

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE ENGENHARIA
CAMPUS ILHA SOLTEIRA**

RODRIGO FRANCISCO BORGES LOURENÇO

**DIAGNÓSTICO E ANÁLISE DE FALHAS EM MÁQUINAS ROTATIVAS ATRAVÉS
DO ALGORITMO DE SELEÇÃO NEGATIVA COM APRENDIZAGEM CONTÍNUA**

Ilha Solteira - SP

2023



UNIVERSIDADE ESTADUAL PAULISTA
“JÚLIO DE MESQUITA FILHO”
Câmpus de Ilha Solteira

RODRIGO FRANCISCO BORGES LOURENÇO

**DIAGNÓSTICO E ANÁLISE DE FALHAS EM MÁQUINAS ROTATIVAS ATRAVÉS
DO ALGORITMO DE SELEÇÃO NEGATIVA COM APRENDIZAGEM CONTÍNUA**

Tese apresentada à Faculdade de Engenharia
do Campus de Ilha Solteira – UNESP como
parte dos requisitos para obtenção do título
de Doutor em Engenharia Mecânica.
Orientador (a) FABIO ROBERTO CHAVA-
RETTE

**Ilha Solteira - SP
2023**

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

L892d Lourenço, Rodrigo Francisco Borges.
Diagnóstico e análise de falhas em máquinas rotativas através do algoritmo de seleção negativa com aprendizagem contínua / Rodrigo Francisco Borges Lourenço. -- Ilha Solteira: [s.n.], 2023
88 f. : il.

Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Mecânica dos Sólidos, 2023

Orientador: Fabio Roberto Chavarette
Inclui bibliografia

1. SHM. 2. Aprendizagem de máquina. 3. Desbalanceamento. 4. Sistemas imunológicos artificiais.


Raiane da Silva Santos

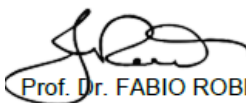
CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: Diagnóstico e Análise de Falhas em Máquinas Rotativas Através do Algoritmo de Seleção Negativa com Aprendizagem Contínua


AUTOR: RODRIGO FRANCISCO BORGES LOURENÇO

ORIENTADOR: FABIO ROBERTO CHAVARETTE


Aprovado como parte das exigências para obtenção do Título de Doutor em Engenharia Mecânica, área: Mecânica dos Sólidos pela Comissão Examinadora:


Fabio Roberto Chavarette:15473115845
Assinado de forma digital por Fabio Roberto Chavarette:15473115845
Dados: 2023.01.30 11:36:48 -03'00'


Prof. Dr. FABIO ROBERTO CHAVARETTE (Participação Virtual)
Departamento de Engenharia, Física e Matemática / Instituto de Química de Araraquara - UNESP
Documento assinado digitalmente

 **MARCIO ANTONIO BAZANI**
Data: 30/01/2023 18:17:13-0300
Verifique em <https://verificador.itl.br>

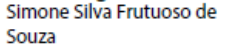
Prof. Dr. MARCIO ANTONIO BAZANI (Participação Virtual)
Departamento de Engenharia Mecânica / Unesp - Ilha Solteira


Assinado de forma digital por Amarildo Tabone Paschoalini:09280956817
Dados: 2023.01.30 16:44:31 -03'00'

Prof. Dr. AMARILDO TABONE PASCHOALINI (Participação Virtual)
Departamento de Engenharia Mecânica / Faculdade de Engenharia de Ilha Solteira - UNESP
Documento assinado digitalmente

 **WARLEY AUGUSTO PEREIRA**
Data: 31/01/2023 00:37:31-0300
Verifique em <https://verificador.itl.br>

Prof. Dr. WARLEY AUGUSTO PEREIRA (Participação Virtual)
Departamento de Engenharia Mecânica / Universidade de Rio Verde


Assinado de forma digital por Simone Silva Frutuoso de Souza
Dados: 2023.01.30 11:46:36 -04'00'

Prof. Dra. SIMONE SILVA FRUTUOSO DE SOUZA (Participação Virtual)
Departamento de Engenharia / Universidade do Estado do Mato Grosso (UNEMAT)

Ilha Solteira, 30 de janeiro de 2023

Agradecimentos

À Deus, pela concessão do dom da vida, saúde, sabedoria, perseverança, foco e fé, em prol das minhas realizações pessoais e profissionais.

Ao meu amigo e orientador Prof. Dr. Fábio Chavarette, que sempre acreditou no meu potencial e me proporcionou grande aprendizado. Um profissional muito competente e um ser humano iluminado, ao qual me espelho e tenho como exemplo para a vida.

Aos meus familiares que sempre estiveram ao meu lado nos altos e baixos da vida, pela paciência, apoio e amor. Sem vocês eu não teria chegado até aqui.

À Universidade de Rio Verde - UNIRV, que me deu todo apoio e subsídios necessários para realização dessa pesquisa.

Ao Programa de Pós-Graduação em Engenharia Mecânica da UNESP de Ilha Solteira pelas oportunidades oferecidas durante minha trajetória acadêmica (mestrado e doutorado).

Aos meus colegas do laboratório de sistemas complexos - SISPLEXOS, por estarem sempre dispostos a ajudar e compartilhar conhecimentos. Sem vocês essa pesquisa seria muito mais custosa e demorada.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo incentivo e fomento ao Programa de Pós-Graduação em Engenharia Mecânica da UNESP de Ilha Solteira, possibilitando a promoção de um ensino de qualidade.

Aos membros dessa banca, por suas valiosas contribuições acadêmicas e compartilhamento de experiências.

*O importante é não parar de questionar.
A curiosidade tem sua própria razão de existir.*
Albert Einstein

Resumo

Com processos produtivos cada vez mais otimizados e eficientes, máquinas e equipamentos rotativos são indispensáveis na maioria dos projetos mecânicos. Eles são responsáveis pelo fornecimento e transferência de forças das plantas industriais, e sua disponibilidade influencia diretamente na produtividade, lucratividade e segurança dos funcionários. A falha nesse tipo de equipamento provoca variações nos parâmetros espaciais da estrutura e modifica seu comportamento dinâmico através da variação da rigidez, massa e amortecimento. Os sistemas de monitoramento de integridade estrutural, do inglês, Structural Health Monitoring (SHM), através da utilização de ferramentas tecnológicas avançadas, como: sensores e técnicas inteligentes, lógica fuzzy e sistemas imunológicos artificiais, são capazes de identificar danos em seu estágio inicial, mensurar a gravidade do problema e otimizar os procedimentos para solução do mesmo. O objetivo dessa pesquisa é o projeto e desenvolvimento de um SHM baseado em técnicas de computação inteligente, através um algoritmo de sistemas imunológicos artificiais com seleção negativa e aprendizado continuado, capaz de detectar, classificar e quantificar falhas estruturais em sistemas dinâmicos rotativos. Verificou-se o desempenho do algoritmo de seleção negativa (ASN) de forma isolada, que apresentou bons resultados quando os danos eram conhecidos e constavam no banco de detectores. Quando esses dados não constavam no banco de dados, o algoritmo foi incapaz de reconhecê-los, justificando-se a integração do algoritmo de seleção clonal (CLONALG) ao algoritmo de seleção negativa (ASN) que, nesse caso, foi capaz de identificar os danos com eficiência e robustez.

Palavras-chave: SHM; Aprendizagem de Máquina, Desbalanceamento, Sistemas Imunológicos Artificiais;

Abstract

With production processes increasingly more optimized and efficient, rotating machines and equipment are indispensable in most mechanical projects. They are responsible for supplying and transferring forces from industrial plants, and their availability directly influences productivity, profitability and employee safety. Failure in this type of equipment causes variations in the spatial parameters of the structure and modifies its dynamic behavior through the variation of rigidity, mass and shock absorption. Structural health monitoring systems (SHM), through the use of advanced technological tools, such as sensors and intelligent techniques, fuzzy logic and artificial immune systems, are able to identify damage in its initial stage, measure the severity of problem and optimize the procedures for solving it. The goal of this research is the design and development of an SHM based on intelligent computing techniques, through an algorithm of artificial immune systems with negative selection and continuous learning, capable of detecting, classifying and quantifying structural failures in rotating dynamic systems. The performance of the negative selection algorithm (ASN) was verified in isolation, which presented good results when the damages were known and included in the detector bank. When these data were not in the database, the algorithm was unable to recognize them, justifying the integration of the Clonal Selection Algorithm (CLONALG) continuous learning algorithm to the ASN which, in this case, was able to identify damage efficiently and robustly.

Keywords: SHM; Machine Learning, Imbalance, Artificial Immune Systems;

Lista de ilustrações

Figura 1 – Modelo esquemático rotor dinâmico.	21
Figura 2 – Modelo esquemático com dois graus de liberdade.	22
Figura 3 – Modelo esquemático de Jeffcott	23
Figura 4 – Estatística de falhas em rotores de indução elétrica.	26
Figura 5 – Sistemas com um grau de liberdade - Movimento Harmônico Simples.	29
Figura 6 – Relação entre os parâmetros de vibrações	29
Figura 7 – Amplitude dos sinais de vibração	30
Figura 8 – Sinais de vibrações - Domínio do tempo/frequência	30
Figura 9 – Níveis de vibrações no domínio do tempo - Pico; Pico a Pico; RMS e Média	31
Figura 10 – Sinais no domínio do tempo	31
Figura 11 – Sinais no domínio da frequência	32
Figura 12 – Transdutores de deslocamento	32
Figura 13 – Transdutores de velocidade	33
Figura 14 – Transdutores de aceleração	33
Figura 15 – Caminhão destruído em acidente.	34
Figura 16 – Caminhão atinge veículos em Piracicaba - SP.	34
Figura 17 – Turbina destruída após explosão.	35
Figura 18 – Esquema hierárquico do SIB.	42
Figura 19 – Funcionamento básico do sistema imunológico biológico	43
Figura 20 – Sistemas naturais. (a) colônia de insetos. (b) neurônios. (c) linfócitos	45
Figura 21 – Fluxograma do sensoriamento do ASN	46
Figura 22 – Fluxograma do monitoramento do ASN	47
Figura 23 – Fluxograma de funcionamento CLONALG	48
Figura 24 – Bancada experimental para aquisição de dados	51
Figura 25 – Sistema de aquisição de dados	52
Figura 26 – Posicionamento dos sensores	53
Figura 27 – Posicionamento de retirada dos parafusos - estudo 1 e estudo 2	54
Figura 28 – Configuração de distribuição das massas de desbalanceamento	54
Figura 29 – Espectro de frequência - sinal completo.	55
Figura 30 – Fluxograma do SHM	56
Figura 31 – Espectro de frequência Estudo 1 - sensor 1	61
Figura 32 – Espectro de frequência Estudo 1 - sensor 2	62
Figura 33 – Espectro de frequência Estudo 1 - sensor 3	63
Figura 34 – Espectro de frequência Estudo 3 - sensor 1	64
Figura 35 – Espectro de frequência Estudo 3 - sensor 2	64
Figura 36 – Espectro de frequência Estudo 3 - sensor 3	65
Figura 37 – Espectro de frequência Estudo 11 - sensor 1	65
Figura 38 – Espectro de frequência Estudo 11 - sensor 2	66
Figura 39 – Espectro de frequência Estudo 11 - sensor 3	66
Figura 40 – Fluxograma do Algoritmo de Seleção Negativa - ASN	67

Lista de tabelas

Tabela 1 – Técnicas de manutenção aplicadas à motores de indução elétrica. . . .	27
Tabela 2 – Distribuição das massas de desbalanceamento.	55
Tabela 3 – Parâmetros do Algoritmos ASN e CLONALG	60
Tabela 4 – Resultados ASN - Identificação dos danos detectados no Sensor 1	68
Tabela 5 – Resultados ASN - Classificação dos danos detectados no Sensor 1	68
Tabela 6 – Resultados ASN - Identificação dos danos detectados no Sensor 2	69
Tabela 7 – Resultados ASN - Classificação dos danos detectados no Sensor 2	69
Tabela 8 – Resultados ASN - Identificação dos danos detectados no Sensor 3	70
Tabela 9 – Resultados ASN - Classificação dos danos detectados no Sensor 3	70
Tabela 10 – Resultados ASN - Identificação dos danos detectados no Sensor 1 - sem um dano	71
Tabela 11 – Resultados ASN - Classificação dos danos detectados no Sensor 1 - sem um dano	71
Tabela 12 – Resultados ASN com aprendizagem continuada - Identificação dos danos no Sensor 1	72
Tabela 13 – Resultados ASN + CONALG - Classificação dos danos detectados no Sensor 1	72
Tabela 14 – Resultados ASN com aprendizagem continuada - Identificação dos danos detectados no Sensor 2	73
Tabela 15 – Resultados ASN + CONALG - Classificação dos danos detectados no Sensor 2	73
Tabela 16 – Resultados ASN com aprendizagem continuada - Identificação dos danos detectados no Sensor 3	74
Tabela 17 – Resultados ASN + CONALG - Classificação dos danos detectados no Sensor 3	74
Tabela 18 – Quantificação de danos detectados no Sensor 1	75
Tabela 19 – Quantificação de danos detectados no Sensor 2	76
Tabela 20 – Quantificação de danos detectados no Sensor 3	76
Tabela 21 – Resumo da classificação de danos	77

Lista de abreviaturas e siglas

SHM	Structural Health Monitoring
SIA	Sistema Imunológico Artificial
RMS	Root Mean Square
FFT	Fast Fourier Transform
SP	Estado de São Paulo
EUA	Estados Unidos da América
FAA	Federal Aviation Administration
SIH	Sistema Imunológico Humano
ASN	Algoritmo de Seleção Negativa
CLONALG	Clonal Selection Algorithm
USB	Universal Serial Bus
RMSD	Root Mean Square Deviation

Lista de símbolos

K	Unidade de rigidez
r	Unidade de deflexão
m	Unidade de massa
w	Velocidade crítica
L	Unidade de comprimento
C	Centro geométrico
G	Centro de massas
$U_xc, U_yc, U_xg, U_yg, x, y, z$	Coordenadas cartesianas
θ	Ângulo de fases
ϕ	Ângulo de deslocamento
E	Módulo de elasticidade
I	Momento de inércia
d	Unidade de diâmetro
ζ	Unidade de amortecimento
w_n	Frequência natural
Hz, MHz	Unidades de frequência
mm	Unidade de comprimento (milímetros)
rad	Unidade de fases
Ag	Conjunto de dados analisados
Ab	Conjunto de dados detectores
TAf	Taxa de afinidade
An	Numero de cadeias próprias
At	Numero total de cadeias
Ag_i	Valor nominal da posição i do antígeno (padrão em análise)
\underline{Ab}_i	Valor nominal da posição i menos o desvio adotado no anticorpo (padrão detector)
\overline{Ab}_i	Valor nominal da posição i mais o desvio adotado no anticorpo (padrão detector)

Af_T	Percentual de afinidade entre padrões
$\sum_{i=1}^L Pc$	Soma das posições casadas
Pc	Posições casadas
f_j, f_j^*	Vetores de afinidade do CLONALG
Ab_n^j, Ab_i^{j*}	Subconjunto de detectores do CLONALG
C^j	População de clones do CLONALG
C^{j*}	População de clones maturados do CLONALG
$Ab_{(m)}$	Detectores da memória do CLONALG
$Ab_{(R)}$	Detectores de substituição do CLONALG
$Ab_{(d)}$	Melhores detectores do CLONALG
N_c	Quantidade de clones do CLONALG
β	Fator multiplicativo do CLONALG
N	Quantidade de anticorpos de Ab
$round(.)$	Operador de arredondamento
α	Taxa de mutação do CLONALG
ε	Desvio
ρ	Taxa de amortecimento do CLONALG
f^n	Valor normalizado da função f_j
CV	Unidade de potência elétrica
V	Unidade de tensão elétrica
$P1, P2, P3$	Localização dos sensores de vibração
<i>Métrica</i>	Referencial utilizado na caracterização dos estágios de danos da RMSD

