



**Universidade Federal da Paraíba**  
**Centro de Tecnologia**  
**Programa de Pós-Graduação em Engenharia Mecânica**  
Mestrado – Doutorado



**DETECÇÃO DE VELOCIDADE E DE  
FALHA DE EXCENTRICIDADE EM  
MOTORES ELÉTRICOS A PARTIR DE  
SINAIS SONOROS UTILIZANDO  
DENSIDADE DE MÁXIMOS**

por

**FRANK CÉSAR LOPES VÉRAS**

*Tese de Doutorado apresentado à Universidade Federal da  
Paraíba para obtenção do grau de Doutor*

FRANK CÉSAR LOPES VÉRAS

**DETECÇÃO DE VELOCIDADE E DE FALHA DE  
EXCENTRICIDADE EM MOTORES ELÉTRICOS A  
PARTIR DE SINAIS SONOROS UTILIZANDO  
DENSIDADE DE MÁXIMOS**

Tese de Doutorado submetida ao Programa de Pós-Graduação em Engenharia Mecânica do Centro de Tecnologia da Universidade Federal da Paraíba em cumprimento às exigências para obtenção do grau de Doutor em Ciências no Domínio da Engenharia Mecânica.

**Orientador: Prof. Dr. Abel Cavalcante Lima Filho**  
**Coorientador: Prof. Dr. Alisson Vasconcelos de Brito**

João Pessoa – Paraíba, Brasil

©Frank César Lopes Vêras – frank@ufpi.edu.br

**Catálogo na publicação**  
**Seção de Catalogação e Classificação**

V476d Veras, Frank Cesar Lopes.

Detecção de velocidade e de falha de excentricidade em motores elétricos a partir de sinais sonoros utilizando densidade de máximos / Frank Cesar Lopes Veras. - João Pessoa, 2019.

140 f.

Orientação: Abel Cavalcante Lima Filho.

Coorientação: Alisson Vasconcelos de Brito.

Tese (Doutorado) - UFPB/PPGEM.

1. Motores BLDC, Teoria do Caos, Análise de Sinais. I. Abel Cavalcante Lima Filho. II. Alisson Vasconcelos de Brito. III. Título.

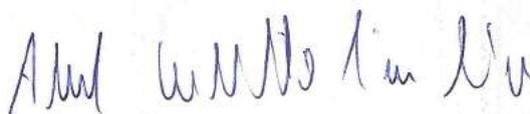
UFPB/BC

**DETECÇÃO DE VELOCIDADE E DE FALHA DE  
EXCENTRICIDADE EM MOTORES DE CORRENTE CONTÍNUA  
SEM ESCOVAS A PARTIR DE SINAIS SONOROS  
UTILIZANDO DENSIDADE DE MÁXIMOS**

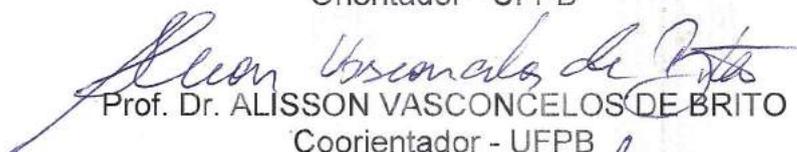
por

**FRANK CESAR LOPES VERAS**

*Tese aprovada em 30 de julho de 2019*



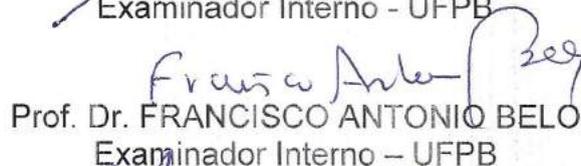
Prof. Dr. ABEL CAVALCANTE LIMA FILHO  
Orientador - UFPB



Prof. Dr. ALISSON VASCONCELOS DE BRITO  
Coorientador - UFPB



Prof. Dr. CICERO DA ROCHA SOUTO  
Examinador Interno - UFPB



Prof. Dr. FRANCISCO ANTONIO BELO  
Examinador Interno - UFPB



Prof. Dr. JORGE GABRIEL GOMES DE SOUZA RAMOS  
Examinador Externo - UFPB



Prof. Dr. ELMAR UWE KURT MELCHER  
Examinador Externo - UFCG

*"Somos afligidos de todos os lados, mas não vencidos pela angústia; postos entre os maiores apuros, mas sem perder a esperança; perseguidos, mas não desamparados; derrubados, mas não aniquilados; por toda parte e sempre levamos em nós mesmos os sofrimentos mortais de Jesus, para que também a vida de Jesus seja manifestada em nossos corpos." (2Cor 4, 6-11)*

## Dedicatória

*Dedico este trabalho a minha esposa, Karina, que com sua força, derminação e amor incomensuráveis, trouxe o alento, o estímulo e as palavras necessárias a mim e a nossos filhos. Pela sua paciência, dedicação e companheirismo, minha vida encontrou o caminho do amor verdadeiro e que nos une matrimonialmente ao Deus Pai do Céu. Dedico, igualmente, aos meus filhos, Samuel César, Maria Luara e Miguel César, por existirem e transformarem minha vida e a minha essência, como pessoa, homem, marido e pai. A chegada de cada um de vocês, esposa e filhos, guiou, guia e continuará guiando meus passos. Amo vocês, meus queridos Doutores!!*

# Agradecimentos

Agradeço a Deus, incomparável e imensamente, por estar sempre ao nosso lado, salvando, orientando, guardando, mostrando o Seu Amor Maior e, conseqüentemente, aliviando todas as preocupações e temores que surgiram ao longo desta e de todas as demais fases de minha vida.

Aos meus amados pais, Francisco Xavier Vêras e Ana Raimunda Lopes Vêras, pela educação primorosa que dedicaram a cada um de seus filhos. Sei que o fizeram respaldados no amor de Deus e na própria educação recebida de meus estimados avós (*in memoriam*), nos quais os agradeço com saudades: Antônio Domingues Vêras e Ideltrudes Alves Vêras - Avós Paternos; Pedro de Oliveira Lopes e Ana Maria de Araújo Lopes - Avós Maternos. Assim, sou agradecido aos meus pais por me apresentaram à vida, falando sobre o respeito, a simplicidade e a honestidade. Com este fraterno cuidado, os momentos de dúvidas foram muito mais suaves. Sou grato pelo amor e entrega ao longo de todos esses anos, por todo apoio, muitas vezes sem a mínima condição, mas que o fizeram com todo zelo.

Aos meus amados irmãos, Fernanda Lopes Vêras, Fábio Lopes Vêras, Cibele Lopes Vêras e Cinara Lopes Vêras, seus esposos e esposas, Fredson, Jane Kércia e Ezequiel, meus sobrinhos(as), Pedro César (afilhado), Pietra Ceres, Paula Cilene, Camila, Pedro Vitor (afilhado de consagração) e Anna Júlia. Agradeço pela calorosa, alegre e amorosa convivência ao longo desses anos, sempre buscando a união e a alegria entre todos nós. Crescer com todos vocês foi, tem sido e será, sempre, uma dádiva divina. Amo vocês. Agradeço, em igual intensidade, à Maria Madalena, pela dedicação e cuidado conosco ao longo de todos esses anos.

Aos meus tios e tias, tanto da Família Lopes, como da Família Vêras, que souberam educar não apenas os seus filhos, mas também aos seus sobrinhos (coloco-me aqui também) e sobrinhas, com amor e cuidado tão especiais, não medindo esforços para estarem conosco.

À família de minha esposa, Raimundo de Araújo Moura e Sônia Maria Soares Moura, seus filhos(as) Moura Júnior, Dinamara, Mardônia e Daniel, suas respectivas esposas e seus esposos Mara, Antenor, Luis Henrique, e Adriana, sobrinhas Nicole e Mariana, sobrinhos Herick (sua noiva, Cássia e o filho do casal, Benício - *in utero*), Ícaro e Lucas. Em especial, a minha sogra, em nome da qual saúdo a todos os membros de sua família, pelos sábios e divinos ensinamentos, que muito me fortaleceram ao longo dessa jornada, bem como por todos os préstimos,

qualquer que tenha sido e quem quer que tenha dado, mas que foram extremamente especiais e que serão lembrados por toda a minha vida. Minha gratidão e respeito a todos vocês e a cada um, em particular.

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

Aos demais professores do curso que apresentaram e compartilharam seus conhecimentos, a exemplo do Professor Francisco Antônio Belo, ajudando na montagem e evolução deste trabalho, bem como aos funcionários do PPGEM, Mônica e Noaldo, que dedicaram seu tempo auxiliando docentes e discentes do curso, em especial a mim, quando assim precisei.

Às amizades estabelecidas ao longo do curso, em especial, àquelas feitas no GPICE-EMA (Thyago Vasconcelos, Anselmo, Fábio, Júlio, Danielson, Hugo, Marlio, Nayara e Gabriela) e no LASER (Ramon, Jefferson, Thiago Werley, Josimar e Moisés), que dividiram suas habilidades, raciocínios e, por muitas vezes, suas vidas ao longo de todos os momentos do curso. Agradeço, mais ainda, aos amigos Ramon, Thyago Vasconcelos, Thiago Werley, Jefferson, Anselmo, Danielson (conterrâneo) e Fábio que, oportunamente, tornaram-se parceiros não apenas no estudo ou na pesquisa, dividindo e agregando conhecimento, mas também na formação de um forte laço de amizade. Agradeço por terem dividido o seu tempo, algo muito preciso em dias atuais, mas não mais importante do que suas amizades.

Aos meus primos, Pedro Henrique de Goes Lopes e Marcos Antônio Lopes Vasconcelos, suas respectivas esposas Catarina e Joyse, seus filhos Pedro Luiz e Ana Luiza, Bergson e Gabriela, suas funcionárias, Nete e Leide, todos residentes em João Pessoa - PB, por terem dividido suas residências, tempo, paciência, disponibilidade e carinho, cada vez em que me hospedaram em seus lares. A convivência com cada um de vocês esteve, está e estará, para sempre, marcada em meu coração e memória. Eu e minha família somos gratos pelo amor gratuito de vocês.

Ao meu primo Helder Lopes, em nome do qual agradeço aos demais primos(as) da Família Lopes, por todo incentivo dado ao longo de minha vida, em especial e recordando um feliz episódio ocorrido em Teresina - PI, que se fosse um filme, bem poderia intitular-se: "quando um almoço salva uma alma", cujo momento foi divisor de águas em minha vida.

Ao meu primo Nécio Vêras, em nome do qual agradeço aos demais primos(as) da Família Vêras, pela feliz parceria e ajuda na publicação de um artigo científico, ocorrido no transcorrer deste curso. Mas, muito mais importante, agradeço pela oportunidade de crescer com todos vocês, aprendendo, sorrindo, confiando, unindo, congregando e amando como verdadeiros irmãos que somos. Vocês são especialíssimos e merecem minha gratidão.

Aos amigos de longas datas, Marcos Aurélio Gonçalves Guimarães (e esposa, Francilene de Moura Luz, e filho, Júnior), José Adalberto Nogueira Rocha, Maurício Gonçalves Guimarães, Álvaro, Rafael Rodrigues Lima Filho (e esposo, Nilton César Weyne da Cunha) e José Gildemar Macedo Júnior (e esposa, Liduína de Albuquerque Rocha e Sousa), em nome dos quais saúdo a cada membro de suas famílias, pela honra de termos trilhado os caminhos dessa vida, mesmo que atravessando percalços, mas que buscaram, juntos comigo, as devidas soluções. E, hoje, por sorrirmos de cada momento vivido, e por cada lição tomada.

Em especial, agradeço àqueles que plantaram uma semente de amor e carinho em meu coração, transformando a minha essência, enquanto homem, e fazendo-me refletir sobre o verdadeiro sentido da vida, mas que foram chamados para o convívio com o Pai. São eles (*in memoriam*): Antônio Angélico de Oliveira Lopes, Cristino de Oliveira Lopes, Joaquina Gomes de Lacerda, Francisco Tabajara de Vasconcelos, Izaac Vilanova e Silva Júnior, João Batista Vêras, Teresa de Jesus Vêras Fontenele, Luís Carlos Vêras, Luiza Alves Vêras Pachêco, Antônio Domingues Vêras Filho e Orlando Vêras Fontenele.

Enfim, a todos aqueles que contribuíram para que esse sonho fosse alcançado. O meu muito obrigado!

# Resumo

Os motores Brushless Direct Current (BLDC) têm sido utilizados em uma larga faixa de setores de atividades. Em algumas aplicações críticas, falhas nessas máquinas podem causar desastres operacionais e custar vidas, caso elas não sejam diagnosticadas com antecedência. Os métodos clássicos para detecção de falhas incipientes em motores BLDC realizam processamento do sinal de corrente de armadura para se obter a informação requerida. Neste trabalho, a técnica SAC-DM (Signal Analysis based on Chaos using Density of Maxima) é aplicada pela primeira vez no diagnóstico de falhas de sistemas eletromecânicos a partir de sinais sonoros. Análise wavelet multiresolução é utilizada para separar uma componente caótica do sinal do som emitido pelo motor, a partir da qual é calculado o Coeficiente de Comprimento de Correlação (CLC) usando a técnica SAC-DM. Este trabalho demonstra que é factível realizar diagnóstico de excentricidade dinâmica em motores BLDC identificando variações do SAC-DM do sinal de som. A técnica exposta nesse trabalho possui baixo custo computacional e alto índice de acerto. Para validar o método, foram realizados testes em um pequeno motor BLDC normalmente utilizado em Veículo Aéreo Não Tripulado (VANT), demonstrando a capacidade do método em detectar a velocidade do motor em 95,89% dos casos, e detectar problemas de excentricidade a uma velocidade fixa em 92,87% dos casos, empregando a Transformada de Wavelet. Para os casos analisados sem Wavelet, foram alcançados 98,38% de acurácia na detecção de velocidade e 88,65% na detecção de excentricidade, com uma velocidade fixa.

**Palavras-chave:** Motores BLDC, Teoria do Caos, Análise de Sinais, Detecção, Excentricidade, Velocidade.

# Abstract

Brushless Direct Current (BLDC) motors have been used in a wide range of fields. In some critical applications, failures in these machines can cause operational disasters and cost lives if they are not detected in advance. The classical methods for detecting incipient faults in BLDC motors perform processing of the current signal to obtain the required information. In this work, the SAC-DM (Signal Analysis based on Chaos using Density of Maxima) technique is applied for the first time in the diagnosis of failures of electromechanical systems from sound signals. Multiresolution wavelet analysis is used to separate a chaotic signal component from the sound emitted by the motor, from which the Correlation Length Coefficient (CLC) is calculated using the SAC-DM technique. This work demonstrates that it is feasible to perform dynamic eccentricity diagnosis in BLDC motors by identifying variations of the SAC-DM of the sound signal. The technique exposed in this work requires low computational cost and achieves high success rate. To validate the method, tests were carried out on a small BLDC motor normally used in Unmanned Aerial Vehicle (UAV), demonstrating the ability of the method to detect the speed of the motor in 95,89% of the cases, and to detect eccentricity problems at a fixed speed in 88.34% of the cases, using the Wavelet Transform. For the cases analyzed without Wavelet, 98.38% accuracy in speed detection and 88.65 % in eccentricity detection were achieved at a fixed speed.

**Keywords:** BLDC Motors, Chaos Theory, Signal Analysis, Detection, Unbalanced.

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>1</b>
1.1	Trabalhos Relacionados . . . . .	4
1.1.1	Tabela com resumo dos Trabalhos Relacionados . . . . .	8
1.2	Hipóteses . . . . .	9
1.3	Objetivos . . . . .	10
1.3.1	Objetivo Geral . . . . .	10
1.3.2	Objetivos Específicos . . . . .	10
1.4	Organização . . . . .	10
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>11</b>
2.1	Motores Elétricos . . . . .	11
2.1.1	Classificações e Funcionamento . . . . .	11
2.1.2	Veículos Elétricos . . . . .	13
2.1.3	Motores de Corrente Contínua sem Escova - BLDC . . . . .	17
2.1.4	Métodos de Diagnósticos de Falhas . . . . .	21
2.1.4.1	Métodos Baseados em Modelos . . . . .	24
2.1.4.2	Métodos Baseados em Sinais . . . . .	27
2.1.4.3	Métodos Baseados em Conhecimento . . . . .	29
2.1.4.4	Métodos Híbridos . . . . .	32
2.1.4.5	Métodos de Diagnósticos de Falhas Ativas . . . . .	32
2.1.5	Veículos Aéreos não Tripulados (VANTs) . . . . .	33
2.2	Processamento de Sinais . . . . .	35
2.2.1	Sinais e Sistemas . . . . .	36
2.2.1.1	Sistema de Comunicação . . . . .	36
2.2.1.2	Sistema de Controle . . . . .	38
2.2.2	Tipos de Processamento de Sinais . . . . .	39
2.3	SAC-DM - <i>Signal Analysis based on Chaos using Density of Maxima</i> . . . . .	41
2.4	Séries Temporais . . . . .	43
2.5	Autocorrelação . . . . .	45

2.6	Coeficiente de Comprimento da Correlação - CLC . . . . .	45
2.7	<i>Wavelet Multiresolution Analysis (WMA)</i> . . . . .	46
<b>3</b>	<b>METODOLOGIA</b>	<b>48</b>
3.1	Diagrama do Sistema Desenvolvido . . . . .	48
3.2	Bancada . . . . .	49
3.3	Aquisição de Dados . . . . .	52
3.4	<i>Wavelet Discrete Transform - WDT</i> . . . . .	54
3.5	Calculando o SAC-DM e Análise do Sistema . . . . .	56
<b>4</b>	<b>COMPORTAMENTO CAÓTICO</b>	<b>57</b>
4.1	Provando o Comportamento Caótico . . . . .	57
<b>5</b>	<b>EXPERIMENTOS E RESULTADOS</b>	<b>60</b>
5.1	Repetitividade e Análise das Medições . . . . .	60
5.2	Registrando a Velocidade do Motor da Bancada . . . . .	62
5.3	Usando o SAC-DM para Detecção de Velocidade e Desbalanceamento . . . . .	63
5.3.1	Resultados Preliminares alcançados com <i>wavelet</i> . . . . .	63
5.3.2	Resultados Alcançados sem <i>wavelet</i> . . . . .	66
5.3.2.1	Velocidades de 70, 80, 90% . . . . .	68
5.3.2.2	Velocidades de 50, 70, 90% . . . . .	73
5.3.3	Análise Comparativa: Com <i>wavelet</i> x Sem <i>wavelet</i> . . . . .	79
5.3.3.1	Velocidades de 60, 70 e 80% . . . . .	79
5.3.3.2	Velocidades de 70, 80 e 90% . . . . .	81
5.3.4	Análise Comparativa: Vibração Mecânica x Sinal Sonoro . . . . .	84
<b>6</b>	<b>CONSIDERAÇÕES FINAIS</b>	<b>91</b>
6.1	Conclusões . . . . .	91
6.2	Futuras Contribuições . . . . .	92
<b>A</b>	<b>Failure Detection of Brushless DC Motors from Sound Signals based on Chaos</b>	<b>102</b>
A.1	Introduction . . . . .	103
A.2	Signal Analysis based on Chaos using Density of Maxima (SAC-DM) . . . . .	104
A.3	Methodology . . . . .	105
A.3.1	Sound Signal Acquisition . . . . .	105
A.3.2	Application of Wavelet Multiresolution Analysis (WMA) . . . . .	106
A.3.3	Calculating SAC-DM and system analysis . . . . .	107
A.4	Proving the chaotic behavior . . . . .	108
A.5	Experiments and Results . . . . .	110
A.5.1	Speed and Unbalance Detection using SAC-DM . . . . .	110
A.6	Conclusions . . . . .	112

<b>B</b>	<b>Outros Dados</b>	<b>113</b>
B.1	Tabelas . . . . .	113

# Lista de Figuras

1.1	Quantidade de drones cadastrados no Brasil no ano de 2018. Fonte: ANAC (2019)	2
1.2	O tamanho do mercado de drones e previsão - 2018 à 2024. Fonte: Schroth (2019)	3
2.1	Princípio básico de funcionamento do motor . . . . .	12
2.2	Torque produzido por uma armadura de uma bobina de espira única . . . . .	12
2.3	Torque produzido por uma armadura de uma bobina de várias espiras . . . . .	12
2.4	Motores Industriais e de Tração: (a) Motor CC; (b) Motor de Indução; (c) PM brushless motor; (d) SRM. Fonte: (Zeraoulia <i>et al.</i> , 2006) . . . . .	14
2.5	Componentes principais de um motor CC . . . . .	14
2.6	Motor CC de ímã permanente . . . . .	15
2.7	Motor CC Série . . . . .	15
2.8	Motor CC <i>Shunt</i> . . . . .	16
2.9	Motor CC Composto . . . . .	16
2.10	Circuito Elétrico Equivalente para drivers de motores BLDC. Fonte: Park <i>et al.</i> (2011) . . . . .	18
2.11	Saída do sensor <i>Hall</i> comparada com <i>Back-EMF</i> do motor BLDC trifásico. Fonte: Park <i>et al.</i> (2011) . . . . .	19
2.12	Motor <i>Brushless</i> DC para VANTs. Fonte: Morbidi <i>et al.</i> (2016) . . . . .	19
2.13	Sistema de controle típico de um motor BLDC. Fonte: Xia (2012) . . . . .	21
2.14	Redundância Analítica baseada em diagnóstico de falhas. Fonte: Gao <i>et al.</i> (2015a) . . . . .	22
2.15	Diagnóstico e Tolerância à Falhas. Fonte: Gao <i>et al.</i> (2015a) . . . . .	23
2.16	Métodos de Diagnóstico e Identificação de Falhas (FDI) . . . . .	24
2.17	Esquema de diagnóstico de falhas baseado em modelo. Fonte: Gao <i>et al.</i> (2015a) . . . . .	25
2.18	Métodos baseados em sinais. Fonte: Gao <i>et al.</i> (2015a) . . . . .	27
2.19	Métodos baseados em conhecimento. Fonte: Gao <i>et al.</i> (2015a) . . . . .	30
2.20	Exemplo de Asa Fixa construído no LaSER-UFPB . . . . .	35
2.21	Diagrama esquemático de um sistema . . . . .	36
2.22	Sistema de Comunicação e seus elementos . . . . .	37

2.23	Sistema de Controle com Realimentação . . . . .	39
2.24	Algoritmo de Mallat para calcular o DWT. Fonte: Cruz <i>et al.</i> (2017) . . . . .	47
3.1	Diagrama de blocos do sistema. Fonte: O autor (2018) . . . . .	49
3.2	Bancada para Experimentos. Fonte: O autor (2018) . . . . .	49
3.3	Detalhe do Motor BLDC usado na bancada. Fonte: O autor (2018) . . . . .	50
3.4	Plataforma Arduino com microfone embarcado. Fonte: Lima (2017) . . . . .	52
3.5	Curva de resposta em frequência do microfone Arduino (Hz x dB) - Fonte: Lima (2017) . . . . .	53
3.6	Sinal Puro - Velocidade à 80% - Hélice Normal. Fonte: O autor (2018) . . . . .	53
3.7	Autocorrelação - ESC à 80% - Hélice Balanceada. Fonte: O autor (2018) . . . . .	54
3.8	Gráfico do erro percentual entre o CLC e $\tau$ , para duas contagens de picos máximos por nível de detalhe - ESC à 80% - Hélice Normal. Fonte: O autor (2019) . . . . .	55
3.9	Autocorrelação após <i>wavelet</i> - ESC a 80% da velocidade - Hélice Normal. Fonte: O autor (2018) . . . . .	55
4.1	Coefficiente de Correlação à Meia Altura após <i>wavelet</i> - Veloc. à 80% - Hélice Normal. Fonte: O autor (2018) . . . . .	58
4.2	Zoom no sinal sonoro com picos à 80% da velocidade - hélice normal. Fonte: O autor (2018) . . . . .	58
5.1	Medição da velocidade do motor em tempo de coleta. Fonte: O autor (2019) . . . . .	62
5.2	Gráfico da amostra do sinal sonoro com hélice balanceada para velocidade de 60%, 70% e 80%. Fonte: O autor (2018) . . . . .	64
5.3	Histograma do SAC-DM calculado a partir do sinal sonoro com hélice balanceada para velocidade de 60%, 70% e 80%. Fonte: O autor (2018) . . . . .	65
5.4	Gráfico da amostra do sinal sonoro com hélice desbalanceada para velocidade de 60%, 70% e 80%. Fonte: O autor (2018) . . . . .	65
5.5	Histograma do SAC-DM calculado a partir do sinal sonoro com hélice desbalanceada para velocidade de 60%, 70% e 80%. Fonte: O autor (2018) . . . . .	66
5.6	Histograma do SAC-DM calculado a partir do sinal sonoro com hélice balanceada e desbalanceada para velocidade de 50%. Fonte: O autor (2018) . . . . .	66
5.7	Autocorrelação sem <i>wavelet</i> - Três condições da hélice e três velocidades - 70, 80 e 90%. Fonte: O autor (2019) . . . . .	67
5.8	Histogramas da Autocorrelação sem Wavelet - Três condições da hélice e três velocidades - 70, 80 e 90%. Fonte: O autor (2019) . . . . .	68
5.9	Autocorrelação sem <i>wavelet</i> - ESC à 90% da veloc. - Hélice Desbal. com Fita de 22 cm. Fonte: O autor (2019) . . . . .	68
5.10	Gráfico da amostra do sinal sonoro com hélice balanceada para velocidade de 70%, 80% e 90% - Sem <i>wavelet</i> . Fonte: O autor (2019) . . . . .	69

---

5.11	Histograma do SAC-DM calculado a partir do sinal sonoro com hélice balanceada para velocidade de 70%, 80% e 90% - Sem <i>wavelet</i> . Fonte: O autor (2019) . . . . .	70
5.12	Gráfico da amostra do sinal sonoro com hélice desbalanceada com fita de 14 cm para velocidade de 70%, 80% e 90% - Sem <i>wavelet</i> . Fonte: O autor (2019) . . .	71
5.13	Histograma do SAC-DM calculado a partir do sinal sonoro com hélice desbalanceada com Fita de 14 cm para velocidade de 70%, 80% e 90% - Sem <i>wavelet</i> . Fonte: O autor (2019) . . . . .	71
5.14	Gráfico da amostra do sinal sonoro com hélice desbalanceada com fita de 22 cm para velocidade de 70%, 80% e 90% - Sem <i>wavelet</i> . Fonte: O autor (2019) . . .	72
5.15	Histograma do SAC-DM calculado a partir do sinal sonoro com hélice desbalanceada com Fita de 22 cm para velocidade de 70%, 80% e 90% - Sem <i>wavelet</i> . Fonte: O autor (2019) . . . . .	73
5.16	Gráfico da amostra do sinal sonoro com hélice balanceada para velocidade de 50%, 70% e 90%. Fonte: O autor (2019) . . . . .	74
5.17	Histograma do SAC-DM calculado a partir do sinal sonoro com hélice balanceada para velocidade de 50%, 70% e 90%. Fonte: O autor (2019) . . . . .	75
5.18	Histograma do SAC-DM calculado a partir do sinal sonoro com hélice desbalanceada para velocidade de 50%, 70% e 90%. Fonte: O autor (2019) . . . . .	76
5.19	Histograma do SAC-DM calculado a partir do sinal sonoro com hélice desbalanceada para velocidade de 50%, 70% e 90%. Fonte: O autor (2019) . . . . .	76
5.20	Histograma do SAC-DM calculado a partir do sinal sonoro com hélice balanceada e desbalanceada para velocidade de 50%, sem <i>wavelet</i> . Fonte: O autor (2019) . . . . .	77
5.21	Histograma do SAC-DM calculado a partir do sinal sonoro com hélice balanceada e desbalanceada para velocidade de 70%, sem <i>wavelet</i> . Fonte: O autor (2019) . . . . .	78
5.22	Histograma do SAC-DM calculado a partir do sinal sonoro com hélice balanceada e desbalanceada para velocidade de 90%, sem <i>wavelet</i> . Fonte: O autor (2019) . . . . .	78
5.23	Histogramas comparativos entre: a) Aplicando a Transformada <i>wavelet</i> ; e b) Sem a aplicação da Transformada. Velocidades de 60, 70 e 80%, com hélice balanceada. Fonte: O autor (2019) . . . . .	80
5.24	Histogramas comparativos entre: a) Aplicando a Transformada <i>wavelet</i> ; e b) Sem a aplicação da Transformada. Velocidades de 60, 70 e 80%, com hélice balanceada. Fonte: O autor (2019) . . . . .	80
5.25	Histogramas comparativos entre 3 condições da hélice: a) Aplicando a Transformada de <i>wavelet</i> ; e b) Sem a aplicação da Transformada. Velocidade fixa de 70%. Fonte: O autor (2019) . . . . .	81

5.26	Histogramas comparativos entre 3 condições da hélice: a) Aplicando a Transformada de <i>wavelet</i> ; e b) Sem a aplicação da Transformada. Velocidade fixa de 80%. Fonte: O autor (2019) . . . . .	82
5.27	Histogramas comparativos entre 3 condições da hélice: a) Aplicando a Transformada de <i>wavelet</i> ; e b) Sem a aplicação da Transformada. Velocidade fixa de 90%. Fonte: O autor (2019) . . . . .	82
5.28	Distribuição gráfica dos níveis de decomposição do sinal sonoro, após a aplicação da Transformada de <i>wavelet</i> para as velocidades de 60% e 70%. Fonte: O autor (2019) . . . . .	84
5.29	Histogramas comparativos entre: a) Dados do acelerômetro (Vibração Mecânica); e b) Dados do sinal sonoro, sem <i>wavelet</i> . Velocidades de 70, 80 e 90%, com hélice balanceada. Fonte: O autor (2019) . . . . .	85
5.30	Histogramas comparativos entre: a) Dados do acelerômetro (Vibração Mec.); e b) Dados do sinal sonoro, sem <i>wavelet</i> . Velocidades de 70, 80 e 90%, com hélice desbalanc. com fita de 14 cm. Fonte: O autor (2019) . . . . .	86
5.31	Histogramas comparativos entre: a) Dados do acelerômetro (Vibração Mec.); e b) Dados do sinal sonoro, sem <i>wavelet</i> . Velocidades de 70, 80 e 90%, com hélice desbalanc. com fita de 22 cm. Fonte: O autor (2019) . . . . .	86
5.32	Histogramas comparativos entre: a) Dados do acelerômetro (Vibração Mec.); e b) Dados do sinal sonoro, sem <i>wavelet</i> . Velocidade de 70%, com hélice balanceada, desbalanc. com fita de 14 cm e desbalanc. com fita de 22 cm. Fonte: O autor (2019) . . . . .	88
5.33	Histogramas comparativos entre: a) Dados do acelerômetro (Vibração Mec.); e b) Dados do sinal sonoro, sem <i>wavelet</i> . Velocidade de 80%, com hélice balanceada, desbalanc. com fita de 14 cm e desbalanc. com fita de 22 cm. Fonte: O autor (2019) . . . . .	88
5.34	Histogramas comparativos entre: a) Dados do acelerômetro (Vibração Mec.); e b) Dados do sinal sonoro, sem <i>wavelet</i> . Velocidade de 90%, com hélice balanceada, desbalanc. com fita de 14 cm e desbalanc. com fita de 22 cm. Fonte: O autor (2019) . . . . .	89
A.1	Methodology for signal analysis using density of maxima . . . . .	106
A.2	Auto-correlation Function for motor with balanced propeller at 80% speed . . .	107
A.3	Auto-correlation after Wavelet at 80% of speed - Balanced Propeller . . . . .	107
A.4	Correlation Coefficient at Half Height after Wavelet with speed of 80% - Balanced Propeller . . . . .	108
A.5	Sound signal in zoom with peaks with speed of 80% - Balanced Propeller . . .	109
A.6	Histogram of SAC-DM for a) balanced, and b) unbalanced propellers for 60%, 70% and 80% of speed . . . . .	111

A.7 Histogram of the SAC-DM for motor at 50% of nominal speed . . . . . 111

A.8 Tendency lines for the SAC-DM, with different propellers . . . . . 112

# Lista de Tabelas

1.1	Resumo dos trabalhos relacionados - Abordagem: Excentricidade em motores BLDC . . . . .	8
1.2	Resumo dos trabalhos relacionados - Abordagem: Excentricidade em motores à indução . . . . .	9
1.3	Resumo dos trabalhos relacionados - Abordagem: Características Caóticas . . .	9
2.1	Topologia e categorias de estratégias de aprendizagem para diagnóstico de falhas NN . . . . .	31
3.1	Especificações do motor BLDC . . . . .	50
3.2	Análise estatística dos pesos (em gramas) da fita utilizada nos experimentos . .	51
3.3	Especificações técnicas do tacômetro . . . . .	52
3.4	Resumo das propriedades do Sistema Arduino DUE para coleta de áudios . . .	53
4.1	Resultados com <i>wavelet</i> - Hélice Balanceada . . . . .	59
4.2	Resultados com <i>wavelet</i> - Hélice Desbalanceada . . . . .	59
5.1	Resultados da repetitividade e análise das medições - Hélice Balanceada . . . .	61
5.2	Resultados da repetitividade e análise das medições - Hélice Desbalanceada . .	61
5.3	Médias das velocidades (em RPM) atingidas pelo motor da bancada . . . . .	62
5.4	Médias das velocidades (em Hz) atingidas pelo motor da bancada . . . . .	62
5.5	Análise estatística dos resultados do SAC-DM para motores BLDC com hélice balanceada . . . . .	64
5.6	Análise estatística dos resultados do SAC-DM para motores BLDC com hélice desbalanceada . . . . .	64
5.7	Análise estatística dos resultados do SAC-DM para motores BLDC com hélice balanceada - Sem <i>wavelet</i> . . . . .	69
5.8	Análise estatística dos resultados do SAC-DM para motores BLDC com hélice desbalanceada (Fita 14 cm) - Sem <i>wavelet</i> . . . . .	70
5.9	Análise estatística dos resultados do SAC-DM para motores BLDC com hélice desbalanceada (Fita 22 cm) - Sem <i>wavelet</i> . . . . .	72
5.10	Acurácia relativa à detecção da velocidade usando o SAC-DM sem <i>wavelet</i> - Hélice balanceada . . . . .	75

5.11	Acurácia relativa à detecção da velocidade usando o SAC-DM sem <i>wavelet</i> - Hélice desbalanceada . . . . .	77
5.12	Acurácia relativa à detecção de falha usando o SAC-DM sem <i>wavelet</i> nas velocidades de 50%, 70% e 90% . . . . .	79
5.13	Acurácia relativa à detecção de velocidade usando o SAC-DM - Velocidades de 60, 70 e 80%, com hélice balanceada . . . . .	80
5.14	Acurácia relativa à detecção de velocidade usando o SAC-DM - Velocidades de 60, 70 e 80%, com hélice desbalanceada . . . . .	81
5.15	Acurácia relativa à detecção de falhas e dos níveis de falhas usando o SAC-DM, à velocidade de 70%. . . . .	83
5.16	Acurácia relativa à detecção de falhas e dos níveis de falhas usando o SAC-DM, à velocidade de 80%. . . . .	83
5.17	Acurácia relativa à detecção de falhas e dos níveis de falhas usando o SAC-DM, à velocidade de 90%. . . . .	83
5.18	Média da acurácia relativa à detecção de falha usando o SAC-DM - Comparativo entre velocidades (Com <i>wavelet</i> . x Sem <i>wavelet</i> ). . . . .	83
5.19	Acurácia relativa à detecção de velocidade usando o SAC-DM - Velocidades de 70, 80 e 90%, com hélice balanceada . . . . .	85
5.20	Acurácia relativa à detecção de velocidade usando o SAC-DM - Velocidades de 70, 80 e 90%, com hélice desbalanceada - Fita 14 cm. . . . .	86
5.21	Acurácia relativa à detecção de velocidade usando o SAC-DM - Velocidades de 70, 80 e 90%, com hélice desbalanceada - Fita 22 cm. . . . .	87
5.22	Média da acurácia relativa à detecção de velocidade usando o SAC-DM - Comparativo entre condições da hélice. . . . .	87
5.23	Acurácia relativa à detecção de falhas e da severidade da falha usando o SAC-DM, à velocidade de 70%, comparando-se vibração e sinal sonoro. . . . .	88
5.24	Acurácia relativa à detecção de falhas e da severidade da falha usando o SAC-DM, à velocidade de 80%, comparando-se vibração e sinal sonoro. . . . .	89
5.25	Acurácia relativa à detecção de falhas e da severidade da falha usando o SAC-DM, à velocidade de 90%, comparando-se vibração e sinal sonoro. . . . .	89
5.26	Média da acurácia relativa à detecção de falha de excentricidade usando o SAC-DM - Comparativo entre velocidades (Vibração Mec. x Sinal Sonoro) . . . . .	90
5.27	Média da acurácia relativa à detecção da severidade da falha usando o SAC-DM - Comparativo entre condições da hélice nas velocidades de 70, 80 e 90% (Vibração Mec. x Sinal Sonoro) . . . . .	90
A.1	Comparison between CLC and SAC-DM after Wavelet - Balanced Propeller . .	109
A.2	Comparison between CLC and SAC-DM after Wavelet - Unbalanced Propeller	109
A.3	Statistical of SAC-DM with regular propeller . . . . .	110
A.4	Statistical of SAC-DM with unbalanced propeller . . . . .	110

- 
- B.1 Média da acurácia relativa à detecção de falha usando o SAC-DM. Comparativo entre Condições da Hélice: Entre Balanceada e Desb. com Fita 14 cm. . . . . 113
- B.2 Média da acurácia relativa à detecção de falha usando o SAC-DM. Comparativo entre Condições da Hélice: Entre Desbalanceada com Fita 14 cm e Desb. com Fita 22 cm. . . . . 113
- B.3 Média da acurácia relativa à detecção de falha usando o SAC-DM. Comparativo entre Condições da Hélice: Entre Balanceada e Desb. com Fita 22 cm. . . . . 113

# Lista de Siglas

ANAC	– Agência Nacional de Aviação Civil
A/D	– Analógico-Digital
AE	– Emissões Acústicas
ASIC	– <i>Application-Specific Integrated Circuit</i>
BLDC	– <i>Brushless Direct Current</i>
CA	– Corrente Alternada
CC	– Corrente Contínua
CLC	– <i>Correlation Length Coefficient</i>
CSA	– <i>Current Signature Analysis</i>
DC	– <i>Direct Current</i>
DECEA	– Departamento de Controle do Espaço Aéreo
DSP	– <i>Digital Signal Processor</i>
EV	– <i>Electric Vehicles</i>
ESC	– <i>Electronic Speed Controller</i>
FFT	– <i>Fast Fourier Transform</i>
FPGA	– <i>Field Programmable Gate Arrays</i>
GPICEEMA	– Grupo de Pesquisa em Instrumentação e Controle em – Estudo de Energia e Meio Ambiente
HEV	– <i>Hybrid Electric Vehicle</i>
Hz	– <i>Hertz</i>
ICEV	– <i>Internal Combustion Engine Vehicles</i>
IM	– <i>Induction Motor</i>
ITF	– <i>Interturn Fault</i>
IWM	– <i>In-Wheel Motor</i>
LSR	– Laboratório de Solidificação Rápida
LASER	– Laboratório de Sistemas Embarcados e Robótica
MCU	– <i>Microcontroller Units</i>
PM	– <i>Permanent Magnet</i>
PMS	– <i>Permanent Magnet Synchronous</i>

---

PWM	–	<i>Pulse Width Modulation</i>
RPM	–	Rotações Por Minutos
SAC-DM	–	<i>Signal Analysis based on Chaos using Density of Maxima</i>
SISANT	–	Sistema de Aeronaves não Tripuladas
SPM	–	<i>Surface Permanent Magnet</i>
SRM	–	<i>Switched Relutance Motor</i>
UFPB	–	Universidade Federal da Paraíba
UFPI	–	Universidade Federal do Piauí
UVS	–	<i>Unmanned Vehicles System</i>
VANTs	–	Veículos Aéreos não Tripulados
WMA	–	<i>Wavelet Multiresolution Analysis</i>

# Lista De Símbolos

$d$	–	Perturbação no processo
$e_a, e_b, e_c$	–	Fase específica do Back EMF
$e(t)$	–	Tensão elétrica através do motor
$e_g$	–	Força contra-eletromotriz (Back EMF) do motor
$f_a$	–	Falha do atuador
$f_c$	–	Falha do processo/componente
$f_s$	–	Falha do sensor
$i_a, i_b, i_c$	–	Corrente de fase específica
$i_t$	–	Corrente elétrica do estator, em A
$I_{ESC}(RMS)$	–	Corrente do ESC [V]
$L$	–	Indutância do enrolamento de fase
$L_a, L_b, L_c$	–	Auto-indutância de fase específica
$M$	–	Indutância mútua
$\mu$	–	Média
$P_{ESC}(RMS)$	–	Energia transferida do ESC para o motor
$R$	–	Resistência do enrolamento de fase
$R_a, R_b, R_c$	–	Resistência específica do estator de fase
$R_L$	–	Perdas na resistência do circuito elétrico
$r_{n(1,2,\dots,n)}$	–	Sinal residual da detecção de falha
$S_{x(x=1,2,\dots,6)}$	–	Chaves inversoras
$\sigma^2$	–	Variância
$\sigma_X$	–	Desvio padrão
$V_{dc}$	–	Link DC de Tensão
$\omega$	–	Ruídos de medição
$\omega_t$	–	Velocidade angular do rotor, em rad/s
$TCAC$	–	Taxa de Crescimento Anual Composta
$T_f$	–	Torque de atrito do motor
$T_L(w(t))$	–	Torque de atrito da carga da veloc. resultante do arrasto da hélice
$V_{ESC}(RMS)$	–	Tensão do ESC [A]

$u, y$  – Entrada e saída, respectivamente, do algoritmo de diagnóstico de falhas

## CAPÍTULO 1

# INTRODUÇÃO

Décadas atrás, associava-se a tecnologia que envolve os VANTs (Veículos Aéreos Não Tripulados), popularmente conhecidos por drones, às práticas militares e suas atividades bélicas. Porém, o uso desses veículos tem sido alvo de reportagens nos noticiários mundiais, divulgados nos mais diversos meios de comunicação atuais, em que são apresentadas novas alternativas de aplicação, compreendendo o divertimento, atividades comerciais e outras.

Registros apontam que os austríacos foram um dos primeiros povos a usarem a tecnologia que envolve os VANTs. O fato ocorreu em julho de 1849, depois de terem lançado cerca de duzentos balões, sem piloto, montados com bombas contra a cidade de Veneza (Shaw, 2014).

Há poucos anos atrás, ainda não eram veiculadas notícias sobre uso de VANTs e, muito menos, não se podia prever que o avanço desta tecnologia traria uma série de benefícios e, também, os cuidados e precauções durante o voo. Ações protocolares para a criação de regulamentações e normas de pilotagem destas novas aeronaves, justificam-se cada vez mais pela grande diversidade de uso das mesmas. É provável que estes novos tipos de veículos, e suas diversas finalidades, venham a substituir as aeronaves tripuladas em muitas operações comerciais (Matias, 2016).

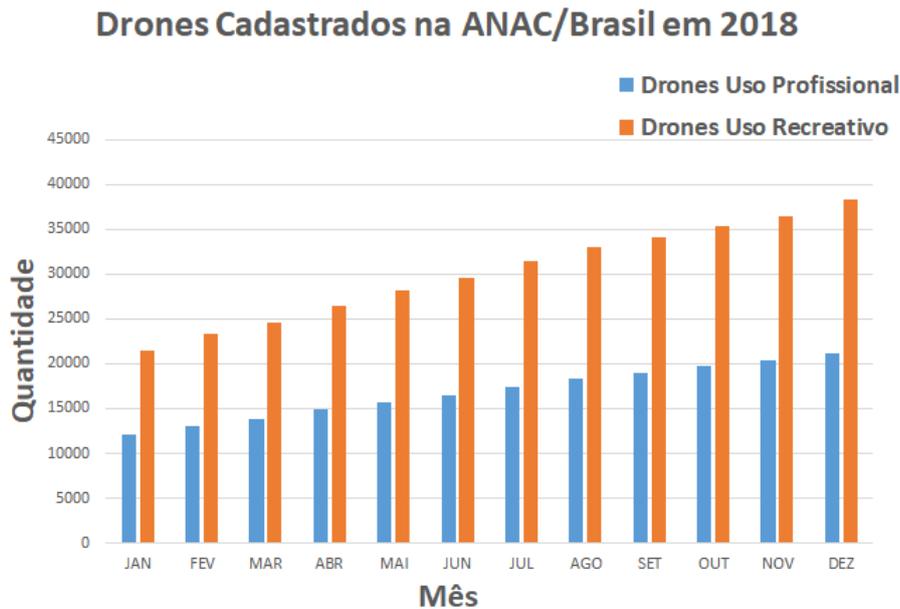
No Brasil, a ANAC (Agência Nacional de Aviação Civil<sup>1</sup>) tem registrado dados que expressam a quantidade de VANTs registrados ao longo de alguns anos. A Figura 1.1, elaborada pelo SISANT (Sistema de Aeronaves não Tripuladas), apresenta a quantidade de cadastros de drones, realizados por pessoas (físicas ou jurídicas), com fins profissionais ou recreativos, no ano de 2018. Segundo a agência, o cadastro é obrigatório e obedece às normas de peso e de limites de voo, segundo padrões de segurança estabelecidos para cada tipo de VANT.

