aprendizado de máquina sobre os sinais gerados pelo algoritmo SAC-DM. O segundo, apresentado em 4.2.2, possui o objetivo de aplicar um algoritmo de aprendizado de máquina sobre os sinais de áudio de um motor BLDC e foi realizado para que o seu resultado pudesse ser equiparado com o resultado obtido no primeiro experimento.

4.2.1 Aplicação do algoritmo de aprendizado de máquina sobre o sinal gerado pelo SAC-DM

Este é o principal experimento da pesquisa realizada, é com o seu resultado que serão comparados os resultados do segundo e o de outros trabalhos. Esta parte do trabalho compreende em incluir a aplicação do algoritmo do SAC-DM na etapa de pré-processamento e após isso, usar uma rede neural convolucional que classifica os dados gerados. Com isso, a rede neural deverá categorizar os sinais de acordo com as classes *no-strip*, *6-cm-strip* e *14-cm-strip*. No começo, realiza-se a etapa de pré-processamento, as quais englobam a segmentação e aplicação do algoritmo SAC-DM sobre os sinais de áudio.

A segmentação é efetuada para conseguir uma quantidade maior de áudios, considerando que os novos sinais segmentados terão um tempo de duração menor, porém suficientes. Nesta etapa, constatou-se que o áudio de menor valor de T possui, aproximadamente, 60,23 segundos. Tendo esse conhecimento, utilizou-se um valor t de 6 segundos para segmentá-los, gerando dez novos sinais para cada sinal de áudio da Tabela 4, a partir das fórmulas presentes na Seção 3.3.1. Ao final, soma-se um total de 90 sinais para a realização da pesquisa.

Para o fim do pré-processamento, aplica-se o SAC-DM sobre os segmentos de áudio gerados. O número de amostras de valor 10 é mandado como parâmetro para o algoritmo, ou seja, a cada 10 amostras de sinal é calculado a densidade de máximos. Esse processo irá gerar um sinal 10 vezes menor que o original. A figura 27 mostra alguns sinais após a etapa de pré-processamento.