Sumário

1	INTRODUÇÃO	17
1.1	Objetivos	18
1.1.1	Objetivo Geral	18
1.1.2	Objetivos específicos e contribuições	18
1.1.3	Justificativa e Contribuições	18
1.1.4	Estrutura da Tese	19
2	ROTORES DINÂMICOS	21
2.1	Conceitos Históricos	21
2.1.1	Modelo De Rankine	21
2.1.2	Modelo De Jeffcott	22
3	FALHAS ESTRUTURAIS	25
3.1	Conceitos Gerais	25
3.2	Falhas em Rotores	26
3.3	Técnicas de detecção de falhas	26
3.4	Vibrações Mecânicas	28
3.4.1	Análise de Vibrações	28
3.4.1.1	Quantificação dos Sinais	29
3.4.1.1.1	Sinais no domínio do tempo	30
3.4.1.1.2	Sinais no domínio da frequência	31
3.4.1.2	Medidores de vibrações	32
3.4.2	Medidores de vibrações	32
3.4.2.1	Medição de deslocamento	32
3.4.2.2	Medição de velocidade	32
3.4.2.3	Medição de aceleração	33
3.5	Histórico de acidentes por falhas mecânicas	34
4	SISTEMA DE MONITORAMENTO DE INTEGRIDADE ESTRUTURAL - SHM'S	36
4.1	Conceitos Gerais	36
4.2	Evolução Histórica das Metodologias Inteligentes	37
5	SISTEMAS BIOLÓGICOS	41
5.1	Princípios Fundamentais	41
5.2	Organização Estrutural	41
5.3	Funcionamento do sistema imunológico biológico	43
6	SISTEMAS ARTIFICIAIS	45
6.1	Introdução	45
6.2	Algoritmo de seleção negativa (ASN)	45
6.3	Critério de casamento e taxa de afinidade	47
6.4	Algoritmo de seleção clonal - CLONALG	48
7	METODOLOGIA	51
7.1	Caracterização do experimento	51

7.2	Metodologia de aquisição de dados	53
7.2.1	Coleta, Processamento e Transmissão dos Sinais	55
7.3	Implementação do SHM	56
7.3.1	Censoriamento ASN	56
7.3.2	Deteção de novidade	57
7.3.3	Módulo de aprendizado	57
7.3.4	Módulo de monitoramento	58
7.3.5	Módulo de atualização de conhecimento	58
7.3.6	Quantificação dos danos	58
8	RESULTADOS	60
8.1	Parâmetros ASN e CLONALG	60
8.2	Etapa 1 - Análise Spectral	61
8.2.1	Espectros do Estudo 1	61
8.2.2	Espectros do Estudo 3	63
8.2.3	Espectros do Estudo 11	65
8.3	Etapa 2 - Algoritmo Convencional - ASN	67
8.3.1	Resultado do ASN para o Sensor 1	68
8.3.2	Resultado do ASN para o Sensor 2	68
8.3.3	Resultado do ASN para o Sensor 3	69
8.3.4	Resultado do ASN para o Sensor 1 - Sem um dano	70
8.4	Etapa 3 - Algoritmo de Seleção Negativa com Aprendizagem Contínua	71
8.4.1	Resultados do ASN + CLONALG - Sensor 1	72
8.4.2	Resultados do ASN + CLONALG - Sensor 2	73
8.4.3	Resultados do ASN + CLONALG - Sensor 3	74
8.5	Etapa 4 - Quantificação dos danos - Métrica RMSD	75
8.5.1	Grau de influência Sensor 1	75
8.5.2	Grau de influência Sensor 2	75
8.5.3	Grau de influência Sensor 3	76
8.6	Discussões	77
9	CONCLUSÕES	78
9.1	Sugestões de Melhoria	78
	REFERÊNCIAS	79
	APÊNDICE A – PRODUÇÃO CIENTÍFICA	86
A.1	Publicação de artigos	86
A.1.1	Periódicos Nacionais	86
A.1.2	Periódicos Internacionais	86
A.2	Participação em Eventos	86
A.3	Apresentação de Trabalhos	87
A.3.1	CNMAC 2021	87
A.3.2	ENEPE 2021	87
A.3.3	CEPEX 2021	87
A.3.4	ENEPE 2020	87
A.3.5	CEPEX 2020	87

A.4	Resumos Publicados em Anais de Eventos	87
A.5	Orientação de Iniciação Científica - Concluída	88
A.6	Orientação de Iniciação Científica - Em andamento	88

1 Introdução

O setor industrial vem inovando seu processo produtivo frequentemente. Na grande maioria das indústrias, os motores de indução são equipamentos essenciais para seu processo. Sua ampla aplicação pode ser justificada por fatores como confiabilidade, robustez e baixo custo. Além disso, esses equipamentos são amplamente empregados em diferentes projetos de máquinas, como: esteiras, compressores, bombas, entre outras (ALVES, 2017). Segundo Ferreira (2009), os motores de indução estão presentes em mais de 90% dos projetos de máquinas industriais, sendo responsáveis pelo fornecimento de torque para a maioria desses equipamentos.

Apesar das inúmeras vantagens de aplicação dos motores de indução, falhas elétricas e mecânicas representam um desafio particular para a indústria e para os usuários finais desses equipamentos que, frequentemente, interrompem o processo produtivo e exigem manutenção. A maior parte dos problemas causados em motores de indução são oriundos de falhas em mancais e estatores, que juntas, representam 78% dos registros efetuados. As falhas relativas a rotores, representam 10% dos registros, e 12% das falhas, se manifestam de forma diversificada (ABRAMAN, 2011).

Independente da intensidade ou origem dos danos, de modo geral, eles podem comprometer a integridade, e gerar falhas em elementos estruturais. Com isso, podem ocorrer variações nos parâmetros espaciais da estrutura, modificando seu comportamento dinâmico através da redução da rigidez estrutural, redução da massa e aumento do amortecimento (TURRA et al., 2013). De acordo com Zheng, Wang e Liu (2004), a variação desses parâmetros espaciais afeta, diretamente, os principais parâmetros dinâmicos, como a frequências de ressonância, funções de respostas, razão de amortecimento e modos próprios da estrutura.

Valles-Novo et al. (2014) ressalta a importância de identificar precocemente os danos em motores de indução. O autor afirma que, nem sempre, os danos em rotores interrompem o funcionamento dos motores, e isso pode ocasionar desgastes progressivos aos outros componentes, provocando vibrações indevidas, consumo excessivo de corrente e falhas prematuras.

Atualmente, as análises de danos em elementos estruturais, são realizadas principalmente de modo off-line, exigindo interrupções periódicas no processo produtivo, ocasionando perda de tempo e produtividade. Nesse sentido, nota-se a necessidade contínua de desenvolvimento de tecnologias de monitoramento e detecção de falhas estruturais em tempo real, o que possibilita a identificação do problema no seu estágio inicial, evitando assim, a propagação do dano, prejuízos financeiros, o colapso da estrutura e, conseqüentemente, acidentes catastróficos.

Os sistemas de monitoramento de integridade estrutural (SHM – Structural Health Monitoring) podem ser utilizados para identificar danos em seu estágio inicial, mensurar a gravidade do problema apresentado e intervir na propagação desses problemas (HALL, 1999). Segundo Lima (2018), os SHMs fazem uso de tecnologias avançadas, como: sensores e técnicas inteligentes, lógica fuzzy e sistemas imunológicos artificiais, a fim de extrair conhecimentos e informações dos processos produtivos, automatizar a tomada de decisões e melhorar a análise dos sinais adquiridos.

Existem vários tipos diferentes de técnicas, destrutivas (DE) ou não destrutivas (NDE), para monitoramento e detecção de barras de rotores danificadas, e sua escolha depende de alguns fatores, como: tipo de estrutura proposta, configuração de projeto e ambiente de aplicação do modelo. Segundo [Contreras-Medina et al. \(2008\)](#) e [Xie \(2012\)](#), dentre as técnicas não destrutivas, as mais comuns se dão através da análise de variáveis elétricas, análise de vibrações, termografia, líquidos penetrantes e análise ultrassônica.

Segundo [Betta et al. \(2002\)](#), a análise e monitoramento de vibrações em máquinas rotativas é muito popular e se apresenta de forma eficaz. O autor ressalta que, a maioria das falhas de equipamentos mecânicos está relacionada a uma mudança na dinâmica das estruturas, e isso ocorre devido a oscilações estruturais do comportamento original. Essas oscilações podem ser utilizadas para identificar presença de comportamentos harmônicos indesejados.

[Holanda \(2016\)](#) destaca que a falta de manutenção, má utilização e o desgaste de um equipamento mecânico estão entre os principais fatores que modificam seu comportamento dinâmico. Conseqüentemente, pode ocorrer um aumento nos níveis de vibrações, causando problemas como folgas mecânicas, desalinhamento e desbalanceamento.

1.1 Objetivos

1.1.1 Objetivo Geral

Desenvolver um SHM baseado em técnicas de computação inteligente, a fim de detectar, classificar e quantificar falhas estruturais em sistemas dinâmicos rotativos, utilizando-se o algoritmo de sistemas imunológicos artificiais com seleção negativa e aprendizado continuado.

1.1.2 Objetivos específicos e contribuições

- Projetar e desenvolver uma bancada para aquisição dos dados necessários para o estudo;
- Implementar um algoritmo para extração e tratamento dos dados, a fim de possibilitar a aplicação do SHM;
- Apresentar uma técnica inovadora para o monitoramento da integridade estrutural de rotores dinâmicos, através de sistemas inteligentes com melhoramento contínuo;
- Aplicar o sistema de monitoramento estrutural, utilizando técnicas imunológicas artificiais de seleção negativa e aprendizagem continuada, a fim de detectar, classificar e quantificar danos no rotor, sob diversas formas de operação;
- Apresentar uma nova abordagem para os SHM, aplicando seus três primeiros níveis em sistemas dinâmicos rotativos com robustez e precisão, no que diz respeito ao diagnóstico e prognóstico de danos.

1.1.3 Justificativa e Contribuições

Os métodos e técnicas de detecção de falhas em máquinas e equipamentos rotativos, convencionalmente, estão vinculados à utilização de mão de obra humana, o que pode

tornar o processo demorado, incerto e muitas vezes inviável. As técnicas de computação inteligentes podem ser utilizadas para promover melhoria e automatização do processo de identificação e tratamento de danos, proporcionando robustez e confiabilidade a esse processo.

Justifica-se este projeto pela necessidade, principalmente dentro da indústria, de uma ferramenta capaz de monitorar a integridade estrutural das máquinas rotativas, de modo automático e com melhoria contínua. Isso pode aumentar a disponibilidade desses equipamentos, melhorar a produtividade e reduzir o índice de acidentes.

O sistema de monitoramento da integridade estrutural desenvolvido nessa pesquisa, é composto pelos algoritmos de seleção negativa (ASN) e algoritmo de seleção clonal (CLONALG), que se baseia no funcionamento dos sistemas imunológicos biológicos para realização de suas funções, trabalhando de maneira sistematizada, organizada e iterativa.

Encontra-se diversas pesquisas baseadas em técnicas de computação inteligentes, com o objetivo de diagnosticar falhas em equipamentos mecânicos de maneira automatizada, porém, nenhuma delas utilizou sistemas imunológicos artificiais com aprendizado continuado aplicado a sistemas dinâmicos rotativos, o que engrandece a proposta dessa pesquisa, e proporciona uma contribuição inédita.

1.1.4 Estrutura da Tese

O texto desenvolvido nessa tese é composto por nove capítulos e um apêndice, conforme descrito a seguir:

Capítulo 1: Introdução

No capítulo 1 foi feita a introdução do tema, onde são apresentados os aspectos fundamentais para desenvolvimento do trabalho, os objetivos, as contribuições da pesquisa e os fundamentos que a justificam.

Capítulo 2: Rotores Dinâmicos

No capítulo 2 são apresentados conceitos numéricos de rotores dinâmicos e seu desenvolvimento histórico.

Capítulo 3: Falhas estruturais

No capítulo 3 são apresentadas as principais falhas em máquinas rotativas, como elas surgem e como podem ser detectadas/mensuradas. Além disso, apresenta-se um histórico de acidentes ocorridos por falhas estruturais.

Capítulo 4: Sistema de monitoramento de integridade estrutural - SHM

No capítulo 4 apresenta-se a contextualização dos SHM's, seus níveis de abrangência e suas etapas de implementação.

Capítulo 5: Sistemas imunológicos biológicos

No capítulo 5 são apresentados conceitos do funcionamento dos sistemas imunológicos biológicos, envolvendo seu processo de reconhecimento de padrões e aprendizado.

Capítulo 6: Sistemas imunológicos artificiais

Neste capítulo são apresentados os algoritmos imunológicos utilizados nessa pesquisa, bem como seu funcionamento e fluxograma de execução.

Capítulo 7: Metodologia

No capítulo 7 apresenta-se todo o processo metodológico proposto. São apresentados os procedimentos de ajuste da bancada, coleta e padronização de sinais e a implementação do SHM proposto.

Capítulo 8: Resultados

Nesse capítulo são apresentados e discutidos os resultados dessa pesquisa, que envolve a análise espectral, algoritmo de seleção negativa e algoritmo de seleção clonal.

Capítulo 9: Conclusão

No capítulo 9 apresenta-se as conclusões e as sugestões de melhoria desta pesquisa.

Apêndice A - Produção científica

No apêndice A são apresentadas as publicações, participações em eventos científicos e apresentação de trabalhos realizados pelo autor durante o processo de realização do doutorado.


2 Rotores Dinâmicos

Nesse capítulo, são apresentados conceitos do desenvolvimento da dinâmica de rotores, conforme contribuição histórica de diversos pesquisadores da área.

2.1 Conceitos Históricos

A ação conjunta de diferentes elementos de engenharia, com objetivo de executar uma determinada tarefa, pode caracterizar um sistema dinâmico. As máquinas rotativas, também chamadas de rotores dinâmicos são constituídas pelo conjunto de mancais, eixo e disco. A figura 1 representa o modelo esquemático de um rotor dinâmico simples.

Figura 1 – Modelo esquemático rotor dinâmico.



fonte: (VANCE; ZEIDAN; MURPHY, 2010)

Um sistema dinâmico pode ser analisado sob parâmetros que variam ou não no tempo. Quando esses parâmetros são invariáveis (sistemas lineares), o tempo se apresenta na função de entrada, sendo possível a previsão matemática de seu comportamento dinâmico. Já nos modelos com parâmetros variáveis (sistemas não-lineares), esse comportamento não pode ser efetivamente representado, visto que, a aleatoriedade dessas variáveis pode fazer com que o comportamento do sistema evolua de forma aperiódica e desequilibrada, a depender das condições iniciais (MONTEIRO, 2002).


Segundo Outa (2019), não existem sistemas físicos reais com parâmetros fixos, logo, a modelagem de sistemas lineares é feita através de aproximações do comportamento de um modelo não-linear.

2.1.1 Modelo De Rankine

Rankine (1869) foi um dos pioneiros em pesquisas relacionados a rotores dinâmicos. O autor utilizou um modelo de dois graus de liberdade, representado na Figura 2, composto por um eixo flexível acoplado a uma massa rígida centrada de órbita circular, e suportes rígidos.

Na tentativa de explicar o comportamento da velocidade crítica dos sistemas rotor-mancais, o modelo de Rankine (1869) (Figura 2), adota a rigidez do eixo como uma força restauradora, capaz de manter a trajetória do disco ao redor de sua órbita, com isso, através da segunda lei de Newton, tem-se a definição do modelo matemático, dado pela Equação 2.1, que simplificada, fornece a Equação 2.2:

Figura 2 – Modelo esquemático com dois graus de liberdade.



fonte: Adaptado de Vance, Zeidan e Murphy (2010)

$$Kr = m\omega^2 r \tag{2.1}$$

$$\omega^2 = \frac{K}{m} \tag{2.2}$$

em que:

Kr : rigidez do eixo;

K_B : rigidez do suporte

EI : rigidez a flexão do eixo

r : deflexão do eixo;

m : massa do disco;

w : velocidade crítica do eixo;


O modelo de Rankine (1869) entrega a ideia de que máquinas rotativas nunca poderiam operar acima de sua velocidade crítica, sob pena de colapso. Porém, segundo Vance, Zeidan e Murphy (2010), como o autor desconsiderou importantes fatores de influência na dinâmica dos rotores, como as forças de Coriolis e o amortecimento, sua análise não representa efetivamente a realidade do comportamento rotativo de rotores. Segundo Cota (2008), esse modelo serviu como fundamentação para o desenvolvimento de alguns outros modelos utilizados até os dias atuais.

2.1.2 Modelo De Jeffcott


O rotor de Jeffcott, representado na Figura 3, é constituído por um eixo de massa desprezível acoplado a um disco em seu centro axial e mancais rígidos. Na vista em perspectiva (Figura 3 (a)), tem-se o eixo em rotação com velocidade angular w e comprimento L . O disco central encontra-se desbalanceado, ou seja, as coordenadas do seu centro geométrico C divergem do centro de massas G , onde e_u é o vetor que conecta esses dois pontos.