Em pesquisas mais recentes, Schroth (2019) apresentou um infográfico (Figura 1.2) na *Drone Industry Insights*<sup>2</sup>, retratando o tamanho do mercado de drones e sua previsão até 2024. Segundo o autor, o mercado de drones gerou 14,1 bilhões de dólares em 2018 e alcançará uma Taxa de Crescimento Anual Composta (TCAC) de 20,5%, atingindo 43 bilhões de dóla-

---

<sup>1</sup><http://www.anac.gov.br>

<sup>2</sup><https://www.droneii.com/project/drone-market-size-and-forecast-2019-2024>



**Figura 1.1** - Quantidade de drones cadastrados no Brasil no ano de 2018. Fonte: ANAC (2019)

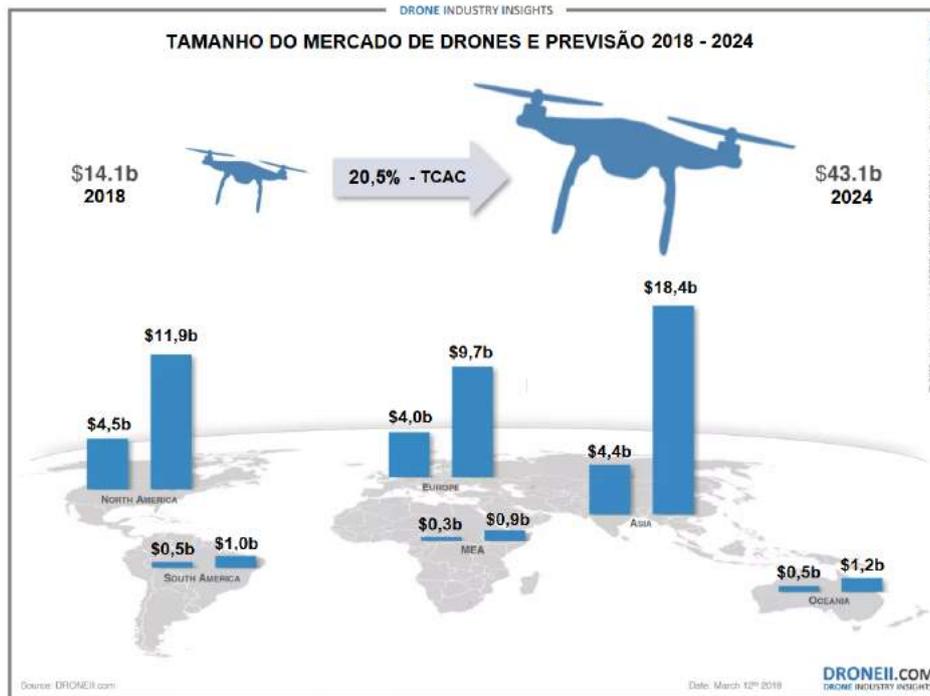
res. A previsão sugere ainda que a Ásia investirá, até 2024, cerca de 18,4 bilhões de dólares, contrapondo-se à 1 bilhão de dólares que a América do Sul terá investido no mercado de drones.

Pelo próprio crescimento do uso dos VANTs no âmbito civil, é natural que novas pesquisas tomem a direção da segurança que envolve o voo, abordando temas como técnicas apropriadas de pilotagem ou aplicações para o seu uso. Em 17 de abril de 2016, o piloto do voo BA729 da *British Airways*<sup>3</sup> pousou, com sucesso, um avião com 137 passageiros. Foi registrado que um objeto, provavelmente um VANT, atingiu a frente do Airbus A320. O fato remete ao questionamento feito por Gettinger e Michel (2015): "Por que esses incidentes estão ocorrendo e o que pode ser feito para evitar um acidente potencialmente catastrófico?".

Da mesma forma, estudos apontam que a principal falha em VANTs tem relação com os motores e com as hélices (Fuggetti *et al.*, 2015). Em outras pesquisas, tem surgido amplo interesse por questões como detecção e diagnóstico de falhas em motores de VANTs, reconhecidos como motores de corrente contínua sem escovas (BLDC - *Brushless Direct Current*), tipicamente usados nestas aeronaves. Estes são aspectos que tratam não apenas de custos de investimentos em projetos, mas que podem envolver acidentes aéreos e vidas humanas, principalmente, e que justificam nosso interesse.

Os motores BLDC têm sido amplamente utilizados em diversos setores como na indústria - Concari *et al.* (2013); Han e Palazzolo (2016), em processos físico-químicos - Dalzin *et al.* (2016), no setor médico - Lim *et al.* (2009), em simulações computacionais - Bisoletti *et al.* (2017), robótica - Misgeld *et al.* (2017), no controle de espaçonaves - Wang *et al.* (2017), nos estudos aeroespaciais - Wang e Shirinzadeh (2014), automotivo - Canepa *et al.* (2015); Mężyk *et al.* (2017); Walter *et al.* (2017), no monitoramento de equipamentos vitais - Lu *et al.* (2018) e nas fontes de energias alternativas - Sashidhar e Fernandes (2017).

<sup>3</sup>[www.britishairways.com](http://www.britishairways.com)



**Figura 1.2** - O tamanho do mercado de drones e previsão - 2018 à 2024. Fonte: Schroth (2019)

Falhas inesperadas nesses motores podem ser catastróficas, ocasionando perdas financeiras e humanas, por exemplo, quando ocorrem em ambiente industrial e em VANTs. Sobre estes últimos, pesquisas trazem os avanços nas aplicações de sistemas que os utilizam, seja sobre a sua comercialização e o crescimento acentuado dessa nova categoria de produto (Kuzma *et al.*, 2017; Mills, 2017), seja sobre a regulamentação dos VANTs em escala global (Stöcker *et al.*, 2017), ou seja sobre a validação de aplicações críticas de segurança, para melhorar a confiança na tecnologia de controle autônomo (Straub e Huber, 2013).

Um dos mais recentes relatórios da IHS Markit<sup>4</sup>, intitulado de “Motores elétricos em robôs de serviço”, mostra que o mercado global de motores elétricos valia US\$ 438 milhões em 2017, com 36 milhões de unidades vendidas. As receitas de mercado devem crescer a uma TCAC de 18,6% de 2017 a 2022, quando irão totalizar aproximadamente US\$ 1,0 bilhão (Goh, 2018).

Em se tratando de motores BLDC, entre 2003 e 2010, houve um crescimento de US\$300 milhões para mais de US\$1,3 bilhões no mercado de motores BLDC, segundo Markets and Markets (2017). As estatísticas também mostram que o mercado global de motores BLDC havia sido estimado em US\$5,19 bilhões em 2016 e que seu crescimento é esperado, devendo atingir uma taxa de 9,4% de 2016 a 2021, chegando à cifra de US\$8,15 bilhões. Estes aspectos demonstram que este é um mercado em amplo crescimento.

O trabalho apresentado nesta tese propõe uma técnica inédita para o diagnóstico de excentricidade dinâmica em motores BLDC, de forma totalmente não invasiva, através do som emitido pelo motor em funcionamento. Para tanto, será aplicada uma técnica designada Aná-

<sup>4</sup><https://technology.ihs.com/Research-by-Market>

lise de Sinais baseada no Caos usando Densidade de Máximos (SAC-DM), aplicada nos sinais sonoros coletados do motor de um VANT, com o propósito de detectar a velocidade e falha de excentricidade no mesmo. A técnica proposta apresenta a vantagem da simplicidade e do baixo esforço computacional quando comparada com as técnicas clássicas de processamento de sinais, consistindo no diagnóstico de falhas na contagem dos picos do sinal sonoro analisado.

O interesse por dados adquiridos a partir do funcionamento de motores não é recente e, pela própria história e evolução industrial, tem sido uma constante fonte de pesquisa. Projetos envolvendo a análise de vários aspectos de motores têm vertentes em diversos sentidos, como por exemplo, na observação do comportamento de um motor de acordo com as variações na corrente elétrica que o faz funcionar (Sashidhar e Fernandes, 2017).

Da mesma forma, uma plataforma mecânica é utilizada com uma série de 3 discos rotativos de alumínio, com massa rotativa desbalanceada, com o objetivo de determinar e localizar a anormalidade analisando os dados de vibração, aplicando uma Rede Neural Artificial, ou seja, utilizando uma técnica computacional que apresenta um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência (Dwi *et al.*, 2015).

Cada uma das abordagens citadas tem níveis de aprofundamento de pesquisa que vem cada vez mais estreitando as relações existentes entre o homem e os milhões de dados gerados em cada projeto. Como exemplo, podem ser citados os desdobramentos da análise dos dados aquisitados para modelagem matemática e simulações computacionais do comportamento de um motor (Xiang *et al.*, 2015).

Outro aspecto a ser considerado para o direcionamento de uma pesquisa envolvendo processamento de sinais, é o fato de que cada conjunto de dados tem uma natureza (Diniz *et al.*, 2014). Na natureza, somos frequentemente forçados a trabalhar com sinais cujas formas de onda não são precisamente conhecidas a cada instante de tempo. Assim, os dados coletados de sinais sonoros têm uma natureza diferente dos dados de corrente elétrica ou dos dados de vibração mecânica de um motor, como os exemplos citados acima. Ruídos presentes em amostras puras de áudio podem mascarar resultados e pesquisas, sendo interessante, portanto, testar a aplicação do devido tratamento. Porém, em tais casos, mesmo sem conhecer o valor exato do sinal, ainda se pode obter informação útil sobre o processo de interesse.

A discussão aqui proposta versa sobre a busca pela prova de um conceito que ultrapasse um conhecimento estabelecido e que, pela interdisciplinaridade, aborda questões atuais e com diversas implicações científicas, como a possibilidade de analisar dados baseando-se em aspectos fisicamente caóticos.

## 1.1 Trabalhos Relacionados

Basicamente, é possível classificar métodos de identificação de falhas em geral pelo sensor utilizado ou pela técnica de processamento de sinais. Na literatura, é possível encontrar

trabalhos que visam identificar falhas de excentricidade dinâmica em diversos tipos de máquinas elétricas. Os métodos mais comuns são aqueles que realizam a aquisição dos sinais elétricos do motor. Destas, podem ser destacadas obras, cujo processamento é baseado em Transformada de Fourier (Artigao *et al.*, 2018), em Elementos Finitos (Kang *et al.*, 2017; Sapena-Bano *et al.*, 2019), em *wavelet* (Rajagopalan *et al.*, 2007a) e em métodos de processamento híbridos como: Elementos Finitos/Fourier (Park e Hur, 2016), Hilbert/Fourier (Kral *et al.*, 2004), *wavelet*/Fourier (Georgoulas *et al.*, 2017).

Métodos usando sinais de vibração também são encontrados na literatura. Em Konar e Chattopadhyay (2015) o sinal de vibração é usado para o diagnóstico de excentricidade dinâmica em um motor de indução usando o algoritmo baseado em *wavelet*/Hilbert. Em Ouachtouk *et al.* (2017) Fourier é usado para processar sinais de vibração e corrente de armadura também em um motor de indução. Em Rezig *et al.* (2010), sinais de vibração e som com processamento baseado em Fourier são usados para investigar o comportamento de motores síncronos de ímã permanente. Em Esfahani *et al.* (2014) os sinais de corrente, de som, vibração e armadura de um motor de indução são processados através do algoritmo baseado em Fourier, transformada de Hilbert-Huang e classificadores para identificar várias falhas, incluindo a excentricidade dinâmica. Em um dos experimentos que realizamos, também coletamos a vibração mecânica e comparamos com o respectivo sinal sonoro, mas o motor observado é um BLDC.

O trabalho desenvolvido por Rajagopalan *et al.* (2007a) apresenta um novo método usando a transformada *wavelet* analítica do sinal da corrente do estator para a detecção da excentricidade dinâmica em motores de Corrente Contínua (CC) sem escovas (BLDC). Esses motores operam sob condições de velocidade e carga que variam rapidamente. Como as *wavelets* são inerentemente adequadas para análise de sinal não-estacionário, este método não requer o uso de nenhuma janela (cortes menores no tempo do sinal). A técnica proposta utiliza *wavelets* analíticos, que são suaves e que possuem informações de magnitude e fase. Em nosso trabalho, várias coletas de sinais sonoros foram realizadas, mantendo-se o motor à velocidade constante para cada coleta feita. Assim, as amostras de áudio foram geradas de acordo com a velocidade na qual o motor foi submetido. No entanto, ao aplicarmos *wavelet* na análise do sinal, usamos um janelamento para que fossem minimizados os ruídos inerentes à própria natureza de um sinal tipicamente sonoro. E também, em razão dos testes e resultados encontrados, não foram delineadas outras conclusões que se referissem à magnitude e a fase do sinal. Contudo, nosso trabalho também realiza a detecção da excentricidade dinâmica em BLDC através de processamento no domínio do tempo e, apesar da utilização de um filtro *wavelet* em alguns experimentos, ela foi útil para separar uma componente caótica do sinal do som emitido pelo motor, a um baixo custo computacional.

Em motores BLDC, a determinação de excentricidade dinâmica tem sido realizada ao longo dos anos, como mostram pesquisas recentes sobre esta categoria de motores. Park e Hur (2016); Rajagopalan *et al.* (2007a,b) apresentam um método para a determinação da excentricidade dinâmica em motores BLDC, através da aquisição e processamento do sinal de corrente da

armadura do motor, assemelhando-se ao nosso trabalho, cuja aquisição e processamento também é feito para a determinação de excentricidade, porém sob sinais sonoros. Em Rajagopalan *et al.* (2007a) é feita a detecção da excentricidade em BLDC sob condições dinâmicas através de processamento no domínio do tempo baseado em *wavelets*. Em Rajagopalan *et al.* (2007b) é demonstrado que a detecção da excentricidade em motores BLDC através de CSA (*Current Signature Analysis*) é viável para diferentes cargas aplicadas e, em Park e Hur (2016), é combinado Método de Elementos Finitos (MEF) e *Fast Fourier Transform* (FFT) para reconhecimento de padrões de falhas. Semelhante ao nosso trabalho, utilizamos uma técnica de processamento de sinais baseado em *wavelet*, porém melhores resultados foram encontrados quando o filtro foi retirado.

Detecção de outros tipos de falhas mecânicas, como defeitos em rolamentos de motores BLDC, também podem ser encontradas na literatura. Em He *et al.* (2015) é utilizado o sinal de vibração para detecção da falha através da combinação de filtragem *wavelet*, regra *Fuzzy* e análise no domínio da frequência. Em experimentos realizados em nosso trabalho, são apresentados resultados comparativos com dados coletados de vibração mecânica e que comprovam a possibilidade da aplicação da técnica do SAC-DM em outros estudos.

Puliyakote e Balasubramaniam (2013) utilizam um algoritmo de processamento de sinais que envolve, recursivamente, *wavelet* e coleta de dados através de Emissões Acústicas (AE - *Acoustic Emission*), para identificar ou aprimorar os recursos associados à falhas em um motor à combustão, tais como, pistão ruim ou anéis de pistão desgastados e que foram condições recriadas para que fossem realizadas as devidas análises. Igualmente, o nosso trabalho coleta e processa sinais sonoros, porém objetivando a detecção de falha de excentricidade e, além disso, a detecção da velocidade do motor elétrico.

Em Lu *et al.* (2016), os autores propõem um novo método para simplificar os instrumentos de diagnósticos de falhas no mancal do motor. Para isso, é feita a gravação de um videoclipe de um sistema de rolamento em execução e, este, é capturado usando um telefone celular equipado com uma câmera e um microfone. O vídeo gravado é, subsequentemente, analisado para obter a frequência instantânea de rotação e a frequência instantânea da característica de falha do rolamento defeituoso é obtida analisando o sinal sonoro gravado pelo microfone. O trabalho que realizamos coleta sinais sonoros para sinalizar a velocidade em que o motor está atuando, usando um circuito com Arduino DUE, possuindo uma elevada capacidade computacional e rápido processamento, e mais um microfone condensador de eletreto, cuja frequência é estável, caracterizando-o como um bom mecanismo de transdução. A similaridade destes trabalhos encontra-se na proposta de detectar anomalias em motores.

Levando-se em consideração a possibilidade de análise de um motor, no intuito de detecção e diagnóstico de falhas, um sistema especialista com alta confiabilidade é utilizado para comparar motores idênticos que funcionam bem, mas que atua na determinação e identificação de diferenças nesse funcionamento, quando de fato ocorrerem (Kim *et al.*, 2014). Embora tenhamos utilizado um mesmo motor em todos os experimentos, a comparação que realizamos em

nosso trabalho foi entre técnicas e sinais diferentes, porém com o mesmo objetivo de detecção de falhas.

Ainda considerando a análise de motores, mas em se tratando de motores de VANTs, o motor desse tipo de aeronave é caracterizado através da detecção de falhas, como um estator solto, utilizando uma abordagem computacional simples a partir do sinal de corrente elétrica (Medeiros *et al.*, 2018). Nos experimentos que realizamos com o mesmo tipo de motor, também há um baixo esforço computacional envolvido no processamento, porém as coletas são provenientes de sinais sonoros que simulam uma falha, e sua severidade, através do posicionamento de fitas adesivas com diferentes pesos, na ponta da hélice.

Usando um método baseado na superposição linear e análise de correlação cruzada, Ning e Gong (2015) eliminam o ruído de fundo do sinal sonoro coletado nos experimentos e apresentam o componente de falha desse sinal. De acordo com a característica do componente de falha chocante, o sinal adquirido foi interceptado em vários segmentos, e a análise de correlação cruzada foi adotada para remover o segmento errado sem o componente de falha de choque. Aplicando cálculos envolvendo outra forma de correlacionar os dados adquiridos, a autocorrelação de amostras sonoras, nosso trabalho assemelha-se a este, em razão dos subconjuntos menores em que as amostras foram divididas, tornando possível a busca por um coeficiente de comprimento de correlação ajustado ao método que aplicamos.

Em trabalhos anteriores (Bazeia *et al.*, 2017), simulações são realizadas para demonstrar que o caos presente na biodiversidade da natureza está associado à evolução caótica das espécies, e inferir o comprimento da correlação a partir da densidade dos máximos. Em nosso trabalho, uma componente caótica, presente no sinal do som emitido pelo motor, é extraído usando uma filtragem *wavelet*. E, após a realização de testes comparativos, uma nova técnica de processamento de sinais chamada SAC-DM (*Signal Analysis based on Chaos using Density of Maxima*) é aplicada para obter o Coeficiente de Comprimento de Correlação (CLC - *Correlation Length Coefficient* - (Medeiros *et al.*, 2018)), porém sem a utilização do filtro *wavelet*. Através do SAC-DM, também é possível identificar a velocidade na qual o motor está operando.

Características caóticas de um motor BLDC são utilizadas por Zhou *et al.* (2016) para estudar o seu comportamento dinâmico complexo. O método aplicado, análise do caos não linear, facilita a compreensão do sistema de um motor BLDC. O trabalho apresenta o modelo matemático adimensional do motor, os diagramas de bifurcação e os diagramas de expoente de *Lyapunov*, obtidos por software, e aplicados na análise do comportamento caótico do motor. Concluem afirmando que a não-linearidade do BLDC pode introduzir comportamentos muito mais complexos. Usando pouco processamento computacional, trabalhamos com a Teoria do Caos também para facilitar a compreensão do comportamento de um motor BLDC, mas para provar a capacidade que o método tem de detectar a velocidade e a excentricidade desse motor.

### 1.1.1 Tabela com resumo dos Trabalhos Relacionados

**Tabela 1.1** - Resumo dos trabalhos relacionados - Abordagem: Excentricidade em motores BLDC

AUTOR	DESCRIÇÃO
Artigao <i>et al.</i> (2018)	Técnica: Transformada de Fourier
Kang <i>et al.</i> (2017)	Técnica: Elementos finitos
Sapena-Bano <i>et al.</i> (2019)	Técnica: Elementos finitos
Park e Hur (2016)	Métodos híbridos: Elem. Fin./Fourier Sinal de corrente da armadura
Kral <i>et al.</i> (2004)	Métodos híbridos: Hilbert/Fourier
Georgoulas <i>et al.</i> (2017)	Métodos híbridos: <i>wavelet</i> /Fourier
Rezig <i>et al.</i> (2010)	<b>Motor de Ímã Perm.</b> Sinais de vibração e som Técnica: Fourier
Ning e Gong (2015)	Análise sinal sonoro – sensor acústico <b>1 - Método Superp. Linear:</b> Elimina ruído de fundo <b>2 - Análise Correl. Cruzada:</b> Remove segmento errado no componente de falha 3 - Proposta futura: <i>Wavelet</i> e Fourier → Tipo de falha
Puliyakote e Balasubramaniam (2013)	1 - Dados de <b>Emissões Acústicas (AE)</b> 2 - Algoritmo Wavelet recursivo 3 - Condições recriadas: a) Pistão ruim b) Anéis de pistão desgastados 4 - Melhoria nas características de uma AE: a) Indicação de falha
Rajagopalan <i>et al.</i> (2007a)	1 - Análise do sinal de corrente da armadura 2 - Detecção em condições variáveis: a) Carga do sinal e velocidade 3 - Processamento no domínio do tempo: a) <i>Wavelets</i> Analíticos e sem janelas b) Magnitude e fase
Lu <i>et al.</i> (2016)	Análise do sinal sonoro (rolamento): <b>1 - Celular (câm. e micr.):</b> a) Vídeo – frequência instantânea de rotação (IFR): Coef. Correlação – <i>frame</i> refeencial e subsequente b) Microf. – freq. caract. da falha instantânea (IFCF): Filtro no domínio da frequência <b>2 - IFCF / IFR → Tipo de falha do rolamento</b>
Kim <i>et al.</i> (2014)	<b>Comparativo entre 2 motores</b> Análise de características magnéticas Método de diagnóstico ITF: <i>Interturn Faults</i> (Falha entre espiras)

**Tabela 1.2** - Resumo dos trabalhos relacionados - Abordagem: Excentricidade em motores à indução

AUTOR	DESCRIÇÃO
Konar e Chattopadhyay (2015)	Sinais de vibração Técnica: <i>wavelet</i> /Hilbert
Ouachtouk <i>et al.</i> (2017)	Sinais de vibração e corrente de armadura Técnica: Fourier
Esfahani <i>et al.</i> (2014)	Sinais: som, corrente e vibração Técnica: Fourier, Transf. Hilber/Huang e Classificadores de falhas

**Tabela 1.3** - Resumo dos trabalhos relacionados - Abordagem: Características Caóticas

AUTOR	DESCRIÇÃO
Bazeia <i>et al.</i> (2017)	Presença do caos na natureza Evolução das espécies Comprimento de correlação Densidade de máximos
Medeiros <i>et al.</i> (2018)	1 - CLC a) Comportamento: Transf. Fourier → Caos 2 - Caracterização de motores BLDC a) Sinais de corrente elétrica Estator solto Direção de rotação
Zhou <i>et al.</i> (2016)	Caract. caóticas em Mot. BLDC: 1 - Simulação e Modelagem matemática do motor: a) Velocidade angular b) Componentes do estator: - Tensão, torque 2 - Diagramas de bifurcação 3 - Espectro de <i>Lyapunov</i> 4 - Método do Caos Não-linear: a) Compreensão do sistema de um BLDC

## 1.2 Hipóteses

A pesquisa realizada neste trabalho foi conduzida a partir de coletas de sinais sonoros de um motor BLDC. A partir deste sinal sonoro, foram formuladas as seguintes hipóteses:

- O sinal sonoro emitido por um motor BLDC com hélice possui componentes caóticos;
- É possível detectar velocidade de motor BLDC com hélice analisando o sinal sonoro emitido utilizando a técnica SAC-DM;
- É possível detectar falha de excentricidade de motor BLDC com hélice analisando o sinal sonoro emitido utilizando a técnica SAC-DM;
- É possível detectar a severidade (ou nível) da falha de motor BLDC com hélice analisando o sinal sonoro emitido utilizando a técnica SAC-DM.

## 1.3 Objetivos

### 1.3.1 Objetivo Geral

O objetivo deste trabalho é propor uma abordagem para a detecção de velocidade e de falha de excentricidade em motores Sem Escovas de Corrente Contínua (BLDC), a partir de sinais sonoros, baseada na densidade de máximos.

### 1.3.2 Objetivos Específicos

Os objetivos específicos deste trabalho são:

- Comprovar que há componentes caóticos no sinal sonoro emitido por um motor BLDC com hélice;
- Apresentar uma abordagem, baseada na densidade de máximos, para detecção da velocidade de um motor BLDC com hélice, analisando o sinal sonoro emitido por ele;
- Utilizar a abordagem apresentada para a detecção de falha de excentricidade de um motor BLDC com hélice, analisando o sinal sonoro emitido por ele e baseada na densidade de máximos;
- Utilizar a abordagem apresentada para a avaliar a severidade (ou nível) da falha detectada em um motor BLDC com hélice, analisando o sinal sonoro emitido por ele e baseada na densidade de máximos.

## 1.4 Organização

Este documento foi dividido em seis capítulos, assim nomeados: Introdução, Fundamentação Teórica, Metodologia, outro capítulo que traz a comprovação do Comportamento Caótico do sinal analisado, outro para Experimentos e Resultados e, por último, um capítulo para as Considerações Finais. Em outra seção, são apresentados os Anexos, contendo artigos submetidos e partes dos códigos desenvolvidos neste projeto.

## CAPÍTULO 2

# FUNDAMENTAÇÃO TEÓRICA

Processos que utilizam a conversão de qualquer forma de energia, seja ela térmica, elétrica, hidráulica, química ou outras, em energia mecânica, podem ser atribuídos ao conceito de motor. Neste capítulo é apresentada a base teórica desse estudo através dos conceitos básicos sobre: a) máquinas elétricas e os motores *brushless* CC, apresentando algumas de suas características e aplicações; b) sistemas tolerantes a falhas; c) processamento de sinais; d) teoria do caos; e) autocorrelação; f) coeficiente de comprimento da correlação (CLC); g) *Signal Analysis based on Chaos using Density of Maxima* (SAC-DM) e h) *Wavelet Multiresolution Analysis* (WMA).

## 2.1 Motores Elétricos

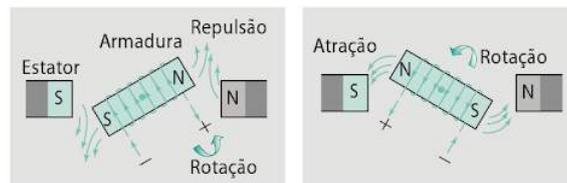
Os motores elétricos são, muitas vezes, a parte mais importante do processo industrial no qual está inserido. Estima-se que, na maior parte dos países industrializados, mais de 60% do consumo da energia elétrica esteja associado a aplicações de força motriz (de Almeida *et al.*, 2002). Ratificando essa informação, Petruzella (2013) afirma que os motores elétricos são um elemento importante da nossa economia industrial e comercial há mais de um século, e que a maioria das máquinas industriais atualmente em uso são acionadas por máquinas elétricas.

### 2.1.1 Classificações e Funcionamento

Conforme Petruzella (2013), os dois tipos básicos de motores elétricos, baseiam-se em magnetismo e correntes elétricas e são: Motores de Corrente Alternada (CA) e Motores de Corrente Contínua (CC).

O princípio de funcionamento de um motor elétrico está baseado na força do magnetismo que é responsável por promover o movimento de rotação do motor elétrico. Por sua vez, esta ação é justificada pela força que o campo magnético exerce, já que ela pode ser produzida por um ímã permanente que atrai e mantém materiais magnéticos próximos a ele.

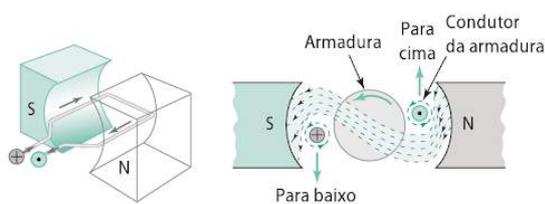
A Figura 2.1 apresenta as forças opostas (atração e repulsão) dos polos magnéticos (N e S) agindo conforme uma das leis do magnetismo. Neste caso, o eletroímã representa a parte móvel (armadura) e o ímã permanente, a parte estacionária (estator). Assim, a armadura gira devido a repulsão entre os polos magnéticos iguais e, após algum tempo em movimento, os polos opostos promovem uma força de atração forte o bastante para que o ímã permanente mantenha-se em rotação. Ao ocorrer o alinhamento dos polos opostos pela continuidade do movimento do eletroímã, o rotor para em razão da atração desses polos. No entanto, os polos iguais da armadura e do campo então se repelem, fazendo a armadura continuar a girar.



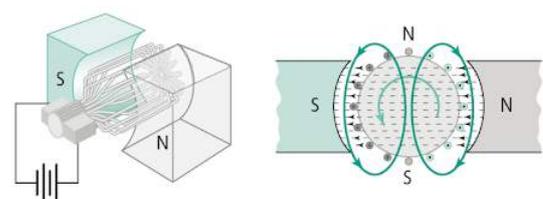
**Figura 2.1** - Princípio básico de funcionamento do motor

Linhas de fluxo que se movimentam no sentido de um dos polos do ímã para o outro polo marcam a força que o campo magnético tem, pois quanto maior o número de linhas de fluxo, mais forte será o campo.

A força rotacional do motor, ou torque, é produzido por uma bobina (ou espira de fio) que transporta corrente em um campo magnético. Assim, quando o campo magnético e o campo elétrico interagem, eles produzem uma força mecânica e, com base nisso, o princípio de funcionamento do motor CC é estabelecido. A Figura 2.2 retrata o torque produzido por uma bobina com espira única, enquanto que a Figura 2.3 apresenta o torque de uma armadura, cuja bobina possui várias espiras.



**Figura 2.2** Torque produzido por uma armadura de uma bobina de espira única



**Figura 2.3** Torque produzido por uma armadura de uma bobina de várias espiras

Em um motor real, cuja armadura é constituída por muitas bobinas de condutores, ocorre uma combinação dos campos magnéticos destes condutores para formarem o campo de armadura resultante.

Os motores que são alimentados por corrente contínua, já classificados de motores CC, podem obter energia de uma bateria ou de outra fonte de alimentação e a comutação de energia entre rotor e estator define uma outra denominação para esses motores: *brushed* (escovado) ou *brushless* (sem escovas). Neste caso, comutação é o processo de inversão da corrente de

armadura no momento em que os polos opostos da armadura e do campo estão frente à frente, invertendo assim a polaridade do campo induzido.

Este trabalho realiza experimentos que abordam apenas motores CC. Com estes, é possível manipular a velocidade do motor e exercer controle na tensão imposta sobre o mesmo, razão pela qual se tem, aqui, diferentes níveis de velocidade e suas respectivas amostras sonoras analisadas. Em motores de corrente alternada, motores CA, esse controle pode ser realizado variando a frequência, mas não é objeto de estudo para a ocasião.

### 2.1.2 Veículos Elétricos

Em se tratando de veículos, Yildirim *et al.* (2014) classifica estas máquinas de forma simples e em três grupos distintos, a saber:

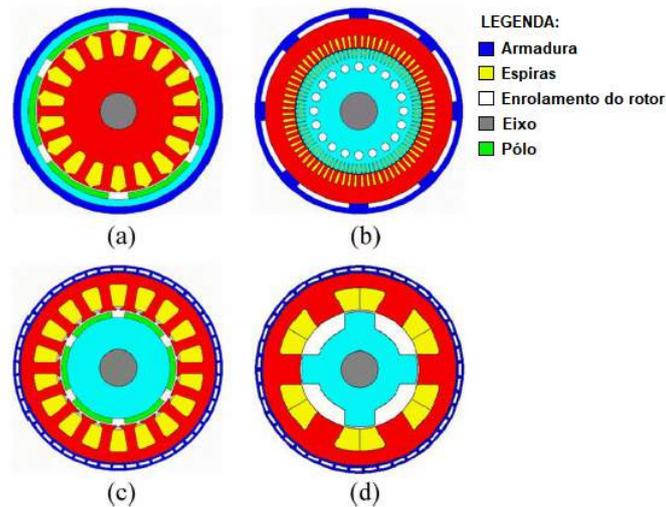
- Veículos de motor à combustão interna (*Internal Combustion Engine Vehicles* - ICEV);
- Veículos Elétricos (*Electric Vehicles* - EV);
- Veículos Elétricos Híbridos (*Hybrid Electric Vehicles* - HEV).

O foco deste trabalho está nos EVs, cuja relevância está na utilização, especificamente, de um motor ou, como demonstrado por Medeiros *et al.* (2018), de vários motores elétricos. No caso da indústria de veículos automotivos, ainda há a busca por um sistema de propulsão elétrico mais adequado para HEVs, bem como para veículos elétricos, conforme cita Zeraoulia *et al.* (2006). Nesse caso, os principais recursos são eficiência, confiabilidade e custo.

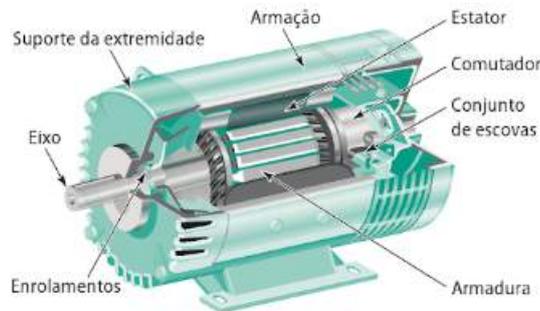
A Figura 2.4 apresenta as seções transversais dos principais tipos de motores elétricos, sob o ponto de vista industrial, assim organizados: a) Motores de Corrente Contínua (CC), ou *Direct Current Motor (DC motor)*; b) Motores de Indução, ou *Induction Motor (IM)*; c) Motor de Imã Permanente Sem Escova, ou *Permanent Magnet Brushless (PM BLDC) motor*; e d) Motores de Relutância Chaveada, ou *Switched Reluctance Motor (SRM)*.

Os Motores CC têm se destacado na propulsão elétrica, já que a relação entre torque e velocidade é adequada à exigência de tração e, também, por seus controles de velocidade simples. Parâmetros, como a velocidade, o torque e a potência (taxa na qual o trabalho é realizado), são importantes e medem o desempenho do motor CC, porém, principalmente pela presença do comutador mecânico (escova), eles registram baixa eficiência, baixa confiabilidade, maior necessidade de manutenção e têm uma construção volumosa, conforme Zeraoulia *et al.* (2006).

Para Petruzella (2013), os motores CC são usados onde torque preciso e acionamento de velocidade são exigidos para satisfazer as necessidades das aplicações, por exemplo, guindastes e elevadores. Porém, a construção de um motor CC é bem mais complicada e dispendiosa do que motores CA, em razão do alto custo de manutenção de componentes (Figura 2.5), como o comutador e as escovas.



**Figura 2.4** Motores Industriais e de Tração: (a) Motor CC; (b) Motor de Indução; (c) PM brushless motor; (d) SRM. Fonte: (Zeraoulia *et al.*, 2006)

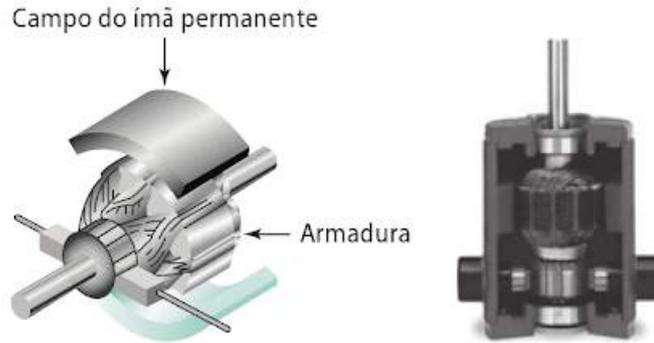


**Figura 2.5** - Componentes principais de um motor CC

Por outro lado, os motores sem comutadores são atraentes, já que a alta confiabilidade e a operação livre de manutenção são as principais considerações para a propulsão elétrica. No entanto, com relação ao custo do inversor, os inversores de frequência são usados geralmente apenas para maior potência. Em baixas potências, o motor DC ainda é mais do que uma alternativa (Zeraoulia *et al.*, 2006).

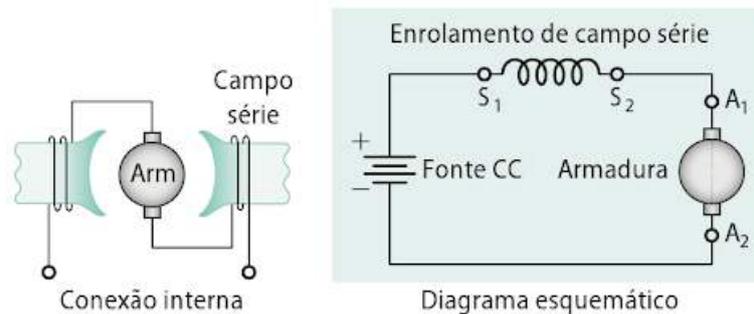
Alguns tipos de motores CC, classificados de acordo com o tipo de campo, são:

- De Ímã permanente – Usam ímãs permanentes para fornecer o fluxo do campo principal e eletroímãs para fornecer o fluxo da armadura. O movimento do campo magnético da armadura é obtido comutando a corrente entre as bobinas no interior do motor. A esta ação dá-se o nome de Comutação. Possui duas partes principais, conforme a Figura 2.6: a) um alojamento contendo os ímãs de campo, e b) uma armadura que consiste em bobinas de fio enroladas em ranhuras em um núcleo de ferro e conectadas a um comutador.



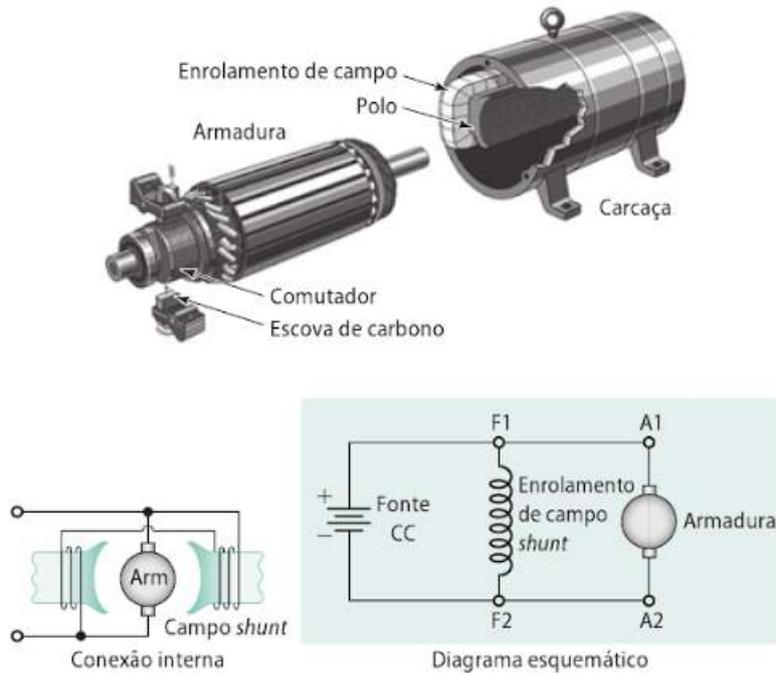
**Figura 2.6 - Motor CC de ímã permanente**

- **Série** – Motor classificado como enrolamento série, consiste em um enrolamento campo série (identificado por S1 e S2 na Figura 2.7) e conectado em série com a armadura (identificada por A1 e A2 na mesma figura). Possui um circuito de campo e de armadura de baixa resistência, elevando a corrente quando a tensão é aplicada a ele. Estes motores não podem ser usados quando é necessária uma velocidade constante com cargas variáveis.



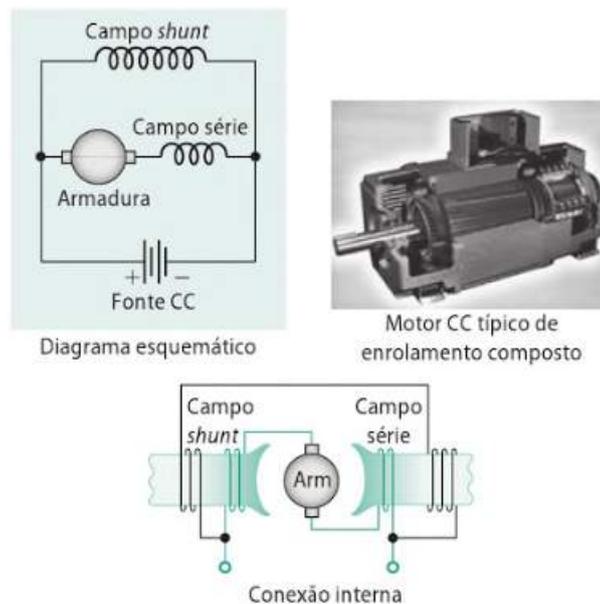
**Figura 2.7 - Motor CC Série**

- **Shunt** - Consiste em um campo *shunt* (identificado por F1 e F2 na Figura 2.8), conectado em paralelo (por isso o termo *shunt*) com a armadura. O enrolamento de campo *shunt* é constituído de muitas espiras de fio fino, tendo uma resistência muito alta e um fluxo de corrente baixo, em comparação com o enrolamento de campo série. Funciona quase com a mesma velocidade, tanto com carga como sem carga. E, ao contrário do motor série, não acelera a uma velocidade alta quando nenhuma carga é acoplada.



**Figura 2.8 - Motor CC Shunt**

- Composto – Combina dois tipos de enrolamento (*shunt* e *série*) e possui dois enrolamentos de campo, conforme a Figura 2.9, em que o campo *shunt* está em paralelo com a armadura e o outro em *série*. Motor com campo *shunt* tem a vantagem da velocidade constante de um motor *shunt* regular, enquanto o campo *série* permite que ele consiga desenvolver um grande torque quando ligado a uma carga pesada.



**Figura 2.9 - Motor CC Composto**

Para Hashemnia e Asaei (2008), os motores SRM apresentam características como simples construção, tolerância a falhas, controle simples e excelente relação torque-velocidade.

Esses motores podem operar intrinsecamente sob uma larga região de potência constante. Além disso, o alto ruído e a interferência eletromagnética são apontadas como desvantagens de seu uso.

Hashemnia e Asaei (2008) também apresentam os motores de ímãs permanentes, ou *Permanent Magnet Synchronous Motors* (PMS), abordando vantagens de seu uso, tais como maior densidade de potência e maior eficiência, além de distribuição mais eficaz de calor no ambiente. Como um motor DC sem escova, ou *brushless*, ele possui um rotor de ímã permanente e enrolamentos no estator. No entanto, a estrutura do estator com enrolamentos construídos para produzir uma densidade de fluxo senoidal no entreferro da máquina se assemelha ao de um motor de indução.

### 2.1.3 Motores de Corrente Contínua sem Escova - BLDC

Este trabalho tem como proposta a utilização da energia mecânica produzida por motores BLDC (*Brushless Direct Current*), especificamente pela coleta e análise de sinais sonoros emitidos ao longo do seu funcionamento e que aqui foram traduzidos em resultados. Neste caso, o som coletado e emitido por um motor BLDC de um VANT - Asa Fixa, em bancada experimental, é usado nos testes e análises desta pesquisa.

Adicionalmente a estes fatos, Usman *et al.* (2016) afirma que os motores de corrente contínua sem escova (BLDC) são cada vez mais utilizados em aplicações industriais e veículos elétricos, elevando o nosso interesse por este tipo de motor. Aqui se enquadra o motor BLDC do Asa Fixa mencionado. E ainda, como afirma Parikh *et al.* (2015), a eliminação do contato físico direto entre o estator e o rotor pela ausência de escovas, promove vantagens como a redução da fricção que permite maior eficiência do motor e suscetibilidade a ambientes adversos.

Zeraoulia *et al.* (2006) afirma que os motores PM BLDC apresentam vantagens importantes e que podem ser decisivos em um projeto, a saber: 1) o peso total e volume são significativamente reduzidos para uma dada potência de saída (alta densidade de potência); 2) eles têm uma eficiência maior em razão da relação anterior; e 3) o calor que é eficientemente dissipado para o ambiente.

Outros benefícios são apontados por Tibor *et al.* (2011), destacando que estes motores são caracterizados por uma maior eficiência, maior confiabilidade e maior densidade de potência e requerem menos manutenção. Os motores de ímã permanente sem escova de corrente contínua (*Permanent Magnet Brushless Direct Current Motors* - PM BLDC), ou simplesmente motores *Brushless DC*, são conhecidos por ter maior torque em relação ao tamanho do motor, alta eficiência e longa vida útil. Assim, fica justificada a escolha por este tipo de motor e, na Seção 3.2, é descrita a forma como esse motor é utilizado.

Segundo Parikh *et al.* (2015), os motores BLDC são classificados em duas grandes categorias, baseados na configuração física e na construção, a saber:

- *In-runner* - São geralmente mais eficientes e úteis para aplicações de alto torque, mas o aumento da caixa de engrenagens e a complexidade mecânica os tornam mais caros.
- *Out-runner* - Têm baixo torque, mas simplicidade tornando-os mais baratos e menos dispendiosos de usá-los e mantê-los. A reduzida complexidade de sua caixa de câmbio também reduz o peso total da aeronave.

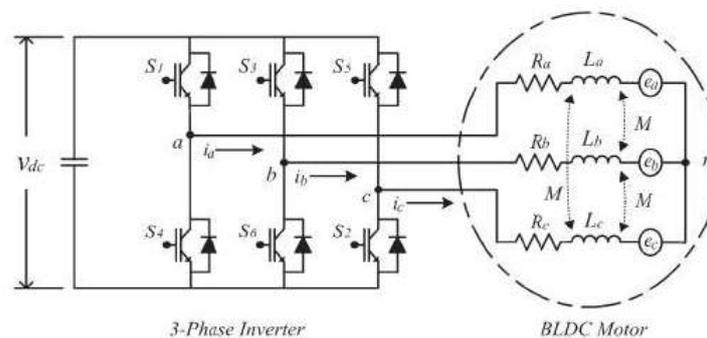
Assim, os motores BLDC *out-runner* são uma alternativa viável e de baixo custo para muitas aplicações de controle de movimento para impulsionar hélices de aeronaves elétricas, por exemplo, a hélice única de um Asa Fixa.