Número de amostras x Amplitude

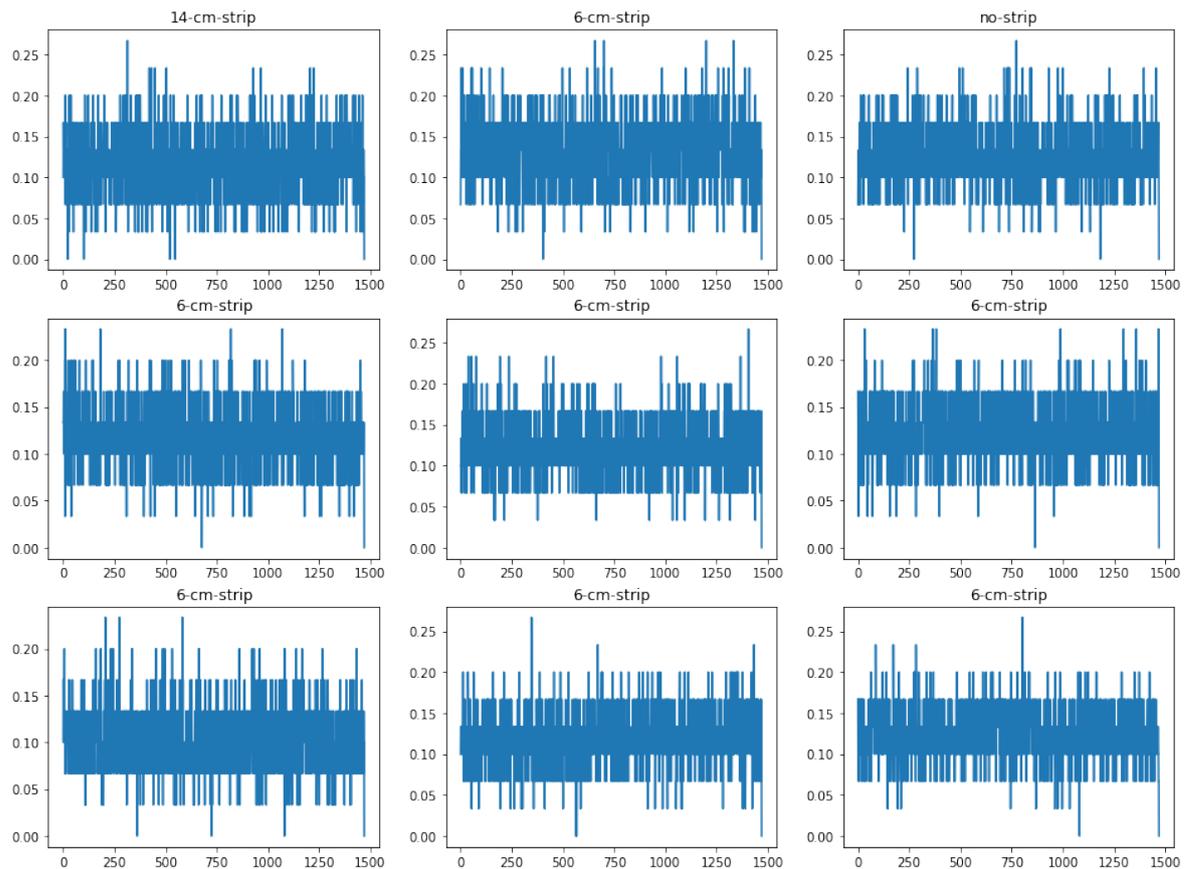


Figura 27 – Sinais de áudio segmentados e aplicados ao SAC-DM. Fonte: O autor.

Com os sinais gerados pelo SAC-DM, realiza-se a geração do espectrograma de cada um deles. Essa abordagem é realizada pois ela converte o sinal em uma imagem no domínio do tempo e frequência, trazendo uma maior detalhamento de informação dos dados para aplicar na rede neural. A Figura 28 apresenta alguns dos áudios pré-processados no formato de espectrograma.

Frequência x Tempo

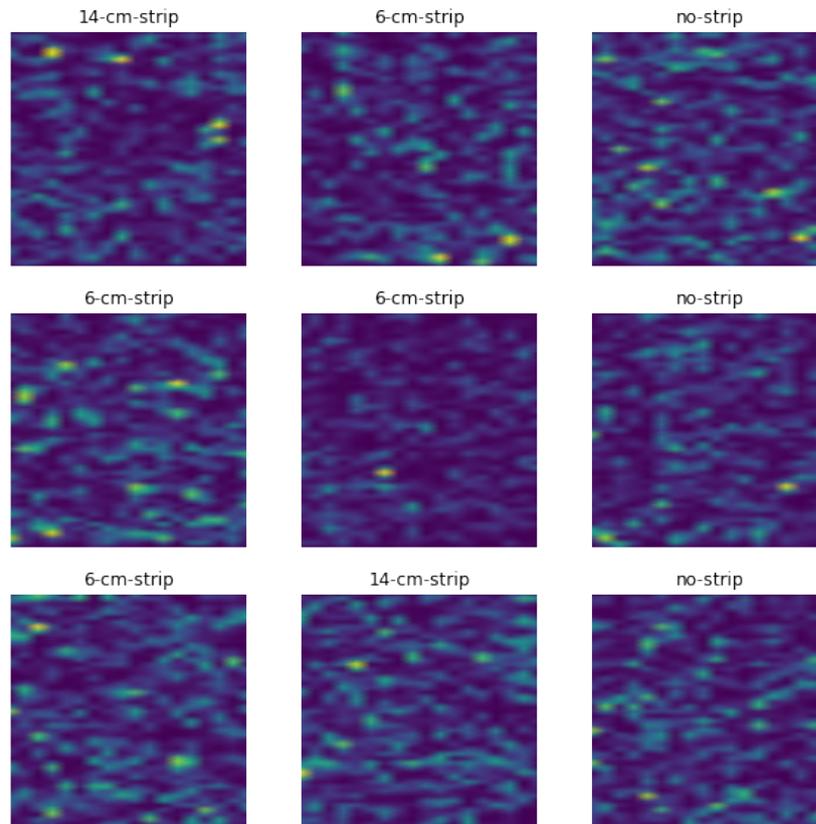


Figura 28 – Espectrogramas gerados a partir dos áudios pré-processados. Fonte: O autor.

4.2.1.1 Resultados da CNN sobre os espectrogramas dos sinais gerados pelo SAC-DM

As imagens geradas foram aplicadas ao modelo da CNN, demonstrada pela arquitetura da figura 25. Após executar o modelo, foi encontrada uma acurácia de 71,43% sobre o *dataset* de teste. A Figura 29 mostra que a acurácia aumenta nas etapas de treinamento e validação, implicando que o modelo está aprendendo à medida que se passam as épocas. A imagem também indica o decaimento da perda, significando que o modelo está definindo os pesos dos atributos corretamente.