Na Figura 3 (b) tem-se o detalhamento geométrico do movimento dinâmico do rotor, em que os pontos C e G podem ser localizados pelas coordenadas cartesianas (U_x,c, U_y,c) e (U_x,g, U_y,g) , respectivamente. O angulo de fases é representado por θ e o angulo de

Figura 3 – Modelo esquemático de Jeffcott



(a) vista em perspectiva



(b) vista frontal da massa

fonte: Adaptado de(YOON; LIN; ALLAIRE, 2012)

deslocamento do centro de massas por ϕ . Considerando-se que o sistema não tem perdas, a rigidez do eixo Ke pode ser calculada pela Equação 2.3, como segue:

$$Ke = \frac{48 \times E \times I}{L^3} \quad (2.3)$$

em que E é o modulo de elasticidade do material e I o momento de inércia, calculado pela Equação 2.4.

$$I = \frac{\pi \times d^4}{64} \quad (2.4)$$

A equação do comportamento dinâmico do rotor de Jeffcott pode ser desenvolvida pela aplicação da 2ª lei de Newton , conforme equações 2.5 e 2.6.

$$mu_{xc} + k_s u_{xc} + c_s u_{xc} = 0 \quad (2.5)$$

$$mu_{yc} + k_s u_{yc} + c_s u_{yc} = 0 \quad (2.6)$$

Sendo a resposta da excitação estacionária dada por $u_{xC} = U_x e^{i\omega t}$; $u_{yC} = U_y e^{i\omega t}$ tem-se as Equações 2.7 e 2.8, que descrevem matematicamente seu comportamento, considerando-se movimento lateral (YOON; LIN; ALLAIRE, 2012).

$$(-\omega^2 + 2i\omega\zeta\omega_n + \omega_n^2)U_x e^{i\omega t} = e_u \omega^2 \cos(\omega t) \quad (2.7)$$

$$(-\omega^2 + 2i\omega\zeta\omega_n + \omega_n^2)U_y e^{i\omega t} = e_u \omega^2 \sin(\omega t) \quad (2.8)$$

em que:

ζ : razão de amortecimento;

ω_n : frequência natural do sistema;

O modelo de Jeffcott apresentou-se em 1919 como uns dos primeiros trabalhos analíticos de rotores dinâmicos, evidenciando a possibilidade de máquinas rotativas operarem acima de sua primeira velocidade crítica, de forma estável (COTA, 2008).

3 Falhas Estruturais

Neste capítulo são apresentados conceitos de falhas estruturais, com enfoque em rotores de motores de indução elétrica.

3.1 Conceitos Gerais

Com plantas e processos produtivos cada vez mais automatizados e modernos, as falhas em máquinas e equipamentos do setor industrial são fenômenos abominados e desafiam engenheiros no âmbito mundial.

Antes de contextualizar o termo "falha", é importante diferenciá-lo do termo "dano". Segundo [Bitencourt e Júnior \(2009\)](#), qualquer modificação nas propriedades físicas ou geométricas de um sistema estrutural, que comprometa sua operação ideal sem impossibilitá-lo de exercer suas funções, podem ser considerados como um dano. Muitos são os fatores que tendem a provocar danos em sistemas mecânicos e estruturais, dentre os mais comuns estão as fissuras ou trincas, afrouxamento de elementos de junta, desgastes e corrosão ([MAIO, 2011](#)).

Mesmo que, em uma escala nano ou micro estrutural, não existem estruturas livres defeitos, que geralmente, são proeminentes de vazios ou má formação cristalina, desenvolvidos ainda no processo de fabricação da peça. Normalmente, existe uma hierarquia na progressão das falhas, ou seja, primeiro surgem os defeitos, que levam aos danos e finalmente à falha. Um sistema de monitoramento deve acumular informações suficientes sobre os danos, para que seus efeitos sejam identificados e as ações corretivas de restauração estrutural aconteçam antes que ocorra a falha ([WORDEN; DULIEU-BARTON, 2004](#)).

As falhas estruturais são evidenciadas quando as modificações no sistema, geralmente causadas pela supressão de danos, são tamanhas que impossibilite a execução de suas funções de forma satisfatória. Os tipos mais comuns de falhas são devidos a componentes do sistema danificados, distúrbios de alimentação, erros de operação e manutenção e defeitos nos sistemas de controle ([SILVA, 2008](#)).

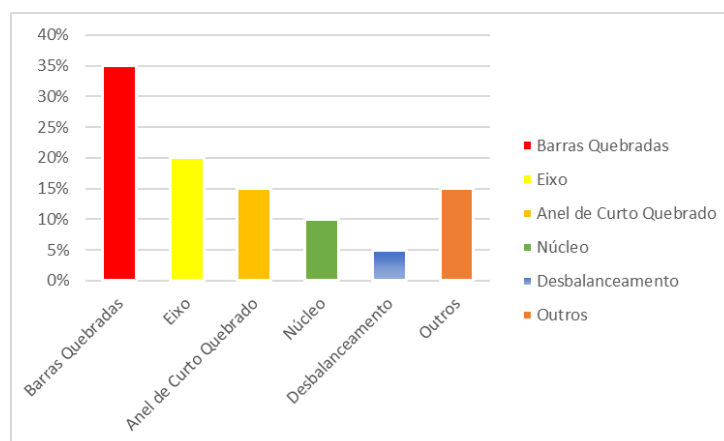
Para [Baccarini \(2005\)](#), o monitoramento e detecção de falhas estruturais não são tarefas triviais, uma vez que, pequenos danos podem ser facilmente confundidos com ruídos discretos, ou seja, modos normais de operações. Nesse contexto, segundo [Betta et al. \(2002\)](#), para um diagnóstico preciso, é necessário:

- monitoramento em tempo real dos padrões de comportamento estrutural;
- determinar-se adequadamente os parâmetros de medição: quantidades de pontos, frequência de amostragem, entre outros;
- utilizar-se de ferramentas computacionais adequadas para tratamento e manipulação dos dados, de modo preciso e direcionado para cada aplicação.

3.2 Falhas em Rotores

Segundo [ABRAMAN \(2011\)](#), citado por [Silva \(2008\)](#), a maioria das avarias recorrentes em rotores (Figura 4), são provenientes de barras quebradas e problemas nos eixos, esses fatores somados, equivalem a 55% das falhas detectadas. O percentual restante (45%), divide-se em defeitos no anel coletor, núcleo, desbalanceamento e problemas diversificados.

Figura 4 – Estatística de falhas em rotores de indução elétrica.



fonte: Adaptado de ([SILVA, 2008](#))

As falhas recorrentes em rotores são, em sua maioria, causadas por tensões diversificadas. Em seu trabalho, [Bonnett e Soukup \(1988\)](#) citaram um estudo apresentado na 32ª Conferência Anual da Indústria Química e do Petróleo que, dividiu esses esforços em seis grupos:

1. Térmicos: desequilíbrios de temperatura; bloqueio de rotor; cargas excessivas.
2. Mecânicos: folgas mecânicas; fadiga; ruptura; fabricação ou projeto; desalinhamento; desbalanceamento; entre outras.
3. Magnéticos: tração magnética desregulada; vibrações; forças e ruídos eletromagnéticos.
4. Dinâmicos: vibrações; folgas; fricção; tensões dinâmicas e cíclicas;
5. Residuais: tensões desiguais; concentradores de tensões;
6. Ambientais: abrasão; umidade; temperatura excessiva; forças naturais.

3.3 Técnicas de detecção de falhas

A detecção, diagnóstico e prognóstico precoce de falhas em motores, permitem uma melhor organização no cronograma de manutenção preventiva da planta, possibilitando priorizar-se os períodos de inatividade programados, o que melhora a disponibilidade dos equipamentos, enquanto reduz os custos de manutenção ([CHOW, 2000](#)).

Os métodos para detecção de falhas, consistem basicamente na leitura de grandezas físicas provenientes de equipamentos da planta industrial. Atualmente, essas grandezas

são adquiridas por sistemas automatizados (sensores) e podem se apresentar em forma de vibrações, correntes elétricas, temperatura, ondas acústicas e magnéticas, entre outras.

Para diagnóstico de falhas, de modo generalizado, compara-se as características físicas já conhecidas do equipamento saudável, com leituras efetuadas, que podem, ou não, ser em tempo real, ou seja, online ou offline. As técnicas de monitoramento mais utilizadas são (SILVA, 2008):

- offline: teste de alto potencial, teste de isolamento, teste de resistência, análise do circuito.
- online: análise de vibração, termografia, acústica, assinatura elétrica, medidas elétricas.

A Tabela 1, apresenta um apanhado das práticas de manutenção preditiva aplicadas em motores de indução elétrica. Note que, a análise de vibrações acontece de modo on-line, sendo empregada em motores de baixa e média tensão e possibilita a análise da maioria das falhas mecânicas presentes nos motores elétricos.

Tabela 1 – Técnicas de manutenção aplicadas à motores de indução elétrica.

Técnicas	Motor		Condição		Modos de falha									
	Média Tensão	Baixa Tensão	on-line	off-line	Descargas Parciais	Curto entre espiras	Vibração	Barras Quebradas	Desbalanço de Tensão	Mau Contato Conexões	Isolação	Excentricidade Entrefeirro	Envelhecimento Térmico	Sobrecarga
Análise de Vibração	x	x	x				x	x				x		
Ass. de Corrente	x	x	x			x	x	x	x	x	x	x		x
Descargas Parciais	x		x	x	x						x			
Fluxo magnético	x	x	x			x	x	x	x		x	x		x
FP da Isolação	x			x							x			
Impedância	x	x		x		x					x	x	x	
Isolamento Off-line	x	x		x							x			
Tensão e Corrente	x	x	x						x	x				x
Partidas Repetidas	x	x	x										x	x
R. Isolamento	x	x		x							x			
R. Ôhmica	x	x		x		x				x				
Temperatura	x	x	x						x				x	x
Tensão Aplicada	x	x		x							x			
Termografia	x	x	x							x			x	x
Teste de Impulso	x	x		x		x					x			
Ultra-som	x	x	x		x		x	x			x	x		

fonte: Adaptado de (FILHO, 2007)

3.4 Vibrações Mecânicas

A definição do termo vibração mecânica está relacionada com o movimento repetido ou oscilatório dos corpos em torno de uma posição nominal, geralmente de equilíbrio (INMAN, 2018). Os diversos aspectos conceituais envolvendo o tema estão difundidos no cotidiano da maioria das pessoas, principalmente daquelas envolvidas em atividades técnicas. Exemplos comuns de equipamentos que vibram ao executar suas funções podem ser amplamente listados, como é o caso dos eletrodomésticos, automóveis e máquinas industriais.

A maioria das atividades humanas envolve vibração de uma forma ou outra. Por exemplo, ouvimos porque nossos tímpanos vibram, e vemos porque as ondas de luz sofrem vibração. A respiração está associada à vibração dos pulmões, e andar envolve movimento oscilatório (periódicos de pernas e mãos). Falamos devido ao movimento oscilatório da laringe (e da língua) (RAO, 2008).

O fenômeno da vibração deve ser cuidadosamente estudado pelos setores de engenharia e tecnologia, visto que, existem sistemas que precisam vibrar para a perfeita execução de suas funções, como é o caso dos marteleiros, compactadores de solo e até mesmo alguns órgãos do corpo humano, como o coração. Por outro lado, seus efeitos, quando indesejados, são catastróficos e agressivos para as estruturas mecânicas, o que pode causar desgastes prematuros, rupturas e falhas por fadiga (LOURENÇO, 2017).

As vibrações, quando indesejadas, devem ser eliminadas ou, pelo menos, reduzidas a níveis aceitáveis. Esse processo não é algo trivial e exige uma abordagem holística, ou seja, é necessário identificar, quantificar e atuar na redução do ruído, o que envolve diversos conceitos, que são abordados nas seções seguintes.

3.4.1 Análise de Vibrações

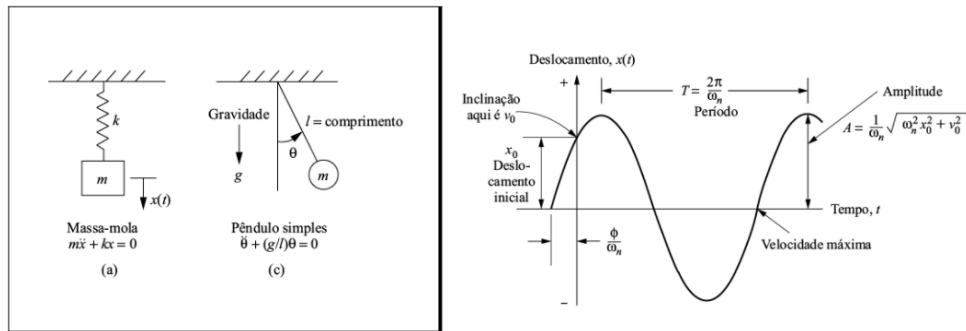
A análise de vibração é uma das principais técnicas utilizadas no diagnóstico de danos em máquinas rotativas, mais especificamente, em problemas de excentricidade e desalinhamento de eixos, engrenagens e rolamentos danificados e cavitação de bombas. O método possibilita o monitoramento da progressão da falha, e gera um histórico de informações necessárias para desvendar as causas de interrupção na operação (BENEDETTI, 2002).

O comportamento dinâmico de um sistema rotativo é efetivamente influenciado pelos esforços decorrentes de seu funcionamento e, a presença de defeitos, danos e/ou falhas na estrutura, podem alterar seus modos de vibrar. Existem ferramentas capazes de monitorar esses sinais, de modo pontual ou contínuo, e podem fornecer amplitudes em função do tempo do deslocamento, velocidade ou aceleração.

Para melhor entendimento dos parâmetros de vibração, faz-se necessário o estudo do movimento harmônico simples, ou seja, a forma mais simples de oscilação de um corpo em torno de um ponto. Exemplos clássicos, como a de um pêndulo ou de um sistema massa mola, estão representados na Figura 5 e demonstram essa oscilação, onde a massa vai de uma extremidade à outra, passando sempre pelo ponto central.

O deslocamento é representado pela variação da distância do ponto de referência até a massa, a variação desse deslocamento no tempo caracteriza-se como a velocidade e, se existe uma velocidade variável, conseqüentemente, existe a aceleração. Esses três


Figura 5 – Sistemas com um grau de liberdade - Movimento Harmônico Simples.



fonte: Adaptado de (INMAN, 2018)

parâmetros estão relacionados (Figura 6), com defasagens respectivas de 90° , e são capazes de quantificar os níveis de vibração presentes nas estruturas.

Figura 6 – Relação entre os parâmetros de vibrações




fonte: Adaptado de (INMAN, 2018)

3.4.1.1 Quantificação dos Sinais

A amplitude dos sinais de vibrações (Figura 7), independente de como se apresentam (deslocamento, velocidade ou aceleração), esta relacionada com a quantidade de energia contida nesse sinal e podem indicar o grau de criticidade das funcionalidades dos equipamentos mecânicos (BANDEIRA; ABREU; GIANELLI, 2010).


A perspectiva de análise dos sinais de vibrações, representado na Figura 8, pode acontecer sob o domínio do tempo ou convertido para o domínio da frequência, a depender das necessidades e objetivos dos testes realizados. Nota-se que as amplitudes estão no eixo vertical e os eixos horizontais representam suas respectivas formas, de acordo com o domínio.

Figura 7 – Amplitude dos sinais de vibração



fonte: (BANDEIRA; ABREU; GIANELLI, 2010)

Figura 8 – Sinais de vibrações - Domínio do tempo/frequência



fonte: Adaptado de (COSTA; MATHIAS, 2008)


3.4.1.1.1 Sinais no domínio do tempo

Os sinais de vibrações no domínio do tempo se apresentam em forma de onda e plota o histórico de ruídos no decorrer do tempo. Usualmente são utilizados para identificar eventos repetitivos e curtos, como é o caso dos impactos. Para descrição completa dos sinais nesse domínio, é necessário o conhecimento da sua amplitude (mm), frequência (Hz), que é definido pela quantidade de vezes (ciclos) que o fenômeno se repete em uma determinada unidade de tempo, e a fase (rad), que é o ângulo inicial do movimento harmônico, característico da função senoidal (COSTA; MATHIAS, 2008).

A quantificação dos níveis de vibrações, analisadas no domínio do tempo, podem ser representadas em níveis de pico, pico a pico, valor médio ou valor eficaz (RMS), e estão representadas na Figura 9.