Em relação ao caminho do fluxo (*flux path*), a maioria dos tipos comuns de máquinas é de fluxo radial ou axial. Outras topologias, tais como caminhos de fluxo transversal e esférico foram descritas, mas seu uso é limitado. Existem muitas estratégias diferentes de montagem de ímãs no rotor.

As máquinas de fluxo axial geralmente têm ímãs montados na superfície do rotor, enquanto que as máquinas de fluxo radial podem ter os magnetos montados na superfície ou montados internamente. Motores SPMs (*Surface Permanent Magnet*) permitem grande flexibilidade no design e são adequados para caber em espaços limitados, tais como "tração traseira elétrica" e "motores em roda" (IWMs - *In-Wheel Motor*), onde não é possível outra alternativa (de Santiago *et al.*, 2012).

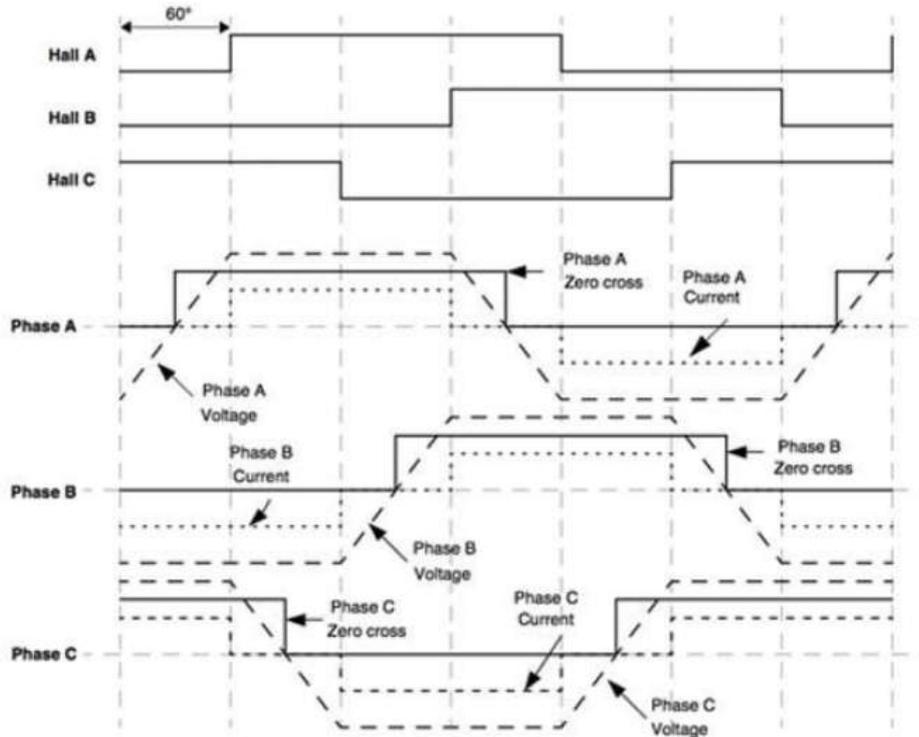
É um motor síncrono de ímã permanente que usa detectores de posição e um *inverter* para controlar a corrente de armadura. Ao invés de utilizar comutador mecânico como um motor DC convencional, utiliza comutação eletrônica. Apenas duas fases conduzem correntes por vez, deixando uma terceira fase em "*floating*".

Geralmente o motor BLDC é controlado por um inversor com comutador de "*six-step*", como mostra a Figura 2.10.



**Figura 2.10** - Circuito Elétrico Equivalente para drivers de motores BLDC. Fonte: Park *et al.* (2011)

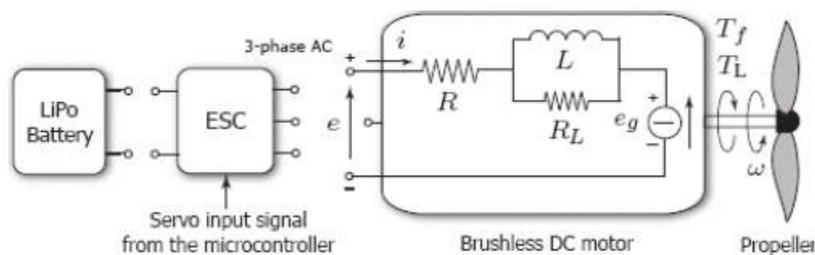
O circuito equivalente elétrico deste sistema é mostrado na Figura 2.10. Geralmente, um sistema de acionamento de motor BLDC pode ser representado como um circuito equivalente elétrico que consiste em uma resistência, uma indutância e uma força *Back-EMF* (*Back*



**Figura 2.11** Saída do sensor *Hall* comparada com *Back-EMF* do motor BLDC trifásico. Fonte: Park *et al.* (2011)

*Electromotive Force*), ou Força Contra-Eletromotriz, por fase (Park *et al.*, 2011). A Figura 2.11 mostra o comportamento dos sinais para um motor BLDC.

No motor de BLDC, que tem uma força *back-EMF* em forma de trapézio para cada fase, é possível verificar que a presença de um sensor de efeitos Hall detecta as variações nas fases. Esta aplicação é ilustrada na na Figura 2.12.



**Figura 2.12** - Motor *Brushless* DC para VANTs. Fonte: Morbidi *et al.* (2016)

Um sistema de propulsão elétrica converte energia elétrica em impulso mecânico e consiste de quatro componentes principais: uma fonte de energia elétrica, um controlador eletrônico de velocidade (*Electronic Speed Controller* - ESC), um motor elétrico e uma hélice.

Cada um desses componentes tem suas próprias características de funcionamento e desempenho. A escolha de cada um destes é crítica para a obtenção de um sistema de propulsão global que seja eficiente e adequado aos requisitos da plataforma de aplicação.

A energia ( $P_{bat}$ ) derivada, neste caso da bateria, provê:

$$P_{bat} = V_{bat} \times I_{bat} \quad (2.1)$$

Onde:

- $V_{bat}$  : Tensão da Bateria
- $I_{bat}$  : Corrente da Bateria

O ESC recebe sinais de controle de aceleração de modulação de largura de pulso (*Pulse Width Modulation* - PWM) do controlador de voo. A porcentagem de aceleração é repassada ao ESC que controla a velocidade do motor de acordo com o ciclo de trabalho percentual recebido. A energia é transferida do ESC para o motor na forma de uma arquitetura de energia *quasi-three-phase* AC (Gabriel *et al.*, 2011).

$$P_{ESC}(RMS) = V_{ESC}(RMS) \times I_{ESC}(RMS) \quad (2.2)$$

Onde:

- $V_{ESC}(RMS)$  : Tensão do ESC
- $I_{ESC}(RMS)$  : Corrente do ESC

O motor CC sem escova converte a energia elétrica em um torque (M) no seu eixo de saída a uma velocidade angular ( $\omega$ ) específica, dada por (2.3).

$$P_M = M \times \omega \quad (2.3)$$

Onde:

- $M$  : Torque [N.m]
- $\omega$  : Velocidade Angular [rad/s]

Considerando o projeto de controladores de hardware e software e outras funções no futuro, os tipos de circuitos podem ser assim classificados (Xia, 2012):

1. FPGA (*Field Programmable Gate Arrays*) - que é um circuito integrado projetado para ser configurado por um consumidor ou projetista após a fabricação;
2. MCU (*Microcontroller Units*) - que é um pequeno computador (*System on Chip* - SoC) num único circuito integrado contendo contém um núcleo de processador, memória e periféricos programáveis de entrada e saída; e

3. DSP (*Digital Signal Processor*) - que são microprocessadores especializados em processamento digital de sinal usados para processar sinais de áudio, vídeo, quer em tempo real quer em *off-line*, que têm as vantagens de funções perfeitas e fáceis de controlar.

Estes tipos poderiam ser implementados para controlar o motor BLDC, com a condição de que o correspondente custo pode ser maior do que o dos controladores ASIC (*Application-Specific Integrated Circuit*) - que são circuitos orientados para implementação de tarefas específicas em domínios bem definidos. A diferença é que os MCU são comumente usados para sistemas de controle de motores simples, enquanto o DSP é usado para sistemas de controle inteligente devido à sua poderosa capacidade de computação e processamento de dados. A Figura 2.13 apresenta o esquema de um sistema típico do motor BLDC de controle MCU ou DSP.

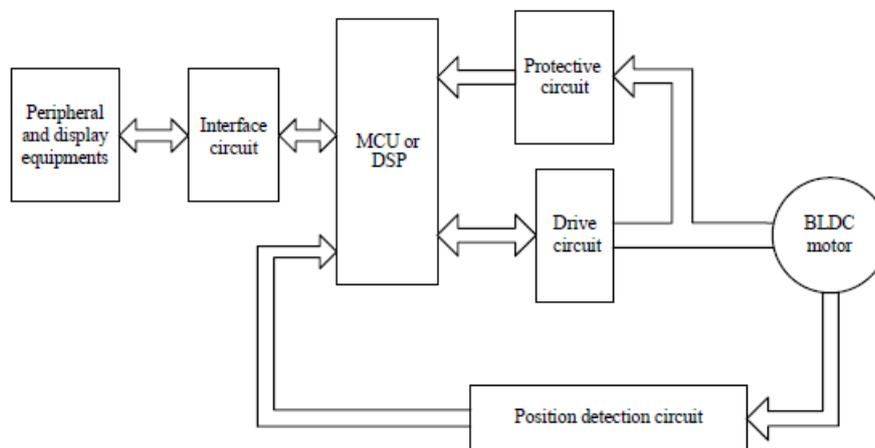


Figura 2.13 - Sistema de controle típico de um motor BLDC. Fonte: Xia (2012)

#### 2.1.4 Métodos de Diagnósticos de Falhas

Máquinas elétricas podem apresentar falhas em partes distintas da sua estrutura física devido às adversidades térmicas, ambientais e desgastes mecânicos que podem provocar interrupções ocasionando, por exemplo, perdas financeiras em processos industriais (Nakano *et al.*, 2015). Atualmente, o desempenho de um sistema de máquinas elétricas ao longo de sua operação pode ser monitorado por técnicas não invasivas, tais como, baseada em análise de corrente, em vibrações na estrutura da máquina e até na atividade sonora produzida pela máquina.

Os tipos de falhas podem ser classificados de acordo com suas localizações, como no estator, rotor, inversor, circuito de energia, sensor e outros dispositivos mecânicos. Para melhorar o seu desempenho e garantir a competitividade, o desenvolvimento de motores requer estabilidade e confiabilidade muito melhores e, por isso mesmo, o monitoramento eficaz e o diagnóstico preciso de falhas são muito importantes.

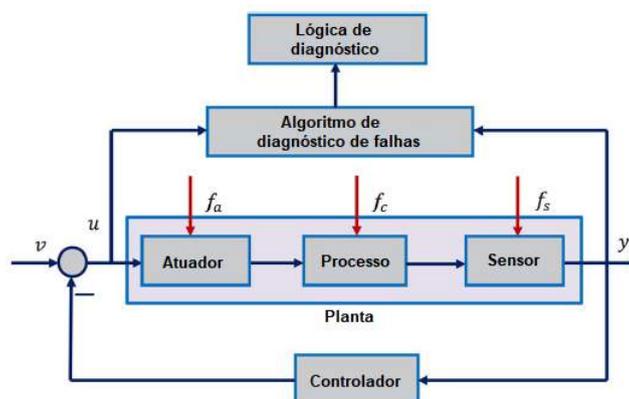
Kim *et al.* (2014) cita que uma Falha Entre Espiras (*Interturn Fault - ITF*) é um problema crítico porque esse tipo de falha se espalha rapidamente para todo o enrolamento, em particular. O autor descreve que este tipo de falha é responsável por 21% das falhas que ocorrem em

máquinas elétricas. A maioria das falhas de curto-circuito começam como ITFs, que ocorrem por quebra de isolamento, e se desenvolvem em falhas mais sérias muito rapidamente.

Os métodos de análise de tempo-frequência são um método de diagnóstico ITF representativo sem um sensor, e usam os harmônicos específicos no espectro atual de motores de indução e síncronos, embora a aplicação do diagnóstico dessas técnicas exija o entendimento de suas respectivas limitações. Porém, métodos de diagnóstico baseados no processamento de sinais têm dificuldade em determinar as ordens harmônicas devido à variação nas velocidades do motor.

Uma falha é definida como um desvio não permitido (ou previsto) de, pelo menos, uma propriedade característica ou parâmetro do sistema a partir de uma condição aceitável/normal/-padrão (Gao *et al.*, 2015a). Os autores diferenciam a evolução, no decorrer das últimas décadas, dos métodos e aplicações tanto de tolerância à falhas, quanto de diagnóstico. As falhas podem ser classificadas a partir de três situações: falhas do atuador, falhas do sensor e falhas da planta (ou chamadas falhas de componentes ou falhas de parâmetro). Elas podem interromper a ação do controlador na planta, ou produzir erros de medição substanciais, ou alteram diretamente a dinâmica da entrada/saída das propriedades do sistema, levando à degradação do desempenho do sistema e até mesmo à danos e, conseqüentemente, ao colapso de todo o sistema.

Com o intuito de melhorar a confiabilidade dos sistemas de diagnóstico de falhas o conceito de redundância, redundância de hardware ou redundância de software (ou chamada redundância analítica) é utilizado. Com o avanço da teoria de controle moderno, a técnica de redundância analítica se tornou a principal corrente de pesquisa de diagnóstico de falhas, conforme é apresentado pela Figura 2.14. Esta técnica, se comparada com os métodos de redundância de hardware, apresenta um melhor custo benefício, mesmo que ruídos ambientais, erros de modelagem inevitáveis, complexidade do sistema e a estrutura de controle tornem a implementação mais difícil (Gao *et al.*, 2015a).

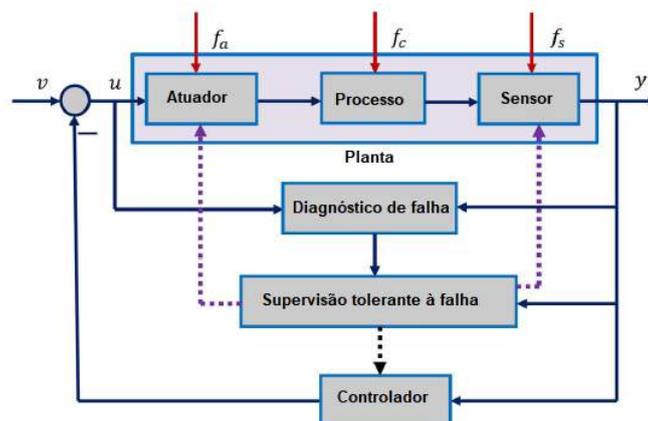


**Figura 2.14** - Redundância Analítica baseada em diagnóstico de falhas. Fonte: Gao *et al.* (2015a)

Para que se possa implementar um diagnóstico de falhas, três atividades são primordiais: a detecção, o isolamento e a identificação de falhas. A detecção de falhas é a tarefa mais básica do diagnóstico, mas não menos importante, já que ela é usada para a verificação de mau

funcionamento ou falha no sistema, determinando, assim, o momento em que ocorre a falha. O isolamento de falhas tem a função de determinar a localização do componente defeituoso e, por fim, a identificação de falha trata da determinação do tipo, da forma e do tamanho da falha. Esses aspectos são vitais para que o sistema tenha respostas tolerantes à falhas de maneira oportuna e apropriada, visando a remoção dos efeitos adversos das partes defeituosas e promovendo o funcionamento normal do sistema.

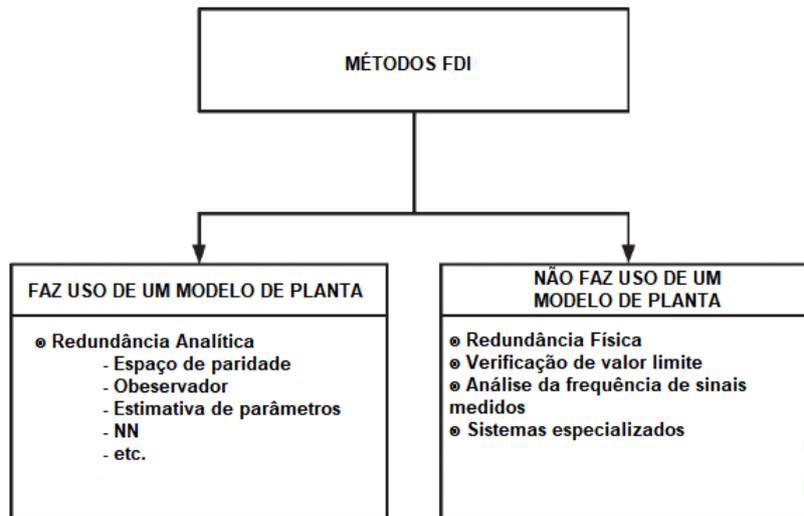
A Figura 2.15 apresenta os aspectos que diferenciam o diagnóstico de falhas e a tolerância à falhas. Igualmente, mostra que o controle tolerante a falhas é integrado ao diagnóstico, em sua essência. Em tempo real, o diagnóstico de falhas pode detectar se o sistema está com defeito e informar onde a falha ocorreu e quão grave é o defeito.



**Figura 2.15** - Diagnóstico e Tolerância à Falhas. Fonte: Gao *et al.* (2015a)

Para um sistema controlado submetido a um tipo de falha - seja no atuador, processo / componentes ou sensor - a entrada  $u$  e a saída  $y$  são usados para construir um algoritmo de diagnóstico de falhas, que é utilizado para verificar a consistência da informação característica do processo em tempo real.

Existem vários métodos de Diagnóstico e Identificação de Falhas (*Fault Diagnosis and Identification - FDI*), podendo ser classificados conforme o esquema da Figura 2.16.



**Figura 2.16** - Métodos de Diagnóstico e Identificação de Falhas (FDI)

Basicamente a classificação divide-se em métodos que utilizam um modelo da planta e os que não utilizam este modelo. De forma mais ampla, os Métodos de Diagnóstico de Falhas podem ser categorizados em Métodos Baseados em Modelos (*Model-Based Methods*), Métodos Baseados em Sinais (*Signal-Based Methods*), Métodos Baseados em Conhecimentos (*Knowledge-Based Methods*), Métodos Híbridos (*Hybrid-Based Methods*), e Métodos de Diagnóstico de Falhas Ativas (*Active Fault Diagnosis Methods*).

#### 2.1.4.1 Métodos Baseados em Modelos

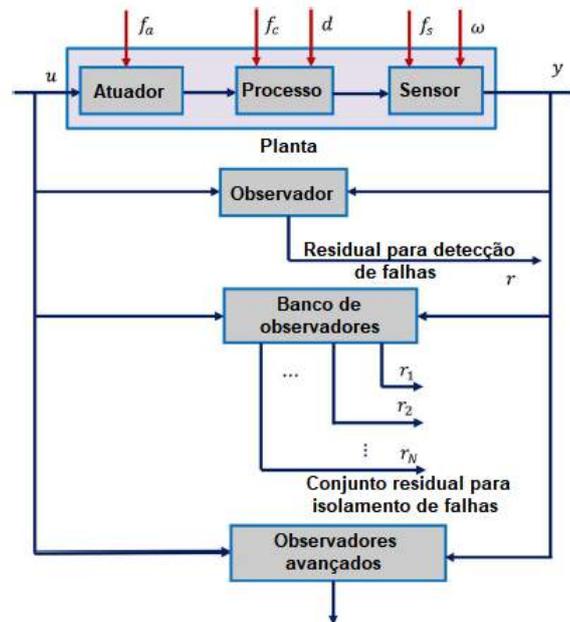
No caso dos métodos com base em modelo, é preciso conhecer os modelos de processos industriais ou os sistemas práticos, cujos podem ser obtidos usando qualquer princípios físicos ou técnicas de identificação de sistemas.

Com base no modelo, algoritmos de diagnóstico de falhas são desenvolvidos para realizar comparações entre as saídas medidos nos sistemas práticos e as saídas prevista pelo modelo.

Aqui, os métodos de diagnóstico de falhas baseadas em modelos são revistos de acordo com as quatro categorias:

- Métodos Determinísticos de Diagnóstico de Falhas

Observador desempenha um papel fundamental no diagnóstico de falhas baseada em modelo para sistemas/processos monitorados e caracterizados por modelos determinísticos. O esquemático do diagnóstico de falhas baseado em observador é representada pela figura a seguir, que inclui detecção, isolamento e identificação de falhas (ou chamado de reconstrução falha ou estimativa de falhas).



**Figura 2.17** - Esquema de diagnóstico de falhas baseado em modelo. Fonte: Gao *et al.* (2015a)

Para simplicidade, o modelo do processo na Figura 2.17 é assumida como sendo um modelo de estado-espço linearizado. A identificação de falha determina o tipo, tamanho e forma da falha em questão, que é a informação vital para uma operação tolerante a falhas. Técnicas avançadas de observer, como: proportional and integral (PI) observers; proportional multiple-integral (PMI) observers; adaptive observer; sliding mode observers e descriptor observers são normalmente utilizados para a estimativa/reconstrução de falha. A essência dos observadores avançados é construir um sistema aumentado através da introdução da falha em questão como um estado adicional. Assim o vetor de estado estendido é posteriormente estimado, levando as estimativas do sinal de falha em questão, juntamente com os estados de sistema originais. Portanto, os observadores avançados também são chamados simultâneos observadores de estado e de falha. As técnicas de observação avançadas acima mencionadas estão em uma posição de vantagem tanto para a reconstrução "slow-varying additive faults"(observadores PI e PMI), "slow-varying parameter faults"(observadores adaptativos), "actuator faults with sinusoidal waveforms"(observadores "sliding mode"), e "high-frequency sensor faults"(descriptor system approaches). As técnicas de observação acima mencionados podem ser integrados ou combinados, a fim de resolver problemas de engenharia.

- Métodos Estocásticos de Diagnóstico de Falhas

Desenvolvido desde 1970, um procedimento de detecção de falhas e diagnóstico geral foi proposto pela primeira vez utilizando resíduos (ou inovações) gerados por filtros de Kalman com estrutura semelhante aos observadores, em que as faltas foram diagnosticadas por meio de testes estatísticos sobre limpeza, média e covariância dos resíduos.

Pesquisas desenvolvidas levaram a uma série de técnicas de filtragem Kalman modificadas para diagnóstico de falhas, tais como: *extended Kalman filters* (EKFs), que pode ser utilizado para diagnosticar falhas em um processo industrial não-linear; *unscented Kalman filters* (UKFs), dependendo de uma aproximação estocástica mais precisa, pode captar melhor a média verdadeira e covariância, levando a um melhor desempenho diagnóstico; *adaptive Kalman filters*, podem ser empregues para ajuste da *process noise covariance matrix* ou *measurement noise covariance matrix*, a fim de se obter o diagnóstico de falha satisfatória; e *augmented state Kalman filters*, pode ser utilizado para estimar simultaneamente estados do sistema e sinais de falha.

Outro método estocástico de diagnóstico de falhas importante é estimativa de parâmetros (parameter estimation) com base em técnicas de identificação de sistemas (por exemplo, estimador de mínimos quadrados e seus métodos derivados). Nesta abordagem, as falhas são assumidas para ser refletida em parâmetros do sistema, e somente a estrutura do modelo é necessário para ser conhecido. A ideia básica do método de detecção consiste em identificar os parâmetros do processo real online, os quais são comparados com os parâmetros de referência obtidos inicialmente sob condições saudáveis. Os métodos de diagnóstico de falhas com base em estimativa de parâmetros são muito simples, se os parâmetros do modelo têm um mapeamento explícito com os coeficientes físicos.

- Diagnóstico de Falhas para Eventos Discretos e Sistemas Híbridos

Em processos industriais, os sinais de alguns sistemas dinâmicos mudam de um valor para outro em vez de alterar os seus valores continuamente. Este tipo de sistemas é chamado de sistemas a eventos discretos. O problema básico do diagnóstico de falha orientada a eventos é a realização de inferência baseado em modelo em tempo de execução para determinar se um determinado evento de falha não observável ocorreu ou não no passado, usando sequências de eventos observáveis. De acordo com o modelo utilizado, os métodos de diagnóstico de falhas para o sistema de eventos discretos podem ser grosseiramente classificados em *automata-based fault method* (dividido em *decentralized method*, *symbolic method* ou a combinação destes) e *Petri-net-based method*.

- Diagnóstico de Falhas para Sistemas em Rede e Distribuídos

O rápido desenvolvimento das tecnologias de rede têm estimulado muito o controle em tempo real e monitoramento através de canais de comunicação, o que é chamado de controle e monitoramento de rede, cujo têm valiosas vantagens como relação custo-benefício, menos exigências de peso e de energia, instalação e manutenção mais fácil, e recursos compartilhados.

Nota-se que a utilização de cabos de rede com capacidade limitada ou sensores sem fio em ciclos de controle e monitoramento tem, inevitavelmente, trazido alguns problemas imprevistos como atrasos aleatórios de comunicação, dropout de dados e confusão de

programação, o que torna a monitorização e o diagnóstico de falhas baseada em rede mais desafiador em comparação com sistemas de monitoramento e de controle convencional ponto-a-ponto.

Portanto, no diagnóstico de falha com base na rede, o erro residual ou estimativa falha deve ser robusto não só contra erros de modelagem, perturbação de processo, e os ruídos de medição, mas também contra os atrasos de transmissão, o descarte de dados e medições incompletas causadas pela capacidade limite de comunicação canais. Recentemente, uma variedade de técnicas de diagnóstico de falhas têm sido desenvolvidos para vários sistemas em rede.

Sistemas industriais complexos podem ser modelado como uma interconexão de subsistemas e cada subsistema tem um tomador de decisão (agente inteligente), que pode ter acesso a medições locais, modelos de subsistema, avaliadores/controladores locais, e canais de comunicação restrito entre o agente e os seus vizinhos. Este tipo de estrutura descentralizada ou distribuída tornou-se o mainstream em processos industriais complexos devido à sua menor utilização de recursos de rede, relação custo-eficácia e conveniência para a expansão. Por outro lado, o acompanhamento em tempo real e diagnóstico de falhas para sistemas distribuídos é muito difícil devido à redundância de informação restrita e capacidade de comunicação limitada.

#### 2.1.4.2 Métodos Baseados em Sinais

Métodos baseados em sinal utilizam sinais medidos, em vez de modelos de entrada-saída explícitos, para diagnóstico de falhas. Têm uma ampla aplicação no monitoramento e diagnóstico em tempo real para motores de indução, conversores de energia e componentes mecânicos em um sistema.



**Figura 2.18** - Métodos baseados em sinais. Fonte: Gao *et al.* (2015a)

Com o conhecimento prévio sobre o comportamento do sistema saudável, ou seja, o padrão dos sinais para o comportamento padrão do sistema cujas características são extraídas, as falhas no processo são refletidas nos sinais medidos e, conseqüentemente, há uma decisão de diagnóstico com base nesta análise. Esta pode ser tanto no domínio do tempo ou no domínio da frequência.

- Métodos Baseados em Sinais no Domínio do Tempo

Para monitorar um processo contínuo e dinâmico é natural extrair as características no domínio do tempo para trabalhar com diagnóstico de falhas.

Cita Chen e Lu (2013) que analisando a corrente medida, especificamente as mudanças do valor eficaz (*root-mean-square* - RMS) medido entre as condições normais e as situações no âmbito de *single-/dual-transistor short circuit* ou *open circuit*, um método de diagnóstico de falhas foi desenvolvido para conversores de potência de motores de relutância comutadas (*switched reluctance motor*).

Em Bouzid e Champenois (2013) mostrou-se que, sob tensão de alimentação equilibrada, o ângulo de fase e a magnitude das correntes de sequência negativa e zero podem ser considerados como indicadores de confiança de falhas do estator nos motores de indução.

Já Samara *et al.* (2008) apresenta um método estatístico para a detecção de falhas bruscas do sensor nos sistemas de controle de aeronaves foi apresentada, em que a covariância dos sinais detectados foi usada para extração de características.

Estes são métodos que analisam o sinal em uma dimensão. Há também os métodos que analisam em duas dimensões, a exemplo da utilização de sinais de vibração. Este caso pode ser exemplificado com uma abordagem para o diagnóstico de falhas de motores de indução utilizando análise de textura bidimensional com base em padrões binários locais (*Local Binary Pattern* - LBP). Em primeiro lugar, sinais de vibração de domínio de tempo adquiridos a partir do motor operando são convertidos em imagens bidimensionais em escala de cinza. Então, características de textura são extraídas a partir dessas imagens que empregam operador LBP. Estes descritores de recursos locais são posteriormente utilizados por multi-classe de máquinas de vetores de suporte para identificar falhas de motores de indução.

- Métodos Baseados em Sinais no Domínio da Frequência

Método baseado em sinal no domínio da frequência detecta mudanças ou falhas usando a ferramenta de análise de espectro, a exemplo da Transformada Discreta de Fourier. Um dos mais poderosos métodos para o diagnóstico de falhas em motores no domínio da frequência é *motor current signature analysis* (MCSA), que utiliza a análise espectral da corrente do estator para detectar falhas de rotor associados a barras do rotor quebradas e equilíbrio mecânico. Sem a necessidade de acesso ao motor, a abordagem MCSA tem recebido muita atenção.

Análise de sinais de vibração é um método comum para monitoramento de condições e diagnóstico para equipamentos mecânicos. O som máquina indica muito sobre a condição de trabalho da máquina.

- Métodos Baseados em Sinais no Domínio do Tempo e da Frequência

Para máquinas sob uma condição sem carga, ou tensões de alimentação desequilibrada, carga variável, ou oscilações de torque de carga, os sinais medidos são geralmente transitórios e dinâmicos sob uma determinada sessão de tempo. Portanto, em alguns casos, a análise das quantidades fixas tem dificuldade para monitorar ou detectar falhas, quer através de um método puro de domínio de tempo ou domínio da frequência.

Devido à variação do espectro de frequências no tempo para os sinais transitórios, são necessárias ferramentas adequadas de decomposição da frequência no tempo para o monitoramento e diagnóstico de falhas em tempo real. Ou seja, análise tempo-frequência pode identificar os componentes de frequência de sinal e revelar suas características na variação do tempo, que tem sido uma ferramenta eficaz para o monitoramento e diagnóstico de falhas, extraindo informações contidas em sinais não estacionários Feng *et al.* (2013) (*survey time-frequency*).

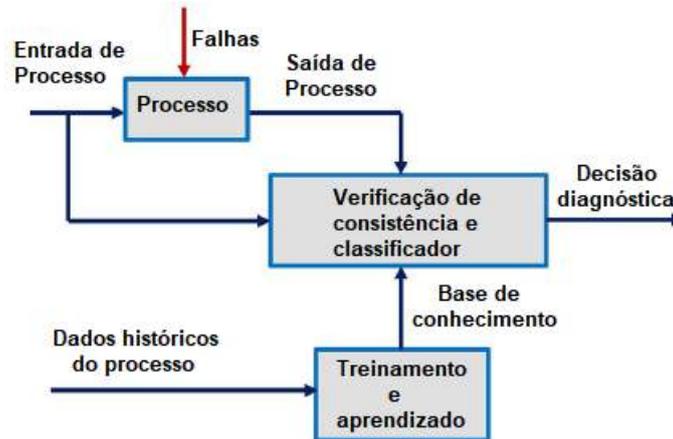
Vários métodos de análise de tempo-frequência têm sido propostos e aplicado a diagnóstico de falhas em máquinas. Sendo *Short-Time Fourier Transform* (STFT), *Wavelet Transforms* (WT), *Hilbert–Huang Transform* (HHT), e *Wigner–Ville Distribution* (WVD) as abordagens comumente utilizadas.

Continuando a classificação dos métodos, Gao *et al.* (2015b) o autor destaca que para processos industriais complicados, uma grande quantidade de dados históricos, em vez de um modelo ou um padrão de sinal, está disponível. O conhecimento subjacente, o que representa, implicitamente, a dependência das variáveis do sistema, pode ser extraído por utilização de várias técnicas de inteligência artificial e os dados históricos disponíveis.

Na segunda-parte, métodos baseados em conhecimentos (*knowledge-based methods*), métodos híbridos (*hybrid-based methods*), e métodos de diagnóstico de falhas ativas (*active fault diagnosis methods*) serão revisto de forma abrangente. As vantagens distintas e as várias limitações destes métodos de diagnóstico estão a ser discutido.

### 2.1.4.3 Métodos Baseados em Conhecimento

Diferente de métodos vistos até aqui, que requer prévio conhecimento seja do modelo ou do padrão de sinais, métodos de diagnóstico de falhas baseadas no conhecimento começa a partir de um grande volume de dados históricos que esteja disponível, ver Figura 2.19 .



**Figura 2.19** - Métodos baseados em conhecimento. Fonte: Gao *et al.* (2015a)

A aplicação de uma variedade de técnicas de inteligência artificial (tanto inteligência simbólica quanto computacional) para os dados históricos disponíveis dos processos industriais, o conhecimento subjacente, o que representa, implicitamente, a dependência das variáveis do sistema que pode ser extraída. A coerência entre o comportamento observado do sistema e a base de conhecimentos é verificada, levando a uma decisão de diagnóstico de falhas com o auxílio de um classificador (*classifier*).

É digno de salientar que os métodos de diagnóstico com abordagens de não baseada em modelos, em sinais e algoritmos de diagnóstico baseados no conhecimento, todos têm de utilizar dados em tempo real ao fazer o monitoramento em tempo real e diagnóstico de falhas on-line. No entanto, as abordagens de diagnóstico apenas com base em conhecimento precisará empregar um grande volume de dados históricos disponíveis. A partir deste ponto de vista, diagnóstico de falhas baseada no conhecimento também é referido como o diagnóstico de falhas data-driven (*data-driven fault diagnosis*). Os métodos de diagnóstico de falhas baseada no conhecimento podem ser classificados em métodos qualitativos e métodos quantitativos.

### 1. Diagnóstico de Falha Qualitativa Baseada no Conhecimento

Um dos métodos de diagnóstico de falhas qualitativas mais conhecidos é o método *expert-system-based*. O sistema especialista surgiu no final dos anos 1960 como um ramo da inteligência artificial, que é um sistema baseado em regras, onde apresenta experiência de um ser humano em um conjunto de regras.

### 2. Diagnóstico Quantitativo de Falha Baseado no Conhecimento

Um método baseado no conhecimento quantitativo é, essencialmente, formular a solução do problema de diagnóstico como um problema de reconhecimento de padrões. A informação quantitativa (ou recursos) podem ser extraídos através de métodos estatísticos ou não estatísticos.

Portanto, o diagnóstico de falhas baseada no conhecimento quantitativo pode ser grosseiramente classificados em diagnóstico de falhas baseada em análise estatística e diagnóstico de falhas baseada em análise não estatística.

- Diagnóstico de falha baseado em análise de dados estatísticos

É importante saber que estes métodos requerem uma grande quantidade de dados de formação para capturar as características fundamentais do processo por meio de análise estatística. Sob o olhar estatístico, os métodos de diagnóstico de falhas baseadas no conhecimento quantitativos são compostas por: *principal component analysis* (PCA); *partial least squares* (PLS); *independent component analysis* (ICA); e o classificador de padrões estatísticos *support vector machine* (SVM)".

- Diagnóstico de falha baseado em dados não estatísticos

As ferramentas de diagnóstico de falhas não estatística baseada em *data-driven* podem ser *Neural Network* (NN) e *Fuzzy Logic* (FL). Devido a sua poderosa capacidade de aproximação não-linear e aprendizagem adaptativa, a rede neutra (NN) tem ganho destaque.

A Tabela 2.1 apresenta a classificação das NNs de acordo com a topologia e categorias de falhas baseadas na estratégia de aprendizagem.

**Tabela 2.1** - Topologia e categorias de estratégias de aprendizagem para diagnóstico de falhas NN

TOPOLOGIA	ESTRATÉGIA DE APRENDIZAGEM
Radial base network	Supervised-learning-based FD
Recurrent dynamic network	Unsupervised-learning-based FD
Selforganizing maps	
Backpropagation networks	
Extension networks	

A lógica fuzzy (FL) é uma abordagem de particionamento de um espaço de características em conjuntos fuzzy e utilizando regras fuzzy para o raciocínio, que essencialmente se aproximam raciocínio humano. FL tem sido empregada com sucesso para o diagnóstico de falhas.

Desenvolvimentos recentes têm demonstrado um interesse de combinar FL com outras técnicas baseadas no conhecimento, tais como sistemas especialistas ou NNs para resolver um problema diagnóstico orientada para projeto ou obter um melhor desempenho em diagnóstico. Em Wijayasekara *et al.* (2014), foi proposta uma fusão de dados fuzzy e NNs, que foi composta de três camadas para a monitorização e diagnóstico como mostra a Figura 8.

- Diagnóstico de Falha Conjunta Controlada por Dados

Em algumas aplicações práticas, os métodos de diagnóstico de falhas estatísticos e não estatísticos são frequentemente utilizados em conjunto.

Um método supervisionado e um método não supervisionado são dois principais modos de formação e de pesquisa no diagnóstico de falhas *data-driven*. Para a abordagem não supervisionada, os dados registados a partir da operação normal do sistema prático e treinados para formar uma base de conhecimento, que é então

utilizado para controlar os desvios de um processo em tempo real. Já no método supervisionado, um *classifier* é treinado com os dados históricos anotados gravados a partir de ambas as condições, normais e com defeito, que é então utilizado para a previsão de falha.

Os métodos supervisionados e não supervisionados têm suas vantagens e desvantagens. A fim de reforçar as suas vantagens, uma ideia natural é combinar o método supervisionado e o método não supervisionado para o diagnóstico de falhas.

#### 2.1.4.4 Métodos Híbridos

Métodos de diagnóstico de falhas baseados no modelo, no sinal e no conhecimento têm suas vantagens distintas e várias restrições. Especificamente, o diagnóstico de falhas baseado em modelo pode monitorar e diagnosticar falhas desconhecidas usando uma pequena quantidade de dados em tempo real, mas requer um modelo explícito que representa a relação de input/output e o desempenho diagnóstico baseia-se na precisão do modelo.

Por outro lado, as abordagens baseadas em sinal e no conhecimento não requerem um modelo explícito ou completo, fato que os torna adequados para a monitorização e diagnóstico de processos industriais complexos, onde modelos de sistemas não estão disponíveis. O método baseado em sinal geralmente extrai as principais características dos sinais de saída para o diagnóstico de falhas, mas dá menos atenção as entradas dinâmicas do sistema, cujo desempenho diagnóstico pode ser, portanto, comprometido sob perturbações de entrada desconhecidas ou condições desequilibradas (por exemplo, em fontes de alimentação ou cargas). Devido à elevada dependência de uma grande quantidade de dados históricos para a formação, o método baseado em conhecimento requer alto custo computacional e pode não funcionar bem para a identificação de tipos de falhas desconhecidas.

A fim de alavancar a força dos vários métodos de diagnóstico de falhas, uma integração ou combinação de dois ou mais métodos de diagnóstico de falhas, que é chamado de abordagem de diagnóstico de falhas híbrido, é utilizada muitas vezes para uma variedade de aplicações de engenharia.

Soualhi *et al.* (2013) apresenta um método híbrido que junta *signal-based* e *data-driven (knowledge-based)* com a intenção de detectar e diagnosticar falhas em motores de indução.

#### 2.1.4.5 Métodos de Diagnósticos de Falhas Ativas

É digno de salientar que os métodos de diagnóstico de falhas acima mencionadas não são invasivos.

Por outro lado, a fim de aumentar a detectabilidade de possíveis falhas em alguns sistemas, um sinal de entrada adequadamente projetado seria injetado nos processos dinâmicos sob um intervalo de teste de modo que os defeitos possam ser distinguidos dos modos normais com rapidez e precisão. Este tipo de diagnóstico de falhas é chamado o diagnóstico de falha ativa,

em que os efeitos adversos do sinal de entrada auxiliar deve ser minimizado e adicionado no desempenho do sistema em tempo real.

### 2.1.5 Veículos Aéreos não Tripulados (VANTs)

A história dos drones é apresentada por Teixeira (2016) e leva em consideração registros do uso das aeronaves tanto no mundo, como no Brasil. Segundo o autor, suas aplicações têm sido registradas, por exemplo, na coleta das primeiras imagens fotográficas, como ocorreu em 1858 com a fotogrametria do francês Gaspar Felix Tournachon; no uso com fins bélicos, como ocorreu com um VANT denominado *Predator* (considerado como o primeiro emprego real de um VANT com lançamento de míssil); e encontrando aplicações nacionais, como ocorreu com o Projeto Arara (Aeronave de Reconhecimento Autônoma e Remotamente Assistida) em que atuava na agricultura.

O Departamento de Controle do Espaço Aéreo (DECEA) trouxe ao conhecimento público, principalmente para fins de regulamentação, a Portaria Nº 415/DGCEA (Diretor Geral de Controle do Espaço Aéreo) e apresentado em DECEA (2015). Este documento traz uma Instrução do Comando da Aeronáutica (ICA 100-40) tratando, especificamente, dos Sistemas de Aeronaves Remotamente Pilotadas, cuja sigla, RPAS, refere-se à tradução para o inglês para o termo que simboliza as aeronaves popularmente conhecidas por drones ou VANTs, além de abordar questões sobre o acesso ao espaço aéreo brasileiro.

A importância da edição deste documento é destacada pela preocupação do Ministério da Defesa em elaborar normas que adequem a legislação existente para a acomodação dos Drones pelo espaço aéreo com as aeronaves tripuladas, e focam na segurança de uso em relação a aviões e pessoas.

Diante dos diversos projetos envolvendo o uso dos VANTs, bem como estudos sobre falhas que podem ocorrer nos motores dessas aeronaves, é importante destacar duas categorias de veículos aéreos: a) os Veículos de Asa Fixa, cuja dificuldade de operação em espaços confinados é mais evidente e b) os Veículos de Asa Giratória, cuja vantagem é ter o atributo de pairar no ar, facilitando determinadas ações.

Também conhecido por *Fixed Wing*, um Asa Fixa possui vários componentes e a tecnologia atual atrelada a um dispositivo como este tem apontado diversas melhorias, principalmente no item autonomia. Pesquisadores do LaSER<sup>1</sup> têm atuado na construção de VANTs e no desenvolvimento de soluções aplicadas a algumas áreas do conhecimento. Usando como modelo uma das versões de um Asa Fixa desenvolvido neste laboratório, conforme a Figura 2.20, alguns componentes podem ser destacados, como a seguir:

- ESC (*Electronic Speed Controller*) - Controle elétrico de velocidade: Este componente é responsável por alimentar os motores a partir da energia que recebe da bateria, de-

---

<sup>1</sup>LaSER - Laboratório de Sistemas Embarcados e Robótica vinculado ao Centro de Informática (CI) da Universidade Federal da Paraíba - UFPB

pendendo do controle realizado pela Placa Controladora de voo, atuando diretamente na velocidade de rotação do motor;

- Servomotores - Conjunto de engrenagens controladas pela Placa Controladora e que auxiliam na pilotagem do Asa Fixa, já que acionam os Ailerons (*Roll*), o Leme (*Yaw*) e o Profundor (*Pitch*) para os movimentos de Rolagem, Guinada e Arfagem da aeronave, respectivamente;
- *Raspberry Pi Zero*<sup>2</sup> - É um computador em miniatura (65 x 30 x 5 mm) que possui como saídas uma mini HDMI (para reproduzir vídeos em *Full HD* ou 1080p), micro USB e de energia. Ela é responsável pelo processamento das imagens coletadas, a depender do projeto em que o VANT for utilizado (por exemplo: análise de imagens coletadas de canais para detecção de pragas);
- Placa Controladora de voo (*Fligh Controller Board*): A placa de controle de voo é o componente que, a partir da interpretação dos sinais recebidos pelo receptor, controla os outros dispositivos com a finalidade de realizar o comando. Neste caso, foi utilizada uma placa do tipo APM (*Ardupilot Mega*) de código aberto e que é utilizada em dispositivos RC (rádio controlado) para missões autônomas;
- Transmissor/Receptor: Estes componentes são responsáveis pelo envio/recebimento de comandos ao VANT. O transmissor é o controle remoto, cujos envios de sinais serão entendidos pelo receptor;
- UBEC (*Universal Battery Eliminator Circuit*) - São pequenos circuitos de redução de voltagem que conseguem reduzir a voltagem da bateria e entregar somente a voltagem que, por exemplo, a placa controladora, a *raspberry* ou um servomotor precisa para trabalhar;
- *Power Module* - Responsável por transferir informações como tensão e corrente elétrica, que podem vir de uma bateria, para a Placa Controladora;
- *Buzzer* - Dispositivo instalado no VANT, responsável por emitir sinais sonoros que podem alertar sobre nível baixo da bateria ou para sua localização, em caso de queda;
- Hélices (*Propellers*): No caso do Asa Fixa, a hélice é única e pode necessitar de dimensões específicas, dependendo do projeto do avião e de determinados parâmetros, como o torque do motor e o peso que a aeronave poderá carregar (neste caso, seu *payload*). Mas, de forma geral, as hélices podem ser Horárias ou Anti-Horárias e de vários tamanhos. Ficam acopladas aos motores, e tem um perfil igual a uma asa, funcionando pela diferença de pressão em frente e atrás da hélice. A intensidade do giro é proporcional à intensidade do movimento a ser realizado;
- Quadro (*Frame*): O Quadro é a estrutura de suporte do veículo em que são acoplados os dispositivos a serem utilizados;
- Outros componentes: Câmera, *Global Position System* (GPS), Trem de Pouso, LEDs (*Light Emitting Diode*), Bateria, e outros.

---

<sup>2</sup>Desenvolvido pela *Raspbery Pi Foundation*

- Motor *Brushless* - A discussão sobre esse item será abordada com mais detalhes na Seção 2.1.3.