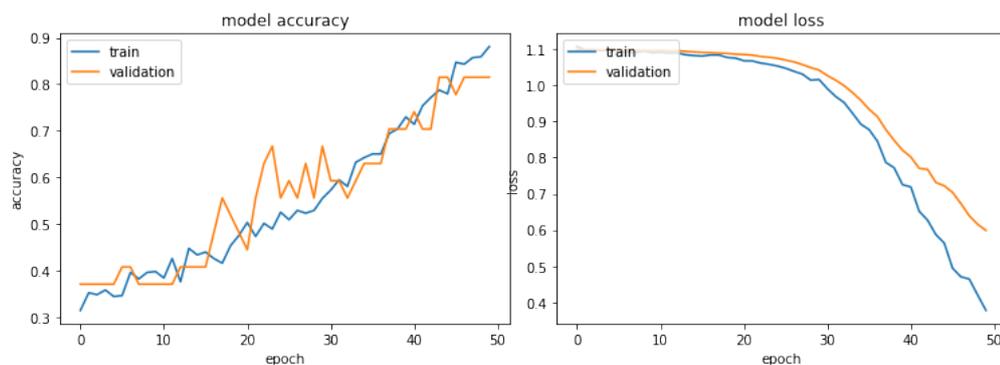


Figura 29 – Gráficos da acurácia e perda para os *datasets* de treino e validação. Fonte: O autor.

Para avaliar o desempenho dos resultados obtidos, exibe-se a matriz de confusão, a qual é organizada em linhas e colunas, onde cada linha representa a classe real dos dados e cada coluna representa a classe prevista pelo modelo. O número de linhas e colunas na matriz de confusão depende do número de classes do problema, e como a CNN analisada possui três classes resultantes, temos uma matriz de dimensão 3 x 3. A figura 30 mostra a matriz de confusão dos resultados obtidos sobre *dataset* de teste. Através dessa imagem, pode-se observar que houveram um total de 8 imagens classificadas incorretamente, ou seja, ao se somar os números que estão fora da diagonal principal, obtém-se esse valor total. A diagonal principal mostra a quantidade de imagens que foram classificadas corretamente, de acordo com as classes, totalizando 20 imagens.

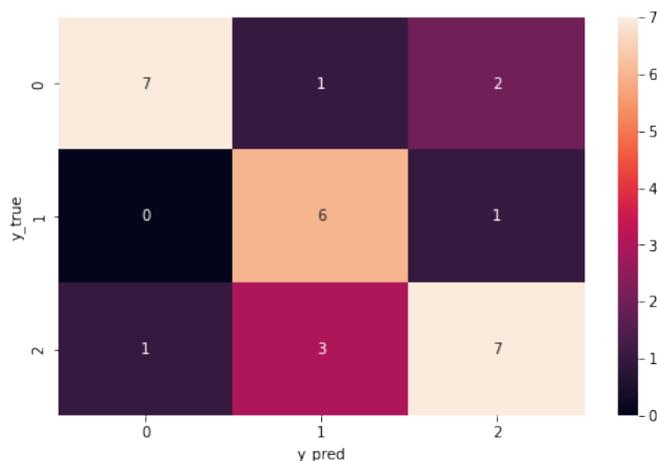


Figura 30 – Matriz de confusão dos resultados do *dataset* de teste. Fonte: O autor.

4.2.2 Aplicação do algoritmo de aprendizado de máquina sobre o sinal de áudio

Este experimento consiste em aplicar uma rede neural convolucional que realiza a classificação dos áudios importados, para comparação com o experimento anterior. Inicialmente os sinais de áudio passam por uma etapa de pré-processamento, onde é realizada a sua segmentação.

A segmentação é efetuada para conseguir uma quantidade maior de áudios, considerando que os novos sinais segmentados terão um tempo de duração menor, porém suficientes. Essa etapa ocorre exatamente da mesma forma apresentada na seção anterior (4.2.1). Com os áudios já segmentados, conclui-se o pré-processamento para este experimento e o resultado obtido é representado através da figura 31.