A análise de vibrações sob valores de pico e pico a pico não levam em consideração o histórico no tempo da onda e, geralmente são utilizados para detectar eventos de curta

Figura 9 – Níveis de vibrações no domínio do tempo - Pico; Pico a Pico; RMS e Média



fonte: Adaptado de (COSTA; MATHIAS, 2008)

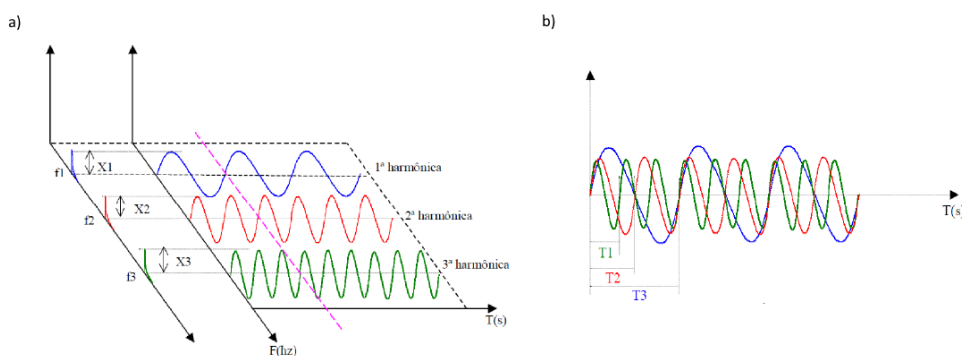
duracão, pois analisam as máximas amplitudes dos sinais em um pico ou um ciclo. Os valores médios ou Eficaz (RMS), analisam o espectro em níveis mais relevantes, pois consideram o histórico no tempo da onda e são capazes de identificar a capacidade destrutiva dos sinais de vibração no decorrer do tempo (HOLANDA, 2016).

3.4.1.1.2 Sinais no domínio da frequência

As vibrações de um sistema mecânico (no domínio do tempo), são constituídas de um conjunto de vibrações características de seus componentes, ou seja, cada componente de uma máquina se comporta como uma massa vibratória e possui uma frequência específica de excitação. Através da análise de vibrações no domínio da frequência, é possível separar e descrever esses sinais característicos de cada componente e, conseqüentemente, efetuar a identificação e localização de danos (COSTA; MATHIAS, 2008).

Na Figura 10(a), é possível identificar-se três sinais distintos no domínio do tempo que, quando analisado no plano cartesiano (Figura 10(b)), estão sobrepostos. Esses sinais, quando convertidos para o domínio da frequência, representados na Figura 11, podem ser trabalhados separadamente e isso facilita a análise particular de cada componente do sistema.


Figura 10 – Sinais no domínio do tempo



fonte: Adaptado de (HOLANDA, 2016)

A divisão dos sinais complexos em componentes individuais, conhecidos como espectro de frequência, é realizada através da utilização de operações matemáticas embasadas nos conceitos da Transformada Rápida de Fourier, do inglês Fast Fourier Transform - FFT e, como resultado, obtém-se um diagrama com a frequência nas abscissas e a amplitude nas ordenadas. A análise do espectro de frequência é fundamental para a identificação de fontes de vibrações indesejadas, em que, os níveis de ruídos de cada componente do sistema

Figura 11 – Sinais no domínio da frequência



fonte: Adaptado de (HOLANDA, 2016)

podem ser quantificados através dos picos de amplitude desse diagrama, e comparados com um sistema de referência, ou seja, sem defeitos (HOLANDA, 2016).

3.4.2 Medidores de vibrações


Os equipamentos utilizados para quantificação de forças, também conhecidos como transdutores de vibrações, são capazes converter grandezas físicas de origem mecânica (deslocamento, velocidade ou aceleração), caracterizadas como sinais de entrada, em um sinal de saída de origem elétrica equivalente, como corrente, tensão ou resistência.

3.4.2.1 Medição de deslocamento

Os transdutores de deslocamento são dispositivos projetados para medir distâncias lineares ou angulares, com magnitudes variadas como metros, polegadas ou milímetros. Esses dispositivos se apresentam de forma diversificada, com variações no tipo de tecnologia embarcada, robustez e precisão de medidas.

Dentre as categorias de transdutores de deslocamento mais comuns, estão os sensores indutivos e capacitivos, potenciômetros, encoders e giroscópios. Na Figura 12 tem-se a representação de alguns desses dispositivos, sendo: (a) sensor capacitivo, (b) e (c) sensores indutivos de posição e rotação, respectivamente.

Figura 12 – Transdutores de deslocamento



fonte: Adaptado de (BALBINOT; BRUSAMARELLO, 2000)


3.4.2.2 Medição de velocidade

Os transdutores de velocidade, também conhecidos como tacômetros, são dispositivos construídos com o objetivo de medir distâncias em função do tempo. Os tacômetros são

caracterizados pela tecnologia utilizada na geração do sinal de saída (digital ou analógico), exemplificando-se os do tipo magnetorresistivos, efeito hall ou relutância variável (MATOS, 2008).

Na Figura 13, tem-se (a) o esboço de um tacômetro digital do tipo relutância variável e (b) analógico do tipo flyball ou centrífugo.

Figura 13 – Transdutores de velocidade



fonte: Adaptado de (MATOS, 2008)

3.4.2.3 Medição de aceleração

Os transdutores de aceleração, conhecidos como acelerômetros, são capazes de medir aceleração, vibração ou impacto e fornecer uma saída elétrica proporcional a esses valores. Existe uma grande variedade de acelerômetros, diferenciando-se por características como dimensões/encapsulamento, faixas de amplitude, eixos de medição (uniaxial, biaxial ou triaxial), frequência de medição e tecnologia embarcada. Sob o aspecto tecnológico, destacam-se os piezoelétricos, capacitivos, piezorresistivos ou integrados. Esses dispositivos são largamente utilizados no monitoramento de eixos, rolamentos, sistemas veiculares e até na vibração ocupacional (BALBINOT; BRUSAMARELLO, 2000).

Na Figura 14, estão representados o esboço de diversos transdutores de aceleração.

Figura 14 – Transdutores de aceleração



fonte: Adaptado de (BALBINOT; BRUSAMARELLO, 2000)

3.5 Histórico de acidentes por falhas mecânicas

Independente da área, motivo ou efeito das falhas estruturais, é comum a ocorrência de acidentes catastróficos devido a esse tipo de problema, que em sua maioria, geram prejuízos financeiros, físicos, e até fatais.

Em 2014, na cidade de Bauru - SP, um caminhão de uma empresa municipal capotou no perímetro urbano da cidade após quebrar o eixo (Figura 15). Na ocasião, o veículo ficou completamente destruído e os ocupantes tiveram ferimentos leves (AZANK, 2014).

Figura 15 – Caminhão destruído em acidente.



fonte: Adaptado de (AZANK, 2014)

Outro acidente causado por falha mecânica ocorreu na cidade de Piracicaba - SP (Figura 16). Após quebrar o eixo, um caminhão desceu desgovernadamente uma avenida da cidade, colidindo-se contra alguns outros veículos. Apesar da gravidade do acidente, houve apenas prejuízos financeiros (MARTINS, 2013).

Figura 16 – Caminhão atinge veículos em Piracicaba - SP.



fonte: (MARTINS, 2013)

Em abril de 2018, um avião da companhia SouthWest modelo Boing 737-700, apresentou problemas no motor esquerdo e teve que fazer um pouso de emergência na cidade Filadélfia, estado da Pensilvânia. O motor da aeronave explodiu (Figura 17) e

parte dos estilhaços atingiram a fuselagem e uma das janelas do avião. Uma mulher foi parcialmente sugada para fora da aeronave e veio a óbito, sete outros passageiros tiveram ferimentos leves. A Administração Federal de Aviação dos EUA - FFA, apontou que o acidente aéreo foi causado por fraturas nas lâminas da turbina, o que provocou a desintegração na tampa do motor. Após o incidente, a FFA recomendou a inspeção ultrassônica das turbinas do modelo CFM56-7B com mais de 30 mil ciclos acumulados, o que afetou cerca de 680 motores em operação no mundo (MELLIS, 2018).

Figura 17 – Turbina destruída após explosão.



fonte: (NTSB/REUTERS, 2018)

Com base nesses exemplos, é notório a necessidade de se identificar e corrigir falhas estruturais precocemente, o que garante a segurança não somente do equipamento, mas pode salvar vidas. Nesse contexto, a aplicação de sistemas de monitoramento de integridade estrutural - SHM, apresenta-se como boa alternativa.

4 Sistema de Monitoramento da Integridade Estrutural - SHM

Neste capítulo são apresentados conceitos de monitoramento da integridade estrutural (SHM's).

4.1 Conceitos Gerais

As estratégias de detecção e prognóstico de falhas em estruturas de engenharia (civil, mecânica ou aeroespacial) são conhecidas como monitoramento da integridade estrutural, do inglês Structural Health Monitoring (SHM). Segundo [Maio \(2011\)](#), existem duas maneiras de conduzir essas estratégias, a primeira é através do método direto, em que se desenvolve um modelo matemático para a estrutura em condição de falha e compara-se os dados gerados com os sinais da estrutura real, o que possibilita a identificação de danos em estruturas simples. Na segunda, e mais utilizada, compara-se os sinais da estrutura real em momentos distintos, e a divergência entre eles indicam a existência do dano.

O projeto de um SHM é composto por dois elementos distintos. O primeiro deles são os sensores (hardwares), utilizados para captação das propriedades físicas que serão utilizadas na detecção da falha, como sinais de vibrações, temperatura, pressão e corrente elétrica. O segundo elemento, são os algoritmos (softwares) capazes de manipular, tratar e utilizar esses sinais para identificação, classificação e quantificação dos danos, através das diversas ferramentas computacionais disponíveis para esse fim ([GOPALAKRISHNAN et al., 2011](#)).

Os SHMs, podem ser categorizados através do critério de classificação de danos, de acordo com sua capacidade de abrangência do problema. Inicialmente, utilizavam-se quatro níveis ([RYTTER, 1993](#)):

- Nível 1 – Fornece uma indicação quantitativa dos danos;
- Nível 2 – Fornece a localização dos danos;
- Nível 3 – Fornece a quantificação dos danos;
- Nível 4 – Fornece uma previsão da vida útil restante do equipamento.

Posteriormente, [Inmam \(2001\)](#) acrescentou mais três níveis para essa classificação, todos voltados para a utilização de materiais inteligentes:

- Nível 5 – Estruturas inteligentes para autodiagnóstico do dano estrutural;
- Nível 6 – Controle para formar um sistema de auto reparo estrutural;
- Nível 7 – Controle ativo e estruturas inteligentes para obtenção de um sistema simultâneo de controle e monitoramento.

Para implementação de um SHM, Segundo [Louzada \(2013\)](#), é necessário dividir o problema em quatro etapas distintas, como segue:

Etapa 1 – Essa etapa é direcionada para as estratégias de aquisição de dados da estrutura a ser modelada. Aqui, são definidos os parâmetros instrumentais (sensores, atuadores, tipos de malhas, etc) utilizados no projeto e a forma e intervalo de aquisição dos dados a serem coletados.

Etapa 2 – Processamento e padronização dos dados brutos adquiridos pelo método escolhido na etapa anterior. Geralmente, são aplicadas algumas técnicas (filtros, normalização, etc), a fim de obter a melhor interpretação dos dados obtidos, objetivando identificar-se de forma eficaz qualquer ruído produzido pelo sistema. Segundo [Oliveira \(2019\)](#), essa etapa é de suma importância na construção dos SHMs, pois, dados manipulados de maneira errada, influenciam diretamente na eficiência da implementação como um todo.

Etapa 3 – Transferência dos dados tratados para o sistema que realizará as análises e interpretação do comportamento dinâmico da estrutura. Nessa etapa, são definidas como a comunicação se dará (ex: cabos, wireless, ondas de rádio, etc).

Etapa 4 – São empregadas técnicas de classificação e interpretação de dados (técnicas de SHMs), gerando a resposta final do sistema. A escolha dos algoritmos utilizados é baseada no tipo de problema de cada situação, podendo variar, por exemplo, em: redes neurais, lógica fuzzy, algoritmos genéticos, entre outros.

O SHM utilizado nessa pesquisa, foi desenvolvido com base em dois algoritmos de reconhecimento de padrões. O algoritmo de seleção negativa para detectar a presença do dano dentre os padrões já conhecidos pelo banco de dados, e o algoritmo CLONALG para o aprendizado de danos desconhecidos, não contemplados pelos padrões conhecidos.

4.2 Evolução Histórica das Metodologias Inteligentes

Na sequência, em ordem cronológica, são apresentadas as principais pesquisas voltadas para o monitoramento da integridade de estrutural através das técnicas de inteligência computacional.

No trabalho de [Pandey e Barai \(1995\)](#), foi feita a aplicação da rede neural Perceptron multicamadas na detecção de danos em estruturas de pontes metálicas, através do algoritmo Backpropagation.

Em [Friswell, Penny e Garvey \(1998\)](#), foi aplicado o algoritmo genético na detecção de danos em um modelo numérico de uma viga e uma placa experimental, ambas através de dados de vibrações. O objetivo da pesquisa foi identificar o local dos danos e quantificar a gravidade deles.

Na pesquisa de [Lopes et al. \(2001\)](#), foi proposta uma metodologia que combina a técnica de impedância elétrica e a aplicação de um modelo de diagnóstico baseado em medições de vibrações com otimização, através de algoritmos genéticos. O objetivo do trabalho é a identificação e localização de falhas em elementos estruturais.

[Furtado \(2004\)](#) utilizou conceitos de redes neurais artificiais, através do algoritmo “Backpropagation”, para detectar e quantificar falhas em sistemas estruturais aeronáuticos.

[Tebaldi \(2004\)](#) combinou a técnica de análise da impedância elétrica com a aplicação de algoritmos genéticos na localização e quantificação de falhas em barras e virabrequim.

Santiago (2004) utilizou a combinação entre as técnicas de transformada de wavelet e redes neurais para diagnosticar e classificar falhas em máquinas rotativas, através de seus sinais de vibrações.

Giurgiutiu e Cuc (2005) utilizaram técnicas de impedância eletromagnética através de sensores piezoelétricos para o monitoramento da integridade estrutural de estruturas aeroespaciais.

Tebaldi, Coelho e Junior (2006) utilizaram uma combinação das técnicas de impedância elétrica e otimização por nuvem de partículas, afim de identificar e quantificar falhas em estruturas inteligentes.

Lee e Kim (2007) monitoraram o comportamento dinâmico de uma ponte através dos sinais de aceleração da estrutura. Os autores utilizaram um algoritmo baseado em redes neurais multicamadas para identificar e localizar as falhas.

Silva, Junior e Junior (2008) aplicaram uma técnica de monitoramento da integridade estrutural baseada nos sinais elétricos emitidos por pedaços de placas piezocerâmicas, coladas em estrutura leve do tipo viga. O objetivo da pesquisa foi detectar e localizar falhas através da mudança dos parâmetros estruturais do modelo experimental proposto.

Chandrashekhar e Ganguli (2009) utilizaram um sistema baseado em lógica fuzzy para detectar, localizar e quantificar falhas em um modelo numérico de uma viga em balanço, através das curvaturas das formas modais de vibrações.

Flynn e Todd (2010), utilizando-se de algoritmos genéticos, propuseram uma metodologia para otimização dos resultados de detecção de danos em uma placa fina, através do ideal posicionamento do conjunto de sensores e atuadores piezoelétricos.

Wang e Tang (2009), através da análise da mudança das curvas de impedância piezoelétrica, desenvolveram um método para identificar, localizar e quantificar falhas em componentes estruturais.

Franco (2009) utilizou uma rede de sensores e atuadores piezoelétricos, acopladas na superfície de uma placa estrutural, afim de monitorar a integridade estrutural do elemento através da metodologia das ondas de Lamb. O objetivo da pesquisa foi a identificação e caracterização de falhas estruturais.

Malange (2010) trabalhou com um sistema denominado Rede Neuro-Fuzzy-Wavelet para detecção e classificação de distúrbios na rede de distribuição elétrica.

Chen et al. (2010) desenvolveram um SHM baseado na transformada de Wavelet para monitorar a integridade de uma ponte e detectar falhas estruturais através de seus sinais de vibrações.

Shen et al. (2011) utilizaram um SHM baseado em rede neural probabilística para diagnosticar danos em um modelo de elementos finitos, que caracterizou a asa de uma aeronave.

Arangio, Bontempi e Ciampoli (2011) desenvolveram um sistema capaz de monitorar, detectar e diagnosticar falhas ao longo da extensão de uma ponte suspensa, através de solicitações diversas, como ação do vento e carregamento do tráfego. Os autores utilizaram um algoritmo baseado em redes neurais bayesianas, que operou através do monitoramento da resposta de vibrações ambientais sob a estrutura.