**Figura 2.20** - Exemplo de Asa Fixa construído no LaSER-UFPB

Portanto, estudos que aprimorem o uso dos VANTs e que apontem soluções úteis para a sociedade, que sejam implantadas com a devida segurança dos equipamentos e, principalmente, para as pessoas, são primordiais para o sucesso de um projeto e para que ele alcance seus objetivos com eficiência e produtividade desejados.

## 2.2 Processamento de Sinais

Um sinal é uma entidade que trafega por um fio e que representa uma informação. Se um sinal é uma variável funcionalmente dependente de uma ou mais variáveis independentes, por uma visão matemática, como no exemplo  $w = f(x, y)$ , na visão da física é considerado uma grandeza.

Para Haykin e Veen (2001), um sinal é formalmente definido como uma função de uma ou mais variáveis, a qual veicula informações sobre a natureza de um fenômeno físico.

Sobre esses mesmos aspectos e, conforme de la Vega (2017), os sinais tem tipos que variam de acordo com o número de variáveis independentes: unidimensional, bidimensional, tridimensional, multidimensional. Ex.: *áudio* =  $g(t)$ , *imagem* =  $g(x, y)$ , *vídeo* =  $g(x, y, t)$  e *tomografia/sismologia* =  $g(v_1, v_2, \dots, v_N, t)$ . Na prática, a fala é um exemplo de sinal unidimensional, cuja amplitude varia com o tempo, dependendo da palavra falada e de quem a fala, assim como uma imagem é um exemplo de sinal multidimensional, com as coordenadas horizontal e vertical da imagem representando as duas dimensões.

## 2.2.1 Sinais e Sistemas

No entanto, os sinais podem ser tipificados de acordo com o tipo das variáveis estudadas. Assim, um sinal podem ser: a) analógico, onde todas as variáveis são contínuas; b) amostrado: com a devida discretização das variáveis independentes (amostragem); c) quantizado: com a devida discretização da variável dependente (quantização) ou d) digital: onde todas as variáveis são discretas (amostragem + quantização).

Em aspectos gerais relativos à sinais, há sempre um sistema associado à geração de cada sinal e, conseqüentemente, há também um outro sistema que está associado à extração da informação do sinal. O processamento de sinais sonoros pode recorrer, naturalmente, ao uso de nossos ouvidos e aos caminhos auditivos em nosso sistema auditivo, envolvendo sistemas de produção e recepção de sinais de natureza biológica. Porém, nada impede de que sistemas eletrônicos simulem ou imitem certos aspectos biológicos envolvidos no processo.

O propósito de um sistema depende da aplicação de interesse. No exemplo anterior, a função do sistema é extrair informações de um sinal sonoro que é recebido, com a finalidade de reconhecer ou identificar determinado som.

Conforme Haykin e Veen (2001), um sistema é formalmente definido como uma entidade que manipula um ou mais sinais para realizar uma função, produzindo, assim, novos sinais. A Figura 2.21 apresenta um esquema que trata sobre a relação existente entre um sistema e os sinais, sendo: a) o Sinal de Entrada - um sinal sonoro (ou dados de computador, ou a posição de uma aeronave, em relação à pista de pouso); b) o Sistema - um computador (ou a combinação de um transmissor, canal e receptor, ou a aeronave em relação ao exemplo anterior); e c) o Sinal de Saída - a identificação do som emitido (ou a estimativa do sinal da mensagem original, ou uma correção na posição lateral da aeronave).



Figura 2.21 - Diagrama esquemático de um sistema

Haykin e Veen (2001) traz ainda algumas definições sobre sistemas, bem como um paralelo interessante entre o processamento de sinal analógico versus digital, que são apresentadas a seguir:

### 2.2.1.1 Sistema de Comunicação

Os elementos básicos de um sistema de comunicação são representados na Figura 2.22, sendo eles: o *transmissor* - localizado num ponto do espaço; o *receptor* - localizado em algum outro ponto separado do transmissor; e o *canal* - meio que liga os dois anteriores. Cada um destes elementos pode ser considerado como um sistema com sinais próprios em que o papel

do transmissor é converter o sinal para uma forma apropriada e que possa ser transmitida pelo canal.

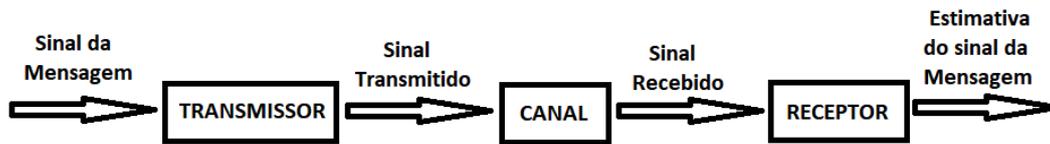


Figura 2.22 - Sistema de Comunicação e seus elementos

À medida que o sinal transmitido se propaga por um canal, ele é distorcido devido às características físicas deste canal. Além disso, ruído e sinais de interferência (que se originam de outras fontes) contaminam a saída do canal, fazendo com que o sinal recebido resulte em uma versão corrompida do sinal transmitido. A função do receptor é operar no sinal recebido a fim de reconstruir uma forma reconhecível (isto é, produzir uma estimativa) do sinal da mensagem original e entregá-lo ao usuário final. O papel de processamento de sinal do receptor é, dessa forma, o inverso do papel do transmissor; além disso, o receptor tenta compensar os efeitos do canal.

Os detalhes das operações executadas no transmissor e no receptor dependem do tipo de sistema de comunicação que é considerado. O sistema de comunicação pode ser do tipo analógico ou digital. Especificamente, o transmissor consiste em um modulador, e o receptor consiste em um demodulador. Modulação é o processo de converter o sinal da mensagem para uma forma que seja compatível com as características de transmissão do canal. Comumente, o sinal transmitido é representado como uma variação de amplitude, fase ou frequência de uma onda portadora senoidal. Deste modo, falamos de modulação de amplitude, fase ou frequência, respectivamente. Correspondentemente, através do uso da demodulação de amplitude, demodulação de fase, ou demodulação de frequência, uma estimativa do sinal da mensagem original é produzida na saída do receptor. Cada uma destas técnicas de modulação/demodulação analógica tem suas próprias vantagens e desvantagens.

Se o sinal da mensagem tiver a forma analógica, como nos sinais sonoros, o transmissor executará as seguintes operações para convertê-lo para a forma digital:

- *Amostragem*, a qual converte o sinal da mensagem em uma sequência de números, com cada número representando a amplitude do sinal da mensagem em um instante de tempo particular;
- *Quantização*, a qual envolve representar cada número produzido pelo amostrador no nível mais próximo escolhido dentre um número finito de níveis de amplitude discreta. Por exemplo, podemos representar cada amostra como um número binário de 16 bits, caso em que há  $2^{16}$  níveis de amplitude. Depois da combinação de amostragem e quantização, obtemos uma representação do sinal da mensagem que é discreta tanto em termos de tempo como de amplitude;

- *Codificação*, cujo propósito é representar cada amostra quantizada por meio de uma palavra de código composta de um número finito de símbolos.

Sendo a *Quantização* um processo irreversível, sempre ocorre perda de informação quando é aplicada. Para minimizar este efeito, tornando-o não perceptível, utiliza-se um quantizador com um número suficientemente grande de níveis de amplitude distintos. Desta forma, quando o número de níveis de amplitude discreta se eleva, deve crescer também o tamanho da palavra de código de maneira correspondente.

No entanto, se a fonte de informação for discreta e quantizada, como é o caso de um computador digital, nenhuma das operações acima será necessária.

Em se tratando de modos de comunicação, podem ser citados duas abordagens: a *Rádiodifusão*, que possui um único transmissor bastante potente e diversos receptores, cujo custo é menor que o primeiro (rádio e televisão, por exemplo); e a *Comunicação ponto a ponto*, cuja comunicação é estabelecida entre um único transmissor e um único receptor (comunicação remota com um robô, por exemplo).

Os sistemas de comunicação revelam também o fator limitante para a qualidade dos sinais que é o "*ruído de canal*". Ele está presente em sinais recebidos, principalmente quando a natureza deste sinal é mais propícia para tê-lo, por exemplo, em sinais sonoros.

### 2.2.1.2 Sistema de Controle

Muitos são os motivos para se usar um sistema de controle. Obter uma resposta satisfatória é um motivo importante, assim como ter um desempenho robusto também o é. A resposta satisfatória que uma planta (aeronave, por exemplo) produz, deve-se ao fato de que sua saída segue uma entrada de referência específica. Essa regulação objetiva manter a saída da planta próxima da entrada de referência. Da mesma forma, um sistema de controle é dito robusto quando ele executa a devida regulação, mesmo marcado por perturbações do meio externo (força do vento em relação ao voo da aeronave, por exemplo).

Estes dois parâmetros podem ser considerados como *desejáveis* para um sistema de controle, mas para que eles sejam consolidados, deve ser aplicada a realimentação junto ao processo. A Figura 2.23 apresenta os elementos abstratos de um sistema de controle e que o classifica em *Sistema de Controle de Malha Fechada* ou *Sistema de Controle com Realimentação*. Neste esquema, o papel do *Controlador* é dar impulso ( $V(t)$ ) à *Planta*, cuja *Saída*  $y(t)$  tem uma *Perturbação*  $v(t)$  que dá impulso a(os) *Sensor(es)*. A resultante do *Sinal de Realimentação*  $r(t)$  é subtraída da *Entrada de Referência*  $x(t)$ , produzindo um sinal de erro  $e(t)$  que, novamente, dá impulso ao *Controlador* e fecha a malha.

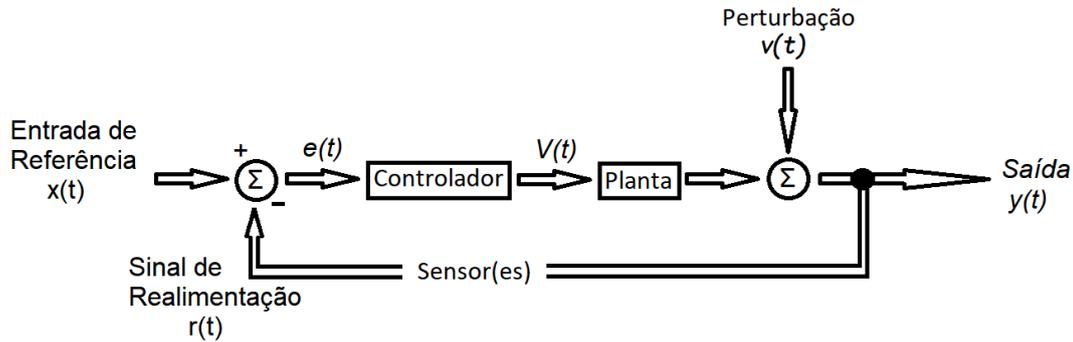


Figura 2.23 - Sistema de Controle com Realimentação

## 2.2.2 Tipos de Processamento de Sinais

Um sinal é um objeto de processamento, visto que ele carrega uma informação e o agente que o processa é um sistema. Neste caso, um sistema é um conjunto de elementos, que interagem entre si, com o objetivo de realizar uma determinada função. O domínio do processamento depende da função para qual o agente é definida e mantém uma relação entre o *tempo/espaco*, registrando a forma como o domínio se situa no tempo e no espaco, e a *frequência*, apresentando a sua composição espectral.

No processamento digital discute-se sobre a arquitetura de sistemas, em que um Sinal de entrada analógico pode ser um sinal elétrico (por exemplo, tensão ou corrente). Assim, como componentes do processamento digital, podem ser citadas as seguintes etapas: a) *Pré-processamento analógico*, que inclui um filtro anti-aliasing (com seletividade em frequência do tipo passa-baixa), a amostragem e retenção - (*sample-and-hold* ou S/H) - responsável por manter fixo o valor da amostra durante o tempo necessário para que ela seja convertida em um número, e um conversor Analógico-Digital (A/D); b) *Sinal de Entrada Digital* que é uma representação numérica computacional; c) o *Processador de Sinal Digital* (*Digital Signal Processor* ou DSP); d) o *Sinal de Saída Digital* que é outra representação numérica computacional; e) o *Pós-Processamento Analógico*, que possui um Conversor Digital-Analógico (D/A), um Filtro de Suavização (*smoothing*) - com seletividade em frequência do tipo passa-baixa; e f) *Sinal de Saída Analógico* que pode ser outro sinal elétrico (por exemplo, tensão ou corrente).

- ANALÓGICO x DIGITAL

Dado que um mesmo sistema pode ser implementado por sinais/componentes analógicos e digitais, naturalmente surge a questão de qual das opções é a melhor. Diversas são as comparações encontradas na literatura técnica entre implementações de sistemas que empregam sinais/componentes analógicos e digitais.

Adeptos de ambos os tipos de implementação facilmente definem parâmetros que os favorecem e normalmente estabelecem comparações tentando mostrar que a sua implementação de preferência é, realmente, a melhor opção.

Antes de tecer meras comparações absolutas, muitas vezes polarizadas, por um tipo ou outro de implementação, deve-se lembrar que estão sendo comparadas duas alternativas de implementação essencialmente equivalentes. Logo, os parâmetros de comparação normalmente empregados fornecem apenas características individuais de cada tipo de implementação, ao invés de estabelecer bases reais de comparação.

Por um lado, uma implementação analógica mapeia sinais matemáticos em sinais físicos e realiza as operações matemáticas através de componentes físicos que possuem equações de definição capazes de realizar os cálculos necessários, isolada ou conjuntamente com outros componentes. Pode-se dizer que o problema matemático é transformado em um problema físico e implementado por sinais/componentes físicos.

Por sua vez, uma implementação digital, apesar de obviamente empregar componentes físicos, não utiliza os seus sinais e as suas equações diretamente. Ao invés disso, é realizada uma codificação, de tal forma que a implementação executa as operações e os operandos matemáticos. Nesse caso, pode-se dizer que o problema matemático não é mapeado em um problema físico, sendo apenas executado em uma implementação física, mas que é matemática.

A comparação direta torna-se ainda mais sem sentido a partir da constatação de que sistemas digitais podem ser implementados por software, por hardware digital ou por ambos simultaneamente. Com tais conceitos em mente, não é difícil perceber que qualquer tentativa para estabelecer parâmetros de comparação entre implementações analógicas e digitais conduz apenas a definições de característica relativas de cada uma das opções consideradas.

Também não é difícil perceber que, devido às características próprias de cada uma das implementações, cada uma delas poderá ser proposta como a melhor solução para problemas específicos, os quais necessitem de tais características. Por vezes, até mesmo uma solução que misture ambos os tipos de implementação pode ser a melhor escolha.

Finalmente, é importante ressaltar que o levantamento de parâmetros comparativos é importante e deve ser efetuado. Não para que se defina qual das duas opções de implementação é absolutamente a melhor, mas para que se possa estabelecer uma base de dados que fundamente a decisão de projeto diante de cada problema diferente.

- **CARACTERÍSTICAS DOS SINAIS ANALÓGICOS x DIGITAIS**

Conforme de la Vega (2017), a ideia do Processamento Discreto de Sinais Analógicos baseia-se em transformar o sinal analógico em um sinal discreto, processar o sinal discreto e transformar o sinal discreto processado em um sinal analógico.

A ideia do Processamento Digital de Sinais Analógicos baseia-se em transformar o sinal analógico em um sinal discreto, transformar o sinal discreto em um sinal digital (números), processar o sinal digital, transformar o sinal digital processado em um sinal discreto e transformar

o sinal discreto processado em um sinal analógico. Para garantir que ambos os tipos de processamento produzam resultados satisfatórios, deve-se recorrer a uma fundamentação matemática que descreva como os sinais envolvidos são afetados em cada etapa do processo.

A modelagem de sinais e sistemas analógicos fundamenta-se na matemática contínua. A modelagem de sinais e sistemas discretos/digitais baseia-se na matemática discreta. Estes dois tipos de modelagem coexistem, independentemente um do outro.

Porém, é possível que se estabeleça uma relação entre eles. Com isso, pode-se representar um deles por meio do outro, pode-se teorizar um deles por meio do outro e pode-se realizar cálculos de um deles por meio do outro. Em alguns casos, essa representação mútua é uma relação biunívoca exata. Em outros, isso não é possível, obtendo-se apenas uma aproximação inexata de um modelo pelo outro.

Os mecanismos que permitem a conexão entre os modelos analógico e discreto/digital são a amostragem e a interpolação. A amostragem permite a conexão “Analógico  $\rightarrow$  Discreto” e, conseqüentemente, a conexão “Analógico  $\rightarrow$  Digital” ou A/D. A interpolação possibilita a conexão “Discreto  $\rightarrow$  Analógico” e, conseqüentemente, a conexão “Digital  $\rightarrow$  Analógico” ou D/A.

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

O comportamento de equilíbrio cíclico é a questão central do trabalho atual, e é usado para identificar o comportamento caótico do sinal sonoro gerado por um motor BLDC, utilizando para isso uma única amostra em uma evolução temporal curta, como é assegurado pelo princípio da máxima entropia, que é o princípio da termodinâmica que mede a desordem das partículas de um sistema físico, e de extensões da Teoria do Caos (Bazeia *et al.*, 2017).

Existem algumas técnicas para a identificação do caos (Gosak *et al.*, 2008; Károlyi *et al.*, 2005; Mitchell e Hraber, 1993; Nowak e May, 1992), mas no presente trabalho aplicamos uma técnica apresentada em um trabalho anterior (Bazeia *et al.*, 2017) baseado no conceito de distância de Hamming (1950), e na contagem da densidade de máximos (Ramos *et al.*, 2011) do sinal sonoro. O trabalho explora a possibilidade de distinguir entre as evoluções temporais que partem de estados iniciais ligeiramente diferentes, guiados pela distância de Hamming, que desvenda heurísticamente o comportamento caótico.

O resultado desse trabalho (Bazeia *et al.*, 2017) introduz uma abordagem quantitativa que relaciona o comprimento da correlação com a densidade média dos máximos de um sinal. Nesse caso, o sinal representa a quantidade de cada espécie biológica ao longo da simulação. Resulta em uma realização experimental que conta a densidade máxima associada à evolução caótica das espécies para inferir seu comprimento de correlação. Em Medeiros *et al.* (2018),

aplicamos esta técnica para demonstrar que o sinal de corrente de um motor BLDC é caótico, e o comprimento de correlação pode ser estimado a partir da densidade dos máximos.

Neste trabalho, apresentamos a possibilidade de estimar o comprimento de correlação do sinal sonoro emitido por um motor BLDC através de uma fórmula simples, que considera apenas a densidade máxima desse sinal.

Ao analisar uma pequena quantidade de dados de um sinal  $q(t)$ , é possível caracterizar o caos neste tipo de motor. Este sinal oscila no tempo para produzir o máximo local no intervalo  $[t, t + \delta t]$ , para um  $\delta t$  suficientemente pequeno, então um tem  $q'_i(t) > 0$  e  $q'(t + \delta t) < 0$ , em que essas relações simbolizam a derivada primeira do sinal no tempo, tal que  $-q''(t)\delta t > q'(t) > 0$ .

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

$$\begin{aligned} \langle \rho_1 \rangle &\equiv \frac{1}{\delta t} \int_{-\infty}^0 dq'' \int_0^{-q''\delta t} dq' P(q', q'') \\ &= \int_{-\infty}^0 dq'' q'' P(0, q'') \end{aligned} \quad (2.4)$$

O fato de que as propriedades estatísticas do número médio de picos são invariantes sob as translações de tempo, indica que ambos,  $q'$  e  $q''$ , têm valores médios em extinção. Além disso, as propriedades de  $P(q', q'')$  podem ser obtidas a partir do menor momento de  $q'$  e  $q''$ , e as variâncias de  $P(q', q'')$  estão diretamente relacionados à função de correlação:

$$C(\delta t) = \langle q(t + \delta t)q(t) \rangle. \quad (2.5)$$

Então, podemos obter em vários momentos e, em particular:

$$\langle q'^2 \rangle = - \left. \frac{d^2 C(\delta t)}{d(\delta t)^2} \right|_{\delta t=0}; \quad \langle q''^2 \rangle = \left. \frac{d^4 C(\delta t)}{d(\delta t)^4} \right|_{\delta t=0}. \quad (2.6)$$

O princípio da máxima entropia pode ser usado para construir a distribuição de probabilidade conjunta para  $q(t)$ , assim como suas derivadas das equações anteriores. Depois de implementar os cálculos algébricos, a integração em  $q(t)$  leva a  $P(q', q'')$ , gerando:

$$P(0, q'') = \frac{1}{2\pi} \frac{1}{\sqrt{\langle q'^2 \rangle \langle q''^2 \rangle}} \exp\left(-\frac{1}{2} \frac{q''^2}{\langle q''^2 \rangle}\right) \quad (2.7)$$

A equação 2.8 é aplicada para analisar amostras de sinais não periódicos, em que  $\langle \rho_1 \rangle$  é teórico e "C" é calculado pelas derivadas segunda e quarta, representadas respectivamente por  $\frac{d^2 C}{dt^2}$  e  $\frac{d^4 C}{dt^4}$ , da função de correlação automática em zero, conforme apresentado em trabalhos anteriores, como os de Bazeia *et al.* (2017) e Medeiros *et al.* (2018), e demonstrados em Avila e Luís (2012).

$$\langle \rho_1 \rangle = \frac{1}{2\pi} \sqrt{\frac{\langle q''^2 \rangle}{\langle q'^2 \rangle}} = \frac{1}{2\pi} \sqrt{\frac{\frac{d^4 C}{dt^4}(0)}{-\frac{d^2 C}{dt^2}(0)}} \quad (2.8)$$

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 Equação 2.9, em que  $\tau$  é o comprimento de correlação e  $\rho_2$  é a densidade de máximos encontrada de forma experimental.

$$\tau = \frac{1}{6\langle \rho_2 \rangle} \quad (2.9)$$

O comportamento caótico presente nos sistemas estocásticos é demonstrado no resultado encontrado na Equação 2.9. Utilizando este método, a partir da média da densidade máxima coletada a partir do sinal sonoro, é possível estimar as características de um sistema através da análise de uma série temporal curta e estimar o coeficiente de correlação.

## 2.4 Séries Temporais

Muitas séries numéricas temporais são não-estacionárias, como as que resultam de áreas econômicas e de negócios. Um processo não-estacionário na média poderia representar um problema muito sério para a estimativa da função média dependente do tempo, sem múltiplas realizações. Porém, Wei (2006) explica que existem modelos que podem ser construídos a partir de uma única realização para descrever esse fenômeno dependente do tempo. Uma dessas classes de modelos que são muito úteis na modelagem de séries temporais não-estacionárias, denomina-se Modelo de Tendência Determinística.

A função média de um processo não-estacionário poderia ser representada por uma tendência determinista do tempo. Nesse caso, um modelo de regressão padrão poderia ser usado para descrever o fenômeno.

Para este trabalho, é utilizado o exemplo sugerido por Wei (2006). Se a função média  $\mu_t$  segue uma tendência linear  $\mu_t = \mu_0 + \mu_1 t$ , então pode-se usar o modelo de tendência linear determinístico da Equação 2.10, com o "a" sendo uma série de ruído branco.

$$Z_t = \alpha_0 + \alpha_1 t + a_t \quad (2.10)$$

Em termos gerais, se a tendência determinística for descrita por um polinômio de ordem "k" de tempo, pode-se modelar o processo conforme a Equação 2.11.

$$Z_t = \alpha_0 + \alpha_1 t + \dots + \alpha_k t^k + a_t \quad (2.11)$$

Como a tendência determinística pode ser representada por uma curva seno-cosseno, então  $Z_t$  pode ser definido como na Equação 2.12, em que "v" é a amplitude, " $\omega$ " é a frequência e " $\phi$ " é a fase da curva.

$$Z_t = v_0 + v \cdot \cos(\omega t + \phi) + a_t \quad (2.12)$$

Adaptando  $Z_t$  às condições do  $\rho_1$  (teórico), apresentado na Equação 2.8, e denominando um dado sinal de "C", aplicado ao previsto na Equação 2.12, deduz-se a Equação 2.13.

$$C = a \cdot \text{sen}(\omega t + \phi_1) + ak_1 \cdot \text{sen}\left(\frac{\omega t}{2} + \phi_2\right) + ak_2 \cdot \text{sen}\left(\frac{3\omega t}{2} + \phi_3\right) \quad (2.13)$$

Derivando a Equação 2.13, deduz-se também a Equação 2.14.

$$\begin{aligned} C' &= \frac{dC}{dt} = a \cdot \omega \cdot \cos(\omega t + \phi_1) + ak_1 \cdot \frac{\omega}{2} \cdot \cos\left(\frac{\omega t}{2} + \phi_2\right) + ak_2 \cdot \frac{3\omega}{2} \cdot \cos\left(\frac{3\omega t}{2} + \phi_3\right) \\ C'' &= \frac{d^2C}{dt^2} = -a \cdot \omega^2 \cdot \text{sen}(\omega t + \phi_1) - ak_1 \cdot \frac{\omega^2}{4} \cdot \text{sen}\left(\frac{\omega t}{2} + \phi_2\right) - ak_2 \cdot \frac{9\omega^2}{4} \cdot \text{sen}\left(\frac{3\omega t}{2} + \phi_3\right) \\ C''' &= \frac{d^3C}{dt^3} = -a \cdot \omega^3 \cdot \cos(\omega t + \phi_1) - ak_1 \cdot \frac{\omega^3}{8} \cdot \cos\left(\frac{\omega t}{2} + \phi_2\right) - ak_2 \cdot \frac{27\omega^3}{8} \cdot \cos\left(\frac{3\omega t}{2} + \phi_3\right) \\ C''^2 &= \frac{d^4C}{dt^4} = a \cdot \omega^4 \cdot \text{sen}(\omega t + \phi_1) + ak_1 \cdot \frac{\omega^4}{16} \cdot \text{sen}\left(\frac{\omega t}{2} + \phi_2\right) + ak_2 \cdot \frac{81\omega^4}{16} \cdot \text{sen}\left(\frac{3\omega t}{2} + \phi_3\right) \end{aligned} \quad (2.14)$$

Aplicando os resultados de  $\frac{d^2C}{dt^2}$  e de  $\frac{d^4C}{dt^4}$  em  $\rho_1$  (Equação 2.8), tem-se:

$$\rho_1 = \frac{1}{2\pi} \sqrt{\frac{-a\omega^4 \cdot [\text{sen}(\omega t + \phi_1) + \frac{k_1}{16} \cdot \text{sen}\left(\frac{\omega t}{2} + \phi_2\right) + \frac{81k_2}{16} \cdot \text{sen}\left(\frac{3\omega t}{2} + \phi_3\right)]}{-a\omega^2 \cdot [\text{sen}(\omega t + \phi_1) + \frac{k_1}{4} \cdot \text{sen}\left(\frac{\omega t}{2} + \phi_2\right) + \frac{9k_2}{4} \cdot \text{sen}\left(\frac{3\omega t}{2} + \phi_3\right)]}} \quad (2.15)$$

E, fatorando os devidos termos, tem-se:

$$\rho_1 = \frac{1}{2\pi} \sqrt{\frac{\omega^2 \cdot (\text{sen}(\omega t + \phi_1) + k_1 \cdot \left(\frac{1}{2}\right)^4 \cdot \text{sen}\left(\frac{\omega t}{2} + \phi_2\right) + k_2 \cdot \left(\frac{3}{2}\right)^4 \cdot \text{sen}\left(\frac{3\omega t}{2} + \phi_3\right))}{\text{sen}(\omega t + \phi_1) + k_1 \cdot \left(\frac{1}{2}\right)^2 \cdot \text{sen}\left(\frac{\omega t}{2} + \phi_2\right) + k_2 \cdot \left(\frac{3}{2}\right)^2 \cdot \text{sen}\left(\frac{3\omega t}{2} + \phi_3\right)}} \quad (2.16)$$

Retirando  $\omega$  do radical, tem-se:

$$\rho_1 = \frac{\omega}{2\pi} \sqrt{\frac{\text{sen}(\omega t + \phi_1) + k_1 \cdot \left(\frac{1}{2}\right)^4 \cdot \text{sen}\left(\frac{\omega t}{2} + \phi_2\right) + k_2 \cdot \left(\frac{3}{2}\right)^4 \cdot \text{sen}\left(\frac{3\omega t}{2} + \phi_3\right)}{\text{sen}(\omega t + \phi_1) + k_1 \cdot \left(\frac{1}{2}\right)^2 \cdot \text{sen}\left(\frac{\omega t}{2} + \phi_2\right) + k_2 \cdot \left(\frac{3}{2}\right)^2 \cdot \text{sen}\left(\frac{3\omega t}{2} + \phi_3\right)}} \quad (2.17)$$

Para  $t = 0$ , encontra-se:

$$\rho_1 = \frac{\omega}{2\pi} \sqrt{\frac{\text{sen}(\phi_1) + k_1 \cdot \left(\frac{1}{2}\right)^4 \cdot \text{sen}(\phi_2) + k_2 \cdot \left(\frac{3}{2}\right)^4 \cdot \text{sen}(\phi_3)}{\text{sen}(\phi_1) + k_1 \cdot \left(\frac{1}{2}\right)^2 \cdot \text{sen}(\phi_2) + k_2 \cdot \left(\frac{3}{2}\right)^2 \cdot \text{sen}(\phi_3)}} \quad (2.18)$$

Para que se evite uma inconsistência matemática, justifica-se o uso da fase da curva. Dessa forma,  $\rho_1$  estabelece uma relação entre a Frequência Fundamental ( $f_{FUNDAMENTAL}$ ) e

uma constante ( $K$ ), representando uma senóide  $\text{sen}(\omega t + \phi_1)$ , com  $\omega = 2\pi t$ , como apresentado na Equação 2.19, em que o  $\rho$  tende a um valor próximo da frequência fundamental.

$$\rho_1 = f_{\text{FUNDAMENTAL}} \cdot K \quad (2.19)$$

## 2.5 Autocorrelação

Para realizar a Autocorrelação, as amostras são representadas por  $X_t$  e dispostas em uma matriz, conforme Medeiros *et al.* (2018), denominada matriz M (Equação 2.20). Suas linhas variam de  $t$  até  $s$ , com  $t$  inicial  $t_0 = 1$ , suas colunas variam de 1 até  $k$  e representam a quantidade de amostras a cada fração do tempo. O sinal  $X_t$  representa um processo estacionário, com média  $\mu$ , variância  $\sigma^2$  e suas covariâncias do sinal são representadas por  $\text{Cov}(X_t, X_s)$  e dependem apenas da diferença de tempo  $|t - s|$ . Para este caso, a covariância está entre  $X_t$  e  $X_{t+k}$ .

$$M = \begin{vmatrix} X_{t,1} & X_{t,2} & X_{t,3} & \cdots & X_{t,k} \\ X_{t+1,1} & X_{t+1,2} & X_{t+1,3} & \cdots & X_{t+1,k} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ X_{s,1} & X_{s,2} & X_{s,3} & \cdots & X_{s,k} \end{vmatrix} \quad (2.20)$$

A partir de M, é calculada a Função de Autocorrelação apresentada por Wei (2006) e representada na Equação 2.21.

$$\langle \rho_k \rangle = \frac{\text{Cov}(X_t, X_{t+k})}{\sqrt{\text{Var}(X_t)}\sqrt{\text{Var}(X_{t+k})}}, k = 1, 2, 3, \dots \quad (2.21)$$

Assim, é organizada a matriz de Autocorrelação em função de  $\langle \rho_k \rangle$ , aplicada à Matriz M. No entanto, é necessário calcular a Função de Autocorrelação Parcial para que seja calculado o *Correlation Length Coefficient* (CLC), como será descrito a seguir.

## 2.6 Coeficiente de Comprimento da Correlação - CLC

Esta técnica baseia-se no fato de que sistemas caóticos se autocorrelacionam ao longo do tempo, diferente de sistemas aleatórios, cuja função de autocorrelação tende a não convergir.

Conforme Medeiros *et al.* (2018); Wei (2006), para encontrar a Função de Autocorrelação Parcial é necessário calcular  $\hat{X}_{t+k}$  (Equação 2.22) como a melhor estimativa linear no sentido da média quadrática de  $X_{t+k}$ .

$$\hat{X}_{t+k} = \alpha_1 X_{t+k-1} + \alpha_2 X_{t+k-2} + \cdots + \alpha_{k-1} X_{t+1} \quad (2.22)$$

Considerando  $\alpha_i$  como o coeficiente de regressão linear médio quadrático, tem-se que a condição de correlação  $Corr(X_t, X_{t+k}|X_{t+1}, \dots, X_{t+k-1})$  é usualmente referida como a Função de Autocorrelação Parcial para análise de séries temporais, com  $(1 \leq i \leq k-1)$ . Esta função pode ser expressa por  $R_k$  (Equação 2.23).

$$R_k = \begin{vmatrix} \gamma_1 \\ \gamma_2 \\ \vdots \\ \gamma_{k-1} \end{vmatrix} = \begin{vmatrix} 1 & \gamma_1 & \cdots & \gamma_{k-2} \\ \gamma_1 & 1 & \cdots & \gamma_{k-3} \\ \vdots & \vdots & & \vdots \\ \gamma_2 & \gamma_1 & \cdots & 1 \end{vmatrix} \begin{vmatrix} \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_{k-1} \end{vmatrix} \quad (2.23)$$

Assim, a Função de Autocorrelação Parcial faz parte do cálculo do Coeficiente de Comprimento à Meia Altura, calculado em  $R_k$ , denominado Coeficiente de Comprimento de Correlação - CLC (*Correlation Length Coefficient*).

A constante a ser estimada e citada na Seção 2.3 é denominada de Coeficiente de Comprimento da Correlação (CLC - *Correlation Length Coefficient*). No entanto, a técnica de contagem de picos Bazeia *et al.* (2017); Medeiros *et al.* (2018), denominada de Análise de Sinais baseada no Caos usando Densidade de Máximos (SAC-DM), auxiliada heurísticamente pelo conceito da distância de Hamming (1950), pode revelar o comportamento caótico de um sistema. Por este conceito, é medido a diferença entre dois estados, que é uma maneira simples e apropriada de distinguir quantidades como vetores e matrizes, podendo ser ilustrada com vetores binários.

## 2.7 Wavelet Multiresolution Analysis (WMA)

Conforme Cruz *et al.* (2017), uma ferramenta poderosa no processamento de sinais estacionários ou dinâmicos é a Análise Multiresolução *Wavelet* (WMA), onde o sinal é subdividido em vários níveis de resolução. Baseada no algoritmo de Mallat (2008), no primeiro nível da WMA, o sinal original amostrado  $c[k]$  é convolucionado com um filtro passa baixas, originando a aproximação  $A_1$ , e por um filtro passa altas, originando o detalhe  $D_1$ , conforme a Equação 2.24:

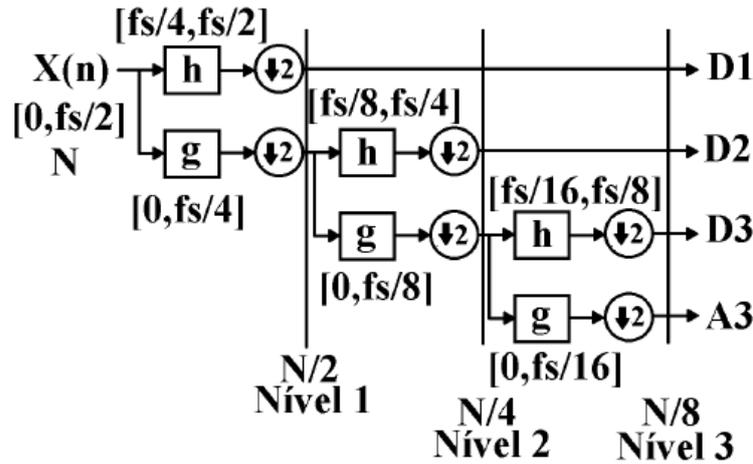
$$\begin{aligned} A_1[n] &= \sum_k h[k-2n] c[k] \\ D_1[n] &= \sum_k g[k-2n] c[k] \end{aligned} \quad (2.24)$$

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

A partir do nível 2, os filtros passa-altas e passa-baixas são submetidos às aproximações do subnível anterior, conforme a Equação 2.25, formando uma estrutura de decomposição em cascata conforme ilustrado por Mallat (2008) - Figura 2.24.

$$\begin{aligned} A_m[n] &= \sum_k h[k - 2n] A_{m-1}[k] \\ D_m[n] &= \sum_k g[k - 2n] A_{m-1}[k] \end{aligned} \quad (2.25)$$

A largura de banda de cada sinal é definida pela estrutura dos filtros utilizados na decomposição. A aplicação desses filtros resulta em uma subamostragem do sinal pela metade, fazendo com que a largura de banda seja reduzida na mesma proporção.



**Figura 2.24** - Algoritmo de Mallat para calcular o DWT. Fonte: Cruz *et al.* (2017)

Devido ao processo de decomposição apresentado na Figura 2.24, a banda passante das aproximações e dos detalhes obedece a relação da Equação 2.26.

$$\begin{aligned} AC_L &= \left[ 0, \frac{f_s}{2^{L+1}} \right] \\ DC_L &= \left[ \frac{f_s}{2^{L+1}}, \frac{f_s}{2^L} \right] \end{aligned} \quad (2.26)$$

Neste trabalho, a WMA foi utilizada em razão de sua abordagem simultânea no tempo e na frequência. Porém, aspectos discutidos na Seção 2.2.1, são apresentados e tratados como dificuldades ou problemas que podem surgir quando se trabalha com sinais sonoros. E, ainda, o trabalho proposto por Ning e Gong (2015), comprova a presença de perturbações na aquisição de dados deste tipo, dada a sensibilidade inerente à natureza do tipo de sinal ou do próprio equipamento utilizado na coleta, sugerindo a aplicação de soluções como a que foi discutida aqui.

Por estas razões, justifica-se a utilização da WMA em nosso trabalho, por ser uma técnica que reduz, sensivelmente, os ruídos presentes nas amostras, possibilitando a análise do sinal após a sua aplicação.

## CAPÍTULO 3

# METODOLOGIA

Neste capítulo é descrita a metodologia aplicada neste trabalho, são apresentadas as ferramentas utilizadas para aquisição, bem como os tratamentos aos quais os dados coletados foram submetidos ao longo da pesquisa. A Seção 3.1 apresenta um diagrama esquemático do sistema desenvolvido neste trabalho. A descrição da bancada utilizada para testes está na Seção 3.2 e o equipamento desenvolvido para a coleta de áudio vê-se na Seção 3.3. O comportamento do sinal coletado nos testes, após a aplicação da Transformada Rápida de *Wavelet* é apresentado na Seção 3.4, enquanto que a equação aplicada sobre os dados é abordada na Seção 3.5.

### 3.1 Diagrama do Sistema Desenvolvido

O sistema aqui desenvolvido é apresentado de forma esquemática na Figura 3.1, trazendo as etapas de execução e funcionamento do mesmo.

Nos experimentos realizados, uma bancada com um motor BLDC é usada para testar e analisar os áudios coletados. O modelo de simulação utilizado para a validação do experimento é apresentado na Figura 3.2. As especificações técnicas do motor utilizado estão na Tabela 3.3 e têm como base o modelo desenvolvido.

Os sinais sonoros são coletados a partir de um circuito eletrônico com Arduino, adaptado com um microfone que realiza a gravação de cada áudio, conforme Seção 3.3.

Em seguida, a WMA é executada para filtrar o sinal e calcular o SAC-DM referente aos 1.000 valores que compõem cada coluna da matriz de correlação. Cada coluna foi denominada de subconjunto das partes de 1.000. Por fim, é calculada a média desses valores e registrado como sendo o SAC-DM do sinal corrente. Nesta etapa, os níveis de detalhe executados partiram do D5 ao D11 e, dentre estes, o que melhor encontrou resultados para as características caóticas do sinal, foi o D8.

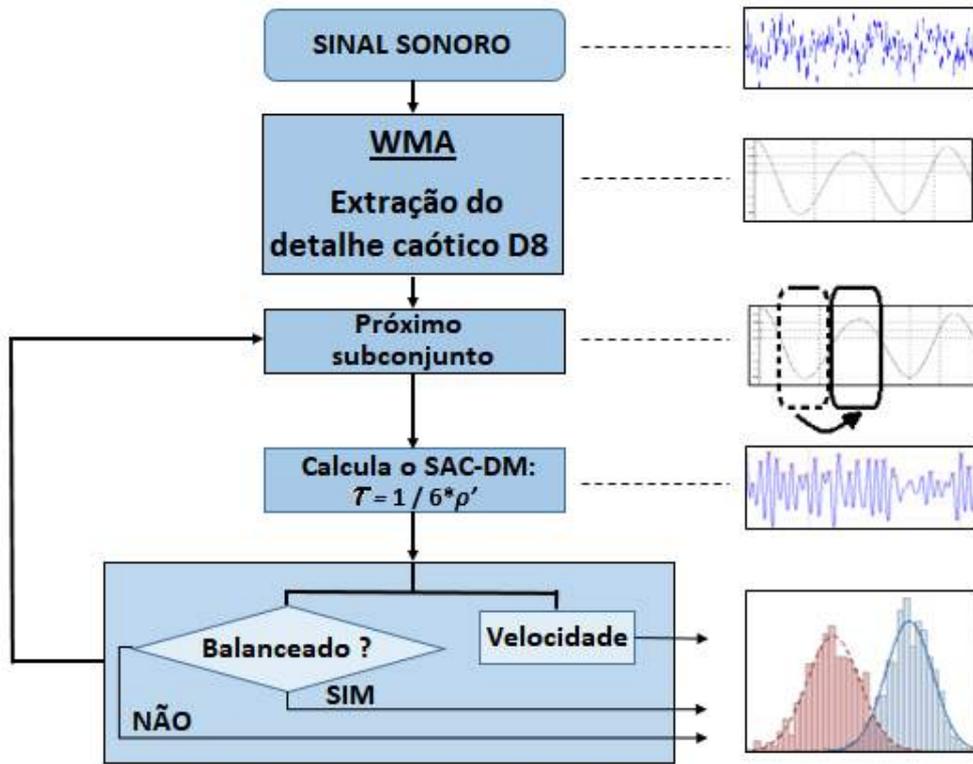


Figura 3.1 - Diagrama de blocos do sistema. Fonte: O autor (2018)

### 3.2 Bancada

Para que fossem realizados os testes e simulações de forma semelhante ao próprio VANT em atividade, uma bancada com base de madeira foi montada, conforme a Figura 3.2.

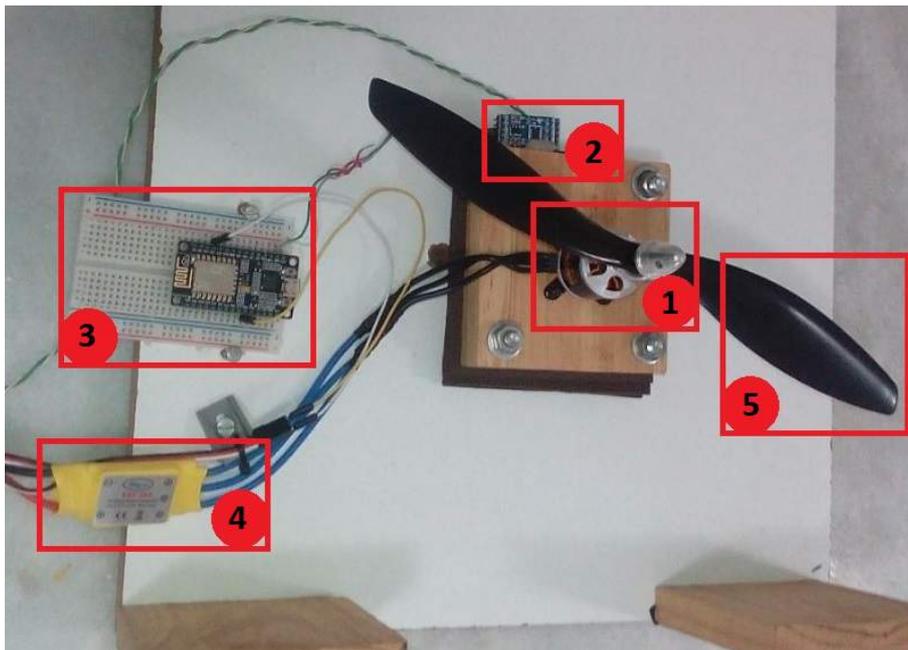


Figura 3.2 - Bancada para Experimentos. Fonte: O autor (2018)

Na bancada de testes foram fixados e conectados os seguintes equipamentos:

1. Pequeno motor *Brushless DC* - BL2215/20 EMAX de 1200 Kv *Outrunner*, para VANTs até 1200 gramas - conforme detalhe na Figura 3.3 e especificações técnicas na Tabela 3.1;
2. Acelerômetro *Adafruit XL345*;
3. Módulo *Wifi Node MCU Esp 8266 12F* - Micro controlador baseado em Arduino para definir a velocidade enviada ao ESC, com interface USB Serial e um regulador de tensão de 3,3V, cuja programação foi feita com a própria IDE do Arduino;
4. Controlador Eletrônico de Velocidade (*Electronic Speed Controller - ESC*) de 30A;
5. Hélice de 10.4 polegadas;
6. Fonte Bi-volt de alimentação da bancada com 115/230VAc, 47-63Hz e 6/4A.