Número de amostras x Amplitude

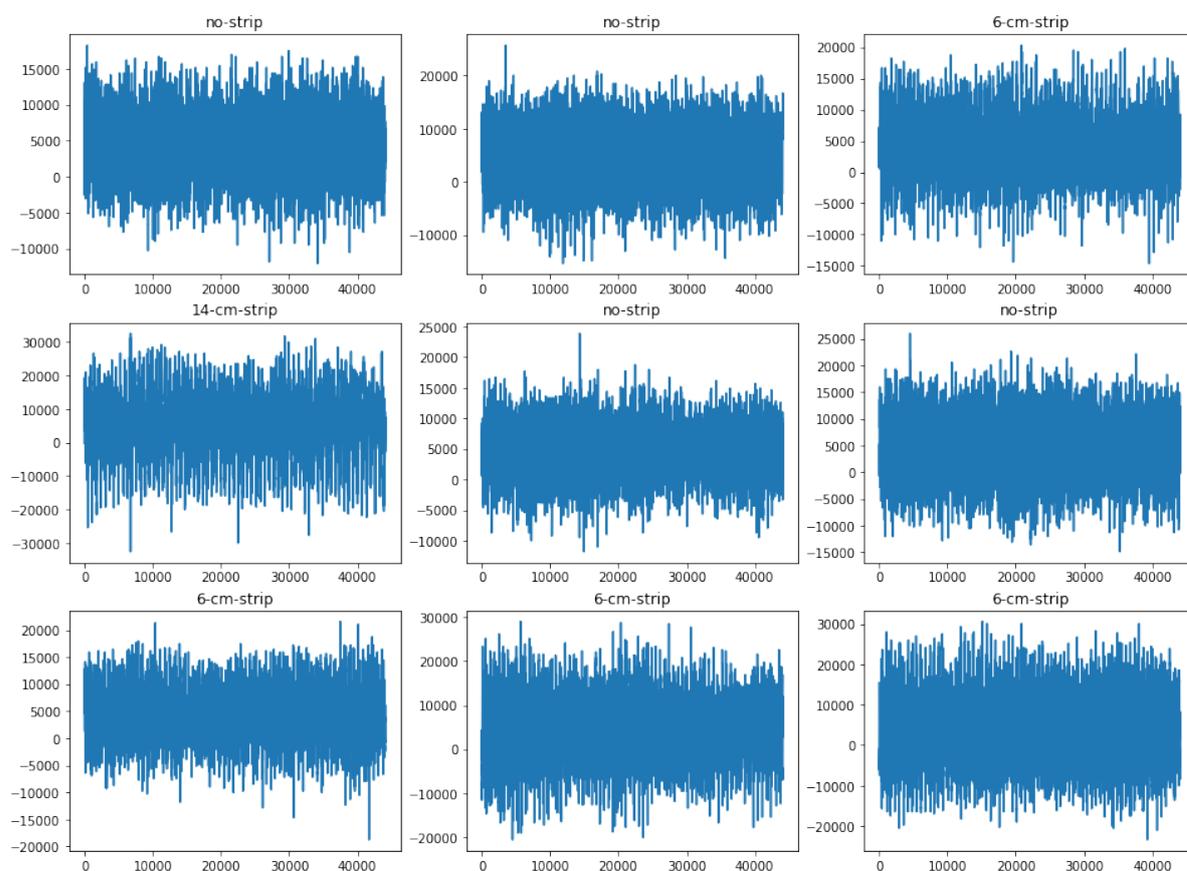


Figura 31 – Sinais de áudio segmentados. Fonte: O autor.

Com os novos sinais de áudio, realiza-se a geração do espectrograma de cada um deles. A Figura 32 apresenta alguns dos áudios pré-processados no formato de espectrograma.

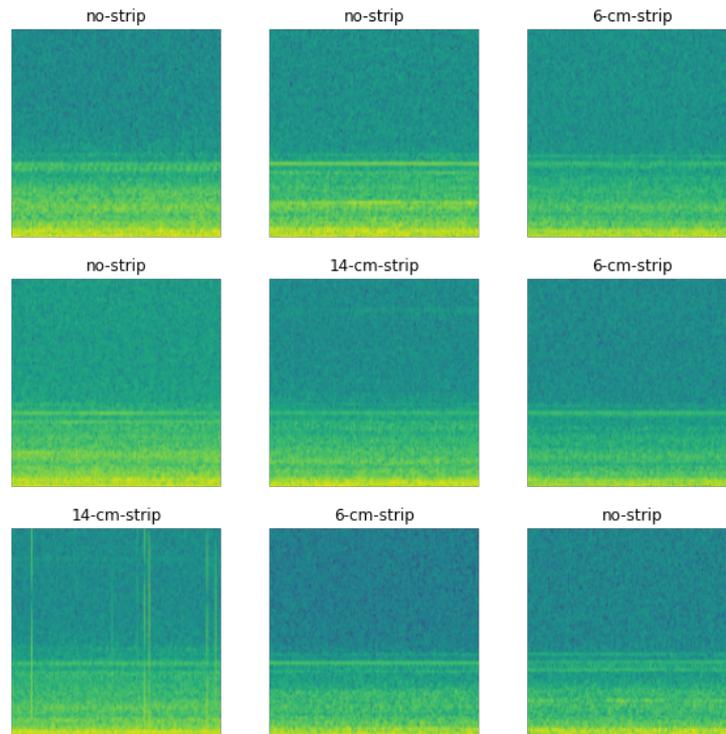


Figura 32 – Espectrogramas gerados a partir dos áudios pré-processado. Fonte: O autor.

4.2.2.1 Resultados da aplicação da rede neural sobre os espectrogramas dos sinais de áudio

Os espectrogramas criados são aplicados no modelo da CNN, o qual possui arquitetura representada pela figura 26. Após executar o modelo, foi possível encontrar uma acurácia de 98,21% sobre o *dataset* de teste. A Figura 33 mostra que a rede neural apresenta um comportamento semelhante ao do primeiro experimento, diferenciando apenas que, neste, o modelo demora menos até se estabilizar.