Gonzalez (2012) utilizou um SHM baseado em uma metodologia híbrida, com

técnica de impedância eletromecânica, para detecção de danos em um painel aeronáutico. O autor aplicou a técnica de agrupamento Fuzzy c-means para entender e considerar o efeito da temperatura nos sinais e a análise de variância (ANOVA) para tornar o processo de detecção mais robusto.

Song, Sezen e Giriunas (2012) desenvolveram uma pesquisa experimental em dois edifícios residenciais, através da remoção de quatro colunas de sustentação do primeiro andar de cada edificação. Os autores investigaram o desempenho estrutural antes da demolição programada, através de análises estáticas lineares e dinâmicas não lineares.

Turra et al. (2013) utilizaram uma metodologia baseada em impedância eletromecânica, através de medidas da norma H2, RMSD (Root-Means-Square Deviation), IFM (Índice de Falha Métrica) e CCDM (Correlation Coefficient Deviation) para detecção de danos em placas de alumínio.

Wang et al. (2013) propuseram a utilização de um algoritmo genético multicamadas para detecção de falhas em uma ponte de aço treliçada.

Lima (2013) trabalhou com um método de detecção e classificação de distúrbios de tensão em sistemas de distribuição de energia elétrica. O autor utilizou os conceitos dos sistemas imunológicos artificiais, através do algoritmo de seleção negativa.

Souza et al. (2014) apresentaram um SHM baseado em redes neurais artificiais (ARTMAP-Fuzzy) para identificação e caracterização de falhas estruturais em um edifício.

Lima et al. (2014) apresentaram um SHM baseado em sistemas imunológicos artificiais com seleção negativa para identificação e classificação de danos em estruturas aeronáuticas.

Souza et al. (2015) propuseram um estudo comparativo entre três técnicas para o monitoramento da integridade estrutural de um trator agrícola. Os autores utilizaram como ferramentas inteligentes: K-Means, Fuzzy C-Means e rede neural artificial de Kohonen, afim de identificar e caracterizar danos na estrutura.

Silva (2016) desenvolveu um sistema inteligente para o monitoramento da integridade estrutural de um trator agrícola, através dos conceitos de redes neurais artificiais. O comportamento estrutural foi obtido através de um modelo numérico e a rede neural utilizada para identificação e classificação dos danos foi do tipo ARTMAP-Fuzzy.

Lima et al. (2017) apresentaram uma metodologia para diagnóstico de falhas em estruturas aeronáuticas através do algoritmo Wavelet-Artificial Immune System (WAIS) e um sistema imunológico artificial de seleção negativa. Para identificação e classificação das falhas, são utilizados os sinais de vibrações da estrutura.

Chaves et al. (2017) desenvolveram um SHM para identificar e caracterizar falhas em uma estrutura predial através da aplicação de redes neurais artificiais do tipo ARTMAP-Fuzzy.

Lima (2018) trabalhou com três metodologias híbridas inteligentes para monitoramento e diagnóstico de falhas em dois modelos numéricos: um edifício e um trator agrícola. As técnicas foram baseadas em sistemas imunológicos artificiais, redes neurais artificiais e transformada wavelet, através dos algoritmos Imuno-Wavelet, Neural-Neural e Neural-Imuno.

Outa (2019) trabalhou com duas metodologias para prognose e detecção de falhas em rotores dinâmicos através dos seus sinais de vibrações. O autor utilizou regressão

linear e sistemas imunológicos artificiais com seleção negativa para identificar, quantificar e classificar as falhas no sistema rotativo.

Oliveira (2019), tendo como intuito detectar, localizar e quantificar falhas estruturais em aeronaves utilizando os sistemas imunológicos artificiais (SIA) desenvolveu uma metodologia baseada no monitoramento da integridade estrutural (SHMs), com foco em técnicas de computação inteligente. Foram empregados dois algoritmos imunológicos artificiais: o algoritmo de seleção negativa, e o algoritmo de seleção clonal. Segundo a autora, o aprendizado continuado detecta o dano desconhecido, atualiza o conhecimento do sistema e melhora os resultados em uma próxima análise, aumentando gradativamente a taxa de acerto, proporcionando melhoria e robustez ao algoritmo.

Gonçalves et al. (2021) utilizaram um SHM baseado em sistemas imunológicos artificiais com seleção negativa para detectar falhas em motores de combustão com combustíveis adulterados. Os resultados demonstraram a influência da contaminação do combustível na resposta dinâmica estrutural, e o sistema proposto foi capaz de identificar e classificar os danos de maneira eficiente.

Lourenço et al. (2021) utilizaram a aplicação de uma das técnicas de bioengenharia para monitorar a integridade de um sistema dinâmico rotativo. Os autores utilizaram a rede perceptron, que permite a detecção de falhas do sistema, e auxilia na escolha da localização do melhor sensor a ser utilizado no sistema dinâmico.

5 Sistema Imunológico Biológico

O desenvolvimento de sistemas imunológicos artificiais, são baseados nos conceitos biológicos de defesa dos seres vivos, portanto, é de suma importância a compreensão de seu funcionamento. Neste capítulo serão apresentados os principais conceitos dos sistemas imunológicos biológicos - SIB, com ênfase nos processos utilizados no desenvolvimento dos algoritmos artificiais.

5.1 Princípios Fundamentais

Derivada do Latim *immunis*, a palavra *imunologia* significa "isento de carga", e nesse contexto, "carga" refere-se à uma enfermidade qualquer. Quando o organismo adquire resistência à uma doença infecciosa, considera-se que ele está imune, e o status dessa resistência é denominado "imunidade". Esse tema já entregou pesquisas diversificadas e de extrema importância para a humanidade, como o desenvolvimento de vacinas, sínteses de anticorpos e seleção clonal (MACHADO, 2005).

O sistema imunológico biológico constitui-se de uma rede de células, tecidos e órgãos que, juntos, se empenham para proteger o corpo de ataques de agentes externos maliciosos, como fungos, bactérias, micróbios e parasitas. Esse sistema é incrivelmente complexo e pode reconhecer, combater e gravar milhões de inimigos diferentes. Para isso, as células são agrupadas em conjuntos e subconjuntos formando a rede de comunicações dinâmicas, que é uma espécie de nuvem de abelha em torno da colméia, utilizada para receber e transmitir informações dos agentes infecciosos. Uma vez que, as células imunes recebem o alarme, são ativadas e começam a desenvolver a estratégia de combate e produzir as substâncias capazes de eliminar a infecção (HEALTH, 2007).

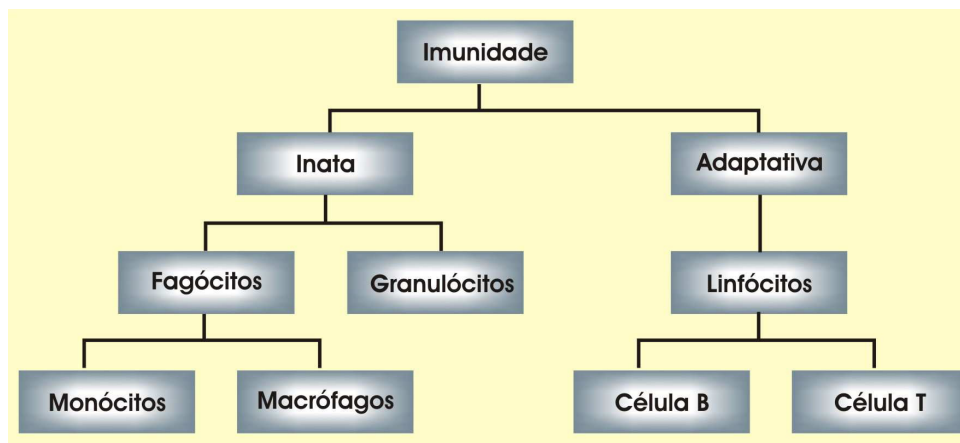
5.2 Organização Estrutural

O sistema imunológico global, é o principal mecanismo de defesa contra os ataques infecciosos nos seres humanos. Esse sistema possui dois mecanismos de atuação, um que responde de maneira rápida e eficiente, conhecido como sistema imune inato, e outro que tem atuação lenta e duradoura, que é o caso do sistema imunológico adaptativo (TIMMIS, 2000).

- **Sistema imune inato:** é a primeira linha de defesa do organismo, atuando através de barreiras físicas e químicas, de maneira semelhante para qualquer tipo de ameaça. Por essa característica de atuação, na maioria das vezes, sua ação é insuficiente, porém, fundamental para que o sistema adaptativo tenha tempo de preparar sua resposta (PAULA, 2004).
- **Sistema imunológico adaptativo:** tem atuação mais específica e eficiente a cada tipo de patógeno, contudo, mais demorada. Nesse sistema, são produzidos anticorpos que, além de combater as infecções, são capazes de armazenar o conhecimento e responder de maneira mais rápida e melhorada à novas exposições do mesmo agente (PAULA, 2004).

De modo geral, esses sistemas de defesa (inato e adaptativo) dependem da atuação das células brancas, também conhecidos como leucócitos (SILVA, 2001). A Figura (18) representa o fluxograma de atuação do sistema imunológico, nota-se que, a imunidade inata utiliza-se principalmente de macrófagos e granulócitos, enquanto a imunidade adaptativa é mediada pelos linfócitos.

Figura 18 – Esquema hierárquico do SIB.



fonte: (MACHADO, 2005)

De maneira sucinta, serão apresentadas as principais funções das células que compõem o SIB (PAULA, 2004; SILVA, 2001; MACHADO, 2005).

Fagócitos: são responsáveis por expor os antígenos para as células linfóides, e pela ingestão de diversos agentes invasores como micróbios, células e partículas desconhecidas. Se apresentam mais efetivamente no SHI em forma de monócitos e macrófagos.

Monócitos: Células que se movimentam através do sangue, tonando-se macrófagos ao adentrarem nos tecidos.

Macrófagos: atuam, principalmente, no desenvolvimento de respostas imunológicas, através da coleta e ingestão de resíduos. São responsáveis por fornecer informações da infecção aos linfócitos.

Granulócitos: atuam na ingestão de patógenos e no combate aos parasitas.

Linfócitos: são as principais células que compõem os sistema imune adaptativo, e tem como função o controle das atividades do sistema imunológico, ou seja, por intermédio dessas células, o sistema realiza o reconhecimento de patogenias, define a melhor estratégia de respostas imunológicas e armazena a memória imunológica. A maioria dessas células permanecem inativas no organismo, sendo ativadas somente quando houver interação com algum tipo de estímulo antigênico. Os linfócitos se diferem, principalmente, em células B e células T.


Celulas B: tem importante papel na imunidade humoral, sendo responsáveis, principalmente, pela produção de anticorpos contra antígenos.

Celulas T: atua diretamente sobre células infectadas ou danificas pela ação de vírus, bacterias, ou parasitas, induzindo-as a autodestruição.

5.3 Funcionamento do sistema imunológico biológico

As células e moléculas que compõem o organismo imunológico biológico, trabalham de maneira harmônica e organizada, através do reconhecimento de padrões, aprendizado e neutralização dos agentes infecciosos, conhecidos como antígenos (LIMA, 2016). Essas etapas compõem a resposta imunológica humana e estão representadas de forma simplificada na Figura (19).

Figura 19 – Funcionamento básico do sistema imunológico biológico



fonte: (LIMA, 2016)

Ao deparar-se com um agente infeccioso (Figura 19 - I), o sistema imunológico é ativado e inicia-se o processo de identificação dos antígenos, que pode acontecer de duas formas:

Opção 1: se o antígeno for uma ameaça já conhecida pelo organismo, a resposta imune adaptativa é iniciada (passo VII) e o processo de reconhecimento dos invasores acontecem pelos linfócitos de memória, armazenados no corpo.

Opção 2: o antígeno é desconhecido, e a resposta imune inata atua (passo II) afim de identificar e sinalizar a célula infectada para que o sistema adptativo possa atuar, ou seja, aprender e gerar os anticorpos necessários para o combate. Nessa primeira etapa, os antígenos são ingeridos, fragmentados pelas células dendrítica, transformando-se em peptídeos antigênicos. Os fragmentos de peptídeos se fundem com as moléculas MPC (passo III) e são apresentados aos linfócitos T, iniciando-se o processo de reconhecimento (passo IV). As células T possuem moléculas receptoras e são capazes de reconhecer diferentes agentes infecciosos fundidos (MHC/peptídeos) e diferenciá-los das células próprias, esse procedimento é conhecido como próprio/não próprio, em que diferencia-se as células sadias dos agentes infecciosos. No passo V, após o reconhecimento dos antígenos, os linfócitos T são ativados e liberam linfocina, que são agentes químicos capazes de sinalizar a presença de

um agente maligno no organismo. As linfocinas liberadas impregnam nos antígenos (passo VI), tornando-os conhecidos pelo sistema imunológico, possibilitando o reconhecimento, aprendizado e combate através dos linfócitos B (passo VII).

Após o reconhecimento do antígeno (passo II ou VII), inicia-se o processo de aprendizado (passo VIII). Nesse passo, também conhecido como seleção clonal, os linfócitos passam por um procedimento de clonagem e hipermutação, formando um aglomerado de linfócitos B. Ocorre então, o processo de diferenciação (passo IX), em que os linfócitos B com maior grau de afinidade são direcionados para o grupo de memória, e os com menor afinidade são ativados, transformando-se em plasmócitos (passo X), que geram os anticorpos de combate aos linfócitos. No passo XI, os agentes infecciosos são neutralizados e a ameaça destruída. No último passo (XII), ocorre a atualização dos linfócitos de memória, ou seja, as células separadas no processo de diferenciação, substituem as que fazem parte da memória, porém, com menor afinidade. Com isso, o processo é continuamente melhorado e a resposta acontece cada vez mais rápida, quando há recorrência da ameaça.


Os conceitos apresentados nessa seção, ou seja, o reconhecimento de padrões e aprendizado, embasam os conceitos artificiais apresentados nesse trabalho, nas seções seguintes.

6 Sistema Imunológico Artificial

6.1 Introdução

Diversos sistemas biológicos são utilizados como fonte de inspiração no desenvolvimento de soluções tecnológicas, que são baseados em uma sequência simplificada e detalhada de regras que entregam uma solução global para o problema. Esses procedimentos buscam soluções básicas para execução de tarefas específicas, através de procedimentos sistemáticos, sequenciais e iterativos (SILVA, 2001). Alguns exemplos de sistemas compostos por vários elementos simplificados, que através da cooperatividade realizam tarefas complexas, podem ser encontrados na natureza, que é o caso da colônia de formigas, o sistema nervoso central e o sistema imunológico, ilustrados na Figura 20.

Figura 20 – Sistemas naturais. (a) colônia de insetos. (b) neurônios. (c) linfócitos



fonte: (SILVA, 2001)

Segundo Machado (2005), é crescente o interesse por pesquisas que utilizam conceitos, fenômenos e mecanismos naturais como referência, para soluções computacionais. O autor cita a aplicação dessas teorias no desenvolvimento de redes neurais artificiais, computação evolutiva e molecular.

Outra linha da teoria de sistemas inteligentes, que se despontou a partir do ano de 1996, é denominado sistemas imunológicos artificiais (SIA). Os SIA, possuem a habilidade de detecção de mudanças de comportamento de padrões e são frequentemente utilizados para realização de diagnósticos ou detecção de falhas. Além disso, esses sistemas possuem aprendizagem continuada, ou seja, são capazes de aprender novos padrões de anomalias, sem que a memória seja reiniciada (LIMA, 2016).

Dentre as diversas áreas de aplicação dos SIA, destacam-se: otimização de processos, aprendizagem de máquina, reconhecimento de padrões, segurança computacional, detecção de danos e anomalias, análise de dados, entre outras (SILVA, 2001).

6.2 Algoritmo de seleção negativa (ASN)

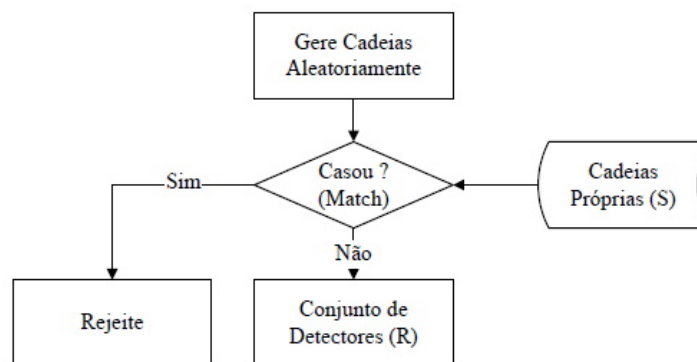
O algoritmo de seleção negativa, é um modelo computacional inspirado no processo de reconhecimento de padrões, executado pelos sistemas imunológicos biológicos. Essa técnica foi desenvolvida por Forrest et al. (1994), e baseada no princípio de seleção negativa das células T, que diferenciam as células saudáveis das infectadas ou danificadas, conhecida como próprias e não-próprias.