**Figura 3.3** - Detalhe do Motor BLDC usado na bancada. Fonte: O autor (2018)

**Tabela 3.1** - Especificações do motor BLDC

Descrição	Medidas	Unidade
<b>Peso</b>	60	grama
<b>Dimensões do Estator</b>	22 x 15	mm
<b>Diâmetro do Eixo</b>	3,00	mm
<b>Velocidade<sup>1</sup></b>	7400	rpm
<b>Hélice Utilizada</b>	10 x 4,7	polegada
<b>Corrente Máxima</b>	24.5	A
<b>Tensão de Trabalho</b>	7,4 a 11,1	volt
<b>Constante<sup>2</sup> Kv</b>	1200	rpm/V

<sup>1</sup>Para o caso em que a hélice é de 10x5 polegadas, a velocidade é de 9.350 rpm e corrente máxima de 20,2A. O valor expresso na tabela equivale, aproximadamente, a 80% da sua eficiência máxima.

<sup>2</sup>Kv é a constante que relaciona rotação com voltagem, expressa em rpm/V.

A hélice descrita na Tabela 3.3 e utilizada nos experimentos tem como unidade de medida a polegada ("). Para medir as polegadas de uma hélice, deve-se tomar o comprimento (em cm) de uma ponta a outra da asa e multiplicar por 2,54. Então, em hélices de 10x4,7 polegadas, trata-se cada dimensão da seguinte forma: a) 10" (polegadas) de comprimento (10 x 2,54 = 25,40 cm), medindo-se de uma ponta à outra, e b) que percorre 4,7" a cada volta (4,7 x 2,54 = 11,94 cm) ou passo.

Cinco cenários experimentais foram aplicados, onde três variáveis são combinadas: a) velocidade do motor (60, 65, 70, 75 e 80%); b) condição da hélice (balanceada ou desbalanceada); c) tipo de sinal executado pelo algoritmo (puro ou após a aplicação da Transformada de *wavelet*). A condição normal da hélice sugere perfeito funcionamento do motor e, neste trabalho, será denominada de *balanceada*. Da mesma forma, a expressão *desbalanceada*, e aqui utilizada ao longo de todo o trabalho, deve ser compreendida como sendo a falha de excentricidade. Para sugerir o desbalanceamento do motor, foi utilizada uma fita adesiva fixada à 10 cm do centro da hélice e, para que fossem simuladas três diferentes condições de falhas de excentricidade, foram cortados três tamanhos de fita (6 cm, 14 cm e 22 cm), porém todas com a mesma largura (2,80 cm).

A pesagem das fitas foi realizada numa balança de precisão<sup>3</sup>, localizada no Laboratório de Solidificação Rápida (LSR) da UFPB e, para cada fita, foram repetidas 5 pesagens. A Tabela 3.2 traz as medidas (em gramas) extraídas em cada pesagem, a média ( $\mu$ ) e o desvio padrão ( $\sigma_X$ ) referentes aos pesos de cada fita.

**Tabela 3.2** - Análise estatística dos pesos (em gramas) da fita utilizada nos experimentos

<b>Pesagens</b>	<b>6 cm</b>	<b>14 cm</b>	<b>22 cm</b>
<b>Peso 1</b>	0,2284 g	0,5240 g	0,8196 g
<b>Peso 2</b>	0,2283 g	0,5237 g	0,8191 g
<b>Peso 3</b>	0,2284 g	0,5240 g	0,8196 g
<b>Peso 4</b>	0,2283 g	0,5243 g	0,8203 g
<b>Peso 5</b>	0,2285 g	0,5239 g	0,8193 g
$\mu$	<b>0,2284 g</b>	<b>0,5239 g</b>	<b>0,8196 g</b>
$\sigma_X$	$8,37 * 10^{-5}g$	$2,17 * 10^{-4}g$	$4,55 * 10^{-4}g$

A velocidade de rotação da hélice utilizada na bancada foi medida com um tacômetro foto/contato digital<sup>4</sup>. As especificações técnicas do referido equipamento estão disponíveis na Tabela 5.3.

<sup>3</sup>Balança Analítica Marte/Shimadzu, Modelo AY 220, Capacidade 220 g, Leitura 0,1 mg, Repetitividade 0,1 mg - [www.shimadzu.com.br](http://www.shimadzu.com.br)

<sup>4</sup>Marca/Modelo: MINIPA MDT-2238B - Minipa do Brasil Ltda. - [www.minipa.com.br](http://www.minipa.com.br)

**Tabela 3.3** - Especificações técnicas do tacômetro

Descrição	Medidas	Unidade
Taxa de Amostragem	0,5	s
Distância de Detecção	50 a 500	mm
Faixa	2,5 a 99999	RPM
Resolução (2,5 a 999,9 RPM)	0,1	RPM
Resolução (acima de 1000 RPM)	1	RPM
Precisão	± (0,05 Leit. + 1 Díg.)	

### 3.3 Aquisição de Dados

O sistema embarcado apresentado na Figura 3.4, foi desenvolvido por Lima (2017) e, de forma parceira, foi utilizado neste trabalho para as coletas dos áudios em cada experimento. O sistema é constituído da plataforma de desenvolvimento Arduino DUE e do microfone condensador de eletreto CMA-4544PF-W.

**Figura 3.4** - Plataforma Arduino com microfone embarcado. Fonte: Lima (2017)

O Arduino DUE possui capacidade computacional e rápido processamento, visto que possui um microcontrolador ARM de 32 bits: Atmel SAM3X8E ARM Cortex-M3. Mediante a configuração prévia de seus registradores e *timers* internos, a frequência de aquisição pôde ser estabelecida com o valor de 44.1 kHz.

O CMA-4544PF-W é um microfone condensador de eletreto omnidirecional com sensibilidade de 44dB e com frequência de operação de 20 Hz até 20 kHz. A sua curva de resposta em frequência (Figura 3.5) é estável, caracterizando-o como um bom mecanismo de transdução. Os arquivos de áudio são armazenados seguindo o padrão do formato WAVE, garantindo um armazenamento de áudio sem compressão, sendo salvos em um cartão de memória para análise posterior dos dados. A Tabela 3.4 apresenta um resumo das propriedades do Arduino DUE utilizado neste trabalho.

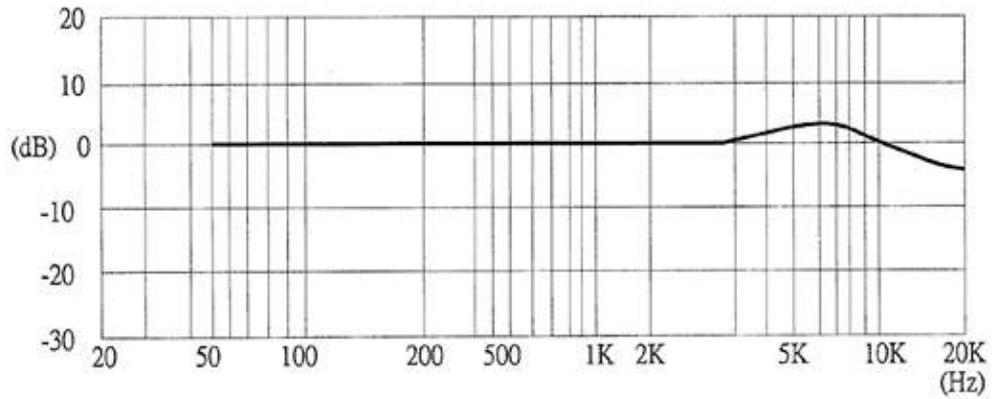


Figura 3.5 - Curva de resposta em frequência do microfone Arduino (Hz x dB) - Fonte: Lima (2017)

Tabela 3.4 - Resumo das propriedades do Sistema Arduino DUE para coleta de áudios

Parâmetro	Característica	Descrição
Placa de Desenvolvimento	Modelo	Arduino Due
	Taxa de aquisição	44,1 kHz (44.100 amostras/s)
	Resolução	16 bits
Microfone	Modelo	CMA-4445PF-W
	Sensibilidade	-44 dB
	Frequência de operação	20 Hz - 20 kHz
Áudio	Formato	Wave

A Figura 3.6 apresenta o sinal puro do motor capturado pelo sistema de aquisição aqui apresentado a uma velocidade de 80% da potência do motor.

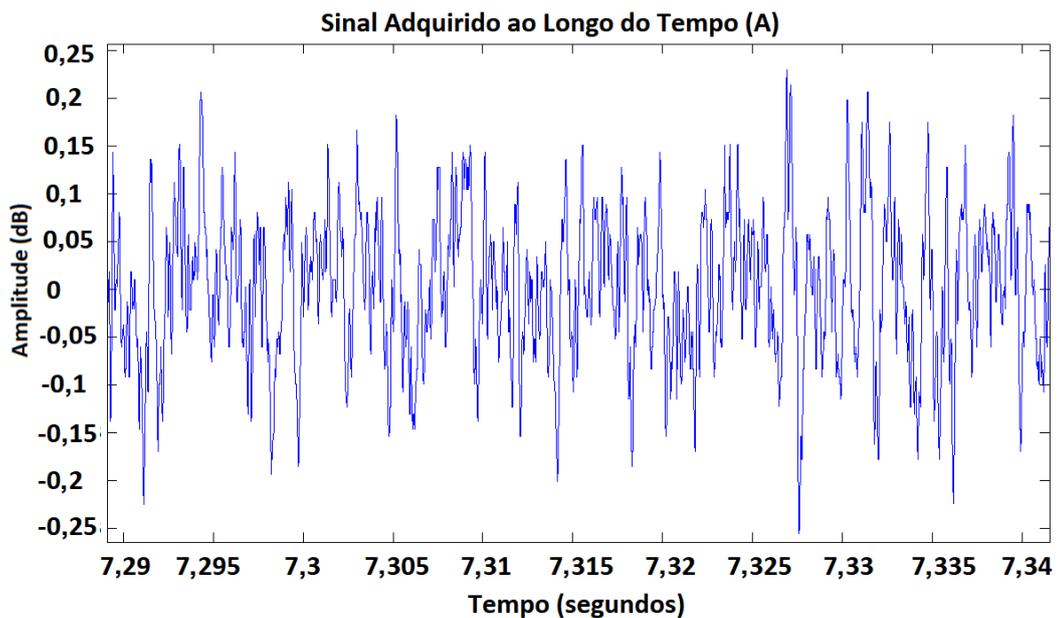
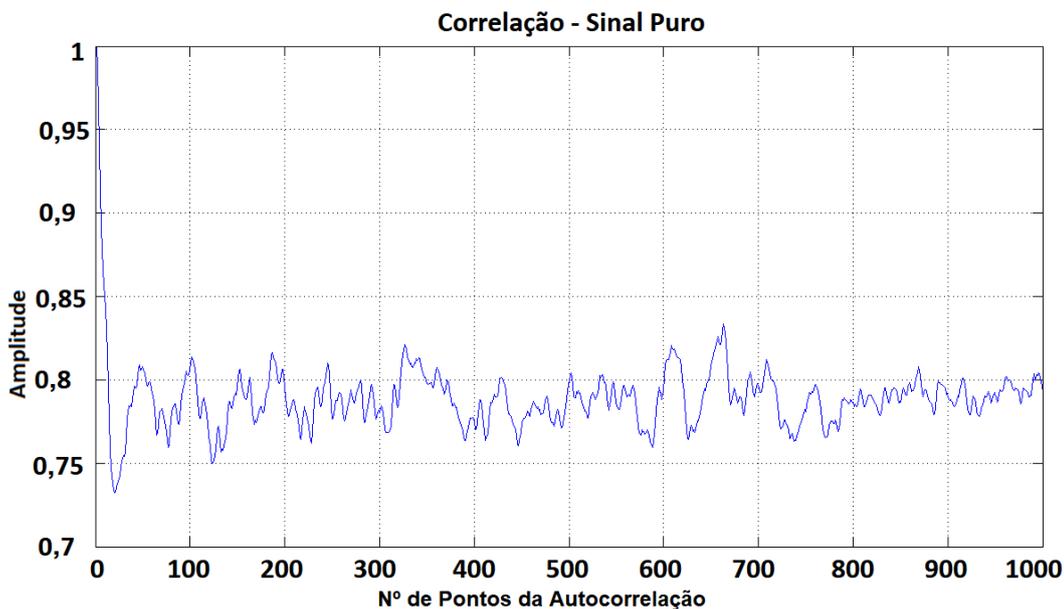


Figura 3.6 - Sinal Puro - Velocidade à 80% - Hélice Normal. Fonte: O autor (2018)

### 3.4 Wavelet Discrete Transform - WDT

A Figura 3.7 representa a Função de Autocorrelação encontrada para o mesmo sinal da Figura 3.6. Neste caso, a função tem tendência para convergir e amortecer. No entanto, os ruídos presentes na coleta, ou as impurezas do circuito de medição, não permitem que esse amortecimento esteja conforme o esperado.

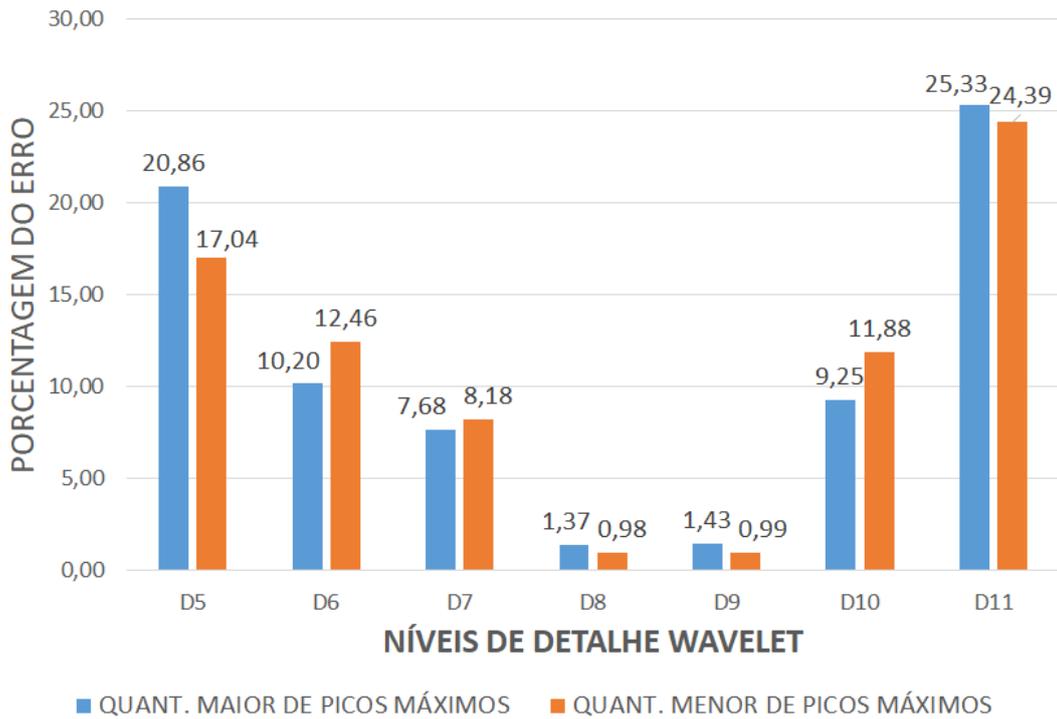
Desta forma, sobre o sinal sonoro coletado à velocidade de 80%, foi aplicada a Transformada Discreta de *Wavelet* (WDT), conforme a Seção 2.7. Consequentemente, foi executada a decomposição do sinal em vários níveis de detalhe ( $D_m[n]$ ), melhorando as condições de análise dos experimentos e aumentando a tendência da função de convergir e amortecer.



**Figura 3.7** - Autocorrelação - ESC à 80% - Hélice Balanceada. Fonte: O autor (2018)

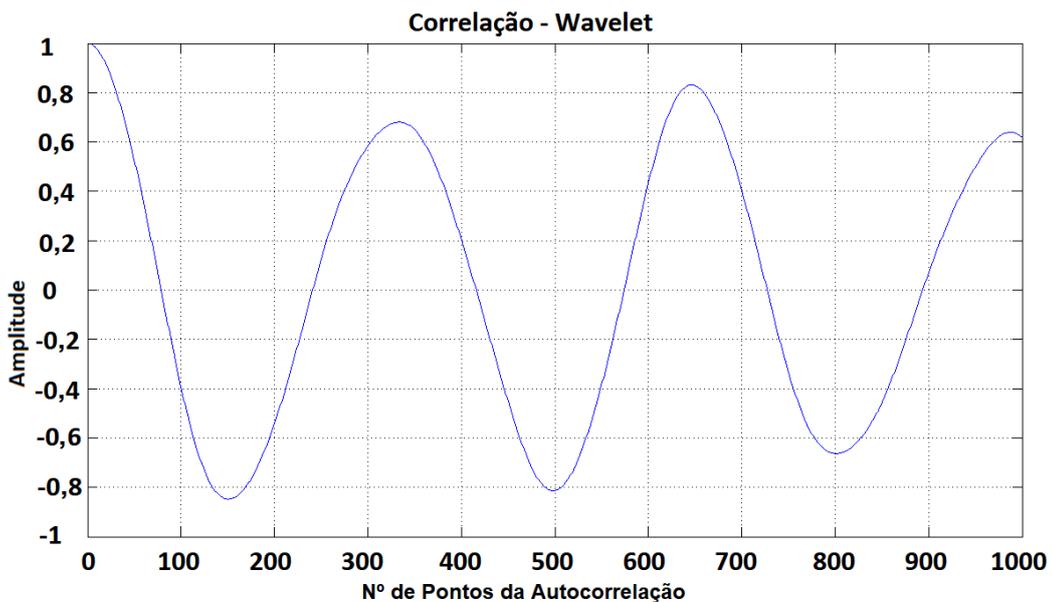
Duas contagens de picos máximos foram realizadas no intuito de observar o comportamento do sinal, cada vez que fosse aplicado um nível de detalhe *wavelet* no mesmo. A ação resultou em dados expressos no Gráfico 3.8, onde é apresentada a curva percentual do erro relativo aos níveis de decomposição *wavelet*. Tendo experimentado as variações nos níveis de detalhe compreendidas entre D5 e D11, o resultado que apresentou menores erros percentuais foi o detalhe D8, independentemente do maior ou menor número de picos máximos contados por amostra.

Da mesma forma, esse nível (D8) foi o que melhor apresentou convergência e amortecimento, para a velocidade em questão (80%). Por essa razão, D8 foi o nível escolhido para a realização dos testes preliminares, e que será descrita na Seção 5.3.1.



**Figura 3.8** Gráfico do erro percentual entre o CLC e  $\tau$ , para duas contagens de picos máximos por nível de detalhe - ESC à 80% - Hélice Normal. Fonte: O autor (2019)

O comportamento do sinal da Autocorrelação com Detalhe D8 do *wavelet* aplicado ao sinal sonoro na velocidade de 80% é apresentado na Figura 3.9. Nesta figura, é possível observar que a aplicação da DWT resultou na diminuição dos ruídos, melhorando a convergência do sinal, com uma amplitude alcançada maior em relação ao atingido na Figura 3.7.



**Figura 3.9** Autocorrelação após *wavelet* - ESC a 80% da velocidade - Hélice Normal. Fonte: O autor (2018)

### 3.5 Calculando o SAC-DM e Análise do Sistema

O SAC-DM é calculado para cada subconjunto do sinal sonoro filtrado de acordo com a Equação 3.1, em que  $\rho$  é o número de picos dividido pelo número de amostras, ou seja, a densidade dos máximos. Após o cálculo para cada subconjunto, verifica-se se o valor do SAC-DM está dentro da faixa esperada para um motor balanceado. Se não for, retorna que está desequilibrado. A partir do valor do SAC-DM, a velocidade estimada do motor também é retornada.

$$SAC\_DM = \tau = \frac{1}{6\langle\rho\rangle} \quad (3.1)$$

## CAPÍTULO 4

# COMPORTAMENTO CAÓTICO

Antes de apresentar os experimentos e resultados obtidos com a aplicação do SAC-DM, serão apresentados nesta seção os testes que indicam que o sinal de som emitido pelo motor BLDC apresenta um comportamento caótico. Isto é verdade se o Coeficiente de Comprimento de Correlação (CLC) obtido da Função de Autocorrelação (FAC) resultar em um valor similar ao obtido pela aplicação da Densidade Máxima na Equação 3.1.

### 4.1 Provando o Comportamento Caótico

O gráfico na Figura 4.1 apresenta o CLC, representado por  $\tau$ , que é o valor em x, quando y atinge o valor de 0,5. Para esta figura, portanto, mostra o comprimento de correlação à meia altura obtido com uma velocidade de 80% do motor e hélice normal, cujo valor é de 50,73 e expresso na Equação 4.1.

$$\tau = X_B - X_A = 51,73 - 1 = 50,73 \quad (4.1)$$



O erro relativo percentual encontrado entre o CLC apresentado na Figura 4.1 e o resultado na Equação 3.1 é de 0,4033%. Quando o SAC-DM é calculado para todo o sinal, tem-se um erro relativo percentual de 0,1011%.

As Tabelas 4.1 e 4.2 trazem os resultados encontrados no motor experimental em que a Transformada de *wavelet* é aplicada no sinal sonoro. Elas mostram o CLC e o SAC-DM encontrados para as velocidades em que o motor atuou nos testes (60%, 65%, 70%, 75% e 80%), de acordo com a condição da hélice (Balanceada ou Desbalanceada), acompanhados dos seus respectivos erros relativos percentuais. Neste caso, tanto o CLC, quanto o SAC-DM foram calculados do mesmo sinal, ou seja, do Detalhe originado da *wavelet*.

**Tabela 4.1 - Resultados com *wavelet* - Hélice Balanceada**

VELOCIDADE do ESC	CLC	SAC-DM	ERRO REL.PERC.
60%	393,39	396,23	0,72%
65%	377,75	375,96	0,47%
70%	383,87	386,33	0,64%
75%	53,80	53,93	0,23%
80%	50,73	50,78	0,10%

**Tabela 4.2 - Resultados com *wavelet* - Hélice Desbalanceada**

VELOCIDADE do ESC	CLC	SAC-DM	ERRO REL.PERC.
60%	12,41	12,44	0,26%
65%	98,99	98,23	0,77%
70%	6,54	6,52	0,29%
75%	6,56	6,53	0,36%
80%	6,42	6,45	0,45%

Observa-se que os valores do Erro Relativo Percentual nas Tabelas 4.1 e 4.2 são menores que 1% e, na maioria dos casos, chegam a menos de 0,5%, independente da condição da hélice. Com isso, pode-se afirmar que o sinal sonoro aqui analisado e discutido tem um comportamento caótico e, por esta razão, pode ser conduzido, como será visto nas próximas seções, por cálculos envolvendo apenas a Equação 3.1.

## CAPÍTULO 5

# EXPERIMENTOS E RESULTADOS

Neste capítulo são apresentados os experimentos e resultados obtidos na bancada de laboratório que se tornaram possível em razão da comprovação do comportamento caótico mostrado no capítulo anterior.

Diversos experimentos utilizando o sistema de instrumentação e controle são feitos e, com o sistema de medição, é possível analisar o sinal sonoro capturado diretamente do motor e fornecer informações como velocidade e desbalanceamento do mesmo.

O presente capítulo foi organizado de forma que fossem mostrados, nas duas primeiras sessões, aspectos estatísticos relativos à repetitividade das medições (Seção 5.1) e o uso de equipamento específico para aferir as velocidades alcançadas pelo motor da bancada (Seção 5.2). Em seguida, são apresentados os resultados alcançados usando o SAC-DM (Seção 5.3). Nesta seção, quatro etapas de testes são discutidas: a) resultados alcançados com a aplicação da Transformada de *wavelet* (Subseção 5.3.1); b) resultados sem *wavelet* (Subseção 5.3.2); c) uma comparação entre os dois resultados anteriores (Subseção 5.3.3) e, d) uma comparação entre resultados alcançados com áudio e com a vibração mecânica (Subseção 5.3.4).

### 5.1 Repetitividade e Análise das Medições

Esta seção apresenta uma análise estatística relativa à dispersão das amostras dos sinais coletados. O uso de informações acerca da repetitividade e, adicionalmente, a realização de medidas repetidas reduziram a incerteza de medição dos resultados, justificando a análise aqui realizada.

Para tanto, fica estabelecido que os termos *população* e *amostra* são, respectivamente, a quantidade total de pontos contidos em cada sinal coletado e a quantidade correspondente à 25 valores aleatórios do SAC-DM, calculados a partir de subconjuntos menores do que a população de cada sinal. O valor de referência para a *população* foi obtido a partir do cálculo do CLC.

No guia de referência para incerteza padrão (ISO-GUM, 2008), a palavra “incerteza” significa dúvida, e assim, no sentido mais amplo, “incerteza de medição” significa dúvida acerca da validade do resultado de uma medição.

A incerteza padrão ( $U_M(I)$ ) é a medida da intensidade da componente aleatória do erro de medição correspondente à estimativa do desvio padrão da distribuição dos erros de medição (Albertazzi e Sousa, 2008). Esta medida pode ser estimada através de procedimentos estatísticos a partir de um conjunto de “n” medições repetidas, conforme Equação 5.1.

$$U_M(I) = \sqrt{\frac{\sum_{i=1}^n (I_i - \bar{I})^2}{n - 1}} \quad (5.1)$$

Neste caso,  $I_i$  é o valor percentual calculado da *Exatidão* da indicação (SAC-DM) e o  $\bar{I}$  é a *Média da Exatidão* dos 25 valores aleatórios da indicação. Os resultados encontrados nas diferenças  $I_i - \bar{I}$  e  $n - 1$  determinam, respectivamente, o valor do Erro - calculado entre a Exatidão da indicação e a Média da Exatidão dos valores aleatórios - e o grau de liberdade ( $25 - 1 = 24$ ), representando o grau de segurança com que a estimativa do desvio-padrão é conhecida, conforme Albertazzi e Sousa (2008).

A partir de cada cenário apresentado na Seção 3.2, cujos sinais foram coletados com velocidades de 60, 65, 70, 75 e 80%, foram comparados os respectivos valores do CLC, com as amostras aleatórias do SAC-DM. Aplicando os dados obtidos de cada uma destas coletas na Equação 5.1, foram encontrados os resultados expressos nas Tabelas 5.1 e 5.2, onde  $RM_{Exatidao}$  é o Resultado da Medição da Exatidão. A primeira expressa os resultados da repetitividade e análise das medições alcançadas em testes com a hélice balanceada, enquanto a segunda, com hélice desbalanceada.

**Tabela 5.1** - Resultados da repetitividade e análise das medições - Hélice Balanceada

ESC Speed	Média da Exatidão (%)	$U_M(I)$	$RM_{Exatidao}$
60%	99,22	0,52	$99,22 \pm 0,52$
65%	94,27	0,51	$94,27 \pm 0,51$
70%	95,45	0,37	$95,45 \pm 0,37$
75%	89,63	0,60	$89,63 \pm 0,60$
80%	94,19	0,74	$94,19 \pm 0,74$

**Tabela 5.2** - Resultados da repetitividade e análise das medições - Hélice Desbalanceada

ESC Speed	Média da Exatidão (%)	$U_M(I)$	$RM_{Exatidao}$
60%	98,05	0,29	$98,05 \pm 0,29$
65%	98,77	0,33	$98,77 \pm 0,33$
70%	98,87	0,32	$98,87 \pm 0,32$
75%	95,83	0,26	$95,83 \pm 0,26$
80%	98,17	0,25	$98,17 \pm 0,25$

## 5.2 Registrando a Velocidade do Motor da Bancada

Utilizando um tacômetro Minipa (conforme Figura 5.1), modelo MDT-2238b, foram observadas as velocidades (em RPM) em que o motor da bancada atingiu durante as coletas.



**Figura 5.1** - Medição da velocidade do motor em tempo de coleta. Fonte: O autor (2019)

As Tabelas 5.3 e 5.4 apresentam as médias das velocidades alcançadas, respectivamente em Rotações por Minutos (RPM) e Hertz (Hz). Em ambos os casos foram observadas as condições da hélice (Balanceada ou Desbalanceada) em que as coletas ocorreram e a relação com a velocidade do motor (em %).

**Tabela 5.3** - Médias das velocidades (em RPM) atingidas pelo motor da bancada

HÉLICE	60%	65%	70%	75%	80%	85%	90%
<b>Balanceada</b>	2886,8	3252	3525	3768	3985,2	4247	4373
<b>Desbalanc. - Fita 6 cm</b>	2881	3234,8	3517,2	3753,6	3960,8	4158	4315,6
<b>Desbalanc. - Fita 14 cm</b>	2897	3190,8	3526,8	3703,8	4001,6	4228,8	4304,2
<b>Desbalanc. - Fita 22 cm</b>	2897	3190,8	3526,8	3703,8	4001,6	4137,4	4337

**Tabela 5.4** - Médias das velocidades (em Hz) atingidas pelo motor da bancada

HÉLICE	60%	65%	70%	75%	80%	85%	90%
<b>Balanceada</b>	48,11	54,2	58,75	62,8	66,42	70,78	72,88
<b>Desbalanc. - Fita 6 cm</b>	48,02	53,91	58,62	62,56	66,01	69,3	71,93
<b>Desbalanc. - Fita 14 cm</b>	48,28	53,18	58,78	61,73	66,7	70,48	71,74
<b>Desbalanc. - Fita 22 cm</b>	48,3	53,18	58,78	61,73	66,7	68,96	72,3

## 5.3 Usando o SAC-DM para Detecção de Velocidade e Desbalanceamento

Para a realização das primeiras coletas deste trabalho, foram utilizados três dispositivos de coleta de áudio distintos: a) o gravador de um celular Samsung<sup>1</sup>; b) o gravador de um notebook Samsung<sup>2</sup>; e c) o gravador citado na Seção 3.3. Este último dispositivo foi o escolhido como padrão de coleta dos áudios em nossas pesquisas, tendo em vista as especificações técnicas da placa, do microfone embarcado na mesma e por sua taxa de coleta (44.1 kHz). No entanto, nada impede de que outros testes ocorram com os demais dispositivos listados acima.

A metodologia aplicada no desenvolvimento do sistema foi representada por um diagrama, conforme a Figura 3.1 (Seção 3.1). O referido diagrama indica que a Transformada de *wavelet* foi aplicada no intuito de buscar resultados que mais convergissem e amortecessem o sinal analisado. No entanto, antes que fosse aplicada a *wavelet*, os resultados dos testes preliminares indicavam que havia a necessidade da melhoria do algoritmo do SAC-DM ou de ajustes na processo de coleta dos áudios.

### 5.3.1 Resultados Preliminares alcançados com *wavelet*

Para cada condição da hélice (balanceada ou desbalanceada), combinadas a cada uma das velocidades testadas (mais os testes à 50%), foram coletados 5 (cinco) áudios de 1 minuto, em que cada sinal sonoro possui 1.764.000 pontos, aproximadamente, totalizando 60 arquivos de áudio analisados nesta etapa preliminar, ou seja, 1 hora de arquivos de áudio coletados.

As Tabelas 5.5 e 5.6 apresentam a análise estatística do SAC-DM nas condições de hélice balanceada e desbalanceada, respectivamente. O desbalanceamento aqui apresentado foi o obtido com o uso da Fita de 6 cm, conforme descrito na Tabela 3.2 (Seção 3.2). Estas tabelas trazem a média ( $\mu$ ), a variância ( $\sigma^2$ ) e o desvio padrão ( $\sigma_X$ ) referentes a cada velocidade analisada (60%, 65%, 70%, 75% e 80%) neste cenário.

Analisando a Tabela 5.5, observa-se que as médias alcançadas pelo SAC-DM, com a hélice balanceada, são diferentes e aumentam à medida que a velocidade do motor também aumenta. No entanto, isso não acontece com a hélice desbalanceada, conforme apresentado na Tabela 5.6. Este fato gerou a necessidade de uma análise mais detalhada do sinal sonoro, conforme segue a discussão neste trabalho.

As faixas coloridas e distintas do SAC-DM apresentadas nos gráficos das Figuras 5.2 e 5.4 representam a capacidade do método aplicado em distinguir as velocidades do motor, independente da condição da hélice. Estes gráficos apresentam os valores do SAC-DM para cada subconjunto do sinal sonoro, respectivamente para hélice balanceada e desbalanceada. A

<sup>1</sup>Galaxy J2 Prime, SO Android com processador de 1.4Ghz Quad Core, Memória RAM 1.5 GB e Memória Total 16 GB - <https://www.samsung.com/br/smartphones/galaxy-j2-prime-tim>.

<sup>2</sup>Intel(R) Core(TM) i5-5200U CPU @ 2.20Ghz 2.20Ghz, Memória RAM 8,00 Gb, SO de 64 bits, Windows 10 Home Single Language ©2018 Microsoft Corporation - <https://www.samsung.com/br/pc/>.

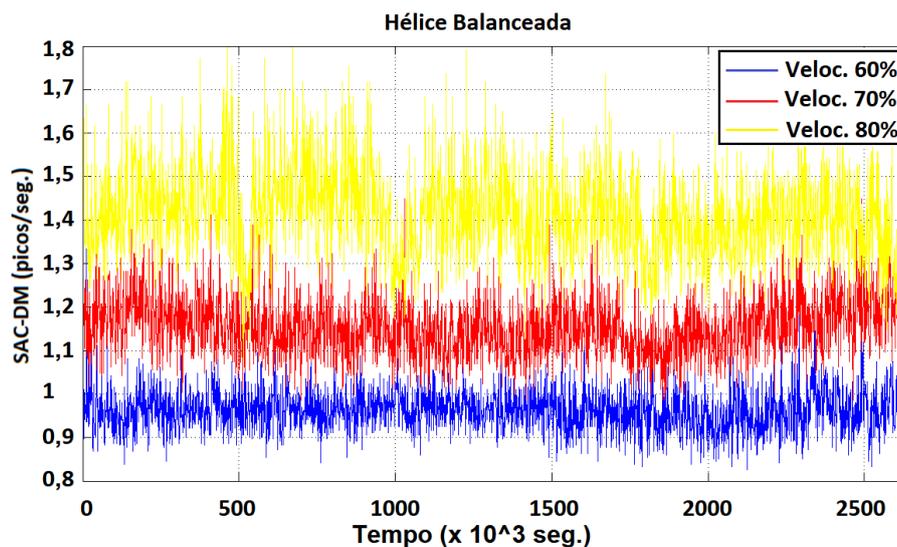
**Tabela 5.5** Análise estatística dos resultados do SAC-DM para motores BLDC com hélice balanceada

VELOCIDADE do ESC	$\mu$	$\sigma^2$	$\sigma_X$
60%	0,96	$2,41 * 10^{-3}$	0,05
65%	1,01	$2,74 * 10^{-3}$	0,05
70%	1,16	$4,91 * 10^{-3}$	0,07
75%	1,29	$6,75 * 10^{-3}$	0,08
80%	1,41	$1,10 * 10^{-2}$	0,10

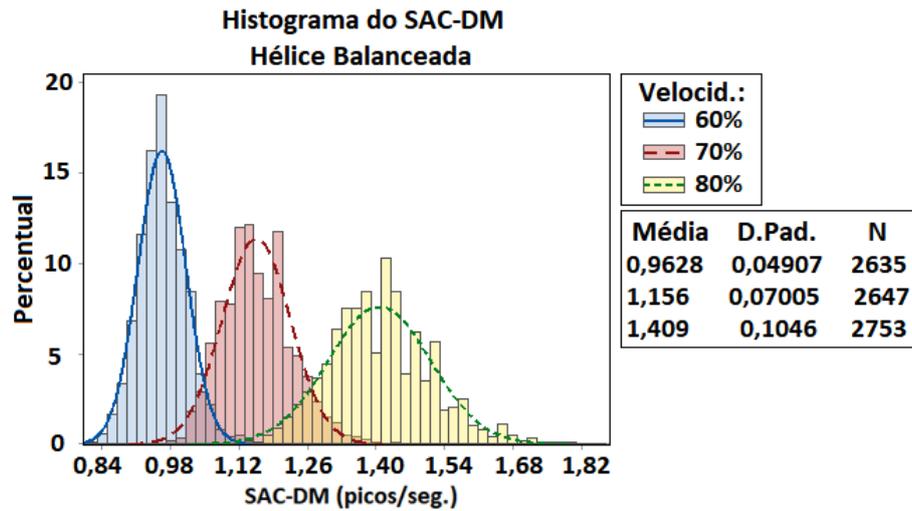
**Tabela 5.6** Análise estatística dos resultados do SAC-DM para motores BLDC com hélice desbalanceada

VELOCIDADE do ESC	$\mu$	$\sigma^2$	$\sigma_X$
60%	1,06	$3,7 * 10^{-3}$	0,06
65%	1,22	$9,4 * 10^{-3}$	0,10
70%	1,20	$6,1 * 10^{-3}$	0,08
75%	1,31	$8,0 * 10^{-3}$	0,09
80%	1,20	$7,5 * 10^{-3}$	0,09

partir disso, é possível confirmar que quando a hélice está desequilibrada, há mais interseção de valores do SAC-DM ao longo do tempo, em comparação com uma hélice balanceada.

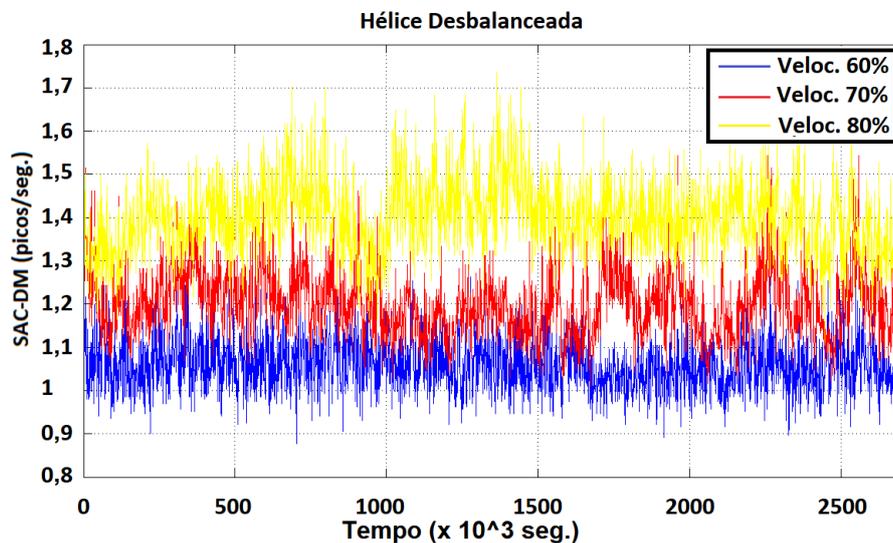
**Figura 5.2** Gráfico da amostra do sinal sonoro com hélice balanceada para velocidade de 60%, 70% e 80%. Fonte: O autor (2018)

Para calcular essa interseção, produzimos os histogramas do SAC-DM para cada caso. A Figura 5.3 apresenta o histograma das velocidades (60%, 70% e 80%) com hélice balanceada. Nesse caso, a área de interseção entre 60% e 70% da velocidade é 0,18%. Entre 70% e 80% da velocidade, a área é de 0,36%. Isto significa que, com o SAC-DM, é possível determinar a velocidade do motor com 95,89% de precisão, para os casos em que a hélice estiver balanceada. Para um sistema que trabalha com velocidade controlada, como é o caso dos VANTs, torna-se possível restringir a análise pela faixa do SAC-DM esperada.

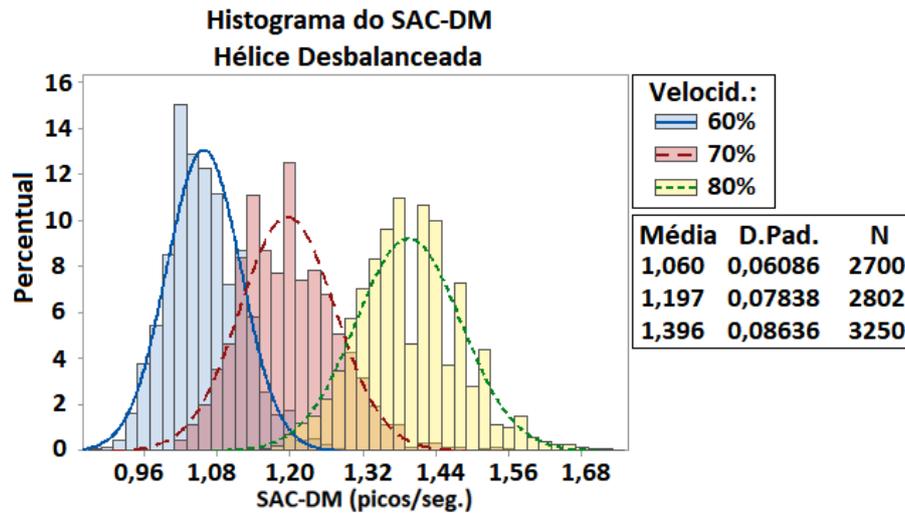


**Figura 5.3** Histograma do SAC-DM calculado a partir do sinal sonoro com hélice balanceada para velocidade de 60%, 70% e 80%. Fonte: O autor (2018)

Da mesma forma, a Figura 5.5 apresenta o histograma do motor à 60%, 70% e 80% da velocidade com hélice desbalanceada. Neste caso, as interseções entre as áreas são maiores, o que reduz a precisão da estimativa de velocidade. Agora, a interseção entre 60% e 70% da velocidade é de 0,84%. Entre 70% e 80% da velocidade, a área é de 0,6%. Isso significa uma precisão de 88,34% para detectar a velocidade do motor quando a hélice está desbalanceada.

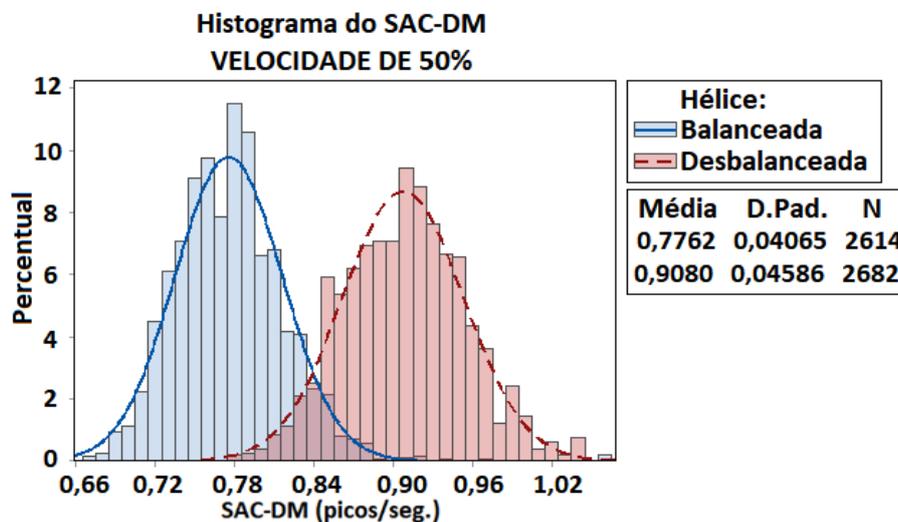


**Figura 5.4** Gráfico da amostra do sinal sonoro com hélice desbalanceada para velocidade de 60%, 70% e 80%. Fonte: O autor (2018)



**Figura 5.5** Histograma do SAC-DM calculado a partir do sinal sonoro com hélice desbalanceada para velocidade de 60%, 70% e 80%. Fonte: O autor (2018)

Na Figura 5.6, a distribuição dos valores do SAC-DM é mostrada para o caso em que um motor está atuando a uma velocidade de 50%, e analisando duas condições: hélice balanceada (azul) e desbalanceada (vermelha). A área de intersecção entre os histogramas apresentados diz respeito aos casos onde a detecção de desbalanceamento não seria precisa. As áreas restantes resultam em uma acurácia na detecção de desbalanceamento de 92,87%.