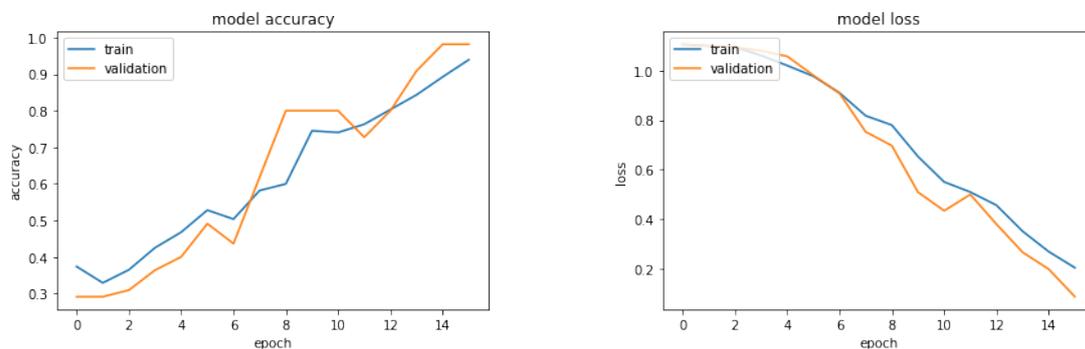


Figura 33 – Gráficos da acurária e perda para os *datasets* de treino e validação. Fonte: O autor.

A figura 34 mostra a matriz de confusão dos resultados obtidos sobre *dataset* de teste. Através dessa imagem, pode-se observar que houve uma única imagem que foi classificada incorretamente, pois na figura, a soma dos valores fora da diagonal principal é 1. Já o total de imagens classificadas corretamente, soma-se um total de 55 imagens.

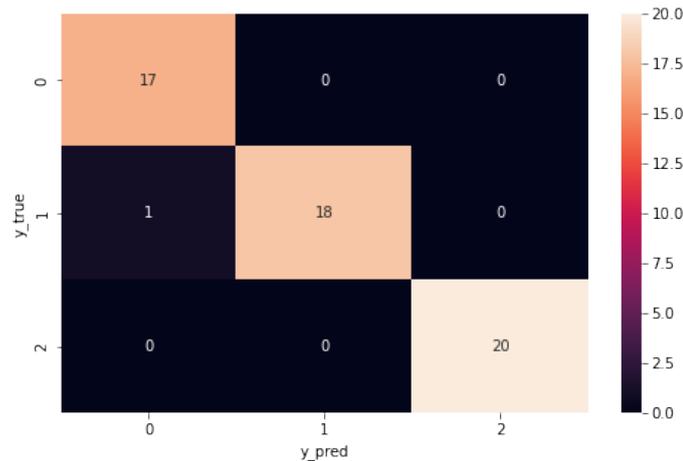


Figura 34 – Matriz de confusão dos resultados do *dataset* de teste. Fonte: O autor.

4.3 Comparação do Resultados

Esta seção realiza a comparação dos resultados dos experimentos realizados nesta pesquisa e nos resultados encontrados em trabalhos relacionados. A Tabela 6 mostra essas informações e também os dados de cada trabalho, possibilitando fazer um comparativo e posteriormente chegar a uma conclusão à respeito da metodologia usada nesta pesquisa.

A tabela 5 detalha os resultados obtidos nos dois experimentos, os quais são identificados por Experimento 1 (Seção 4.2.1.1) e Experimento 2 (Seção 4.2.2.1), onde o primeiro engloba os algoritmos SAC-DM e CNN, enquanto o segundo engloba o algoritmo CNN.

Tabela 5 – Resultados dos experimentos

Experimento	Dataset	Algoritmos usados	Acurácia
Experimento 1	Validação	SAC-DM, CNN	81.48%
Experimento 1	Teste	SAC-DM, CNN	71.43%
Experimento 2	Validação	CNN	98.18%
Experimento 2	Teste	CNN	98.21%

Para efeito comparativo, toma-se o Experimento 1, como objeto principal, ou seja, compara-se o seu resultado com os encontrados no Experimento 2 e em outros trabalhos, como mostrados na Tabela 6. Para o trabalho de Vêras et al. (2019), faz-se uma média dos resultados encontrados, sem o uso da transformada de Wavelet, em seu trabalho. Em Medeiros et al. (2018) também é feita a média dos resultados encontrados. Para esses dois trabalhos, preferiu-se fazer a média da acurácia encontrada, pois neles são apresentadas as acurácias de forma separada para cada velocidade de motor analisada, enquanto no presente trabalho a acurácia é calculada a partir das três velocidades, 70%, 80% e 90% analisadas de forma conjunta. Em Altinors, Yol e Yaman (2021) foram encontrados vários

valores distintos para a classificação, pois para o mesmo problema, foi utilizado diversos algoritmos de classificação, e, por isso, não foi trazida uma média dos resultados desse trabalho.