As etapas de implementação do ASN compreendem duas fases (SILVA, 2001):

- sensoriamento:
 - define o conjunto de cadeias próprias (s), que representam o funcionamento normal do problema (sem defeito);
 - gerar cadeias variadas (aleatoriamente) e verificar a afinidade (match) entre elas e as cadeias próprias. Em caso de afinidade superior ao estipulado, rejeita-se a cadeia, caso contrário, essas cadeias passam a compor o conjunto de detectores, e farão a detecção e classificação de falhas da etapa de monitoramento;

A Figura 21 ilustra as etapas do sensoriamento executadas pelo ASN.

Figura 21 – Fluxograma do sensoriamento do ASN



fonte: (LIMA, 2016)

- monitoramento:
 - nessa fase, monitora-se os dados com intuito de identificar mudanças de comportamento, e então classifica-las de acordo com os detectores. Para isso, compara-se a afinidade de cada uma dessas cadeias protegidas (S) e o conjunto de detectores (R). Sendo a afinidade superior ao limiar estabelecido, um elemento não próprio é identificado e pode ser classificado.

A Figura 22 ilustra a etapa de monitoramento, executada pelo ASN.

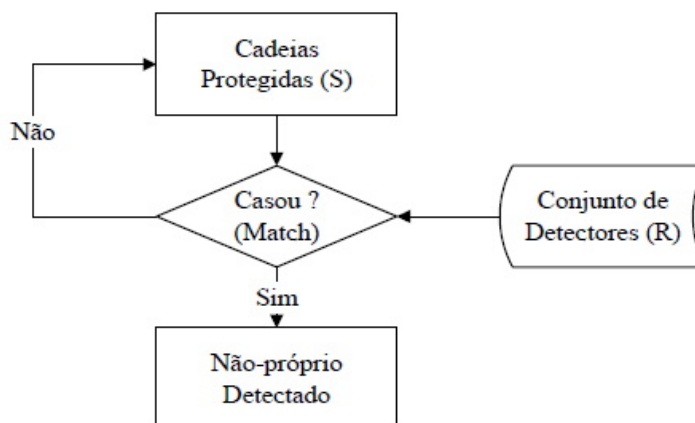
Segundo (LIMA, 2016), os ASN possuem cadeias que são classificadas em antígenos (Ag) e linfócitos (Ab), e representam padrões, por meio de estruturas de dados. O Ag representa o sinal que deve ser analisado, e esta representado pela Equação 6.1. O Ab, é o conjunto de detectores expressos na Equação 6.2.

$$Ag = Ag_1, Ag_2, Ag_3, Ag_4, \dots, Ag_L \quad (6.1)$$

$$Ab = Ab_1, Ab_2, Ab_3, Ab_4, \dots, Ab_L \quad (6.2)$$

nas Equações (6.1) e (6.2), "L" representa a dimensão do espaço de antígenos e linfócitos, respectivamente.

Figura 22 – Fluxograma do monitoramento do ASN



fonte: (LIMA, 2016)

6.3 Critério de casamento e taxa de afinidade

A afinidade das cadeias (A_g) e (A_b) são avaliadas de acordo com um critério denominado casamento, que tem o mesmo sentido de combinação, e pode ser classificado como casamento perfeito ou parcial. O casamento perfeito, é considerado quando as duas cadeias em análise são idênticas, já no casamento parcial, como o nome induz, apenas parte dos padrões analisados são compatíveis, e a grandeza que mensura essa compatibilidade é conhecida como taxa de afinidade, definida na Equação 6.3 (BRADLEY; TYRRELL, 2002; LIMA, 2013).

$$TAf = \left(\frac{An}{At} \right) \times 100 \quad (6.3)$$

em que, TAf é a taxa de afinidade, An o número de cadeias próprias e At o número total de cadeia (próprias e não-próprias).

Nesse trabalho, utilizou-se o conceito de casamento parcial, e a definição do desvio ou tolerância aconteceu de forma individual, em cada posição i do vetor, o que permitiu a verificação do casamento de cada posição, conforme Equação 6.5 (LIMA, 2013).

$$\underline{Ab}_i \leq Ag_i \leq \overline{Ab}_i \quad (6.4)$$

sendo:

Ag_i : valor nominal da posição i do antígeno (padrão em análise);

\underline{Ab}_i : valor nominal da posição i menos o desvio adotado no anticorpo (padrão detector);

\overline{Ab}_i : valor nominal da posição i mais o desvio adotado no anticorpo (padrão detector).

Se o valor nominal Ag_i apresentar-se dentro do intervalo da Equação 6.4, significa que houve casamento para aquela posição. Afim de quantificar a afinidade total entre os padrões, repete-se esse procedimento, posição a posição, conforme Equação 6.5 (BRADLEY; TYRRELL, 2002).

$$Af_T = \frac{\sum_{i=1}^L Pc}{L} \times 100 \tag{6.5}$$

sendo:

Af_T : percentual de afinidade entre os padrões;

$\sum_{i=1}^L Pc$: soma das posições casadas;

Pc : posições casadas;

L : quantidade total de posições;

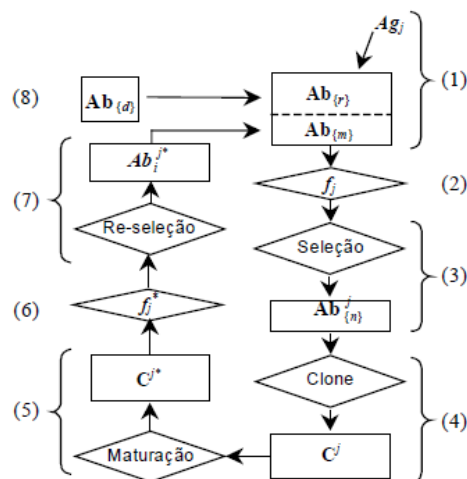
Assim, se Af_T for maior ou igual $T Af$, significa que ocorreu casamento entre os dois padrões, ou seja, os sinais são considerados como parcialmente iguais e, identifica-se um comportamento ou modo de operação estrutura analisada. Caso contrário, uma condição desconhecida de dano é detectada e o ASN não consegue identifica-la, classifica-la e quantifica-la. Nesse caso, utilizou-se o modulo de aprendizado realizado pelo algoritmo de seleção clonal, apresentado na seção 6.4.

6.4 Algoritmo de seleção clonal - CLONALG

O algoritmo CLONALG (Clonal Selection Algorithm), foi desenvolvido por [Castro e Zuben \(2000\)](#), e inicialmente, proposto para resolver problemas de aprendizado de máquina e reconhecimento de padrões, em que, a população de anticorpos é utilizada para aprender e reconhecer um conjunto de antígenos. Posteriormente, estendeu-se suas aplicações aos projetos de otimização ([SILVA, 2001](#)).

A versão inicial do programa (aprendizado e reconhecimento de padrões), está ilustrado na Figura 23.

Figura 23 – Fluxograma de funcionamento CLONALG



fonte: ([SILVA, 2001](#))

A descrição do algoritmo CLONALG, com embasamento dos autores [Castro e Timmis \(2002\)](#), [Castro e Zuben \(2000\)](#), [Silva \(2001\)](#), está apresentada a seguir:

1. Gera-se uma população aleatória de linfócitos ($Ab = Ab_{(m)} + Ab_{(R)}$). Em que $(M + R) = n$, e atribui-se um "n" para cada antígeno (Ag_j);
2. Cria-se um vetor de afinidade (f_j). Para isso, cada antígeno (Ag_j) é comparado com toda a população de linfócitos (Ab), verificando-se a afinidade entre as duas cadeias.
3. A partir do conjunto (Ab), cria-se um subconjunto (Ab_n^j), através da seleção dos linfócitos com maior afinidade f_j , em relação a (Ag_j).
4. Os linfócitos com maior taxa de afinidade, selecionados no passo 3, irão se proliferar, em um processo conhecido como "clonagem". Essa proliferação acontece, proporcional ao grau de afinidade, ou seja, quanto maior a afinidade, maior será o número de clones da população C^j .
5. Os clones C^j são maturados, formando a população C^{j*} . Para isso, cada anticorpo da população C^j , passa por um processo de mutação, com taxa inversamente proporcional à sua afinidade.
6. Verifica-se a afinidade (f_j^*) entre os clones mutados (C^{j*}) e os antígenos (Ag_j).
7. Seleciona-se os melhores (com maior afinidade) anticorpos da população (C^{j*}), formando a subpopulação (Ab_i^{j*}). Os melhores linfócitos dessa subpopulação, são candidatos a compor os linfócitos de memória ($Ab_{(m)}$), e isso acontece quando a afinidade de (Ab_i^{j*}) é superior à de algum linfócito que compõe a memória.
8. Substitui-se d anticorpos de $Ab_{(R)}$ por novos (com maior afinidade) indivíduos de $Ab_{(d)}$. Esse processo de substituição de antígenos, é também conhecido, como geração.

Ao final do processo iterativo, o conjunto de memórias gerados possui alta taxa de afinidade, e pode ser utilizado para detectar e classificar a falha aprendida no processo de seleção clonal ([OLIVEIRA, 2019](#)).

No passo 4, a quantidade de clones (N_c) da população C^j , gerados para cada linfócito i , é dada pela Equação 6.6 ([SILVA, 2001](#)):

$$N_c = \sum_{i=1}^n \text{round}\left(\frac{\beta \times N}{i}\right) \quad (6.6)$$

em que:

β : fator multiplicativo, que varia entre 0 e 1;

N : quantidade total de anticorpos de Ab ;

$\text{round}(\cdot)$: operador responsável por arredondar o resultado do parenteses para o inteiro mais próximo;

A taxa de mutação (passo 5) dos clones (α), pode ser expressa pela Equação 6.7 (SILVA, 2001).

$$\alpha = \exp(-\rho \times f^n) \quad (6.7)$$

sendo: ρ parâmetro de controle (amortecimento) da função exponencial, f^n é o valor normalizado da função f_j , expresso pela Equação 6.8.

$$f^n = \frac{f}{f_{max}} \quad (6.8)$$

Finalmente, o processo de mutação desenvolvido por cada clone, é dado pela Equação 6.9 (FRANÇA; ZUBEN; CASTRO, 2005).

$$m = \text{round}(\alpha \times N(0, 1)) \quad (6.9)$$

em que:

m : quantidade de mutações de cada clone;

$N(0, 1)$: variável randômica gaussiana de média zero e desvio padrão $\sigma = 1$.


7 Metodologia Experimental

Nesse capítulo, apresentou-se a metodologia utilizada para aquisição de informações (dados), ou seja, o aparato experimental. Apresenta-se também, a metodologia proposta para o diagnóstico de falhas em rotores dinâmicos, através de conceitos de algoritmo imunológico artificial com aprendizado continuado.

7.1 Caracterização do experimento

O rotor dinâmico utilizado para aplicação do reconhecimento de padrões e do sistema imunológico desse trabalho, representado na Figura 24, foi baseado no projeto desenvolvido por H. H. Jeffcott no ano de 1919, conforme apresentado na Seção 2.1.2.

Figura 24 – Bancada experimental para aquisição de dados



fonte: (Autoria própria)

A composição da bancada experimental (Figura 24), está enumerada e corresponde aos itens:

1. Motor elétrico WEG de 3 CV trifásico 220 V, frequência 60 Hz;
2. Acoplamento flexível Rex Omega tipo Standard;
3. Carcaça de motobomba hidráulica Mark com mancal, adaptada para acoplamento do disco de aço;
4. Disco de aço com diâmetro de 180 mm, 10 mm de espessura e 48 furos;
5. Inversor de frequência Schneider Altivar 312 (alternância 0 a 60 Hz), dentro do quadro de comando;

A bancada experimental foi desenvolvida com o intuito de simular uma condição real de campo, considerando-se o acoplamento de um motor elétrico a uma motobomba hidráulica. A utilização do acoplamento flexível permite ajustes e elimina problemas de desalinhamento e folgas. O princípio metodológico do experimento permite medir a vibração da carcaça adaptada, variando os limites dos parâmetros do acoplamento flexível, entre o motor elétrico e o mancal. A variação da velocidade do motor elétrico, feita pelo inversor de frequência, é de 2Hz até 60 Hz a cada 2 Hz.

Para monitoramento e aquisição dos dados, utilizou-se um microcontrolador Arduino modelo Uno R3 (Figura 25 - parte inferior), composto por microcontrolador ATmega328 (datasheet), 14 pinos de entrada/saída digital, 6 entradas analógicas, um cristal oscilador de 16MHz, uma conexão USB, uma entrada de alimentação, uma conexão ICSP e um botão de reset. O sensor utilizado na aquisição dos sinais foi o MPU-6050 (Figura 25 - parte superior) com seis graus de liberdade, três eixos para o giroscópio (range: ± 250 , 500, 1000, 2000 $^{\circ}/s$) e três eixos para o acelerômetro (range: ± 2 , 4, 8, 16 g), tensão de operação 3-5 V.

Figura 25 – Sistema de aquisição de dados



fonte: (Autoria própria)

Na etapa de monitoramento e aquisição de dados, afim de possibilitar a detecção e caracterização de falhas, procedeu-se as seguintes fases:

- Caracterização dinâmica do sistema em estado normal de operação (sem adição de massas de desbalanceamento);
- Desbalanceamento com massas em diversas configurações, conforme Figura 28;


Cada fase ocorreu de forma distinta, através de uma série de atividades que contemplam a aquisição, tratamento e processamento dos sinais de vibrações. Para isso, utilizou-se algumas ferramentas computacionais (algoritmos), descritas nas seções subsequentes.

7.2 Metodologia de aquisição de dados

Considerando-se que o objetivo principal dessa pesquisa é identificar e quantificar danos em máquinas rotativas através de um projeto de SHM robusto e confiável, é importante a compreensão de seu comportamento vibracional, identificando os pontos mais suscetíveis ao ruído. Isso deve ser feito de forma estratégica, através do correto posicionamento dos sensores em locais específicos, o que possibilita o mapeamento das diferentes características da variação da energia rotativa, transmitida pelo motor ao acoplamento flexível.

Segundo Brito et al. (2002), o posicionamento dos sensores de vibrações deve ocorrer em locais rígidos, tanto do motor como do redutor, em posições verticais, horizontais ou axiais. Nessa pesquisa, os dados foram coletados através do posicionamento dos acelerômetros sobre a carcaça adaptada em três pontos diferentes, indicados na Figura 26 (P1, P2 e P3), de acordo com a direção de cada eixo (x, y e z).

Figura 26 – Posicionamento dos sensores



fonte: (Autoria própria)

O sensor posicionado na posição P1, monitora o comportamento da vibração transmitida do motor para a carcaça adaptada, através do acoplamento flexível. Em P2, têm-se o comportamento da junção entre o redutor e a flange. Na posição P3, demonstra-se o comportamento da vibração da fixação da carcaça adaptada à base da estrutura de sustentação.


Cada sensor foi analisado de forma distinta, através de sua posição e coordenada cartesiana específica, o que gerou um banco de dados com sinais próprios (sistema sem danos) e um banco com sinais não próprios (sistema com danos). Cada sinal de vibração foi composto por 400 pontos (aceleração).

Para a constituição do banco de dados com sinais livres de falhas (sinais próprios), todos os parafusos da bancada encontravam-se apertados e não houve adição de nenhuma massa de desbalanceamento no disco de aço, o que gerou uma matriz 3000x400. Para isso,

considerou-se um intervalo de frequência que variou de 2 Hz a 60 Hz, em passos de 2 Hz e 100 sinais para cada frequência.

O projeto de aquisição dos sinais não-próprios consistiu na indução de 14 danos, dois deles provocados pela retirada de parafusos da junta flexível, caracterizados como estudo 1 e 2. No estudo 1, retirou-se 2 parafusos, um oposto ao outro, na posição da seta (a), demonstrada na Figura 27 e, no estudo 2, retirou-se um terceiro parafuso, perpendicularmente aos retirados anteriormente, em formato de "Y".


Figura 27 – Posicionamento de retirada dos parafusos - estudo 1 e estudo 2



fonte: (Autoria própria)

Os estudos 3 a 14, ocorreram com a presença de todos os parafusos do sistema e através da adição de massas de desbalanceamento de 10 g, compostas por um conjunto de parafuso, porca e arruela. Essas massas foram distribuídas nas posições 1 a 8, conforme demonstrado na Figura 28.