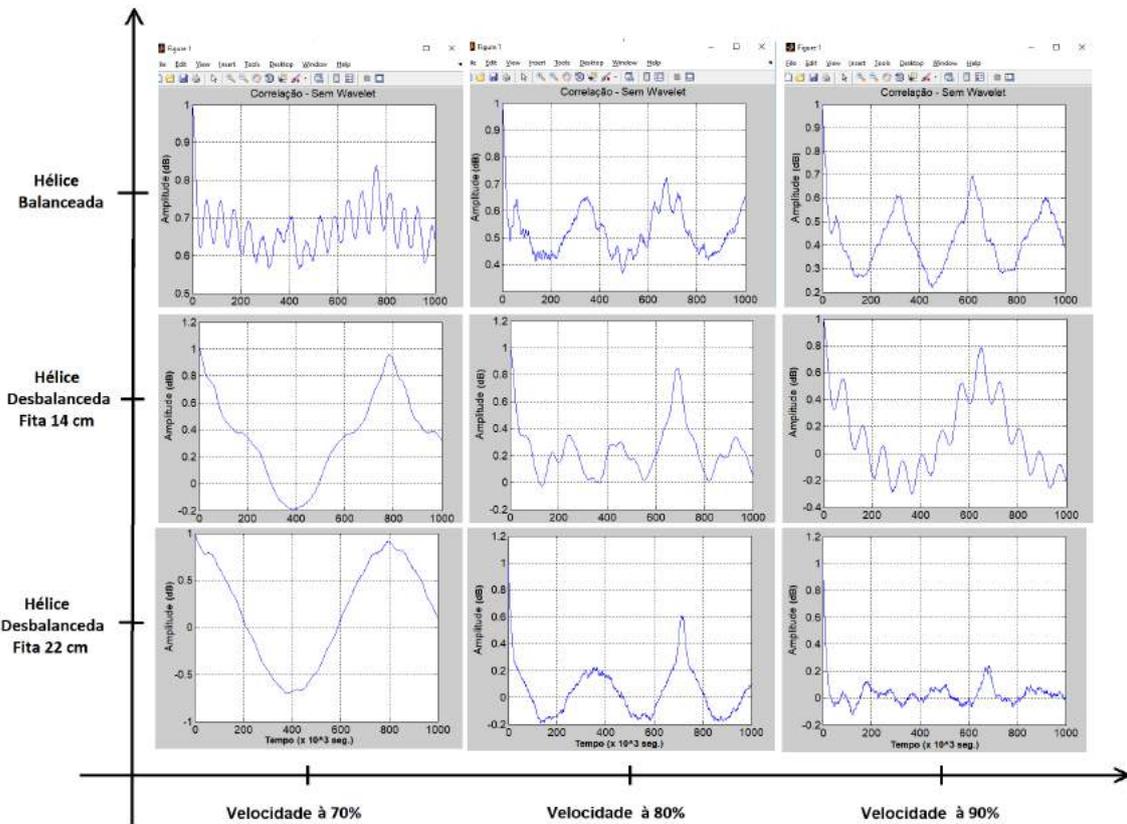


**Figura 5.6** Histograma do SAC-DM calculado a partir do sinal sonoro com hélice balanceada e desbalanceada para velocidade de 50%. Fonte: O autor (2018)

### 5.3.2 Resultados Alcançados sem *wavelet*

Em testes posteriores à análise usando a Transformada *wavelet*, foram processados os sinais sonoros sem a aplicação deste filtro. A Figura 5.7 apresenta os resultados da autocorrelação encontrada quando são analisadas as três condições da hélice (balanceada, desbalanceada com fita de 14 cm e desbalanceada com fita de 22 cm - conforme descrição na Tabela 3.2), relaciona-

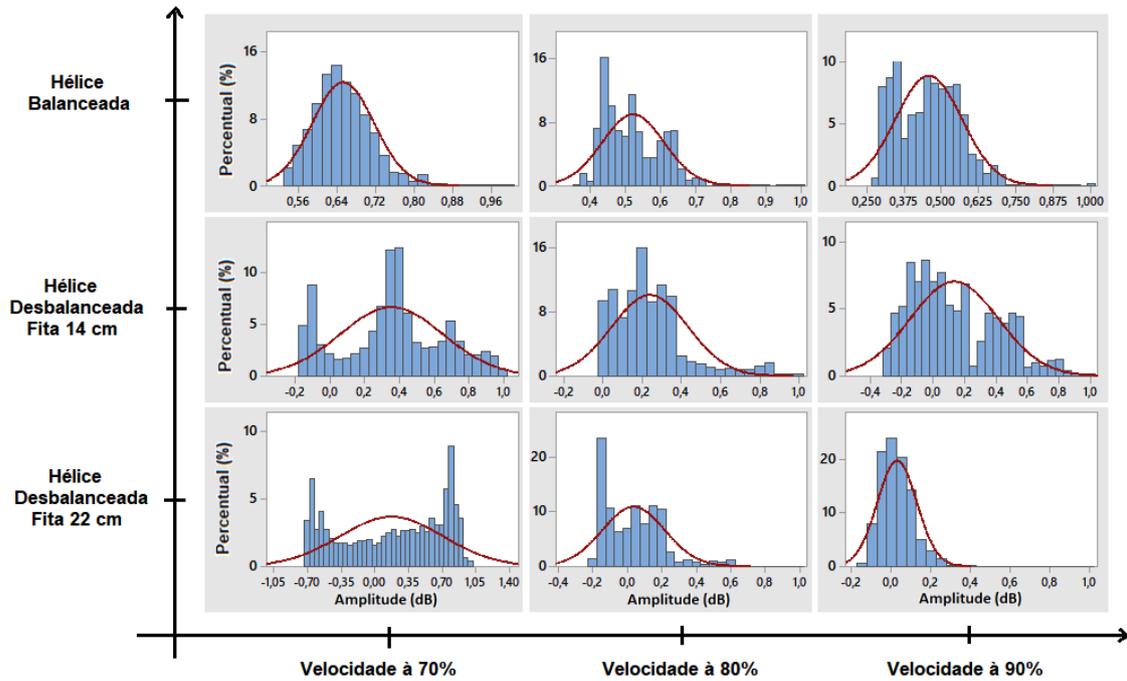
das às velocidades de 70, 80 e 90%. Nesta figura, observa-se uma tendência ao amortecimento à medida que se aumenta a velocidade.



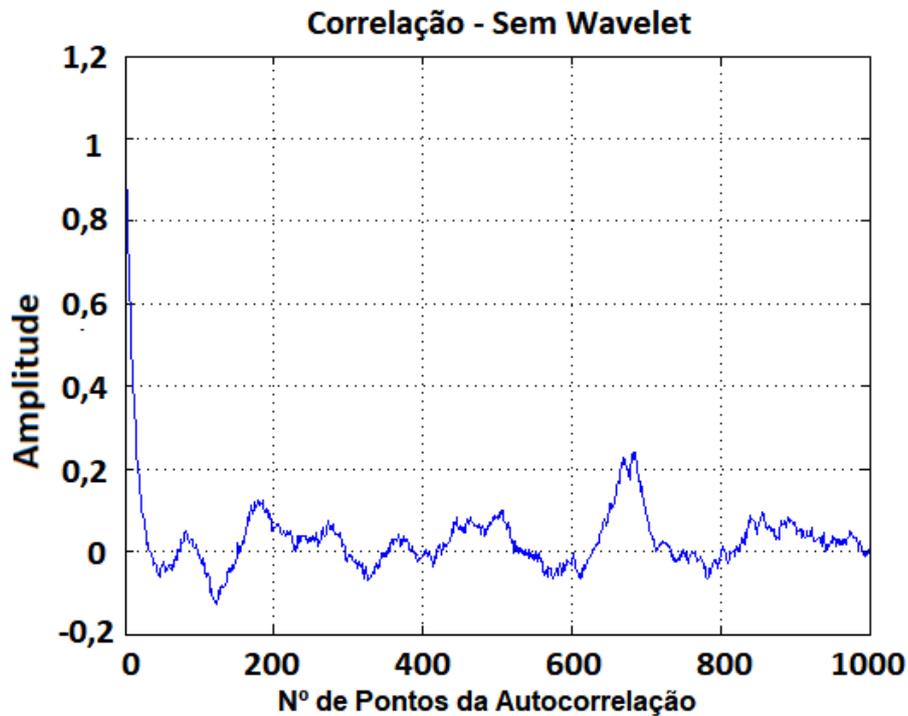
**Figura 5.7** Autocorrelação sem *wavelet* - Três condições da hélice e três velocidades - 70, 80 e 90%.  
 Fonte: O autor (2019)

Para confirmar o fato de que existe uma tendência ao amortecimento à medida em que se aumenta a velocidade do motor, foram gerados os respectivos histogramas na Figura 5.8, relativos a cada gráfico da Figura 5.7.

Dessa forma, a Figura 5.9 (retirada da Figura 5.7), apresenta o comportamento do sinal após o processamento da autocorrelação e traz a convergência e o amortecimento do mesmo, com tendência à zero, quando esse está à velocidade de 90% e com maior carga de desbalanceamento (fita de 22 cm).



**Figura 5.8** Histogramas da Autocorrelação sem Wavelet - Três condições da hélice e três velocidades - 70, 80 e 90%. Fonte: O autor (2019)



**Figura 5.9** Autocorrelação sem wavelet- ESC à 90% da veloc. - Hélice Desbal. com Fita de 22 cm. Fonte: O autor (2019)

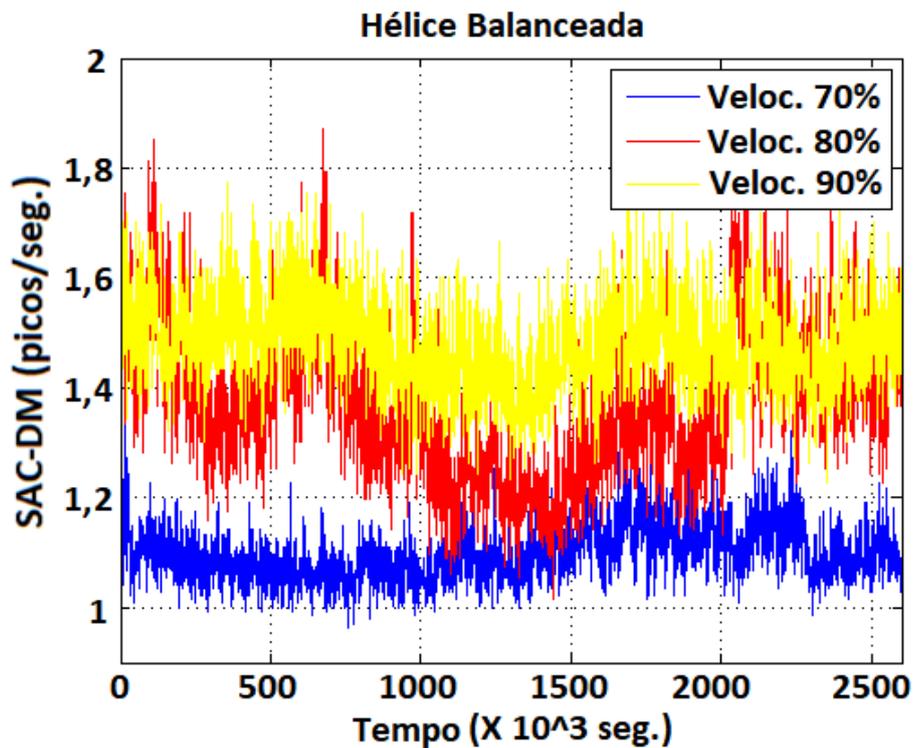
**5.3.2.1 Velocidades de 70, 80, 90%**

As tabelas e figuras (gráficos e histogramas) apresentadas nesta subseção trazem os resultados obtidos nas velocidades de 70, 80 e 90%, quando o SAC-DM é analisado a partir das

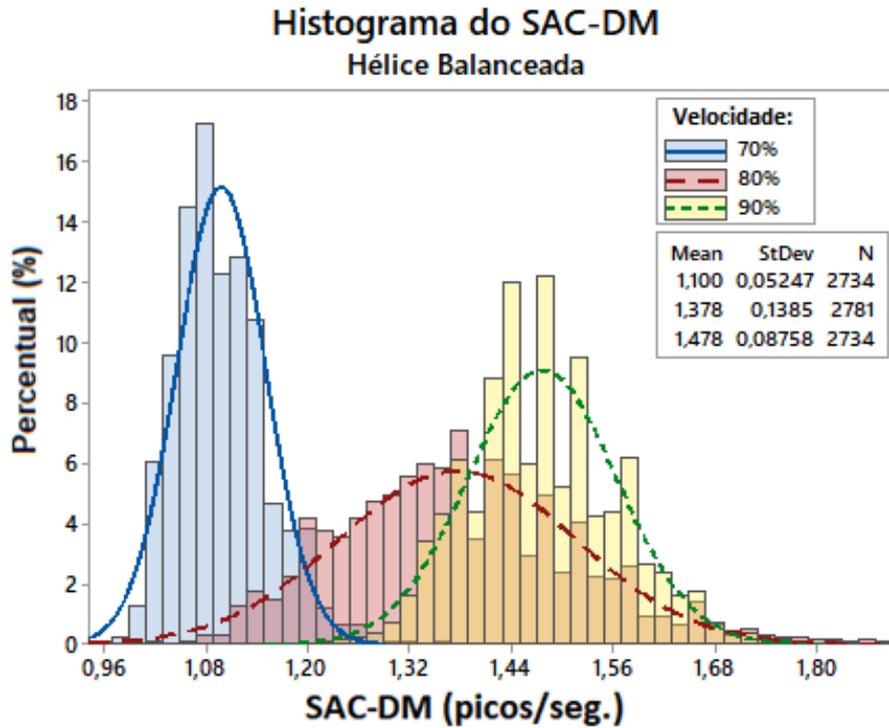
condições da hélice: balanceada, desbalanceada com fita de 14 cm ou desbalanceada com fita de 22 cm.

**Tabela 5.7** Análise estatística dos resultados do SAC-DM para motores BLDC com hélice balanceada - Sem *wavelet*

VELOCIDADE do ESC	$\mu$	$\sigma^2$	$\sigma_X$
70%	1,10	$2,75 * 10^{-3}$	0,05
80%	1,38	$1,92 * 10^{-2}$	0,14
90%	1,48	$7,67 * 10^{-3}$	0,09



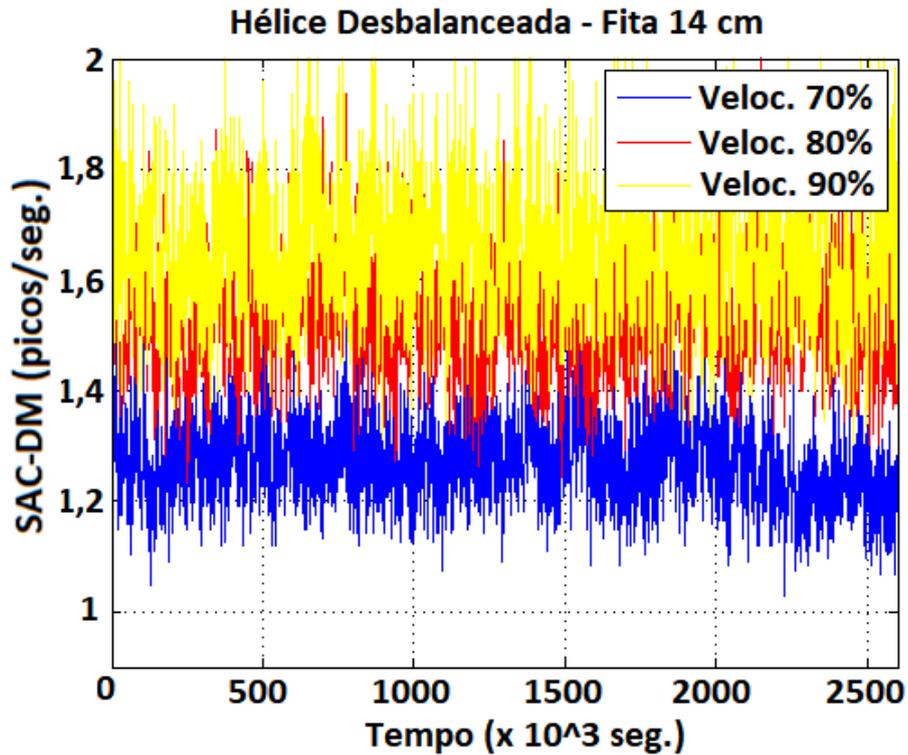
**Figura 5.10** Gráfico da amostra do sinal sonoro com hélice balanceada para velocidade de 70%, 80% e 90% - Sem *wavelet*. Fonte: O autor (2019)



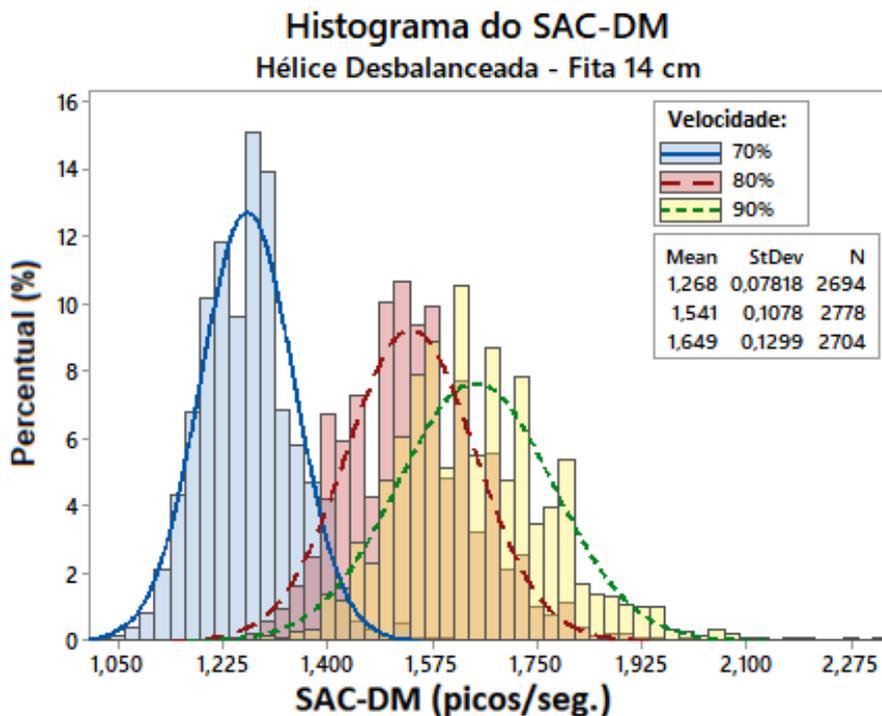
**Figura 5.11** Histograma do SAC-DM calculado a partir do sinal sonoro com hélice balanceada para velocidade de 70%, 80% e 90% - Sem wavelet. Fonte: O autor (2019)

**Tabela 5.8** Análise estatística dos resultados do SAC-DM para motores BLDC com hélice desbalanceada (Fita 14 cm) - Sem wavelet

VELOCIDADE do ESC	$\mu$	$\sigma^2$	$\sigma_X$
<b>70%</b>	1,27	$6,11 * 10^{-3}$	0,08
<b>80%</b>	1,54	$1,16 * 10^{-2}$	0,11
<b>90%</b>	1,65	$1,69 * 10^{-2}$	0,13



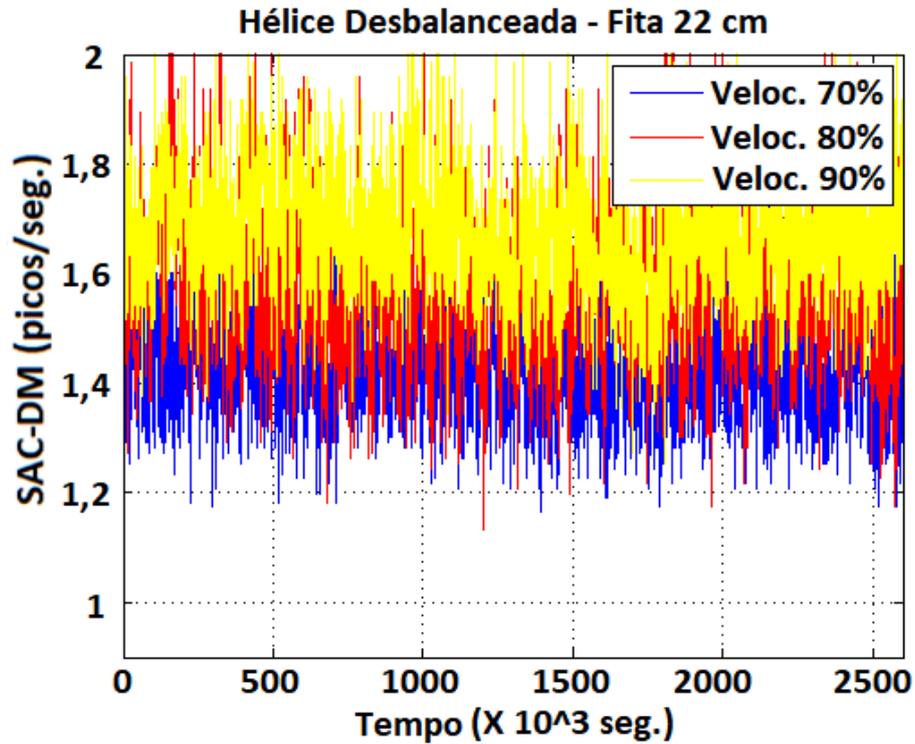
**Figura 5.12** Gráfico da amostra do sinal sonoro com hélice desbalanceada com fita de 14 cm para velocidade de 70%, 80% e 90% - Sem wavelet. Fonte: O autor (2019)



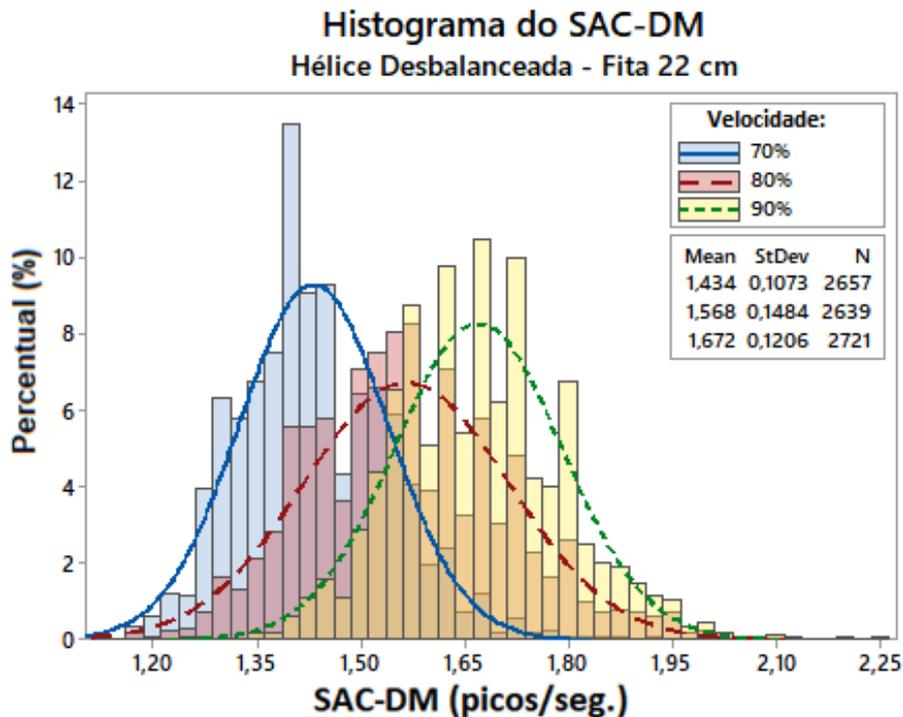
**Figura 5.13** Histograma do SAC-DM calculado a partir do sinal sonoro com hélice desbalanceada com Fita de 14 cm para velocidade de 70%, 80% e 90% - Sem wavelet. Fonte: O autor (2019)

**Tabela 5.9** Análise estatística dos resultados do SAC-DM para motores BLDC com hélice desbalanceada (Fita 22 cm) - Sem *wavelet*

VELOCIDADE do ESC	$\mu$	$\sigma^2$	$\sigma_X$
70%	1,43	$1,15 * 10^{-2}$	0,11
80%	1,57	$2,20 * 10^{-2}$	0,15
90%	1,67	$1,45 * 10^{-2}$	0,12



**Figura 5.14** Gráfico da amostra do sinal sonoro com hélice desbalanceada com fita de 22 cm para velocidade de 70%, 80% e 90% - Sem *wavelet*. Fonte: O autor (2019)



**Figura 5.15** Histograma do SAC-DM calculado a partir do sinal sonoro com hélice desbalanceada com Fita de 22 cm para velocidade de 70%, 80% e 90% - Sem *wavelet*. Fonte: O autor (2019)

- Conclusão:

Embora tenha sido possível encontrar as funções de linearidade que representam os gráficos desta seção, percebe-se que a possibilidade da detecção da velocidade do motor não é clara, já que as áreas dos histogramas entre as três velocidades estão muito próximas, aumentando os valores calculados das áreas de interseção, ou seja, diminuindo a acurácia dos casos estudados, como será mostrado no tópico 5.22. Estas áreas comuns nos histogramas são importantes porque, como já foi discutido anteriormente, as interseções representam a porcentagem de imprecisão dos resultados analisados. E, excluindo-se essas áreas, tem-se a acurácia dos resultados alcançados.

No entanto, nos mesmos gráficos, observando-se as áreas dos histogramas para intervalos maiores entre as velocidades, 70 e 90% por exemplo, ocorrem áreas de interseção mais expressivas, visto serem menores. Assim, a seção seguinte (5.3.2.2) apresenta os resultados das análises relativas às velocidades de 50, 70 e 90%, cujas acurácias denotam melhores percentuais.

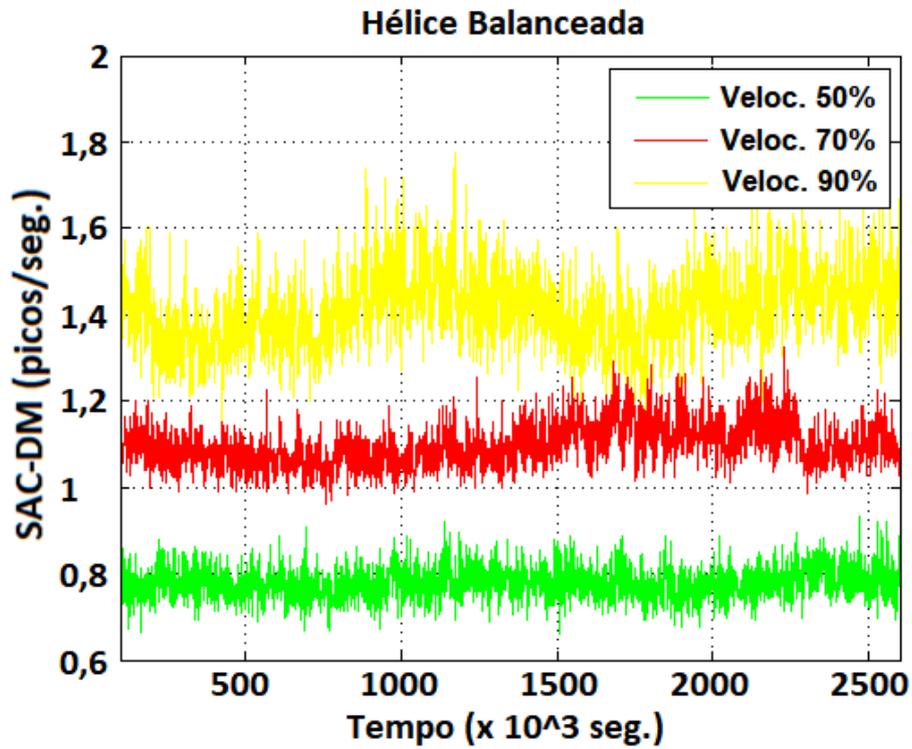
### 5.3.2.2 Velocidades de 50, 70, 90%

- Detecção da velocidade com Hélice Balanceada:

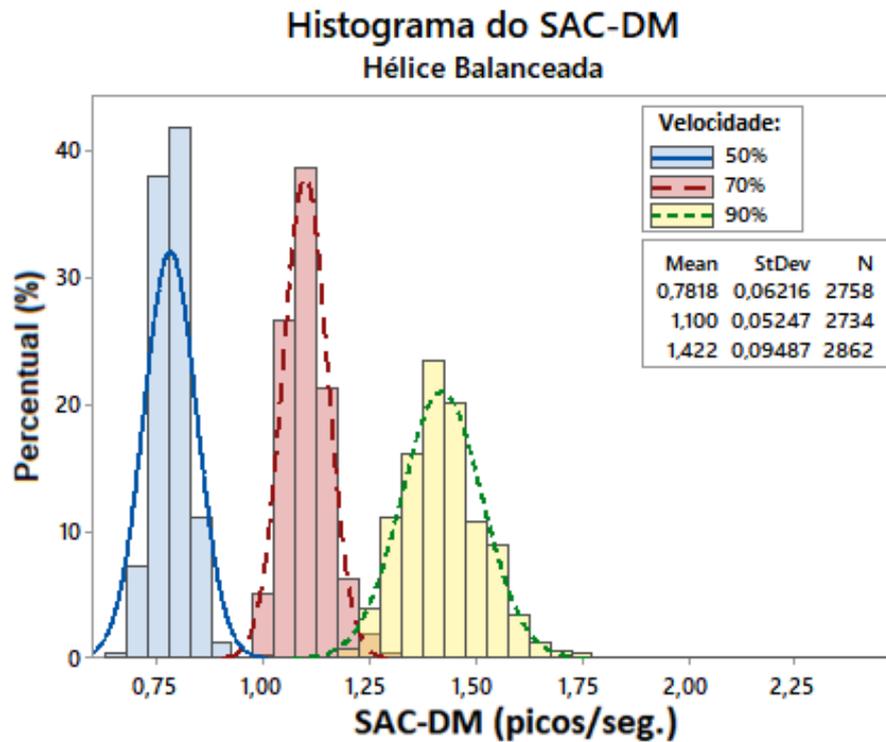
A Figura 5.16 apresenta comparações entre as faixas do SAC-DM encontradas quando o motor é submetido às velocidades de 50, 70 e 90%, para hélice balanceada. Neste caso, a de-

teção da velocidade é claramente percebida, já que as faixas do SAC-DM para cada velocidade estão bem distintas.

Este fato pode ser comprovado observando os histogramas apresentados na Figura 5.17, nos quais são apresentadas as distribuições dos valores do SAC-DM para as mesmas velocidades.



**Figura 5.16** Gráfico da amostra do sinal sonoro com hélice balanceada para velocidade de 50%, 70% e 90%. Fonte: O autor (2019)



**Figura 5.17** Histograma do SAC-DM calculado a partir do sinal sonoro com hélice balanceada para velocidade de 50%, 70% e 90%. Fonte: O autor (2019)

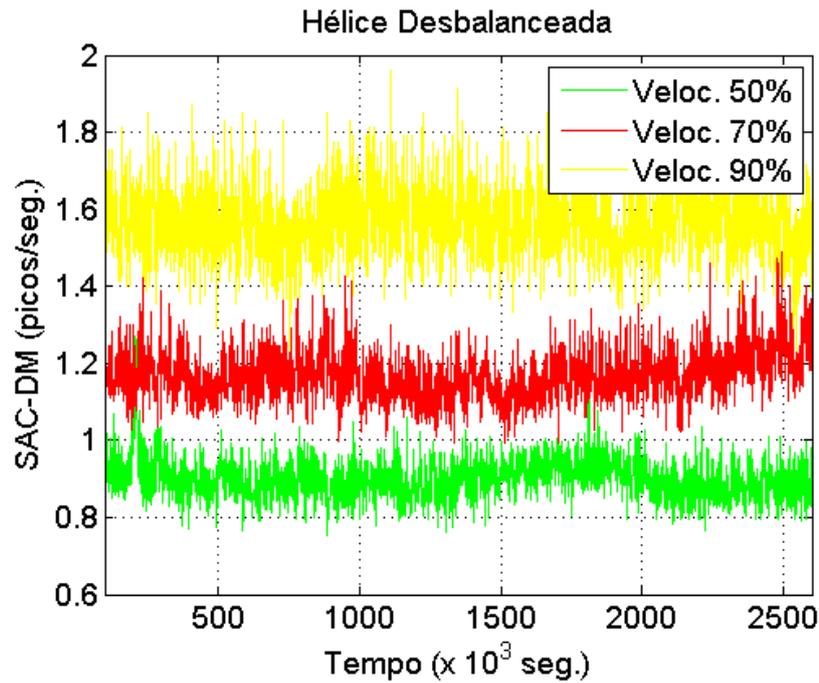
A Tabela 5.10 apresenta a acurácia na detecção da velocidade do motor entre as velocidades de 50 e 70%, bem como a acurácia entre as velocidades de 70 e 90%, baseada nos histogramas da Figura 5.17.

**Tabela 5.10** Acurácia relativa à detecção da velocidade usando o SAC-DM sem *wavelet* - Hélice balanceada

VELOCIDADES DO ESC	ACURÁCIA
ENTRE 50% e 70%	99,62%
ENTRE 70% e 90%	98,79%
MÉDIA	99,21%

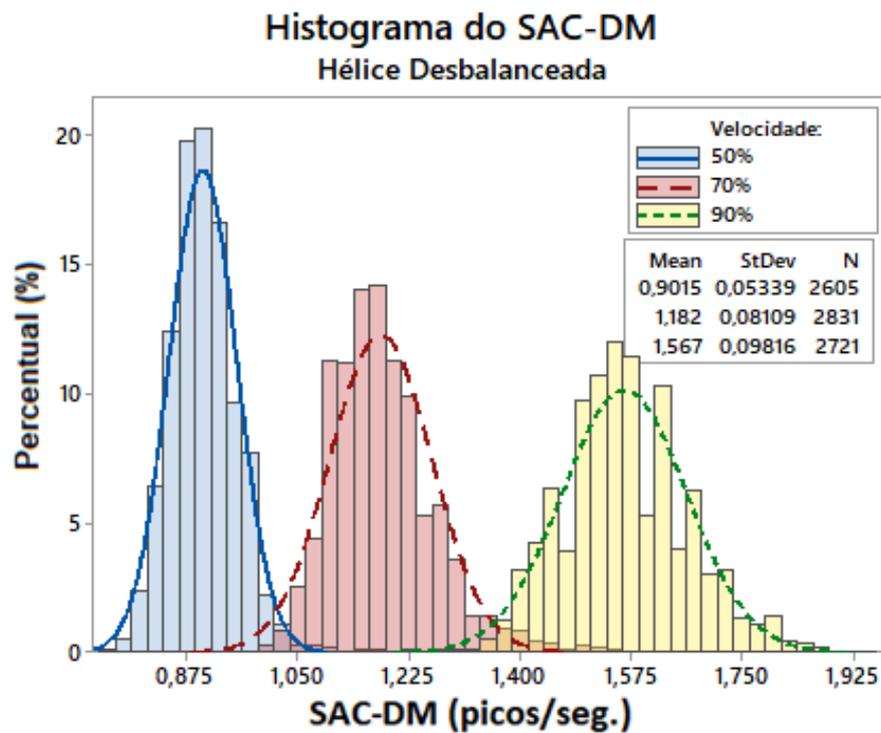
- Detecção da velocidade com Hélice Desbalanceada (Fita 6 cm):

Nos testes em que a hélice estava desbalanceada, as faixas do SAC-DM encontradas às velocidades de 50, 70 e 90%, conforme a Figura 5.18, apresentaram um comportamento semelhante ao caso da hélice balanceada (Figura 5.16). E, no caso corrente, a distinção entre as faixas também proporciona a detecção da velocidade.



**Figura 5.18** Histograma do SAC-DM calculado a partir do sinal sonoro com hélice desbalanceada para velocidade de 50%, 70% e 90%. Fonte: O autor (2019)

A Figura 5.19 e a Tabela 5.11 trazem, respectivamente, os histogramas do SAC-DM para as velocidades de 50, 70 e 90%, e a acurácia na detecção das mesmas velocidades, porém analisadas aos pares, a saber: a) 50 e 70% e b) 70 e 90%.



**Figura 5.19** Histograma do SAC-DM calculado a partir do sinal sonoro com hélice desbalanceada para velocidade de 50%, 70% e 90%. Fonte: O autor (2019)

**Tabela 5.11** Acurácia relativa à detecção da velocidade usando o SAC-DM sem *wavelet* - Hélice desbalanceada

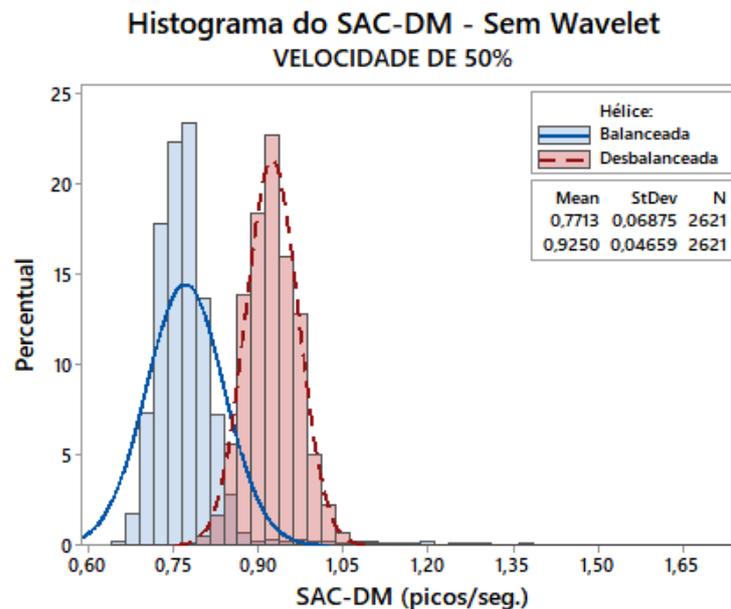
VELOCIDADES DO ESC	ACURÁCIA
ENTRE 50% e 70%	97,33%
ENTRE 70% e 90%	97,78%
MÉDIA	97,55%

Os testes realizados, e seus resultados, com as velocidades de 50, 70 e 90%, tanto com hélice balanceada, como com hélice desbalanceada, tornaram possível a detecção da velocidade em que o referido motor está atuando.

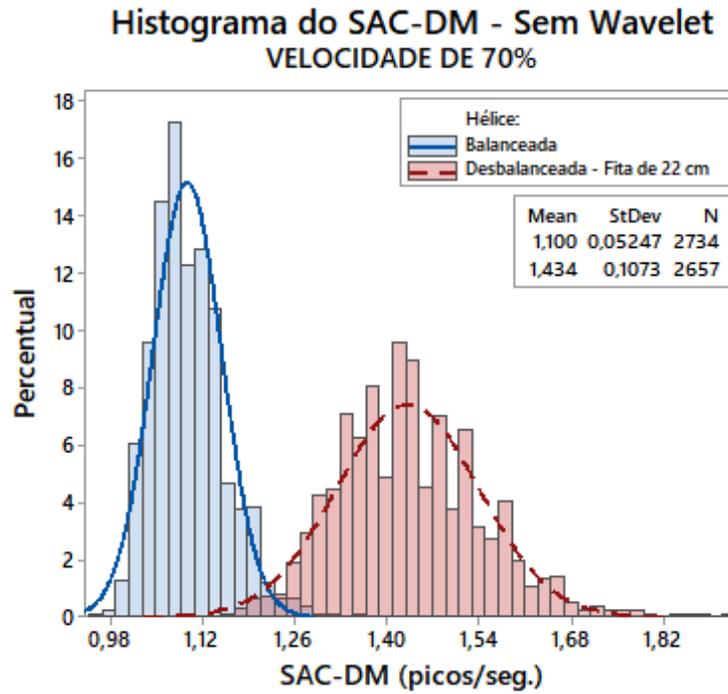
- Detecção de falhas - Hélice Balanceada x Desbalanceada:

As Figuras 5.20, 5.21 e 5.22 apresentam, respectivamente, a distribuição de valores do SAC-DM para o motor às velocidades de 50%, 70% e 90%, quando são comparadas as condições da hélice balanceada e desbalanceada, porém analisadas sob o aspecto da detecção de falhas de excentricidade.

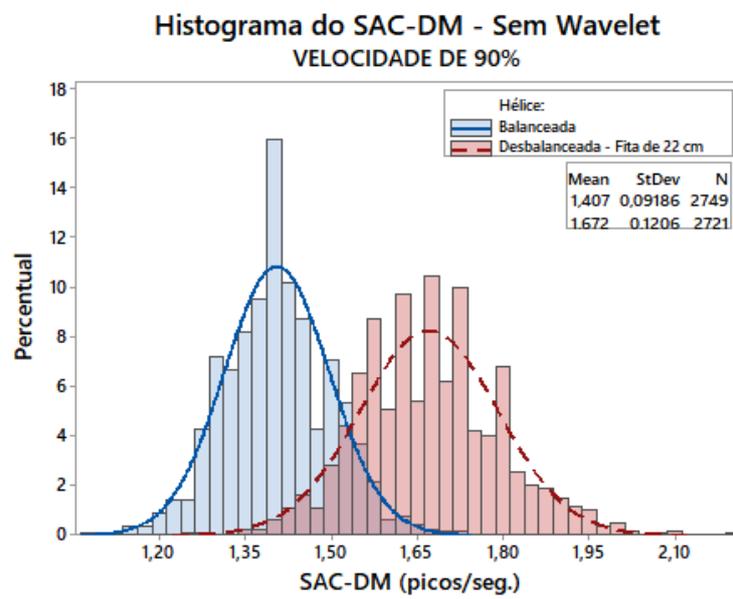
As áreas de interseção entre os histogramas abordam os casos onde a detecção de desbalanceamento não seria precisa. As áreas restantes resultam em uma acurácia na detecção do desbalanceamento cujos percentuais são apresentados na Tabela 5.12, de acordo com a velocidade do motor.



**Figura 5.20** Histograma do SAC-DM calculado a partir do sinal sonoro com hélice balanceada e desbalanceada para velocidade de 50%, sem *wavelet*. Fonte: O autor (2019)



**Figura 5.21** Histograma do SAC-DM calculado a partir do sinal sonoro com hélice balanceada e desbalanceada para velocidade de 70%, sem *wavelet*. Fonte: O autor (2019)



**Figura 5.22** Histograma do SAC-DM calculado a partir do sinal sonoro com hélice balanceada e desbalanceada para velocidade de 90%, sem *wavelet*. Fonte: O autor (2019)

**Tabela 5.12** Acurácia relativa à detecção de falha usando o SAC-DM sem *wavelet* nas velocidades de 50%, 70% e 90%

VELOCIDADES DO ESC	ACURÁCIA
50%	82,82%
70%	97,38%
90%	87,80%
MÉDIA	89,33%

- Conclusão:

Pela acurácia apresentada nas Tabelas 5.10 e 5.11, é possível observar que as análises dos dados, para os casos da hélice balanceada e desbalanceada, indicam que a técnica aplicada encontra excelentes resultados na detecção da velocidade em que o motor está atuando.

Ao realizar a análise dos dados fixando-se uma velocidade, conforme é apresentado nos histogramas das Figuras 5.20, 5.21 e 5.22, bons resultados são alcançados na detecção do desbalanceamento (falha), conforme a acurácia apresentada na Tabela 5.12.

### 5.3.3 Análise Comparativa: Com *wavelet* x Sem *wavelet*

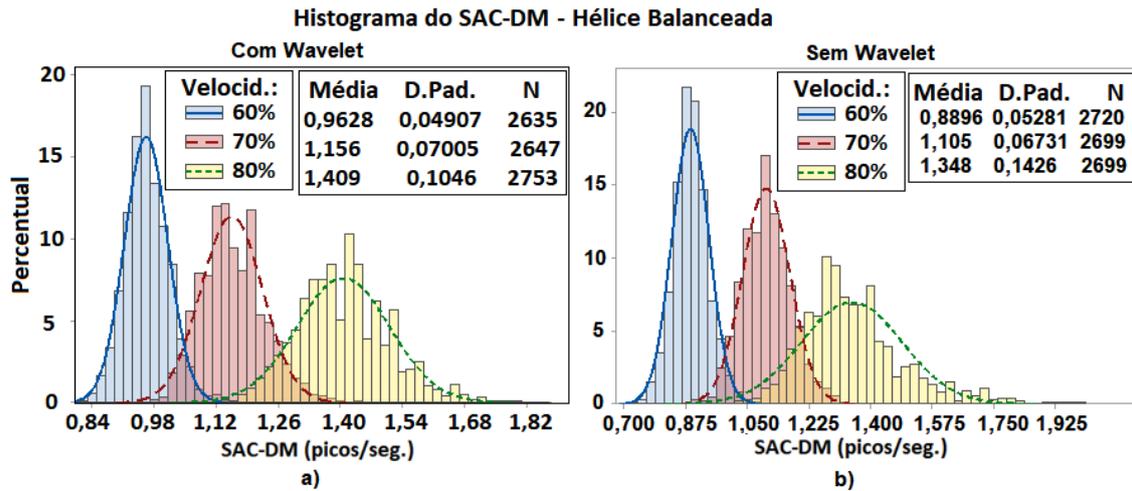
Esta subseção apresenta uma análise entre os resultados alcançados ao aplicar-se a Transformada de *wavelet* (conforme descrito em 5.3.1), comparando-se à análise quando esta Transformada não é aplicada. Neste comparativo, dois conjuntos de velocidades são estudadas: no primeiro são observadas as velocidades de 60, 70 e 80% e, no segundo, as velocidades de 70, 80 e 90%.

#### 5.3.3.1 Velocidades de 60, 70 e 80%

Aqui, são analisados dois casos: quando a hélice está balanceada e quando a hélice está desbalanceada com uma fita de 6 cm. E, em todos os casos, é analisada a detecção de velocidade.

- Detecção de velocidade:

A Figura 5.23 apresenta os histogramas entre os dois casos aqui comparados, com hélice balanceada. A Tabela 5.13 traz a acurácia dos respectivos resultados.



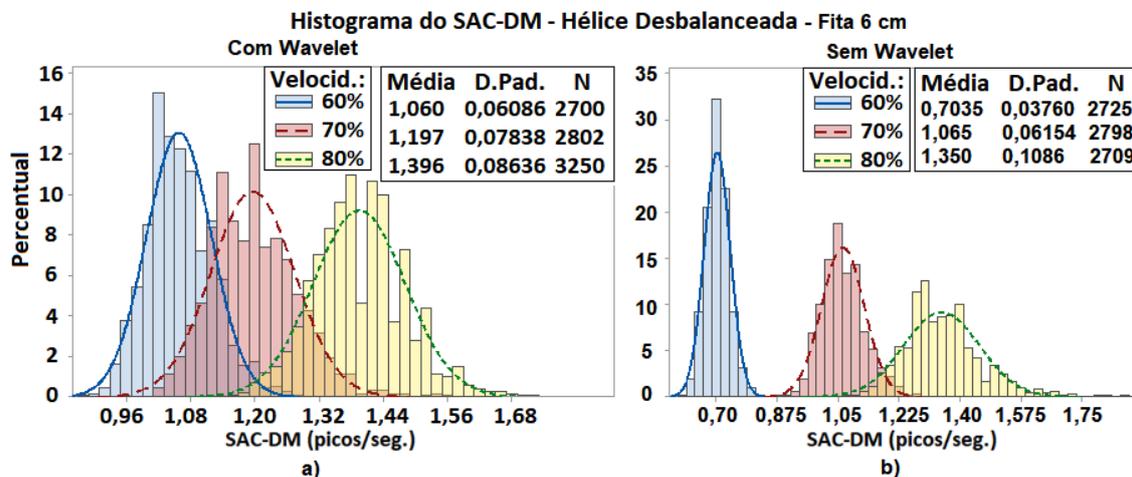
**Figura 5.23** Histogramas comparativos entre: a) Aplicando a Transformada *wavelet*; e b) Sem a aplicação da Transformada. Velocidades de 60, 70 e 80%, com hélice balanceada. Fonte: O autor (2019)

**Tabela 5.13** Acurácia relativa à detecção de velocidade usando o SAC-DM - Velocidades de 60, 70 e 80%, com hélice balanceada

Velocidade do ESC	Com <i>wavelet</i>	Sem <i>wavelet</i>
Entre 60% e 70%	97,12%	94,96%
Entre 70% e 80%	94,66%	83,90%
<b>MÉDIA (%)</b>	<b>95,89%</b>	<b>89,43%</b>

Os percentuais apresentados na Tabela 5.13, demonstram que é possível, com o SAC-DM, determinar a velocidade do motor. Neste caso, com uma acurácia de 95,89%, para hélice balanceada e utilizando a Transformada de *wavelet*. E, sem a aplicação da Transformada, é possível determinar a velocidade com 89,43% de acurácia.