Tabela 6 – Trabalhos que envolvem detecção de falha em motores BLDC

Autor	Técnica utilizada	Acurácia (%)
Experimento 1	SAC-DM, CNN	71,43
Experimento 2	CNN	98,21
Yaman, Yol e Altinors (2022)	MFCC, SVM	Hélicoptero - 100 Duocóptero - 100 Tricóptero - 99,06 Quadcóptero - 90,53
Iannace, Ciaburro e Trematerra (2019)	Análise de frequência, Filtro passa-banda	97,63
Guo et al. (2018)	STFT, CNN	99,60
Sadhu, Zonouz e Pompili (2020)	CNN, LSTM	90
Véras et al. (2019)	SAC-DM, Wavelet	≈ 78,59 (média)
Medeiros et al. (2018)	SAC-DM	≈ 85,61 (média)

Considerações Finais

5.1 Conclusões

Neste trabalho foi apresentado duas metodologias para a detecção de desbalanceamento de uma hélice acoplada a um motor BLDC, operando a uma velocidade fixa e conhecida, por meio do SAC-DM e de uma CNN. O método proposto foi validado através de dois experimentos, sendo o primeiro (seção 4.2.1.1) a aplicação prática da estrutura elaborada nesta pesquisa, enquanto o segundo (seção 4.2.2.1) é realizado para confirmação do benefício do uso do SAC-DM em conjunto com uma CNN. Com as informações obtidas no Capítulo 4, pode-se chegar a conclusão que o método proposto no primeiro experimento apresenta uma acurácia confiável, porém não possui o melhor resultado para a detecção de falhas no balanceamento do motor BLDC.

O objetivo geral e os objetivos específicos foram totalmente atingidos. É realizado a comparação entre duas metodologias, onde a primeira realiza a detecção de falhas de balanceamento em motores BLDC através dos algoritmos SAC-DM, o qual foi necessário realizar sua implementação, e CNN, enquanto a segunda é realizada por meio de uma CNN.

Através do pré-processamento (segmentação e aplicação do SAC-DM) dos sinais de áudio, geração do espectrograma e a aplicação de uma rede neural convolucional, foi possível realizar a classificação dos áudios pré-processados com uma acurácia de 71,43%, como é possível observar nos resultados do primeiro experimento. Para efeito de comparação, é realizado o segundo experimento, o qual passa pelas etapas de pré-processamento (segmentação), geração do expectrograma e aplicação de uma CNN. Nesse, encontrou-se uma acurácia de 98,21%. Apesar de ter encontrado um resultado menos preciso, ao comparar o experimento 1 com experimento 2, o primeiro ainda se sobressai ao comparar cenários específicos de outros trabalhos, como exibido na Tabela 6.

Com essas informações conhecidas, e também, com os dados dispostos na tabela

6, podemos responder os questionamentos dispostos na seção 1.1.3. Segue abaixo os questionamentos realizados, juntamente com as suas respectivas respostas.

❑ **A técnica CNN pode ser mais vantajosa do que a SAC-DM?**

Ao observar a tabela 6, e agrupar as pesquisas que utilizam o SAC-DM e CNN, pode-se notar que os resultados que envolvem a técnica do SAC-DM são menores que as que envolvem a CNN. Por isso, pode-se dizer, a partir dos resultados encontrados e dos resultados de pesquisas conhecidas, que a técnica de CNN é mais vantajosa que a do SAC-DM.

❑ **Quais os prós e contras em utilizar CNN ao invés de SAC-DM?**

De acordo com os resultados exibidos na tabela 6, pode-se dizer que a principal vantagem de se utilizar a CNN é o grau de confiabilidade do resultado que esse algoritmo traz, sendo maior que os resultados do SAC-DM. Outra vantagem de se usar a CNN é que ela consegue aprender características a partir do sinal de entrada, sem haver, de forma obrigatória, um pré-processamento dos dados. Em termos de desvantagem, pode-se dizer que a CNN depende da quantidade de dados utilizados para o seu treinamento, ou seja, quanto mais dados, melhor vai ser o aprendizado e vice-versa. Outra desvantagem é que treinar uma CNN pode exigir recursos computacionais significativos e tempo de processamento prolongado devido ao número de parâmetros configurados na rede e ao tamanho do conjunto de dados.

❑ **A combinação de SAC-DM e CNN pode trazer melhores resultados?**

De acordo com o experimento realizado no presente trabalho, pode-se dizer que a combinação dessas duas técnicas não trouxe resultados melhores. Porém, essa é a primeira pesquisa que aborda essa combinação, logo, ainda há espaço para realização de melhorias em trabalhos posteriores, como utilizar outras arquiteturas de CNN e adquirir um conjunto de dados maior.