Figura 28 – Configuração de distribuição das massas de desbalanceamento



fonte: (Autoria própria)

Os locais em que as massas de desbalanceamento foram adicionadas, conforme o estudo realizado, estão descritos na Tabela 2.

O banco de dados detectores (não-próprios), constitui-se de 14 matrizes 3000x400, que foram compactadas em uma matriz 42000x400. Para caracterizar tais matrizes, adicionou-se as massas no disco conforme posições apresentadas na Figura 28 e especificadas na Tabela 2, o que gerou determinado desbalanceamento do sistema. A variação de frequência ocorreu em um intervalo de 2 Hz a 60 Hz, com passos de 2 Hz e 100 sinais para cada frequência.

Note que, o procedimento de aquisição de dados entregou, para cada sensor, dois bancos de configuração padrão, sendo o primeiro formado por uma matriz 3000x400 de

Tabela 2 – Distribuição das massas de desbalanceamento.

Estudo	Posição							
	1	2	3	4	5	6	7	8
3	x							
4	x	x						
5	x	x	x					
6	x	x	x	x				
7					x			
8					x	x		
9				x	x	x		
10				x	x	x	x	
11	x				x			
12	x				x	x		
13	x				x	x	x	
14	x				x	x	x	x

fonte: (Autoria própria)

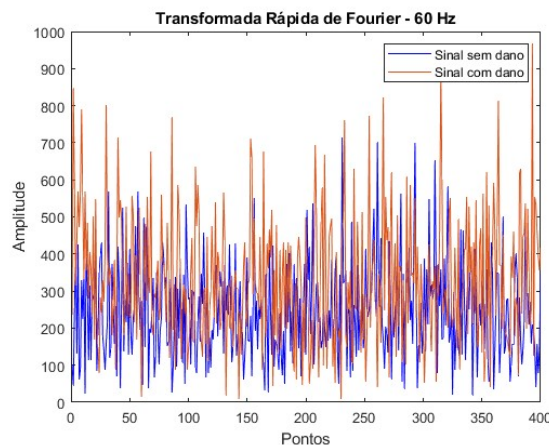
sinais bons, e o segundo, formado por uma matriz 42000x400 de sinais com distúrbios, ou seja, situação de falha.

7.2.1 Coleta, Processamento e Transmissão dos Sinais

A comunicação entre o sistema de aquisição de dados (sensor e arduíno) e o computador, deu-se através do software Arduino Integrated Development Environment, a partir do upload dos algoritmos desenvolvidos para esse fim.

O sensor MPU6050 captou sinais de aceleração nos eixos coordenados x, y e z, de acordo com o posicionamento descrito na Seção 7.2. Esses sinais são salvos em formato de texto, o software GNU Octave é utilizado para convertê-los em deslocamento e posteriormente aplicar a Transformada Rápida de Fourier, conforme descrito na Seção 3.4.1.1.2. Os valores resultantes foram salvos em formato de matrizes e, alguns estudos, plotados em espectros de frequência na Seção 8.2. Na Figura 29 tem-se uma representação amostral do espectro completo (400 pontos).

Figura 29 – Espectro de frequência - sinal completo.



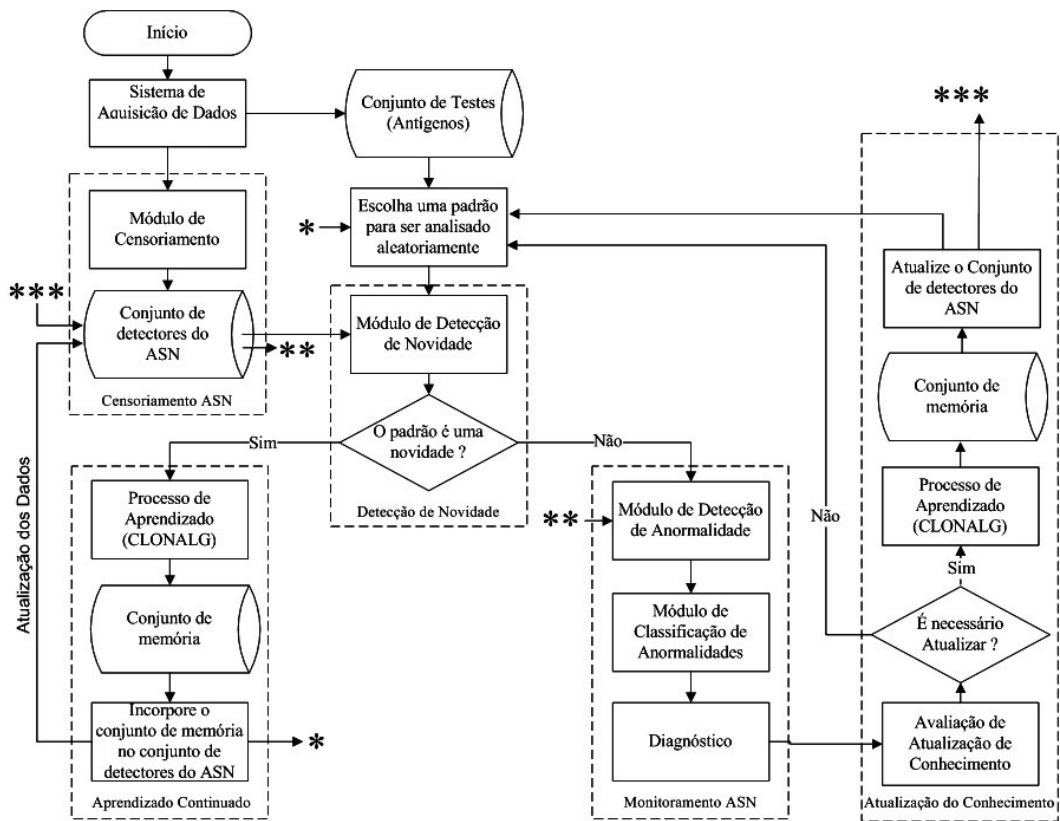
fonte: (Autoria própria)

Os sinais plotados em azul (Figura 29) representam a amplitude do ruído do sistema sem falha para a frequência de 60 Hz, medida pelo sensor 3. Em vermelho, tem-se os sinais do sistema desbalanceado, conforme estudo 3, sensor 3 e 60 Hz de frequência.

7.3 Implementação do SHM

Para o projeto e implementação do sistema de diagnóstico de falhas em rotores com aprendizado continuado, proposto nesse trabalho, utilizou-se o software GNU Octave. Os conceitos envolvidos nessa etapa, basearam-se no processo de reconhecimento de padrões e aprendizado, realizado no sistema imunológico biológico (Seção 5.3). Para detecção de falhas, utilizou-se o algoritmo de seleção negativa (ASN), apresentado na Seção 6.2, e para o aprendizado continuado, utilizou-se o algoritmo CLONALG, representado na Seção 6.4. O SHM apresentado, é composto pelo sistema de aquisição de dados, descrito na Seção 7.2, e mais cinco módulos, todos ilustrados na Figura 30.

Figura 30 – Fluxograma do SHM



fonte: (LIMA, 2016)

7.3.1 Censoriamento ASN

No procedimento de diagnóstico, inicialmente, executa-se o aprendizado do sistema, denominado módulo de censoriamento. Essa fase contempla a aquisição dos dados e são definidos os detectores próprios e não-próprios, que formam o conjunto de detectores, utilizados para tomada de decisão na fase de monitoramento.

No caso do sistema dinâmico, proposto nessa pesquisa, os sinais próprios (características normais de operações) são obtidos de acordo com o método exposto na Seção 7.2.

De posse dos detectores próprios, executou-se novamente o módulo de sensoriamento, uma vez para cada dano, afim de se obter o banco de dados do funcionamento com falha. Nessa fase, ocorre o janelamento, ou seja, os dados não-próprios são comparados, janela por janela, com os detectores próprios. Se ocorre o casamento dos dados, o vetor é descartado, caso contrário, detecta-se uma falha e o vetor é armazenado. Esse procedimento está ilustrado na Figura 21.

O conjunto de dados, próprios e não próprios, são utilizados nas fases de sensoriamento e monitoramento. Para constituição do banco de detectores, podem ser utilizados no máximo 30% desses dados, pois, analogamente, nos sistemas biológicos, esse percentual representa a quantidade total de detectores distribuídos em relação aos agentes infecciosos. (LIMA, 2013; FORREST et al., 1994).

7.3.2 Detecção de novidade

Na fase de monitoramento, criou-se um conjunto de dados (antígenos), que são compostos por todos os sinais da base de dados. Em seguida, selecionou-se aleatoriamente o sinal a ser testado, que foi submetido ao módulo de detecção de novidades. Compara-se esse sinal, com os detectores do ASN, havendo casamento, significa que o sinal é conhecido, sendo direcionado para o módulo de monitoramento. Caso o sinal seja desconhecido (novidade), então, a etapa de aprendizado é acionada e executada através do algoritmo CLONALG.

7.3.3 Módulo de aprendizado

O conjunto de memória/aprendizado, é gerado a partir de sinais desconhecidos (antígenos). Esse processo é realizado pelo algoritmo CLONALG, descrito na Seção 6.4. Para isso, é gerada, aleatoriamente, um conjunto de linfócitos, e sua quantificação de afinidade com relação aos antígenos, é feita através da Equação 6.5. Posteriormente, é realizado o processo de clonagem e hipermutação, com n linfócitos de maior afinidade. A quantificação dos clones é feita pela Equação 6.6, e a quantidade de mutações realizadas, é calculada pelas Equações 6.7 e 6.9.

Os sinais utilizados nessa seção, são expressos em forma de vetores, com valores reais. Segundo Lima (2016), para resolver situações como essa, é comum a utilização de técnicas de mutação indutiva, conforme a proposta de (WYLIE; PLEYDELL, 2008). Esse processo foi desenvolvido pelo conjunto de Equações 7.1, utilizada em uma posição do linfócito, escolhida de forma aleatória.

$$Ab'_i = \begin{cases} Ab_i + \alpha \times (Ab_i - Ag_i), & Ab_i > 0 \\ Ab_i + \alpha \times (Ab_i - Ag_i), & Ab_i < 0 \end{cases} \quad (7.1)$$

em que:

Ab'_i : linfócitos maturados;

Ab_i : posição a ser mutada;

Ag_i : padrão de aprendizado (alvo);

α : numero randômico, pertencente ao intervalo [0 1];

Após o processo de maturação, são reselectionados os n melhores clones maturados, formando um subconjunto. Dessa população, os linfócitos que possuem maior afinidade, comparados aos do conjunto de memória, são recrutados e os substituem. Esse procedimento é repetido, até que um critério de parada é atendido. Nesse trabalho, utilizou-se como critério de parada a afinidade mínima de 95% com o sinal a ser aprendido.

Com a realização desse procedimento, o conjunto de detectores é atualizado e capaz de identificar ameaças recorrentes.

7.3.4 Módulo de monitoramento

Nessa etapa do SHM, é feita a detecção, classificação e diagnóstico da falha existente no sistema, conforme fundamentado na Seção 6.2. Note que, quando o sinal chega nesse ponto, ou ele já era conhecido pelo conjunto de memórias do ASN, e foi prontamente tratado, ou então, passou pelo processo de aprendizado. Conclui-se que, independente do caminho trilhado pelo sinal, nesse módulo, ele já é conhecido e pode ser tratado.

A taxa de afinidade utilizada foi de 70% e o desvio de 3%, valores determinados por testes experimentais, conforme característica de similaridade dos dados.

7.3.5 Módulo de atualização de conhecimento

O processo de atualização do ASN ocorre sempre que houver a necessidade de melhorar o critério de afinidade, ou seja, quando a eficiência dos detectores não satisfazem pelo menos 70%. Nesse caso, o CLONALG é novamente executado, e os detectores com baixa afinidade são substituídos pelos melhores linfócitos separados nesse processo.

7.3.6 Quantificação dos danos

Para quantificação do grau de influência dos danos sob os sinais normais, utilizou-se a métrica Root Mean Square Deviation - RMSD, de acordo com conceitos apresentados em (OLIVEIRA, 2019), em que, realizou-se a soma quadrática do desvio médio dos sinais com e sem danos, conforme Equação 7.2.

$$RMSD = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_{i1} - x_{i2})^2 + (y_{i1} - y_{i2})^2 + (z_{i1} - z_{i2})^2} \quad (7.2)$$

sendo:

$RMSD$: soma da média quadrática;

x_{i1}, y_{i1}, z_{i1} : sinais coordenados sem danos;

x_{i2}, y_{i2}, z_{i2} : sinais coordenados com danos;

n : numero total de sinais;

O valor utilizado como referência para categorização dos danos foi definido através da diferença entre o maior e menor valor de $RMSD$ encontrado, conforme Equação 7.3.

$$Métrica = \frac{(RMSD_{max} - RMSD_{min})}{3} \quad (7.3)$$

sendo:

$Métrica$: referencial utilizado na caracterização dos estágios de danos;

$RMSD_{max}$: maior valor calculado de $RMSD$;

$RMSD_{min}$: menor valor calculado de $RMSD$;

Os valores correspondentes ao teto de graduação para cada categoria de danos foram definidos pelas Equações 7.4, 7.5 e 7.6.

$$Estágio_1 = RMSD_{min} + Métrica \quad (7.4)$$

$$Estágio_2 = Estágio_1 + Métrica \quad (7.5)$$

$$Estágio_3 = Estágio_2 + Métrica \quad (7.6)$$

O grau de influência dos danos foram categorizados em três estágios, sendo pequeno, médio e grande, definidos através dos intervalos determinados nas Equações 7.7, 7.8 e 7.9.

$$RMSD_{min} \leq (Pequeno) \leq Estágio_1 \quad (7.7)$$

$$Estágio_1 < (Médio) \leq Estágio_2 \quad (7.8)$$

$$Estágio_2 < (Grande) \leq Estágio_3 \quad (7.9)$$

A metodologia de quantificação de danos utilizada, representa o grau de divergência entre os sinais próprios e não próprios, sempre utilizando-se das características do banco de detectores para categorizar os sinais testados. O cálculo da métrica e determinação dos estágios de danos utiliza-se de todos os sinais do conjunto de detectores, já a quantificação dos danos é feita após a fase de identificação dos mesmos, conforme sua classificação.

8 Resultados e Discussões

A apresentação dos resultados experimentais foram divididas em quatro etapas. Na primeira etapa, a fim de investigar o comportamento dinâmico do sistema e demonstrar de forma visual a diferença dos sinais coletados, conforme a condição de operação, tem-se os espectros de frequência para os estudos 1, 3 e 11, respectivamente. A escolha desses casos deu-se pela divergência de condições de desbalanceamento entre eles, sendo a retirada de parafusos da junta flexível, a inclusão de uma massa de desbalanceamento e a inclusão de duas massas de desbalanceamento, respectivamente.

Na etapa 2, utilizou-se o algoritmo convencional (seleção negativa - ASN) para identificar e classificar os danos do sistema. Nessa etapa evidenciou-se que o ASN não foi capaz de reconhecer danos inexistentes no banco de detectores.

Na terceira etapa, adicionou-se o algoritmo aprendizado continuado ao ASN, afim de promover o reconhecimento de padrões desconhecidos, sem a necessidade de reiniciar o aprendizado do sistema.

Na última etapa, apresentou-se a quantificação dos danos para os três sensores, em que os ruídos foram classificados em três estágios, conforme grau de divergência com os sinais normais.

A validação do sistema proposto, deu-se pela verificação da robustez, precisão e eficiência no processo de diagnóstico de falhas no rotor. O desempenho do SHM (detecção, aprendizado e atualização de conhecimento), foi testado na fase de sensoriamento de ambas as etapas (com e sem aprendizado). Para isso, excluiu-se o banco de detectores do dano 4, e realizou-se a etapa de monitoramento, sem prévio conhecimento desse padrão.

8.1 Parâmetros ASN e CLONALG

A correta definição dos parâmetros de operação do ASN e CLONALG interfere diretamente na eficiência desses algoritmos. Com base nos valores utilizados por [Lima \(2013\)](#) e adaptados conforme necessidades do projeto, na tabela 3, tem-se os valores adotados nessa pesquisa.

Tabela 3 – Parâmetros do Algoritmos ASN e CLONALG

Parâmetros	ASN	ASN + CLONALG
TAf	70%	70%
N	-	200
β	-	0,3
d	-	0
ρ	-	4
ε	3%	3%
nº detectores	30%	30%

fonte: (Autoria própria)

Devido ao grande volume de sinais presentes no conjunto de detectores, a taxa de afinidade (TAf), calculada pela equação 6.3, apresentou um valor muito baixo (6,67%). Com isso, foi estabelecido um valor de afinidade mínima de 70%.