Em outro comparativo, Figura 5.24, são apresentados os histogramas comparativos para os casos em que a hélice está desbalanceada, cuja acurácia dos respectivos resultados está na Tabela 5.14.



**Figura 5.24** Histogramas comparativos entre: a) Aplicando a Transformada *wavelet*; e b) Sem a aplicação da Transformada. Velocidades de 60, 70 e 80%, com hélice balanceada. Fonte: O autor (2019)

**Tabela 5.14** Acurácia relativa à detecção de velocidade usando o SAC-DM - Velocidades de 60, 70 e 80%, com hélice desbalanceada

VELOCIDADE do ESC	Com wavelet	Sem wavelet
Entre 60% e 70%	89,81%	99,85%
Entre 70% e 80%	86,81%	92,51%
MÉDIA (%)	<b>88,34%</b>	<b>96,18%</b>

Para os casos em que a hélice estiver desbalanceada e utilizando a Transformada de *wavelet*, significa que com o SAC-DM é possível determinar a velocidade do motor com 88,34% de precisão, E, sem a aplicação da Transformada, pode ser determinada com 96,18% de precisão.

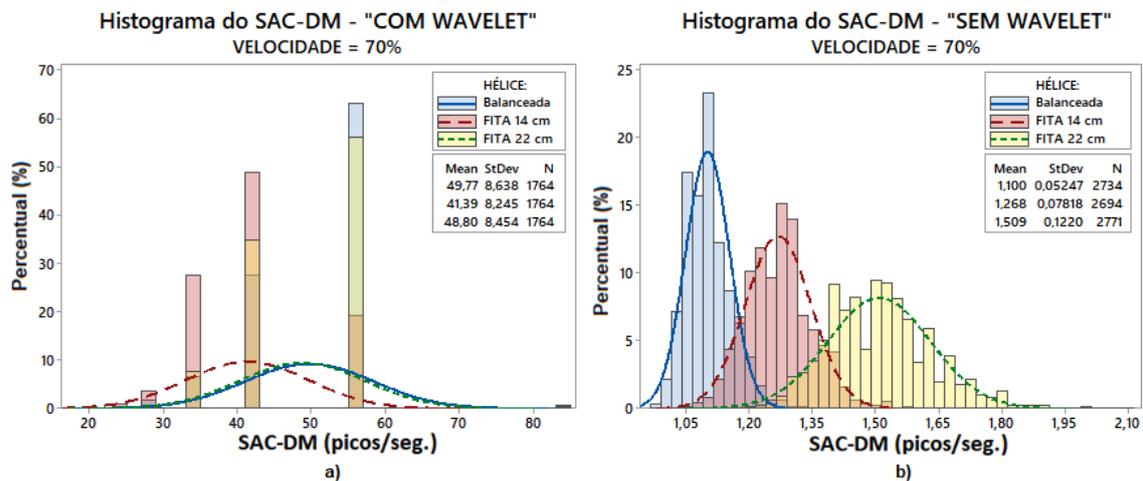
Analisando os dois casos (hélice balanceada e desbalanceada), identifica-se que a detecção da velocidade, usando-se a Transformada de *wavelet* e em condições de hélice balanceada, tem uma melhor precisão para velocidades mais baixas. E, ao contrário, à medida que se aumenta a velocidade, a precisão melhora quando a Transformada não é aplicada e em condições de hélice desbalanceada.

**5.3.3.2 Velocidades de 70, 80 e 90%**

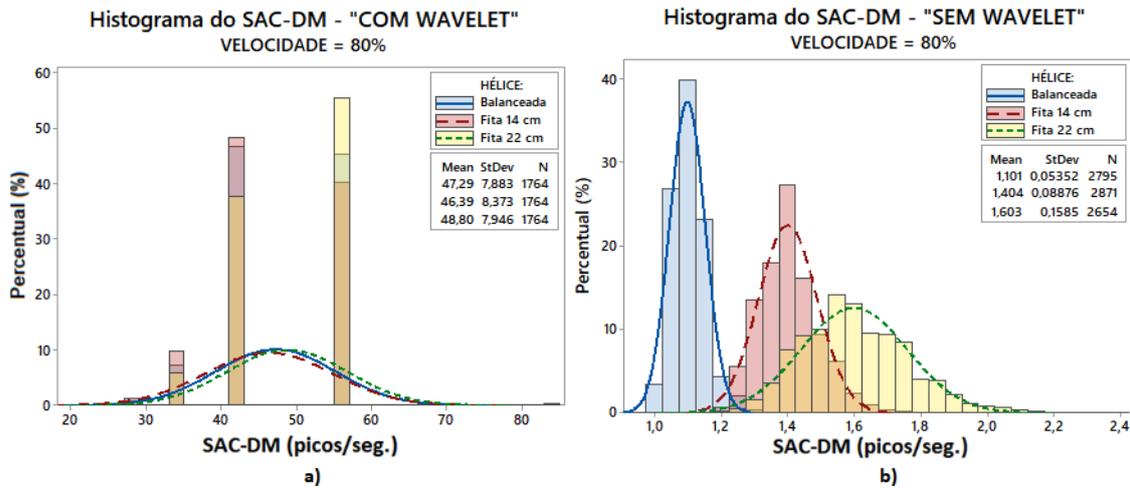
Aqui, são analisados três casos. Em cada um, é fixada uma das velocidades: 70%, 80% ou 90%. Os aspectos analisados são a detecção de falha de excentricidade no motor e seus níveis de falha, quando a hélice está: balanceada, desbalanceada com uma fita de 14 cm e desbalanceada com uma fita de 22 cm.

- Detecção de falhas e severidade da falha:

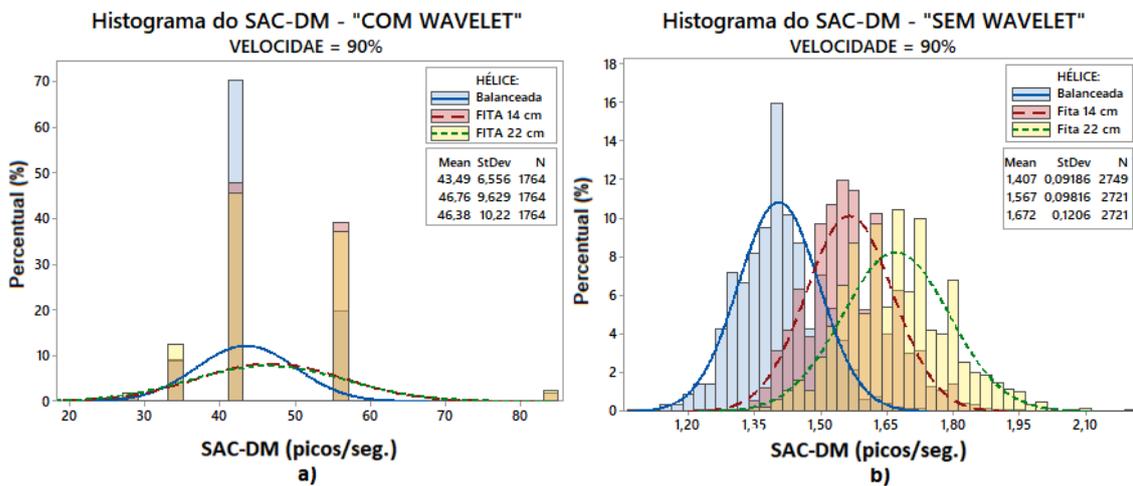
As Figuras 5.25, 5.26 e 5.27 apresentam, respectivamente, os histogramas com as distribuições dos valores do SAC-DM. Em cada figura são observadas as condições da hélice (Balanceada, Desbalanceada com Fita de 14 cm e Desbalanceada com Fita de 22 cm), uma velocidade fixa (70, 80 ou 90%) e, comparativamente, o uso ou não da Transformada de *wavelet*.



**Figura 5.25** Histogramas comparativos entre 3 condições da hélice: a) Aplicando a Transformada de *wavelet*; e b) Sem a aplicação da Transformada. Velocidade fixa de 70%. Fonte: O autor (2019)



**Figura 5.26** Histogramas comparativos entre 3 condições da hélice: a) Aplicando a Transformada de *wavelet*; e b) Sem a aplicação da Transformada. Velocidade fixa de 80%. Fonte: O autor (2019)



**Figura 5.27** Histogramas comparativos entre 3 condições da hélice: a) Aplicando a Transformada de *wavelet*; e b) Sem a aplicação da Transformada. Velocidade fixa de 90%. Fonte: O autor (2019)

• Conclusão:

As comparações realizadas ao se fixar uma velocidade, demonstram que a detecção de falha é bem melhor visualizada quando a Transformada de *wavelet* não é aplicada. E, da mesma forma, a detecção da severidade (ou nível) de falha, diferenciada pelo tamanho da fita desbalanceadora da hélice (14 ou 22 cm), torna-se possível à medida que se reduz a velocidade do motor.

Nas Tabelas 5.15, 5.16 e 5.17, não foi possível realizar a análise da coluna "Com *wavelet*", já que os valores do SAC-DM, ao se aplicar esse filtro em velocidades fixas, são muito semelhantes - conforme demonstra a parte a) das Figuras 5.25, 5.26 e 5.27. Por esta razão, torna-se inviável o cálculo percentual da acurácia. Este fato pode ser justificado pela distribuição gráfica dos níveis de decomposição do sinal sonoro, quando a Transformada de *wavelet* é aplicada, conforme Figura 5.28. Nesta figura são mostrados o quão são semelhantes os valores

do SAC-DM, analisando-se as velocidades de 60% e 70%, com hélice balanceada e desbalanceada com fita de 6 cm. Neste caso, a própria decomposição promove essa equiparação dos valores calculados pelo algoritmo.

**Tabela 5.15** Acurácia relativa à detecção de falhas e dos níveis de falhas usando o SAC-DM, à velocidade de 70%.

CONDIÇÕES DA HÉLICE	Com <i>wavelet</i>	Sem <i>wavelet</i>
Entre Balanceada e Desb. com Fita 14 cm	Não foi possível	84,48%
Entre Desb. com Fita 14 cm e com Fita 22 cm	Não foi possível	82,58%
Entre Balanceada e Desb. com Fita 22 cm	Não foi possível	98,88%
MÉDIA	Não foi possível	<b>88,65%</b>

**Tabela 5.16** Acurácia relativa à detecção de falhas e dos níveis de falhas usando o SAC-DM, à velocidade de 80%.

CONDIÇÕES DA HÉLICE	Com <i>wavelet</i>	Sem <i>wavelet</i>
Entre Balanceada e Desb. com Fita 14 cm	Não foi possível	98,04%
Entre Desb. com Fita 14 cm e com Fita 22 cm	Não foi possível	63,13%
Entre Balanceada e Desb. com Fita 22 cm	Não foi possível	99,14%
MÉDIA	Não foi possível	<b>86,77%</b>

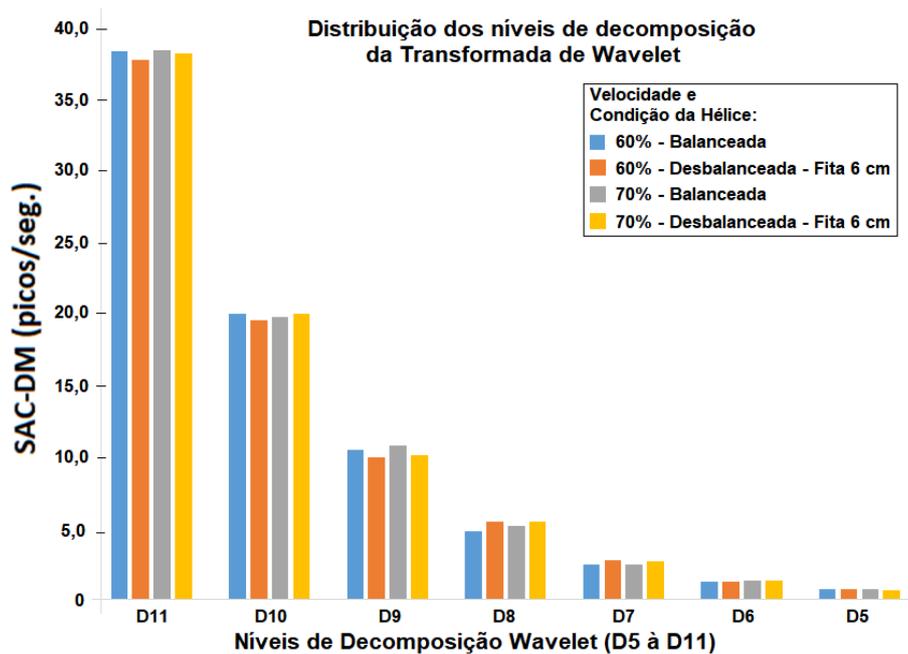
**Tabela 5.17** Acurácia relativa à detecção de falhas e dos níveis de falhas usando o SAC-DM, à velocidade de 90%.

CONDIÇÕES DA HÉLICE	Com <i>wavelet</i>	Sem <i>wavelet</i>
Entre Balanceada e Desb. com Fita 14 cm	Não foi possível	60,33%
Entre Desb. com Fita 14 cm e com Fita 22 cm	Não foi possível	38,57%
Entre Balanceada e Desb. com Fita 22 cm	Não foi possível	82,18%
MÉDIA	Não foi possível	<b>60,36%</b>

No entanto, sem a aplicação da Transformada de *wavelet*, é possível detectar falhas de excentricidade e seus respectivos níveis de falhas com acurácias médias de 88,65%, 86,77% e 60,36%, conforme Tabela 5.18, para as velocidades de 70%, 80% e 90%, respectivamente. Portanto, a detecção de falhas é possível, porém com melhor precisão em baixas velocidades do motor. E, da mesma forma, a detecção de níveis de falhas mostra-se aplicável, porém mais eficaz em velocidades até 80%.

**Tabela 5.18** Média da acurácia relativa à detecção de falha usando o SAC-DM - Comparativo entre velocidades (Com *wavelet*. x Sem *wavelet*).

VELOCIDADE	Com <i>wavelet</i>	Sem <i>wavelet</i>
70%	Não foi possível	88,65%
80%	Não foi possível	86,77%
90%	Não foi possível	60,36%



**Figura 5.28** Distribuição gráfica dos níveis de decomposição do sinal sonoro, após a aplicação da Transformada de *wavelet* para as velocidades de 60% e 70%. Fonte: O autor (2019)

### 5.3.4 Análise Comparativa: Vibração Mecânica x Sinal Sonoro

Nesta subseção são apresentadas as análises e resultados comparativos realizados entre os sinais sonoros e a respectiva vibração mecânica do motor BLDC usado na bancada. A análise dos dados, sob o viés da vibração mecânica, foi feita a partir dos dados coletados com o acelerômetro instalado na bancada de testes, conforme ilustração e descrição na Seção 3.2. Essas coletas foram feitas concomitantes às coletas dos sinais sonoros, portanto de acordo com a velocidade aplicada ao motor.

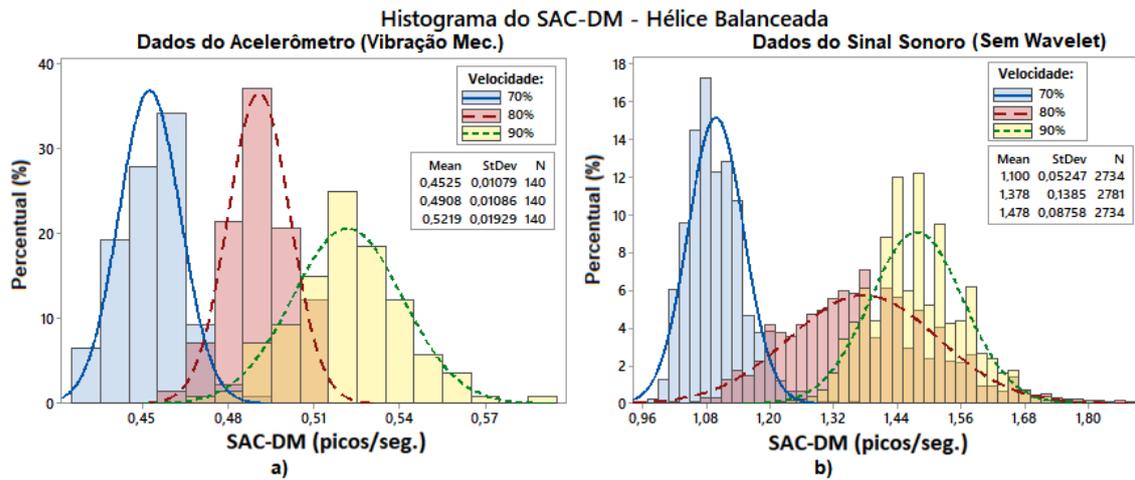
Embora o estudo dos dados coletados com o acelerômetro (vibração mecânica) seja um projeto de pesquisa paralelo ao que está sendo apresentado aqui, uma parceria foi efetivada entre o GPICEEMA e o LASER, objetivando a análise conjunta dos sinais (sonoros e de vibração mecânica) emitidos pelo motor BLDC em questão, para que, ao final das análises, fossem realizados comparativos entre os resultados alcançados.

O LASER é o laboratório responsável pela pesquisa de pós-graduação que envolve a coleta e análise dos dados relativos à vibração mecânica do motor BLDC utilizado na bancada.

- Detecção de velocidade:

Nesta subseção são analisados os resultados alcançados na detecção da velocidade do motor, comparando-se aos respectivos resultados do acelerômetro. No tópico 5.3.3.1 - Tabela 5.14, foi apresentado que a detecção da velocidade, quando a hélice está desbalanceada, atingiu uma acurácia mais expressiva quando não é aplicada a Transformada de *wavelet*. Por esta razão, os dados do acelerômetro são comparados aos sonoros e, estes, não foram submetidos à *wavelet*.

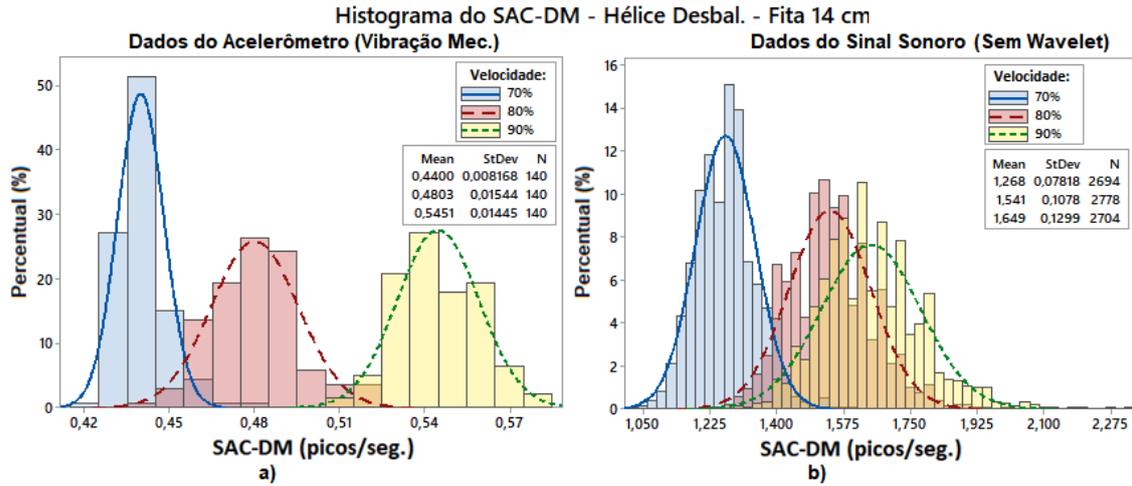
As Figuras 5.29, 5.30 e 5.31 apresentam, respectivamente, os histogramas comparativos entre os valores do SAC-DM. Em cada figura são observados os dados do acelerômetro (vibração mecânica) e do sinal sonoro (sem *wavelet*), às velocidades de 70, 80 e 90%, fixando-se uma condição da hélice (Bal., Desb. fita 14 cm ou Desb. fita 22 cm) para cada figura. Respectivamente, as Tabelas 5.19, 5.20 e 5.21 apresentam a acurácia relativa à detecção da velocidade em cada dessas figuras.



**Figura 5.29** Histogramas comparativos entre: a) Dados do acelerômetro (Vibração Mecânica); e b) Dados do sinal sonoro, sem *wavelet*. Velocidades de 70, 80 e 90%, com hélice balanceada. Fonte: O autor (2019)

**Tabela 5.19** Acurácia relativa à detecção de velocidade usando o SAC-DM - Velocidades de 70, 80 e 90%, com hélice balanceada

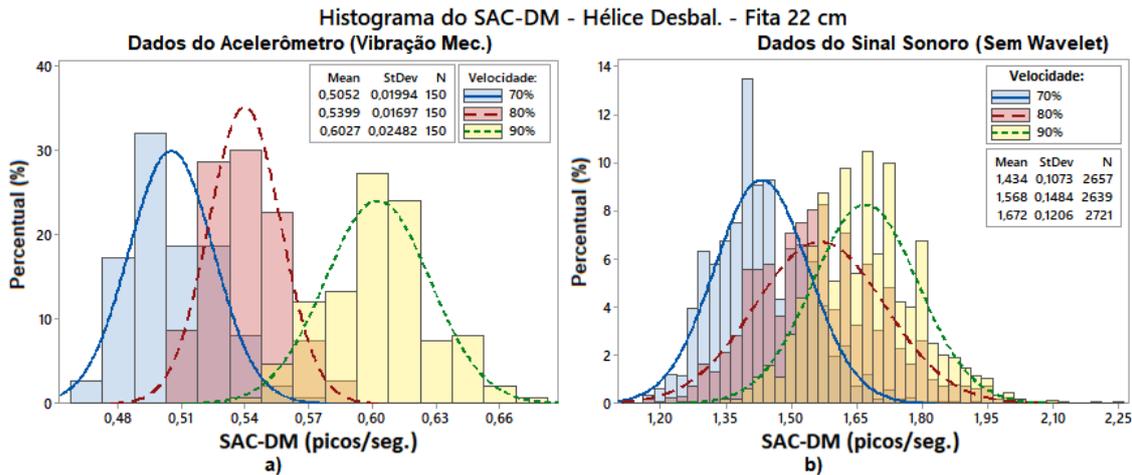
VELOCIDADE do ESC	Vibração Mec.	Sinal Sonoro
Entre 70% e 80%	92,83%	91,75%
Entre 80% e 90%	77,90%	54,42%
Entre 70% e 90%	98,98%	99,63%
<b>MÉDIA (%)</b>	<b>89,90%</b>	<b>81,93%</b>



**Figura 5.30** Histogramas comparativos entre: a) Dados do acelerômetro (Vibração Mec.); e b) Dados do sinal sonoro, sem *wavelet*. Velocidades de 70, 80 e 90%, com hélice desbalancec. com fita de 14 cm. Fonte: O autor (2019)

**Tabela 5.20** Acurácia relativa à detecção de velocidade usando o SAC-DM - Velocidades de 70, 80 e 90%, com hélice desbalanceada - Fita 14 cm.

VELOCIDADE do ESC	Vibração Mec.	Sinal Sonoro
Entre 70% e 80%	94,55%	87,82%
Entre 80% e 90%	98,15%	44,74%
Entre 70% e 90%	100,0%	95,49%
MÉDIA (%)	97,56%	76,02%



**Figura 5.31** Histogramas comparativos entre: a) Dados do acelerômetro (Vibração Mec.); e b) Dados do sinal sonoro, sem *wavelet*. Velocidades de 70, 80 e 90%, com hélice desbalancec. com fita de 22 cm. Fonte: O autor (2019)

**Tabela 5.21** Acurácia relativa à detecção de velocidade usando o SAC-DM - Velocidades de 70, 80 e 90%, com hélice desbalanceada - Fita 22 cm.

VELOCIDADE do ESC	Vibração Mec.	Sinal Sonoro
Entre 70% e 80%	67,34%	46,98%
Entre 80% e 90%	90,38%	37,74%
Entre 70% e 90%	97,99%	73,88%
MÉDIA (%)	85,24%	52,86%

Em aspectos gerais, observa-se que a análise do sinal sonoro apresenta uma melhor precisão na detecção da velocidade quando a hélice está balanceada, atingindo 99,63% de acurácia, conforme mostra a Tabela 5.19. Porém, à medida que o desbalanceamento aumenta, a precisão na detecção da velocidade diminui, nos casos em que se analisa o sinal sonoro. E, observando a Tabela 5.22, a análise da vibração mecânica, independente da condição da hélice, apresenta melhores resultados, com índices percentuais de acurácia melhores.

**Tabela 5.22** Média da acurácia relativa à detecção de velocidade usando o SAC-DM - Comparativo entre condições da hélice.

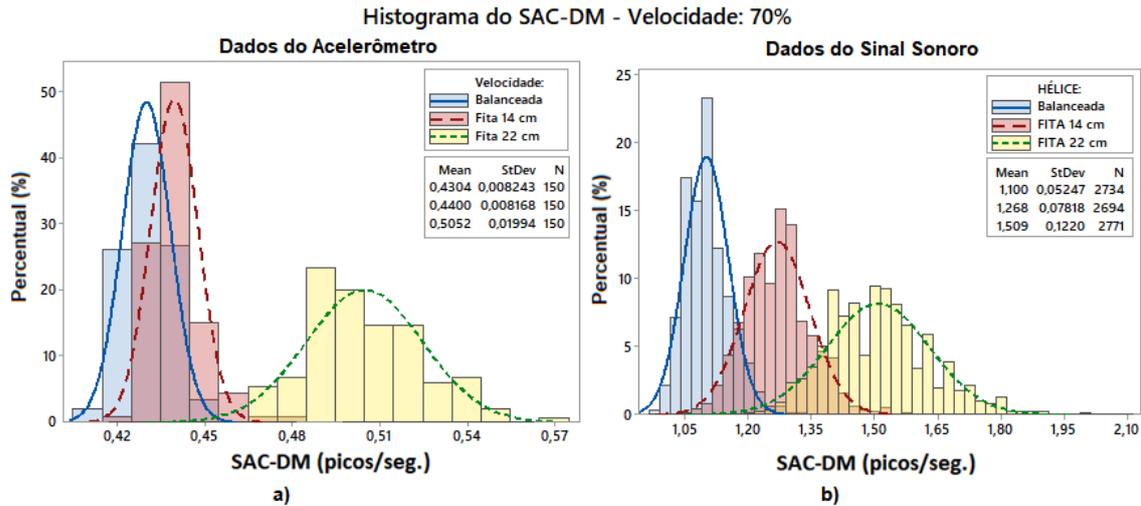
CONDIÇÃO DA HÉLICE	Vibração Mec.	Sinal Sonoro
Balanceada	89,90%	81,93%
Desbalanceada - Fita 14 cm	97,56%	76,02%
Desbalanceada - Fita 22 cm	85,24%	52,86%

No entanto, nos casos em que são analisados os histogramas dos dados do sinal sonoro, cuja velocidade está entre 70 e 90%, com hélice balanceada, desbalanceada com fita de 14 cm e desbalanceada com fita de 22 cm, tem-se, respectivamente, 99,63%, 95,49% e 73,88% de acurácia. Nestes casos, é possível detectar a velocidade com uma precisão média percentual de 89,66%, independente da condição da hélice.

- Detecção de falhas e severidade da falha - Hélice Balanceada x Desbalanceada:

Nesta subseção são analisados os resultados alcançados na detecção de falhas e na detecção da severidade da falha, comparando-se aos respectivos resultados do acelerômetro (vibração mecânica). No tópico 5.3.3.2, foi apresentado que a acurácia mais expressiva é encontrada quando a Transformada de *wavelet* não é aplicada. Por esta razão, os dados do acelerômetro são comparados aos sonoros e, estes, não foram submetidos à *wavelet*.

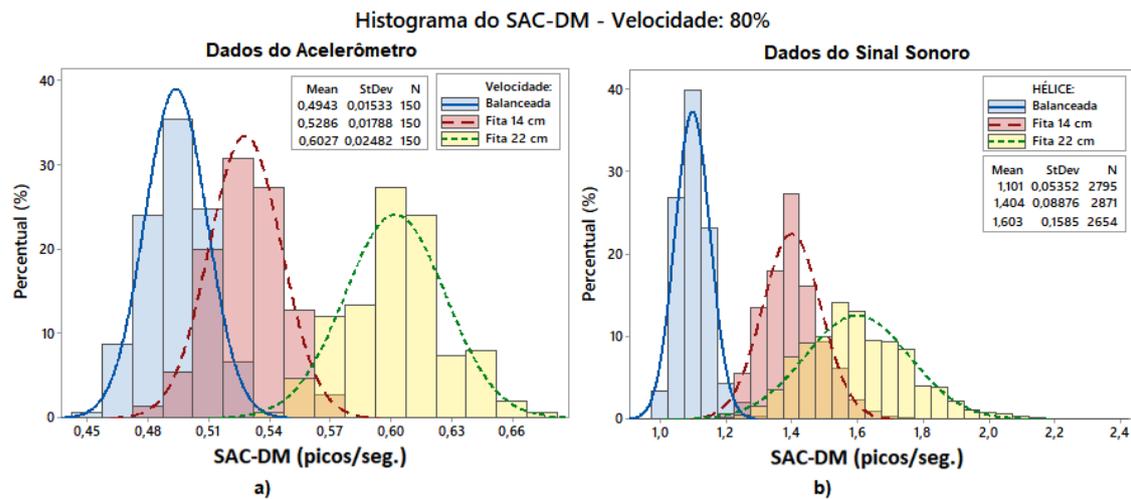
As Figuras 5.32, 5.33 e 5.34 apresentam, respectivamente, os histogramas comparativos entre os valores do SAC-DM. Em cada figura são observados os dados do acelerômetro (vibração mecânica) e do sinal sonoro (sem *wavelet*), submetidos às condições da hélice balanceada, desbalanceada com fita 14 cm e desbalanceada com fita 22 cm, fixando-se uma velocidade (70, 80 ou 90%) para cada figura. Respectivamente, as Tabelas 5.23, 5.24 e 5.25 apresentam a acurácia relativa à detecção de falhas e da severidade da falha usando o SAC-DM em cada uma dessas figuras.



**Figura 5.32** Histogramas comparativos entre: a) Dados do acelerômetro (Vibração Mec.); e b) Dados do sinal sonoro, sem *wavelet*. Velocidade de 70%, com hélice balanceada, desbalanc. com fita de 14 cm e desbalanc. com fita de 22 cm. Fonte: O autor (2019)

**Tabela 5.23** Acurácia relativa à detecção de falhas e da severidade da falha usando o SAC-DM, à velocidade de 70%, comparando-se vibração e sinal sonoro.

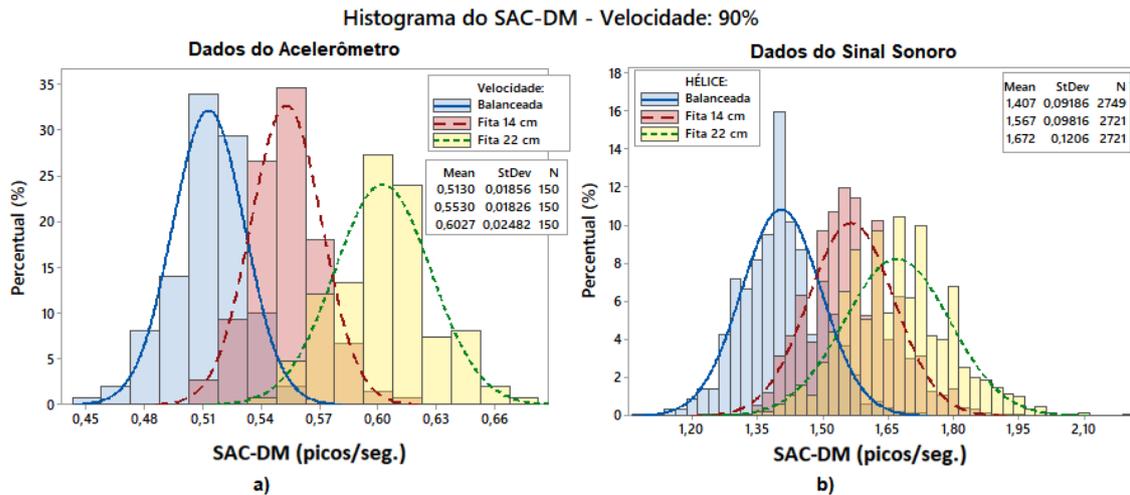
CONDIÇÕES DA HÉLICE	Vibraç. Mec.	Sinal Sonoro
Entre Balanceada e Desb. com Fita 14 cm	40,16%	84,48%
Entre Desb. com Fita 14 cm e com Fita 22 cm	98,98%	82,58%
Entre Balanceada e Desb. com Fita 22 cm	99,60%	98,88%
<b>MÉDIA</b>	<b>79,58%</b>	<b>88,65%</b>



**Figura 5.33** Histogramas comparativos entre: a) Dados do acelerômetro (Vibração Mec.); e b) Dados do sinal sonoro, sem *wavelet*. Velocidade de 80%, com hélice balanceada, desbalanc. com fita de 14 cm e desbalanc. com fita de 22 cm. Fonte: O autor (2019)

**Tabela 5.24** Acurácia relativa à detecção de falhas e da severidade da falha usando o SAC-DM, à velocidade de 80%, comparando-se vibração e sinal sonoro.

CONDIÇÕES DA HÉLICE	Vibraç. Mec.	Sinal Sonoro
Entre Balanceada e Desb. com Fita 14 cm	71,54	98,04%
Entre Desb. com Fita 14 cm e com Fita 22 cm	94,17	63,13%
Entre Balanceada e Desb. com Fita 22 cm	99,68	99,14%
<b>MÉDIA</b>	<b>88,46</b>	<b>86,77%</b>



**Figura 5.34** Histogramas comparativos entre: a) Dados do acelerômetro (Vibração Mec.); e b) Dados do sinal sonoro, sem *wavelet*. Velocidade de 90%, com hélice balanceada, desbalanc. com fita de 14 cm e desbalanc. com fita de 22 cm. Fonte: O autor (2019)

**Tabela 5.25** Acurácia relativa à detecção de falhas e da severidade da falha usando o SAC-DM, à velocidade de 90%, comparando-se vibração e sinal sonoro.

CONDIÇÕES DA HÉLICE	Vibraç. Mec.	Sinal Sonoro
Entre Balanceada e Desb. com Fita 14 cm	75,65%	60,33%
Entre Desb. com Fita 14 cm e com Fita 22 cm	79,54%	38,57%
Entre Balanceada e Desb. com Fita 22 cm	97,64%	82,18%
<b>MÉDIA</b>	<b>84,28%</b>	<b>60,36%</b>

Em aspectos gerais, os dados do sinal sonoro, analisados sob o aspecto da detecção de falhas de excentricidade e da severidade da falha, apresentaram melhor precisão em relação aos dados do acelerômetro quando foram analisadas as velocidades mais baixas e em falhas de menor severidade.

Embora se reconheça que a natureza dos sinais analisados nesta seção sejam diferentes, a maioria das médias percentuais presentes nas Tabelas 5.26 e 5.27 apresentaram, respectivamente, resultados acima de 80% de acurácia, tanto no caso da detecção de falhas, como na detecção da severidade da falha. Ambas as tabelas são o resumo dos resultados descritos nas Tabelas B.1, B.2 e B.3 - Anexo B.

**Tabela 5.26** Média da acurácia relativa à detecção de falha de excentricidade usando o SAC-DM - Comparativo entre velocidades (Vibração Mec. x Sinal Sonoro)

<b>VELOCIDADE</b>	<b>Vibração Mec.</b>	<b>Sinal Sonoro</b>
<b>70%</b>	79,58%	88,65%
<b>80%</b>	88,46%	86,77%
<b>90%</b>	84,28%	60,36%

**Tabela 5.27** Média da acurácia relativa à detecção da severidade da falha usando o SAC-DM - Comparativo entre condições da hélice nas velocidades de 70, 80 e 90% (Vibração Mec. x Sinal Sonoro)

<b>COND. HÉLICE</b>	<b>Vibração Mec.</b>	<b>Sinal Sonoro</b>
<b>Entre Hél. Bal. e Desb. 14 cm</b>	62,45%	80,95%
<b>Entre Hél. Desb. 14 e Desb. 22 cm</b>	90,89%	62,06%
<b>Entre Hél. Bal. e Desb. 22 cm</b>	98,97%	93,40%

## CAPÍTULO 6

# CONSIDERAÇÕES FINAIS

### 6.1 Conclusões

A similaridade dos resultados encontrada entre os valores do CLC e do SAC-DM nos cenários aqui experimentados, prova que o sistema tem um comportamento caótico. Neste caso, atendendo a primeira hipótese elencada no início deste trabalho (Seção 1.2). Embora usando uma série temporal única e curta para calcular o coeficiente de correlação, esta técnica utiliza a média da densidade dos máximos das amostras para estimar as propriedades de um sistema.

As análises dos dados utilizando a densidade de máximos (SAC-DM), validadas pelos resultados obtidos nos experimentos, permitem afirmar que é possível estimar a velocidade na qual o motor está operando. Além disso, com o SAC-DM, também é possível a detecção do desbalanceamento da hélice no motor, operando em uma velocidade fixa e conhecida. Com estas afirmações, atende-se à segunda e terceira hipóteses deste trabalho, respectivamente.

Os experimentos em que a Transformada de *wavelet* foi aplicada, demonstram que é possível, nos melhores casos analisados, detectar a velocidade do motor com precisão de 95,89% quando a hélice está balanceada, e 88,34% quando a hélice está desbalanceada. Pela análise dos resultados encontrados quando o motor está à 50% de velocidade, pode-se afirmar que é possível detectar falhas de excentricidade, com precisão de 92,87%.

Nos testes em que a Transformada de *wavelet* não foi aplicada, a precisão na detecção da velocidade é de 99,21% quando a hélice está balanceada, e 97,55% quando a hélice está desbalanceada. Além disso, quando a velocidade em que o motor atua está em 80%, é possível realizar a detecção da falha de excentricidade, com uma precisão de 99,14%. Pela análise dos resultados alcançados, com ou sem a aplicação da Transformada de *wavelet*, atende-se à segunda e terceira hipóteses deste trabalho.

Sob o aspecto da severidade da falha, quando a velocidade em que o motor atua está em 70%, é possível realizar a detecção com uma precisão de 82,58%, sem o uso da Transformada de *wavelet*. Com este caso, é atendida a quarta hipótese elaborada no início deste trabalho.

Com a técnica aqui aplicada, é possível determinar a velocidade de atuação do motor BLDC, restringindo a análise pela faixa do SAC-DM esperada, tanto nos casos em que a hélice estava balanceada, como também com hélice desbalanceada. Com o método, também é possível realizar a detecção de falha de excentricidade, porém esse aspecto tem uma melhor eficiência quando não é aplicado o filtro *wavelet*.

Evidenciamos, também, que é possível, detectar a velocidade do motor, com melhores resultados sem a aplicação da Transformada de *wavelet*. Porém, foi observado que esses resultados foram bem mais expressivos quando o intervalo entre as velocidades é de 20%. Neste caso, analisando as velocidades de 50, 70 e 90%.

Os experimentos também mostraram que é possível a detecção da severidade (ou nível) da falha, mas os resultados foram expressivos apenas nos casos em que foi aplicada a Transformada *wavelet*. No entanto, a acurácia relativa para estes casos, teve representação quantitativa menor, se observadas as demais análises aqui realizadas.

Pelos comparativos realizados entre os resultados da vibração mecânica e o sinal sonoro, é possível a detecção da velocidade em ambas os casos, porém a acurácia obteve melhores resultados nos dados do acelerômetro.

No aspecto da detecção da falha de excentricidade, a técnica foi mais eficiente com sinal sonoro, se analisada uma velocidade mais baixa. No entanto, sobre o aspecto da detecção da severidade da falha, a vibração mecânica foi o sinal que melhor apresentou resultados, demonstrando que é possível aplicar a técnica para este tipo de análise. Porém, embora tenhamos encontrado resultados quantitativamente menores com sinal sonoro, pode-se dizer afirmar que é possível realizar tal detecção.

Independente de ter sido usada, ou não, a Transformada de *wavelet* nos experimentos realizados neste trabalho, o método é completamente não intrusivo, o que significa que apenas um microfone e um microcontrolador são necessários para implementar um dispositivo para detectar a velocidade. Uma alternativa prática para o diagnóstico de problemas de desequilíbrio é fixar a velocidade do motor a uma velocidade conhecida e executar o SAC-DM.

## 6.2 Futuras Contribuições

Este trabalho foi desenvolvido seguindo os prazos estipulados pelo programa da pós-graduação - PPGEM, porém seguindo um planejamento necessário para o bom andamento das atividades e para que os resultados fossem alcançados.

A pesquisa realizada aqui trouxe uma proposta definida, como foi descrito e discutido nas sessões acima, porém outras propostas paralelas foram surgindo ao longo do trabalho, como a comparação entre os dados processados aplicando-se a Transformada de *wavelet* e os dados processados sem a aplicação dessa Transformada. Também podem ser citados os resultados alcançados com os sinais sonoros, comparando-se com os resultados alcançados com os dados coletados pelo acelerômetro, através de vibrações mecânicas.

A técnica aqui discutida tem diversas aplicações, quer seja na análise da corrente elétrica que circula em motores, ou nas pesquisas com vibrações mecânicas. No entanto, outras áreas podem ser beneficiadas com estudos e futuras aplicações. Como exemplo, a densidade de máximos pode ser utilizada para analisar o som que é emitido por colmeias de abelhas cultivadas por apicultores, já que o mesmo está diretamente ligado a variações do clima ou, até mesmo, a aspectos ligados à ausência da abelha rainha da colmeia.

# Referências Bibliográficas

- Albertazzi, A. e Sousa, A. R., 2008. *Fundamentos de Metrologia Científica e Industrial*. Ed.Manole.
- Artigao, E., Honrubia-Escribano, A. e Gomez-Lazaro, E., 2018. “Current signature analysis to monitor dfig wind turbine generators: A case study”. *Renewable Energy*, volume 116:pp. 5 – 14. Real-time monitoring, prognosis and resilient control for wind energy systems.
- Avila, G. e Luís, C. L. A., 2012. *Cálculo: ilustrado, prático e descomplicado*. 1ª Edição: LTC.
- Bazeia, D., Pereira, M. B. P. N., Brito, A. V., Oliveira, B. F. e Ramos, J. G. G. S., 2017. “A novel procedure for the identification of chaos in complex biological systems”. *Scientific Reports*, volume 7.
- Bisoi, A., Samantaray, A. K. e Bhattacharyya, R., 2017. “Control strategies for dc motors driving rotor dynamic systems through resonance”. *Journal of Sound and Vibration*, volume 411:pp. 304–327.
- Bouzid, M. B. K. e Champenois, G., 2013. “New expressions of symmetrical components of the induction motor under stator faults”. *IEEE Transactions on Industrial Electronics*, volume 60(9):pp. 4093–4102.
- Canepa, E., Cattanei, A. e Zecchin, F. M., 2015. “Installation effects on the tonal noise generated by axial flow fans”. *Journal of Sound and Vibration*, volume 340:pp. 167–189.
- Chen, H. e Lu, S., 2013. “Fault diagnosis digital method for power transistors in power converters of switched reluctance motors”. *IEEE Transactions on Industrial Electronics*, volume 60(2):pp. 749–763.
- Concari, C., Franceschini, G. e Toscani, A., 2013. “Vibrationless alignment algorithm for incremental encoder based bldc drives”. *Electric Power Systems Research*, volume 95:pp. 225–231.