5.2 Trabalhos Futuros

Em trabalhos futuros, pretende-se realizar a análise da velocidade do motor BLDC por meio do SAC-DM e da aplicação de uma CNN, visando detectar a velocidade de rotação desse motor por meio do som. Para isso, será adotado uma metodologia semelhante ao presente trabalho. Será coletado áudios de motores BLDC balanceados, onde esses áudios passarão pelas etapas de segmentação, aplicação do SAC-DM e normalização. Em seguida, será gerado os espectrogramas dos sinais resultantes desse pré-processamento com a finalidade de gerar imagens que servirão de entrada para um modelo de rede neural convolucional.

Também como trabalho futuro, cogita-se realizar a detecção de falhas em outros modelos de motores, diferentes do BLDC, utilizando o mesmo modelo criado na presente pesquisa, e utilizando a técnica de *Transfer Learning*. Nessa proposta, o modelo da rede neural terá seu treinamento realizado previamente e será aplicado a um novo cenário, detecção de falhas em motores diferentes do BLDC. Ou seja, o conhecimento adquirido para resolver um problema específico, será utilizado para resolver um problema diferente.

Por fim, também é proposto uma nova abordagem de geração de espectrograma envolvendo apenas o algoritmo SAC-DM. Considerando que o espectrograma gerado através da STFT é realizado à partir de uma convolução por meio de janelas, pretende-se analisar o resultado do uso do SAC-DM em janelas de tempo, com finalidade de se obter um sinal de saída no domínio do tempo e da frequência, da mesma maneira que ocorre com a Transformada de Fourier.

Referências

- ALBAWI, S.; MOHAMMED, T. A.; AL-ZAWI, S. Understanding of a convolutional neural network. In: **2017 International Conference on Engineering and Technology (ICET)**. [S.l.: s.n.], 2017. p. 1–6.
- ALTINORS, A.; YOL, F.; YAMAN, O. A sound based method for fault detection with statistical feature extraction in uav motors. **Applied Acoustics**, Elsevier, v. 183, p. 108325, 2021.
- BAZEIA, D. et al. A novel procedure for the identification of chaos in complex biological systems. **Scientific reports**, Nature Publishing Group, v. 7, n. 1, p. 1–9, 2017.
- BIRX, D.; PIPENBERG, S. Chaotic oscillators and complex mapping feed forward networks (cmffns) for signal detection in noisy environments. In: [**Proceedings 1992 IJCNN International Joint Conference on Neural Networks**]. [S.l.: s.n.], 1992. v. 2, p. 881–888 vol.2.
- CALOU, V. B. C. et al. The use of uavs in monitoring yellow sigatoka in banana. **Biosystems Engineering**, Elsevier, v. 193, p. 115–125, 2020.
- CHEN, A. Y. et al. A review of rotorcraft unmanned aerial vehicle (uav) developments and applications in civil engineering. **Smart Struct. Syst**, Citeseer, v. 13, n. 6, p. 1065–1094, 2014.
- CHOLLET, F. **Deep learning with Python**. [S.l.]: Simon and Schuster, 2021.
- DENG, C. et al. Unmanned aerial vehicles for power line inspection: A cooperative way in platforms and communications. **J. Commun.**, v. 9, n. 9, p. 687–692, 2014.
- DHILLON, A.; VERMA, G. K. Convolutional neural network: a review of models, methodologies and applications to object detection. **Progress in Artificial Intelligence**, Springer, v. 9, n. 2, p. 85–112, 2020.
- 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: **2015 IEEE Metrology for Aerospace (MetroAeroSpace)**. [S.l.: s.n.], 2015. p. 356–361.