- Cruz, A., Gomes, R., Belo, F. e Lima Filho, A., 2017. “A hybrid system based on fuzzy logic to failure diagnosis in induction motors”. *IEEE Latin America Transactions*, volume 15(8):pp. 1480 – 1489.
- Dalzin, F., Bot, A. L., P.Liaudet e Mazuyer, D., 2016. “Tribological origin of squeal noise in lubricated elastomer–glass contact”. *Journal of Sound and Vibration*, volume 372:pp. 211–222.
- de Almeida, A., Ferreira, F., Busch, J. e Angers, P., 2002. “Comparative analysis of iec 112-b and iec 34-2 efficiency testing standards using stray load losses in low-voltage three-phase, cage induction motors”. *Industry Applications, IEEE Transactions on*, volume 38(2):pp. 608–614.
- de la Vega, A. S., 2017. *Apostila de Teoria para Processamento Digital de Sinais*. UFF-TCE-TET.
- de Santiago, J., Bernhoff, H., Ekergård, B., Eriksson, S., Ferhatovic, S., Waters, R. e Leijon, M., 2012. “Electrical motor drivelines in commercial all-electric vehicles: A review”. *IEEE Transactions on Vehicular Technology*, volume 61(2):pp. 475–484.
- DECEA, 2015. *Guia prático das novas instruções do DECEA para utilização de VANTs em território brasileiro*. GeoEduc.
- Diniz, P., da Silva, E. e Netto, S., 2014. *Processamento Digital de Sinais: Projeto e Análise de Sistemas*. 2ª Edição: Bookman.
- Dwi, H., Alfaradin, F., Darojah, Z. e Raden, S., 2015. “Artificial neural network based identification system for abnormal vibration of motor rotating disc system”. *International Electronics Symposium (IES)*, volume 2015(15702779).
- Esfahani, E. T., Wang, S. e Sundararajan, V., 2014. “Multisensor wireless system for eccentricity and bearing fault detection in induction motors”. *IEEE/ASME Transactions on Mechatronics*, volume 19(3):pp. 818–826.
- Feng, Z., Liang, M. e Chu, F., 2013. “Recent advances in time–frequency analysis methods for machinery fault diagnosis: A review with application examples”. *Mechanical Systems and Signal Processing*, volume 38(1):pp. 165 – 205. Condition monitoring of machines in non-stationary operations.
- Fuggetti, G., Ghetti, A. e Zanzi, M., 2015. “Safety improvement of fixed wing mini-uav based on handy fdi current sensor and a fail-safe configuration of control surface actuators”. *IEEE Metrology for Aerospace (MetroAeroSpace)*.
- Gabriel, D. L., Meyer, J. e du Plessis, F., 2011. “Brushless dc motor characterisation and selection for a fixed wing uav”. In “AFRICON, 2011”, pp. 1–6.

- Gao, Z., Cecati, C. e Ding, S. X., 2015a. “A survey of fault diagnosis and fault-tolerant techniques - part i: Fault diagnosis with model-based and signal-based approaches”. *IEEE Transactions on Industrial Electronics*, volume 62(6):pp. 3757–3767.
- Gao, Z., Cecati, C. e Ding, S. X., 2015b. “A survey of fault diagnosis and fault-tolerant techniques - part ii: Fault diagnosis with knowledge-based and hybrid/active approaches”. *IEEE Transactions on Industrial Electronics*, volume 62(6):pp. 3768–3774.
- Georgoulas, G., Climente-Alarcon, V., Antonino-Daviu, J. A., Tsoumas, I. P., Stylios, C. D., Arkkio, A. e Nikolakopoulos, G., 2017. “The use of a multilabel classification framework for the detection of broken bars and mixed eccentricity faults based on the start-up transient”. *IEEE Transactions on Industrial Informatics*, volume 13(2):pp. 625–634.
- Gettinger, D. e Michel, A., 2015. “Drone sightings and close encounters: An analysis”. *Nova Iorque: Center for the Study of the Drone, Bard College, Annandale-on-Hudson*.
- Goh, J., 2018. “Service robots - a greenfield opportunity for electric motor manufacturers”. <https://technology.ihc.com/604849/service-robots-a-greenfield-opportunity-for-electric-motor-manufacturers>. Access date: 16 Ago. 2018.
- Gosak, M., Marhl, M. e Perc, M., 2008. “Chaos between stochasticity and periodicity in the prisoner’s dilemma game”. *International Journal of Bifurcation and Chaos*, volume 18(03):pp. 869–875.
- Hamming, R. W., 1950. “Error detecting and error correcting codes”. *Bell System Technical Journal*, volume 29:pp. 147–160.
- Han, X. e Palazzolo, A., 2016. “Unstable force analysis for induction motor eccentricity”. *Journal of Sound and Vibration*, volume 370:pp. 230–258.
- Hashemnia, N. e Asaei, B., 2008. “Comparative study of using different electric motors in the electric vehicles”. In “2008 18th International Conference on Electrical Machines”, pp. 1–5.
- Haykin, S. e Veen, B. V., 2001. *Sinais e Sistemas*. Bookman.
- He, W., Miao, M., Q and a Azarian e Pecht, M., 2015. “Health monitoring of cooling fan bearings based on wavelet filter”. *Mechanical Systems and Signal Processing*, volume 64-65:pp. 149–161.
- ISO-GUM, 2008. *Avaliação de dados de Medição - Guia para a expressão de incerteza de medição*. 1ª ed., JCGM.
- Kang, K., Song, J., Kang, C., Sung, S. e Jang, G., 2017. “Real-time detection of the dynamic eccentricity in permanent-magnet synchronous motors by monitoring speed and back

- emf induced in an additional winding”. *IEEE Transactions on Industrial Electronics*, volume 64(9):pp. 7191–7200.
- Károlyi, G., Neufeld, Z. e Scheuring, I., 2005. “Rock-scissors-paper game in a chaotic flow: The effect of dispersion on the cyclic competition of microorganisms”. *Journal of theoretical biology*, volume 236(1):pp. 12–20.
- Kim, K., Lee, S. e Hur, J., 2014. “Diagnosis technique using a detection coil in bldc motors with interturn faults”. *IEEE Journals and Magazines*, volume 50.
- Konar, P. e Chattopadhyay, P., 2015. “Multi-class fault diagnosis of induction motor using hilbert and wavelet transform”. *Applied Soft Computing*, volume 30:pp. 341 – 352.
- Kral, C., Habetler, T. G. e Harley, R. G., 2004. “Detection of mechanical imbalances of induction machines without spectral analysis of time-domain signals”. *IEEE Transactions on Industry Applications*, volume 40(4):pp. 1101–1106.
- Kumar, T. P., Saimurugan, M., Haran, R. B. H., Siddharth, S. e Ramachandran, K. I., 2019. “A multi-sensor information fusion for fault diagnosis of a gearbox utilizing discrete wavelet features”. *Measurement Science and Technology*, volume 30(8):p. 085101.
- Kuzma, J., O’Sullivan, S., Philippe, T., Koehler, J. e Coronel, R., 2017. “Commercialization strategy in managing online presence in the unmanned aerial vehicle industry”. *International Journal of Business Strategy*, volume 17(1):pp. 59–68.
- Lim, T., Zhang, D., Yang, J., Cheng, S., Low, S., Chua, L. e Wu, X., 2009. “Design and parameter estimation of hybrid magnetic bearings for blood pump applications”. *Mechanical Systems and Signal Processing*, volume 23:pp. 2352–2382.
- Lima, T. L. V., 2017. *Desenvolvimento de um Sistema Embarcado para Detecção de Falhas em Veículos Automotivos por meio de Análise Sonora*. Qualificação de doutorado, Universidade Federal da Paraíba - UFPB/PPGEM.
- Lu, S., Wang, X., Liu, F., He, Q., Liu, Y. e Zhao, J., 2016. “Fault diagnosis of motor bearing by analyzing a video clip”. *Mathematical Problems in Engineering*.
- Lu, S., Zhou, P., Wang, X., Liu, Y. e Liu, F., 2018. “Condition monitoring and fault diagnosis of motor bearings using undersampled vibration signals from a wireless sensor network”. *Journal of Sound and Vibration*, volume 414:pp. 81–96.
- Mallat, S., 2008. *A Wavelet Tour of Signal Processing*. Third Edition: The Sparse Way, Academic Press.
- Markets and Markets, 2017. “Brushless dc motors market”. Access date: 7 Abr. 2017.

- Matias, G., 2016. *Critérios de regulamentação-base aplicável à operação das aeronaves não tripuladas (Drones) em espaço aéreo nacional*. Dissertação de mestrado, ISEC - ETEA - Mestrado em Operações de Transporte Aéreo.
- Medeiros, R., Lima Filho, A., Ramos, J. G., Nascimento, T. e Brito, A. V., 2018. “A novel approach for speed and failure detection in brushless dc motors based on chaos”. *IEEE Transactions on Industrial Electronics*, pp. 1–1.
- Medeiros, R. L., G. S. Ramos, J. G., Nascimento, T. P., C. Lima Filho, A. e Brito, A. V., 2018. “A novel approach for brushless dc motors characterization in drones based on chaos”. *Drones*, volume 2(2).
- Mężyk, A., Czapla, T., Klein, W. e Mura, G., 2017. “Numerical simulation of active track tensioning system for autonomous hybrid vehicle”. *Mechanical Systems and Signal Processing*, volume 89:pp. 108–118.
- Mills, M. P., 2017. “Drone disruption: The stakes, the players, and the opportunities”. <https://www.forbes.com>. Access date: 20 Mar. 2017.
- Misgeld, B., M, K. e Leonhardt, S., 2017. “Multivariable friction compensation control for a variable stiffness actuator”. *Control Engineering Practice*, volume 58:pp. 298–306.
- Mitchell, M. e Hraber, P. T., 1993. “Revisiting the edge of chaos: Evolving cellular automata to perform computations”. *Complex Systems*, volume 7:pp. 89–130.
- Morbidi, F., Cano, R. e Lara, D., 2016. “Minimum-energy path generation for a quadrotor uav”. In “2016 IEEE International Conference on Robotics and Automation (ICRA)”, pp. 1492–1498.
- Nakano, A., Miotto, E. e Bresciani, G., 2015. “Estudo de parâmetros acústicos na análise de falhas em máquinas elétricas”. *Simpósio Brasileiro de Telecomunicações*.
- Ning, D. e Gong, Y., 2015. “Shocking fault component of abnormal sound signal in the fault engine extract method based on linear superposition method and cross-correlation analysis”. *Advances in Mechanical Engineering*, volume 7(8).
- Nowak, M. A. e May, R. M., 1992. “Evolutionary games and spatial chaos”. *Nature*, volume 359(6398):p. 826.
- Ouachtouk, I., Hani, S. E. e Dahi, K., 2017. “Wireless health monitoring system for rotor eccentricity faults detection in induction machine”. *Power engineering and electrical engineering*, volume 15.
- Parikh, D., Patel, J. e Barve, J., 2015. “Quad-copter uav bldc motor control: Linear v/s non-linear control maps”. *Nirma University Journal of Engineering and Technology*, volume 4(1).

- Park, B. G., Lee, K. J., Kim, R. Y., Kim, T. S., Ryu, J. S. e Hyun, D. S., 2011. “Simple fault diagnosis based on operating characteristic of brushless direct-current motor drives”. *IEEE Transactions on Industrial Electronics*, volume 58(5):pp. 1586–1593.
- Park, J. e Hur, J., 2016. “Detection of inter-turn and dynamic eccentricity faults using stator current frequency pattern in ipm-type bldc motors”. *IEEE Transactions on Industrial Electronics*, volume 63:pp. 1771–1780.
- Petruzella, F., 2013. *Motores Eléctricos e Acionamentos*. Bookman.
- Puliyakote, S. e Balasubramaniam, K., 2013. “A novel use of signal processing tools for fault detection in ic engines”. *International Ultrasonics Symposium (IUS)*, volume 2013(14062046).
- Rajagopalan, S., Aller, J., Restrepo, J., Habetler, T. e Harley, R., 2007a. “Analytic-wavelet-ridge-based detection of dynamic eccentricity in brushless direct current (bldc) motors functioning under dynamic operating conditions”. *IEEE Transactions on Industrial Electronics*, volume 54:pp. 1410–1419.
- Rajagopalan, S., Roux, W., Habetler, T. e Harley, R., 2007b. “Dynamic eccentricity and demagnetized rotor magnet detection in trapezoidal flux (brushless dc) motors operating under different load conditions”. *IEEE Transactions on Power Electronics*, volume 22:pp. 2061–2069.
- Ramos, J., Bazeia, D., Hussein, M. e Lewenkopf, C., 2011. “Conductance peaks in open quantum dots”. *Physical review letters*, volume 107(17):p. 176807.
- Rezig, A., Mekideche, M. R. e Djerdir, A., 2010. “Effect of rotor eccentricity faults on noise generation in permanent magnet synchronous motors”. *Progress In Electromagnetics Research*, volume C 15:pp. 117 – 132.
- Samara, P. A., Fouskitakis, G. N., Sakellariou, J. S. e Fassois, S. D., 2008. “A statistical method for the detection of sensor abrupt faults in aircraft control systems”. *IEEE Transactions on Control Systems Technology*, volume 16(4):pp. 789–798.
- Sapena-Bano, A., Chinesta, F., Pineda-Sanchez, M., Aguado, J., Borzacchiello, D. e Puche-Panadero, R., 2019. “Induction machine model with finite element accuracy for condition monitoring running in real time using hardware in the loop system”. *International Journal of Electrical Power Energy Systems*, volume 111:pp. 315 – 324.
- Sashidhar, S. e Fernandes, B., 2017. “A novel ferrite smds spoke-type bldc motor for pv borewell submersible water pumps”. *Browse Journal and Magazines*, volume 64(1):pp. 104–115.

- Schroth, L., 2019. “The drone market 2019-2024: 5 things you need to know”. <https://www.droneii.com/project/drone-market-size-and-forecast-2019-2024>. Access date: 26 Jun. 2019.
- Shaw, I., 2014. “The rise of the predator empire: Tracing the history of u.s. drones”. *Understanding Empire: Technology, Power, Politics*.
- Soualhi, A., Clerc, G. e Razik, H., 2013. “Detection and diagnosis of faults in induction motor using an improved artificial ant clustering technique”. *IEEE Transactions on Industrial Electronics*, volume 60(9):pp. 4053–4062.
- Stöcker, C., Bennett, R., Nex, F., Gerke, M. e Zevenbergen, J., 2017. “Review of the current state of uav regulations”. *Remote Sensing*, volume 9(5):p. 459.
- Straub, J. e Huber, J., 2013. “Validating a uav artificial intelligence control system using an autonomous test case generator”. *Proceedings of SPIE - The International Society for Optical Engineering*, volume 8713.
- Teixeira, B. E., 2016. *Utilização de veículo aéreo não tripulado de asa fixa no monitoramento e coleta de imagem de animais e ambientes em propriedades rurais*. Dissertação de mestrado, Faculdade de Zootecnia e Engenharia de Alimentos - Universidade de São Paulo.
- Tibor, B., Fedák, V. e Durovský, F., 2011. “Modeling and simulation of the bldc motor in matlab gui”. In “2011 IEEE International Symposium on Industrial Electronics”, pp. 1403–1407.
- Usman, A., Joshi, B. M. e Rajpurohit, B. S., 2016. “A review of modeling, analysis and control methods of brushless dc motors”. In “2016 International Conference on Computation of Power, Energy Information and Commuincation (ICCPEIC)”, pp. 337–343.
- Walter, P., Zhu, B. e Zhang, N., 2017. “Powertrain dynamics and control of a two speed dual clutch transmission for electric vehicles”. *Mechanical Systems and Signal Processing*, volume 85:pp. 1–15.
- Wang, H., Han, Q., Luo, R. e Qing, T., 2017. “Dynamic modeling of moment wheel assemblies with nonlinear rolling bearing supports”. *Journal of Sound and Vibration*, volume 406:pp. 124–145.
- Wang, X. e Shirinzadeh, B., 2014. “High-order nonlinear differentiator and application to aircraft control”. *Mechanical Systems and Signal Processing*, volume 46:pp. 227–252.
- Wei, W. W. S., 2006. *Time Series Analysis: univariate and multivariate methods*. Pearson.
- Wijayasekara, D., Linda, O., Manic, M. e Rieger, C., 2014. “Fn-dfe: Fuzzy-neural data fusion engine for enhanced resilient state-awareness of hybrid energy systems”. *IEEE Transactions on Cybernetics*, volume 44(11):pp. 2065–2075.

- Xia, C.-l., 2012. *Permanent magnet brushless DC motor drives and controls*. John Wiley Sons Singapore Pte. Ltd.
- Xiang, C., Wang, X., Ma, Y. e Xu, B., 2015. “Practical modeling and comprehensive system identification of a bldc motor”. *Hindawi Publishing Corporation*, volume 2015(879581).
- Yildirim, M., Polat, M. e Kürüm, H., 2014. “A survey on comparison of electric motor types and drives used for electric vehicles”. In “2014 16th International Power Electronics and Motion Control Conference and Exposition”, pp. 218–223.
- Zeraoulia, M., Benbouzid, M. E. H. e Diallo, D., 2006. “Electric motor drive selection issues for hev propulsion systems: A comparative study”. *IEEE Transactions on Vehicular Technology*, volume 55(6):pp. 1756–1764.
- Zhou, Y., Zhao, K. e Liu, D., 2016. “Chaotic dynamic analysis of brushless dc motor”. *Journal of Mathematics and Informatics*, volume 5:pp. 39–43.

## APÊNDICE A

# **Failure Detection of Brushless DC Motors from Sound Signals based on Chaos**

- *Artigo submetido à IOP Science - Measurement Science and Technology - Data da submissão: 01-07-2019*

# Abstract

In this work, the SAC-DM (Signal Analysis based on Chaos using Density of Maxima) technique is applied for the first time in the diagnosis of failures of electromechanical systems from sound signals. Wavelet Multiresolution Analysis (WMA) is used to separate a chaotic signal component from the sound emitted by the motor. This work demonstrates that it is feasible to perform dynamic eccentricity diagnosis in BLDC motors by identifying variations of the SAC-DM of the sound signal. The technique exposed in this work requires low computational cost and achieves high success rate. Tests were carried out to validate the method on a small BLDC motor typically used in Unmanned Aerial Vehicle (UAV), demonstrating the ability of the technique to detect the speed of the engine in 95.89% of the cases and to detect eccentricity problems at a fixed speed in 88.34% of the cases.

## A.1 Introduction

The Brushless Direct Current (BLDC) motors have been widely used in several applications in the productive sector. Unexpected failures in these motors can be catastrophic, causing financial and human losses, for example, when they occur in an industrial environment or Unmanned Aerial Vehicles (UAVs).

It is possible to classify fault identification methods in general by the sensor used or the signal processing technique. In the literature, it is possible to find works that aim to identify failures of dynamic eccentricity in several types of electric machines. The most common methods are those that perform acquisition of the electrical signals of the motor. From these, can be highlighted works, which processing are based on Fourier Transform (Artigao *et al.*, 2018), Finite Elements (Kang *et al.*, 2017; Sapena-Bano *et al.*, 2019), Wavelet (Rajagopalan *et al.*, 2007a) and hybrid processing methods such as: Finite Elements/Fourier (Park e Hur, 2016), Hilbert/Fourier (Kral *et al.*, 2004), Wavelet/Fourier (Georgoulas *et al.*, 2017).

Methods using vibration signals to diagnose BLDC failures are also found in the literature. In Konar e Chattopadhyay (2015) was use Wavelet/Hilbert based algorithm. In Ouachtouk *et al.* (2017), Fourier is used to process vibration signals and armature current also in an induction motor. In Rezig *et al.* (2010) was used vibration and sound signals with Fourier-based

processing. In Esfahani *et al.* (2014) the signals of sound, vibration, and armature current of an induction motor are processed through Fourier-based algorithm, Hilbert-Huang transform and classifiers were used.

In previous work, simulations were executed to demonstrate that the chaos present in the biodiversity of nature is associated with the chaotic evolution of the species and infer the correlation length from the density of maxima Bazeia *et al.* (2017). In Medeiros *et al.* (2018) it was demonstrated that the same behavior detected from the current signal of Brushless Direct Current (BLDC) motors using FFT could also be captured from the chaotic behavior of the signal and in Medeiros *et al.* (2018) a signal processing technique called SAC-DM (Signal Analysis based on Chaos using Density of Maxima) is presented. The work also demonstrated that SAC-DM could be applied to identify the speed at which the BLDC is operating and detecting the presence of unbalanced propeller analyzing the motor current signal.

In this work, the sound emitted by the motor is used for diagnosis. It is necessary to prove that the sound signal generated from the system (BLDC motor with propeller) has chaotic characteristics to evaluate whether SAC-DM is feasible for this type of application, or not. Also, there is a challenge inherent the audio signal to faults detection when compared to electrical signals. For this reason, in Medeiros *et al.* (2018), the SAC-DM technique is applied directly without the need for pre-processing. In this work, a chaotic component present in the signal of the sound emitted by the motor is extracted using a Wavelet approach. From the detail generated from Wavelet Multiresolution Analysis (WMA), it is demonstrated that it is possible to apply SAC-DM to identify dynamic BLDC eccentricity for different speed scenarios.

It was not found in the literature, techniques that allow the detection of dynamic eccentricity fault in electric machines motors using only the sound signal. This work contributes to the monitoring of mechanical systems by acoustic analysis, proving that the sound signal of the BLDC has a chaotic characteristic (making possible the use of the SAC-DM technique). Although wavelet-based algorithms have been applied efficiently in other sound approaches (Kumar *et al.*, 2019), it is the first time an algorithm based on WMA and SAC-DM is applied for dynamic eccentricity fault detection.

## A.2 Signal Analysis based on Chaos using Density of Maxima (SAC-DM)

Equation A.1 is applied to analyze samples from non-periodic signals, where  $\langle \rho_1 \rangle$  is theoretical and  $C$  is calculated by derivative second and forth, respectively, which are represented as  $C^{II}$  and  $C^{IV}$  of the Auto-correlation Function in zero, as defined in other previous works (Bazeia *et al.*, 2017; Medeiros *et al.*, 2018)

By the principle of maximum entropy, for periodic and homogeneous time series, it is possible to write the normalized correlation function from a cosine function, by reducing the

Equation A.1 to the Equation A.2, where  $\langle \tau \rangle$  is the Correlation Length and  $\langle \rho_2 \rangle$  is the Density of Maxima found experimentally.

$$\langle \rho_1 \rangle = \frac{1}{2\pi} \sqrt{-\frac{C^{IV}(0)}{C^{II}(0)}} = \frac{1}{2\pi} \sqrt{-\frac{\langle q''^2 \rangle}{\langle q'^2 \rangle}} \quad (\text{A.1})$$

$$\text{SAC\_DM} = \langle \tau \rangle = \frac{1}{6\langle \rho_2 \rangle} \quad (\text{A.2})$$

The chaotic behavior in stochastic systems is presented in the result found in Equation A.2. It is possible to estimate the characteristics of a system using this method through the analysis of a short time series and to estimate the correlation coefficient, based on the mean of the maximum acquired density from the sound signal. This peak-counting technique is denominated Signal Analysis based on Chaos using Density of Maxima (SAC-DM).

## A.3 Methodology

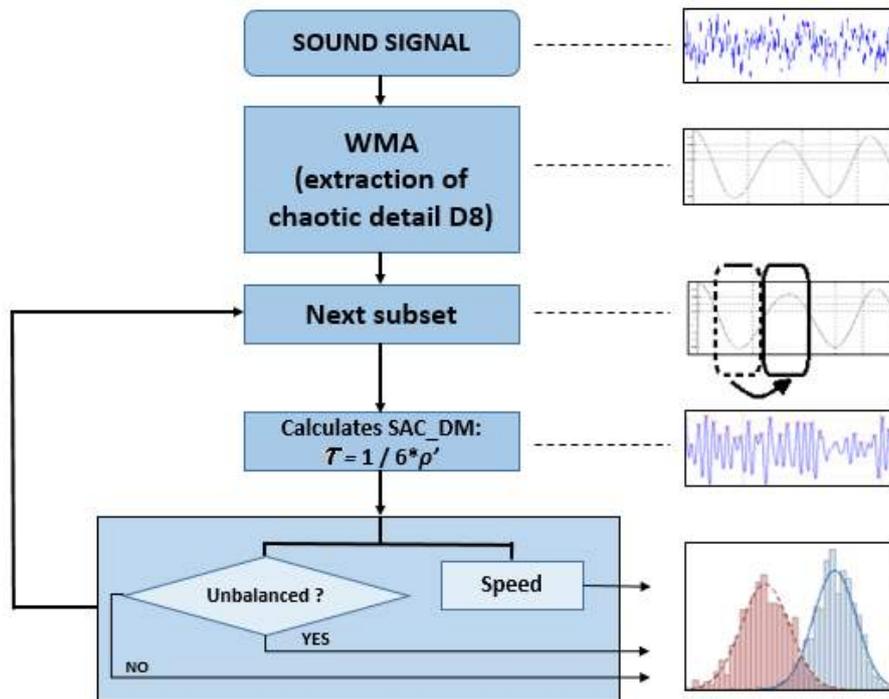
To have a more precise notion of the approach proposed in this work, Figure A.1 is presented. First, the sound signal from a small BDLC motor with a propeller is acquired using an Arduino Board. Then, the Wavelet Multiresolution Analysis (WMA) is performed to filter the signal and obtain the chaotic behavior from detail **D8** in the next steps. Then, the value of SAC-DM is calculated for each subset of the filtered signal using Equation A.2. Finally, the value of SAC-DM of each subset is analyzed to identify the speed of the motor, and if the propeller is unbalanced. Each step is described in the following sections.

### A.3.1 Sound Signal Acquisition

The testbench components are: a Brushless DC Motor 1400 Kv; an Accelerometer Adafruit XL345; a Node MCU ESP8266 12F micro-controller to set the speed sent to the ESC; an Electronic Speed Controller (ESC) of 30 A; and a 10.4 inch propeller. The power supply is Bi-volt with 115/230 VAc, 47-63 Hz, and 4-6 A.

Five experimental scenarios were executed, where three variables are combined: a) engine speed (60%, 65%, 70%, 75% and 80% of maximum power); b) propeller condition (regular or unbalanced); c) type of signal executed by the algorithm (raw or after the application of WDT). The regular propeller suggests perfect engine conditions. To generate the unbalanced state, a 6 cm by 2.80 cm adhesive tape, approximate weight of 0.22838 grams, is fixed at 10 cm from the center of the propeller.

The Arduino Due has a 32-bit ARM microcontroller: Atmel SAM3X8E ARM Cortex-M3. By the prior configuration of its registers and timers, the acquisition frequency was established in this work as 44.1 kHz. The CMA-4544PF-W is an omnidirectional electret condenser microphone with the sensitivity of 44 dB and operating frequency from 20 Hz to 20 kHz. Audio



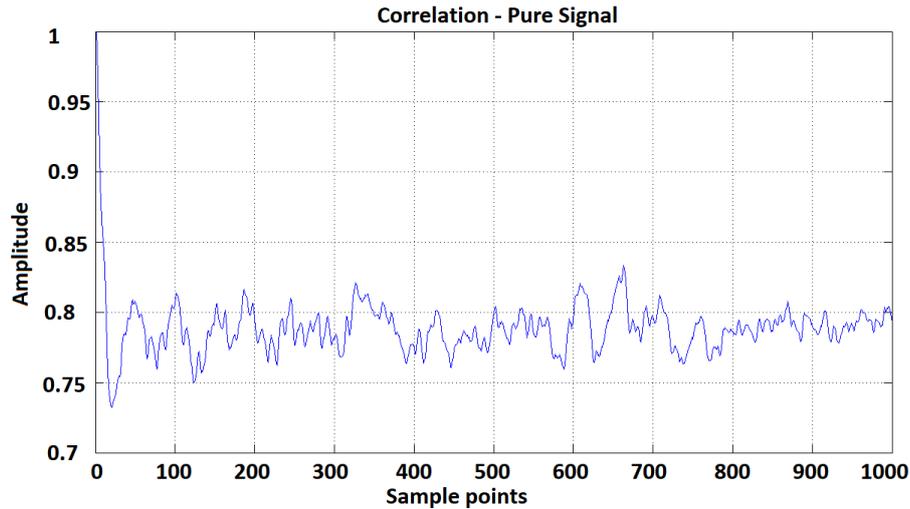
**Figure A.1** - Methodology for signal analysis using density of maxima

files are stored following the WAVE format, ensuring uncompressed audio storage in a memory card for later data analysis.

### A.3.2 Application of Wavelet Multiresolution Analysis (WMA)

The Figure A.2 represents the ACF generated from a sound signal with motor at 80% of nominal speed. This function might tend to converge and dampen. However, the noise present in the signal, or the impurities in the measurement circuit, do not allow this damping as expected.

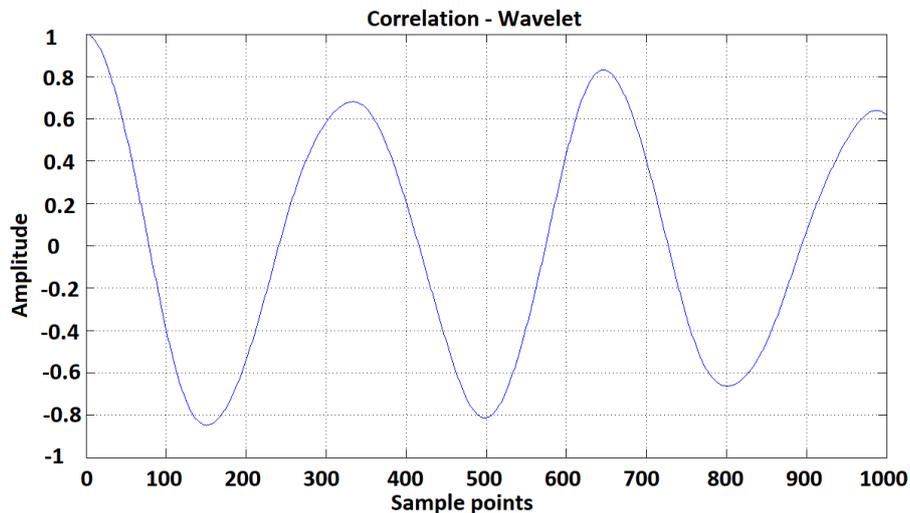
In this way, the WDT was applied to the sound signal. Consequently, the signal decomposition at various levels of detail ( $D_m[n]$ ) was performed, improving the conditions of analysis of the experiments and increasing the tendency of the function to converge and dampen.



**Figure A.2** - Auto-correlation Function for motor with balanced propeller at 80% speed

Among the levels of signal decomposition by wavelet, the one that presented better convergence and damping was the Detail **D8**. In this case, this level of decay reached the most significant and adequate results for the desired parameters of this work, minimizing the external noise present in the sound samples.

The auto-correlation function of Detail **D8** from a sound signal at speed of 80% is shown in Figure A.3. It is possible to observe that the application of the WDT resulted in the reduction of the noise, improving the convergence of the signal, with an amplitude greater than one in Figure A.2.



**Figure A.3** - Auto-correlation after Wavelet at 80% of speed - Balanced Propeller

### A.3.3 Calculating SAC-DM and system analysis

The SAC-DM is calculated for each subset of the filtered sound signal according to Equation A.2, where  $\rho$  is the number of peaks divided by the number of samples, i.e., the density of maxima. After calculation for each sub-set, it is checked whether the value of the SAC-DM

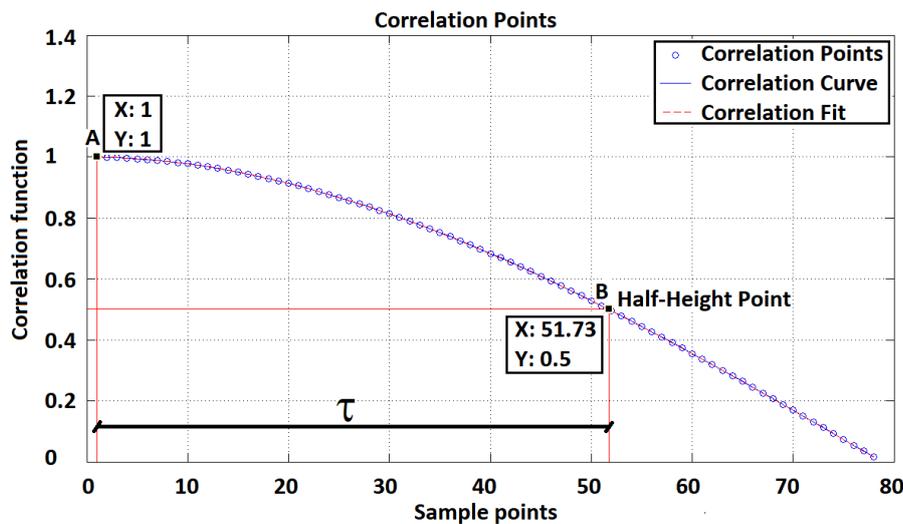
is within the normal range for a balanced motor. If it is not, it returns that it is unbalanced. From the amount of the SAC-DM, the estimated motor speed is also returned.

## A.4 Proving the chaotic behavior

Before presenting the experiments and results obtained with the application of the SAC-DM, this section presents tests that indicate the sound signal emitted by the BLDC motor has a chaotic behavior. It is chaotic if the Correlation Length Coefficient (CLC) obtained from the Auto-correlation Function (ACF) results in a value similar to the one received by applying the density of maxima in the Equation A.2.

In Figure A.4 is presented the CLC of the signal after the application of Wavelet, represented by  $\tau$ , which is the value at X when Y reaches the value of 0.5. In this example, the correlation length at half height obtained with a speed of 80% of the motor, and with the balanced propeller is 50.73 and expressed in Equation A.3.

$$\tau = X_B - X_A = 51.73 - 1 = 50.73 \quad (\text{A.3})$$

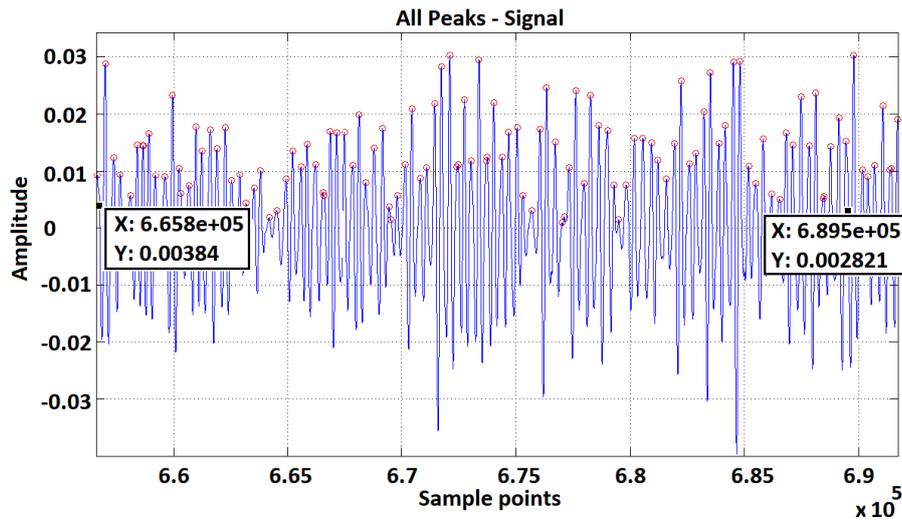


**Figura A.4** Correlation Coefficient at Half Height after Wavelet with speed of 80% - Balanced Propeller

Figure A.5 presents a zoom in a sound signal. It is possible to count 107 peaks and a total of 32,700 samples. Calculating the value of SAC-DM by Equation A.2, we have:

$$\text{SAC\_DM} = \frac{1}{6 \frac{107}{32,700}} = 50.9346 \quad (\text{A.4})$$

The relative percentage error found between the CLC shown in Figure A.4 and the resulted from Equation A.2 is 0.4033%. When the SAC-DM is calculated for the entire signal, the relative error decreases to 0.1011%.



**Figura A.5** - Sound signal in zoom with peaks with speed of 80% - Balanced Propeller

Tables A.1 and A.2 present the results obtained from the sound signal in which the WDT is applied. They show the values for the CLC and SAC-DM followed by the relative percentage errors, for speed at 60%, 65%, 70%, 75% and 80%, and with two different propeller conditions: balanced or unbalanced.

**Tabela A.1** - Comparison between CLC and SAC-DM after Wavelet - Balanced Propeller

ESC Speed	CLC	SAC-DM	Relative Error
60%	3.9339	3.9623	0.7197%
65%	3.7775	3.7596	0.4740%
70%	3.8387	3.8633	0.6397%
75%	53.7995	53.9252	0.2336%
80%	50.7259	50.7772	0.1011%

**Tabela A.2** - Comparison between CLC and SAC-DM after Wavelet - Unbalanced Propeller

ESC Speed	CLC	SAC-DM	Relative Error
60%	12.4089	12.4413	0.2610%
65%	98.9916	98.2292	0.7702%
70%	6.5368	6.5181	0.2857%
75%	6.5575	6.5342	0.3552%
80%	6.4220	6.4508	0.4479%

It is observed that the Relative Error in Table A.1 and Table A.2 are less than 1%, and in most cases, less than 0.5%, regardless of the condition of the propeller. It means the value obtained by SAC-DM is similar to the value of CLC obtained from ACF. Thus, it is demonstrated that the sound signal analyzed here has a chaotic behavior and, for this reason, it is possible to apply the SAC-DM to examine the motor behavior now only using the Equation A.2.

## A.5 Experiments and Results

In the experiments, for each speed (60%, 65%, 70%, 75%, and 80%), 60 seconds of audio were acquired. After application of Wavelet, each audio signal contained 1,764,000 samples. The SAC-DM was calculated for each subset of 1,000 samples. In the following subsections are presented the results SAC-DM for detection of speed and eccentricity problems.

### A.5.1 Speed and Unbalance Detection using SAC-DM

Table A.3 and Table A.4 present the statistical analysis of the SAC-DM with the balanced and unbalanced propeller, respectively. The mean ( $\mu$ ), variance ( $\sigma^2$ ), and standard deviation ( $\sigma_X$ ) are also presented for each analyzed speed. In Table A.3 is observed that the SAC-DM has achieved significant results since the means of SAC-DM are different and increase with the motor speed. However, this does not happen with the unbalanced propeller (Table A.4), which requires a more detailed investigation.

**Tabela A.3** - Statistical of SAC-DM with regular propeller

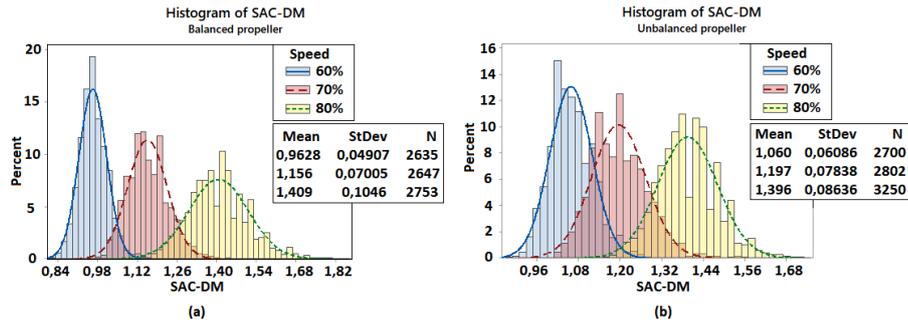
ESC Speed	$\mu$	$\sigma^2$	$\sigma_X$
60%	0.9628	$2.408 * 10^{-3}$	0.0491
65%	1.0097	$2.742 * 10^{-3}$	0.0524
70%	1.1559	$4.908 * 10^{-3}$	0.0701
75%	1.2877	$6.751 * 10^{-3}$	0.0822
80%	1.4085	$1.095 * 10^{-2}$	0.1046

**Tabela A.4** - Statistical of SAC-DM with unbalanced propeller

ESC Speed	$\mu$	$\sigma^2$	$\sigma_X$
60%	1.0597	$3.7 * 10^{-3}$	0.0609
65%	1.2249	$9.4 * 10^{-3}$	0.0969
70%	1.1973	$6.1 * 10^{-3}$	0.0784
75%	1.3123	$8.0 * 10^{-3}$	0.0894
80%	1.1964	$7.5 * 10^{-3}$	0.0864

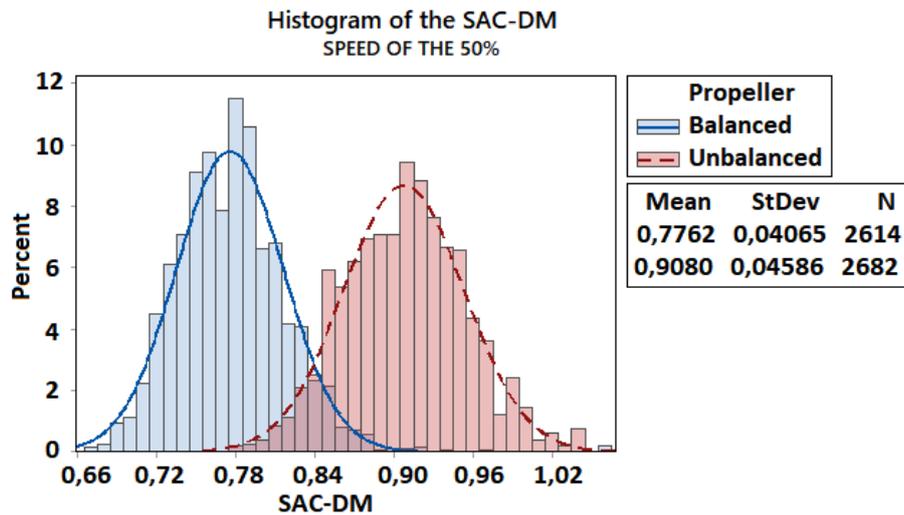
To calculate this intersection, we produced the histograms of SAC-DM for each case. Figure A.6 shows the SAC-DM histogram for the balanced (a) and unbalanced (b) propeller. In case a), the intersection between 60% and 70% of speed is 0.18%. Between 70% and 80% of speed, the area is 0.36%, this means that with SAC-DM is possible to determine the motor speed with 95,89% of accuracy when the propeller is balanced.

Likewise, the case b) presents the histogram of SAC-DM for the motor at 60%, 70% and 80% of speed, with an unbalanced propeller. Now, the intersection between 60% and 70% of speed is of 0.84%. Between 70% and 80% of speed, the area is 0.6%. This means the accuracy of 88.34% for detecting the motor speed when the propeller is unbalanced.



**Figure A.6** Histogram of SAC-DM for a) balanced, and b) unbalanced propellers for 60%, 70% and 80% of speed

In Figure A.7, the distribution of the SAC-DM values is shown for the motor with 50% of speed, now with balanced (blue) and unbalanced (red) propeller. The area with no intersection between the presented histograms results in an unbalance detection accuracy of 92.63%.



**Figure A.7** - Histogram of the SAC-DM for motor at 50% of nominal speed

The average values of all SAC-DM values for each motor speed (60%, 65%, 70%, 75%, and 80%) are shown in Figure A.8, together with the tendency line for each of them. In this way, it is possible to estimate the motor speed from the SAC-DM value.

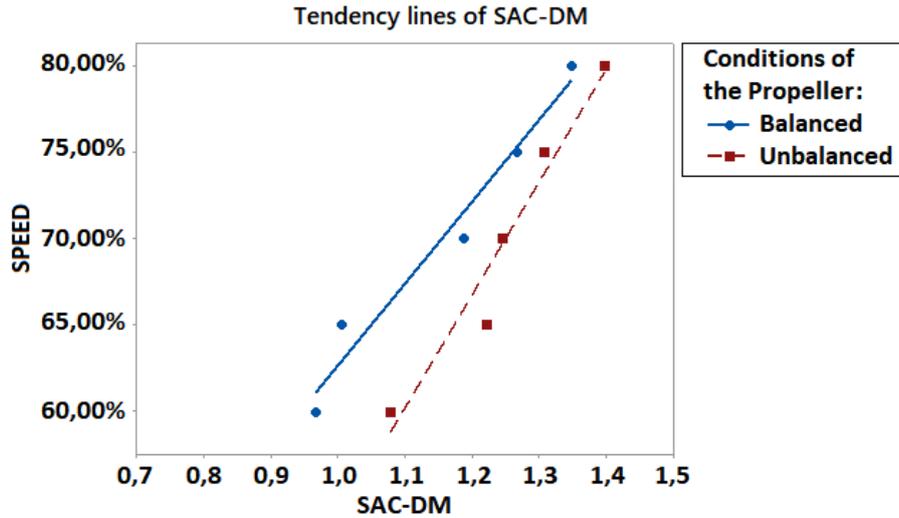


Figura A.8 - Tendency lines for the SAC-DM, with different propellers

From this result, it is possible to determine the relation between Speed(s) for balanced and unbalanced propeller, respectively, where  $s$  is the value of SAC-DM:  $Speed_{balanced}(s) = 0,47s + 0,15$ , and  $Speed_{unbalanced}(s) = 0,65s - 0,12$

## A.6 Conclusions

Data analyzes using the SAC-DM, as well as the results obtained in the experiments, allow the detection of the unbalanced propeller in the motor running in a fixed and known speed. Also, the experiments demonstrated that it was possible to detect the speed of the engine with an accuracy of 95.89% and to detect eccentricity problems when the motor is at 50% of speed with an accuracy of 88.34%. The method is entirely non-intrusive, which means that only a microphone and a micro-controller are necessary to implement a device to detect speed. A practical alternative for the diagnosis of unbalance problems is to keep the speed constant at a known value and run the SAC-DM.

## APÊNDICE B

# Outros Dados

### B.1 Tabelas

**Tabela B.1** Média da acurácia relativa à detecção de falha usando o SAC-DM. Comparativo entre Condições da Hélice: Entre Balanceada e Desb. com Fita 14 cm.

VELOCIDADE DO ESC (%)	VIBRAÇÃO MEC.	SINAL SONORO
70%	40,16%	84,48%
80%	71,54%	98,04%
90%	75,65%	60,33%
<b>MÉDIA</b>	<b>62,45%</b>	<b>80,95%</b>

**Tabela B.2** Média da acurácia relativa à detecção de falha usando o SAC-DM. Comparativo entre Condições da Hélice: Entre Desbalanceada com Fita 14 cm e Desb. com Fita 22 cm.

VELOCIDADE DO ESC (%)	VIBRAÇÃO MEC.	SINAL SONORO
70%	98,98%	84,48%
80%	94,17%	63,13%
90%	79,54%	38,57%
<b>MÉDIA</b>	<b>90,89%</b>	<b>62,06%</b>

**Tabela B.3** Média da acurácia relativa à detecção de falha usando o SAC-DM. Comparativo entre Condições da Hélice: Entre Balanceada e Desb. com Fita 22 cm.

VELOCIDADE DO ESC (%)	VIBRAÇÃO MEC.	SINAL SONORO
70%	99,60%	98,88%
80%	99,68%	99,14%
90%	97,64%	82,18%
<b>MÉDIA</b>	<b>98,97%</b>	<b>93,40%</b>