- GOKYILDIRIM, A.; UYAROGLU, Y.; PEHLIVAN, I. A novel chaotic attractor and its weak signal detection application. **Optik**, v. 127, n. 19, p. 7889–7895, 2016. ISSN 0030-4026. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0030402616306039>>.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. [S.l.]: MIT Press, 2016. <<http://www.deeplearningbook.org>>.
- GUO, D. et al. A hybrid feature model and deep learning based fault diagnosis for unmanned aerial vehicle sensors. **Neurocomputing**, Elsevier, v. 319, p. 155–163, 2018.
- HAYKIN, S.; VEEN, B. V. **Sinais E Sistemas**. Bookman, 2001. ISBN 9788573077414. Disponível em: <<https://books.google.com.br/books?id=tdNYclZwaYIC>>.
- IANNACE, G.; CIABURRO, G.; TREMATERRA, A. Fault diagnosis for uav blades using artificial neural network. **Robotics**, MDPI, v. 8, n. 3, p. 59, 2019.
- JAFARI, A.; FAIZ, J.; JARRAHI, M. A. A simple and efficient current-based method for interturn fault detection in bldc motors. **IEEE Transactions on Industrial Informatics**, v. 17, n. 4, p. 2707–2715, 2021.
- JOHNSON, D. **Fundamentals of Electrical Engineering I**. University Press of Florida, 2008. ISBN 9781616100377. Disponível em: <<https://legacy.cnx.org/content/col10040/1.9/>>.
- JUNG, W.; BANG, H. Fault and failure tolerant model predictive control of quadrotor uav. **International Journal of Aeronautical and Space Sciences**, Springer, v. 22, p. 663–675, 2021.
- KATTENBORN, T. et al. Review on convolutional neural networks (cnn) in vegetation remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, Elsevier, v. 173, p. 24–49, 2021.
- KAYED, M.; ANTER, A.; MOHAMED, H. Classification of garments from fashion mnist dataset using cnn lenet-5 architecture. In: IEEE. **2020 international conference on innovative trends in communication and computer engineering (ITCE)**. [S.l.], 2020. p. 238–243.
- KEHTARNAVAZ, N. **Digital signal processing system design: LabVIEW-based hybrid programming**. [S.l.]: Elsevier, 2011.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **nature**, Nature Publishing Group UK London, v. 521, n. 7553, p. 436–444, 2015.
- LIU, K. et al. Breast cancer classification based on fully-connected layer first convolutional neural networks. **IEEE Access**, v. 6, p. 23722–23732, 2018.
- LIU, W.; CHEN, Z.; ZHENG, M. An audio-based fault diagnosis method for quadrotors using convolutional neural network and transfer learning. In: IEEE. **2020 American Control Conference (ACC)**. [S.l.], 2020. p. 1367–1372.
- LOUARGANT, M. et al. Weed detection by uav: Simulation of the impact of spectral mixing in multispectral images. **Precision Agriculture**, Springer, v. 18, n. 6, p. 932–951, 2017.

- LYON, D. A. The discrete fourier transform, part 4: spectral leakage. **Journal of object technology**, v. 8, n. 7, 2009.
- MEDEIROS, R. L. et al. A novel approach for speed and failure detection in brushless dc motors based on chaos. **IEEE Transactions on Industrial Electronics**, IEEE, v. 66, n. 11, p. 8751–8759, 2018.
- MOHANRAJ, D. et al. A review of bldc motor: State of art, advanced control techniques, and applications. **IEEE Access**, v. 10, p. 54833–54869, 2022.
- MORBIDI, F.; CANO, R.; LARA, D. Minimum-energy path generation for a quadrotor uav. In: **2016 IEEE International Conference on Robotics and Automation (ICRA)**. [S.l.: s.n.], 2016. p. 1492–1498.
- MUNDOGEO. **Crescimento do mercado de drones será constante nos próximos anos**. 2021. Disponível em: <<https://mundogeo.com/2021/07/22/crescimento-do-mercado-de-drones-sera-constante-nos-proximos-anos/>>.
- OPPENHEIM, A. et al. **Sinais e Sistemas**. 2. ed. São Paulo: Pearson, 2010. 592 p. ISBN 857605504X.
- PETRITOLI, E.; LECCESE, F.; CIANI, L. Reliability assessment of uav systems. In: IEEE. **2017 IEEE International Workshop on Metrology for AeroSpace (MetroAeroSpace)**. [S.l.], 2017. p. 266–270.
- POURPANAH, F. et al. Anomaly detection and condition monitoring of uav motors and propellers. In: **2018 IEEE SENSORS**. [S.l.: s.n.], 2018. p. 1–4.
- SADHU, V.; ZONOUZ, S.; POMPILI, D. On-board deep-learning-based unmanned aerial vehicle fault cause detection and identification. In: IEEE. **2020 IEEE International Conference on Robotics and Automation (ICRA)**. [S.l.], 2020. p. 5255–5261.
- SILVAGNI, M. et al. Multipurpose uav for search and rescue operations in mountain avalanche events. **Geomatics, Natural Hazards and Risk**, Taylor & Francis, v. 8, n. 1, p. 18–33, 2017.
- VERAS, F. C. et al. Eccentricity failure detection of brushless dc motors from sound signals based on density of maxima. **IEEE Access**, IEEE, v. 7, p. 150318–150326, 2019.
- VÉRAS, F. C. L. et al. Detecção de velocidade e de falha de excentricidade em motores elétricos a partir de sinais sonoros utilizando densidade de máximos. Universidade Federal da Paraíba, 2019. Disponível em: <<https://repositorio.ufpb.br/jspui/handle/123456789/19191>>.
- YAMAN, O.; YOL, F.; ALTINORS, A. A fault detection method based on embedded feature extraction and svm classification for uav motors. **Microprocessors and Microsystems**, Elsevier, v. 94, p. 104683, 2022.
- YEDAMALE, P. Brushless dc (bldc) motor fundamentals. **Microchip Technology Inc**, v. 20, n. 1, p. 3–15, 2003.