O valor do desvio (ε) foi testado nos percentuais de 1% e 2%, porém não apresentaram consideráveis melhorias na eficiência do ASN, portanto, foi mantido o valores praticados na literatura (3%). A quantidade de detectores criados na fase de sensoriamento respeitou o limite estabelecido na literatura, que deve ser no máximo 30% do total de dados coletados.

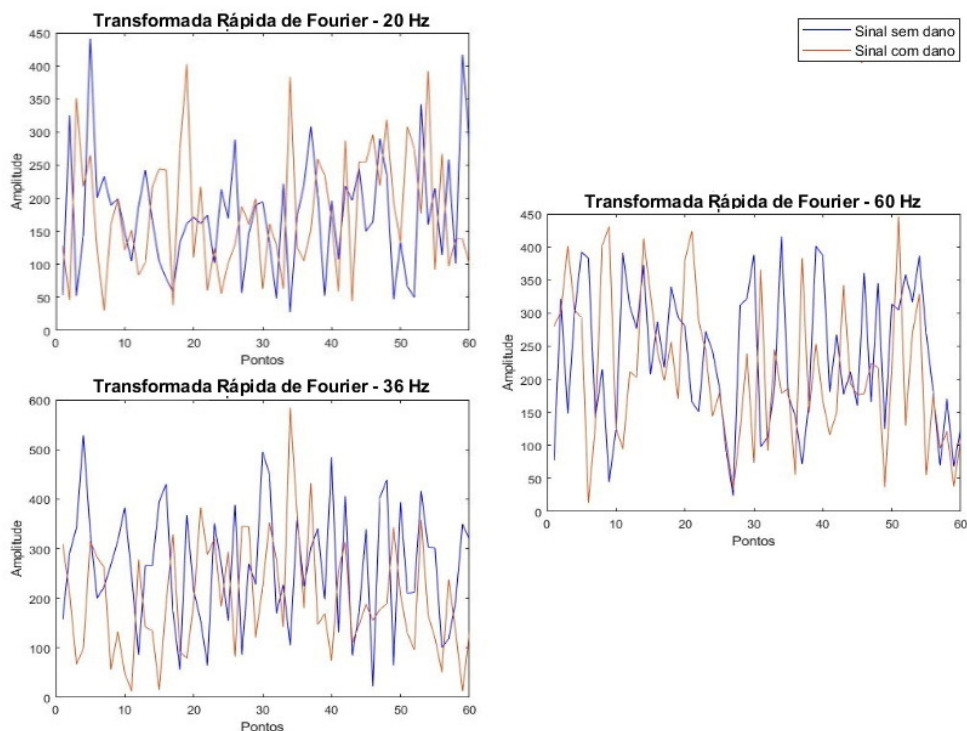
8.2 Etapa 1 - Análise Spectral

A fim de se apresentar graficamente a diferença dos sinais com e sem danos e, assim demonstrar a efetividade do SHM projetado nessa pesquisa, surgiu a necessidade da plotagem dos espectros de frequência para três estudos diferentes, que representam algumas condições de operações do sistema dinâmico utilizado. Esses gráficos foram plotados em 60 pontos de amplitude, o que possibilitou uma visualização expandida do sinal, facilitando a diferenciação dos sinais em condições normais (azul) e com danos (vermelho). Escolheu-se três frequências de operação distintas para cada sensor estudado, caracterizando o funcionamento do equipamento para 20 Hz, 36 Hz e 60 Hz, ou seja, pequena, média e alta frequência de operação do equipamento.

8.2.1 Espectros do Estudo 1

No estudo 1, descrito na Seção 7.2, tem-se o funcionamento do sistema com a retirada de dois parafusos da junta flexível, utilizada para acoplar o motor ao mancal.

Figura 31 – Espectro de frequência Estudo 1 - sensor 1

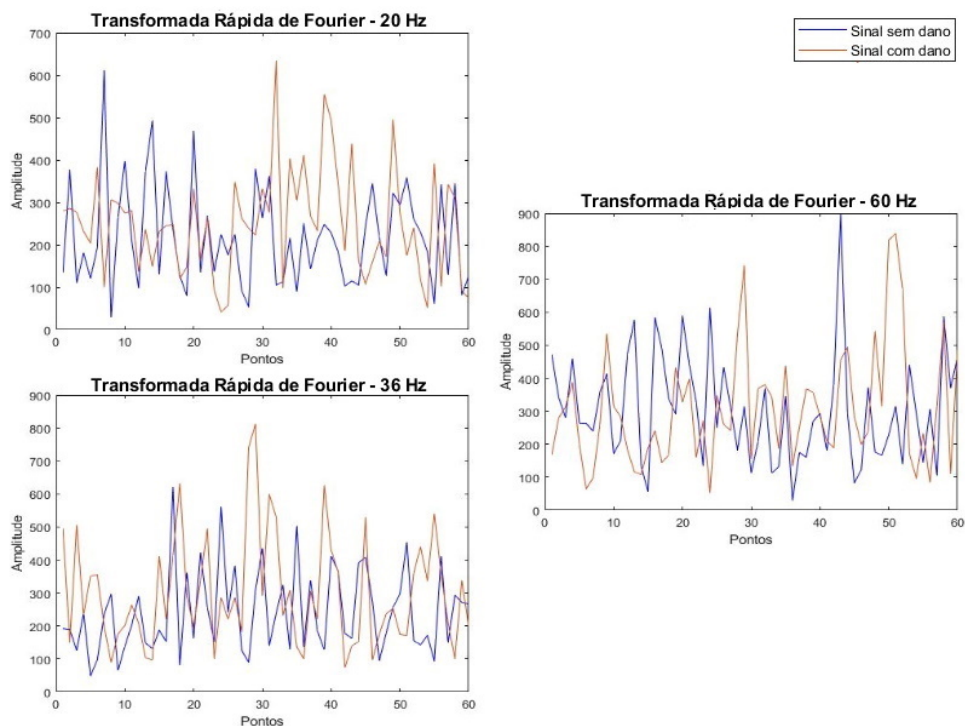


fonte: (Autoria própria)

Na Figura 31 está representado o comportamento do sistema sob o monitoramento do sensor 1, em sinais sobrepostos sob as mesmas condições de operação, ou seja, sinal com e sem falha para baixa, média e alta frequência. Note que, mesmo com a ausência dos parafusos na junta flexível, o sensor 1 (Figura 31) não apresentou sinais com grandes variações em sua amplitude, quando comparados com seu funcionamento normal. Porém, é notório a divergência entre os sinais medidos, em que os picos de amplitude não se apresentam no mesmo instante.

Nas Figuras 32 e 33 estão representados o comportamento do sistema sob o monitoramento dos sensores 2 e 3, respectivamente. Os sinais do funcionamento do rotor, com e sem falhas (azul e vermelho), estão sobrepostos sob as mesmas condições de operação para baixa, média e alta frequência.

Figura 32 – Espectro de frequência Estudo 1 - sensor 2

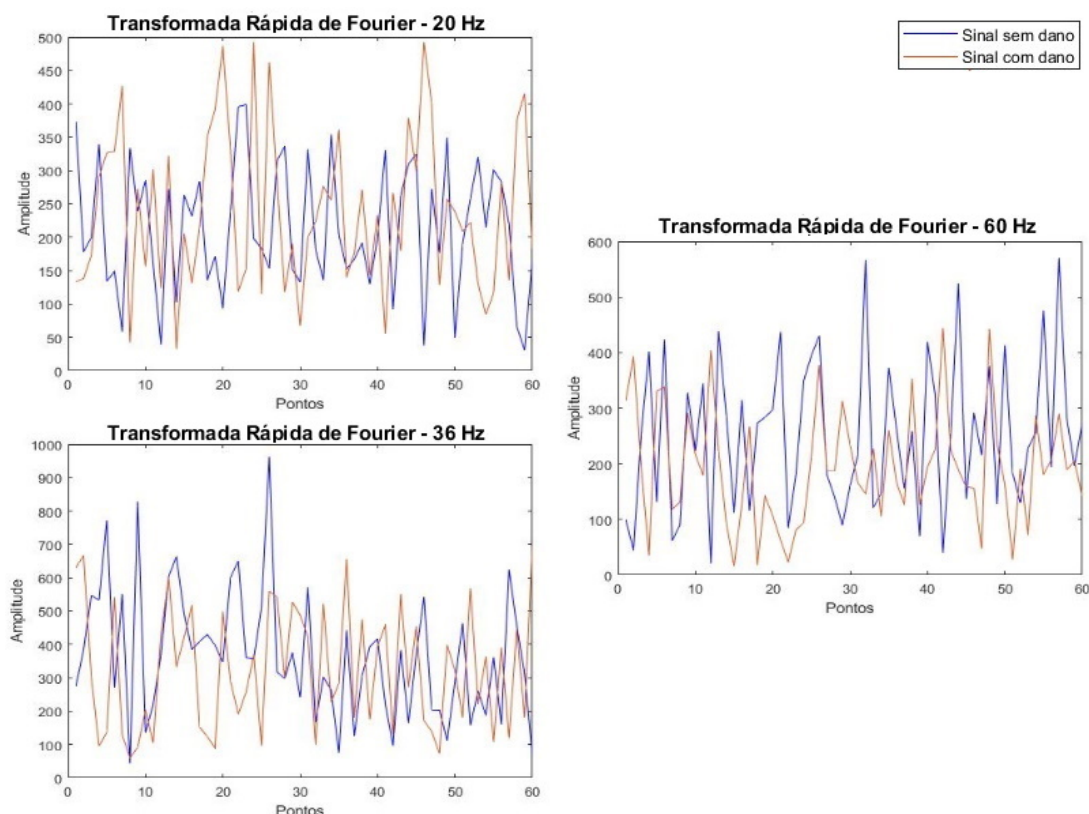


fonte: (Autoria própria)

O sensor 2 (Figura 32) não apresentou sinais com grandes variações em sua amplitude, quando comparados com seu funcionamento normal. Porém, é notório a divergência entre os sinais medidos, em que os picos de amplitude não se apresentam no mesmo instante.

O sensor 3 (Figura 33) apresentou certa tendência de amortecimento de amplitude, principalmente em média e alta frequência, quando comparados seu funcionamento normal. Esse fato está relacionado com o aumento da flexibilidade do conjunto, proporcionado pela retirada dos parafusos da junta flexível, apresentando notória divergência entre os sinais medidos.

Figura 33 – Espectro de frequência Estudo 1 - sensor 3



fonte: (Autoria própria)

8.2.2 Espectros do Estudo 3

No estudo 3, descrito na Seção 7.2, tem-se o funcionamento do sistema com a inclusão de uma massa de 10 g, na posição indicada na Tabela 2 e ilustrada na Figura 28.

A massa adicionada ao disco do rotor provoca desbalanceamento estrutural, alterando seu comportamento dinâmico, conforme ilustrado nos espectros das Figuras 34, 35 e 36.

O sensor 1 (Figura 34), para baixa e média frequência, não registrou grandes variações de amplitude, quando os sinais com e sem falha são comparados. Para a frequência de 60 Hz, nota-se um aumento considerável dos picos de amplitude dos sinais com danos.

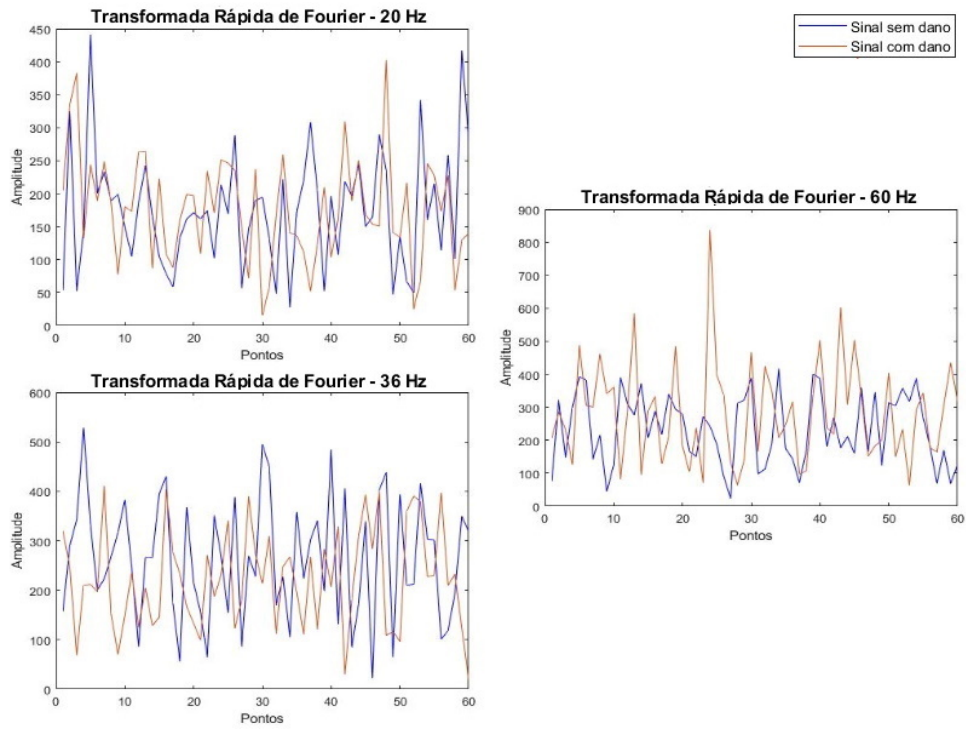
Nas Figuras 35 e 36 estão representados o comportamento do sistema sob o monitoramento do sensor 2 e 3, respectivamente. Os sinais do funcionamento do rotor, com e sem falhas (azul e vermelho), estão sobrepostos sob as mesmas condições de operação para baixa, média e alta frequência.

O sensor 2 (Figura 35), para todas as frequências de excitação, não apresentou sinais com grandes variações em sua amplitude, quando comparados os sinais com danos e de funcionamento normal.

O sensor 3 (Figura 36) apresentou, em seus sinais com danos, certo aumento de amplitude, para todas as frequências medidas, quando comparados ao seu funcionamento normal.

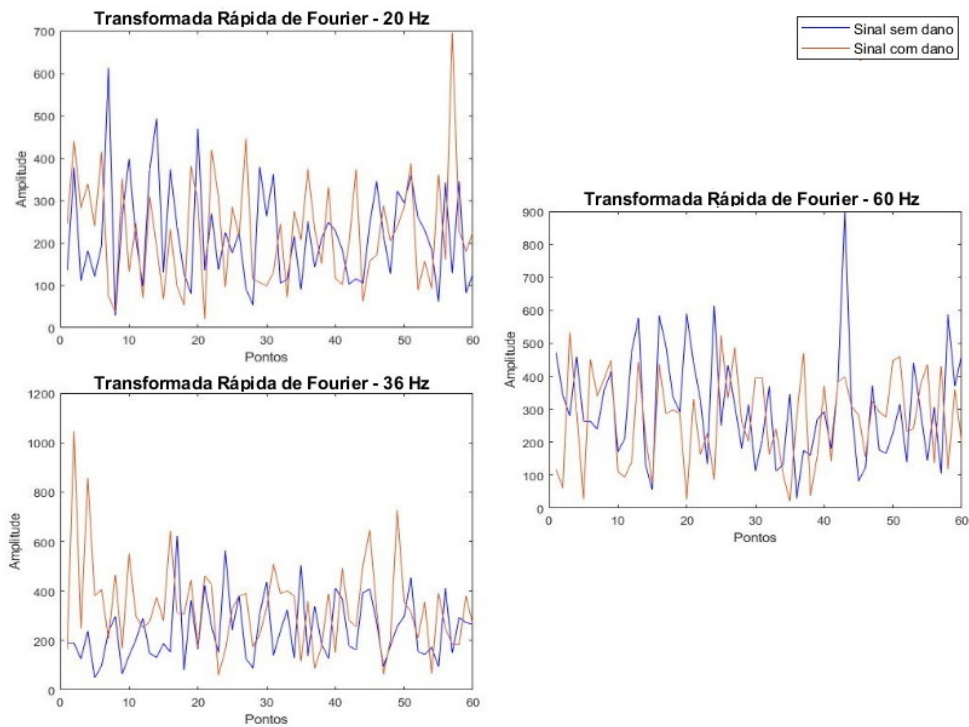
É notório, em todos os espectros apresentados para esse estudo, a divergência entre os sinais com e sem danos, em que os picos de amplitude não se apresentam no mesmo

Figura 34 – Espectro de frequência Estudo 3 - sensor 1



fonte: (Autoria própria)

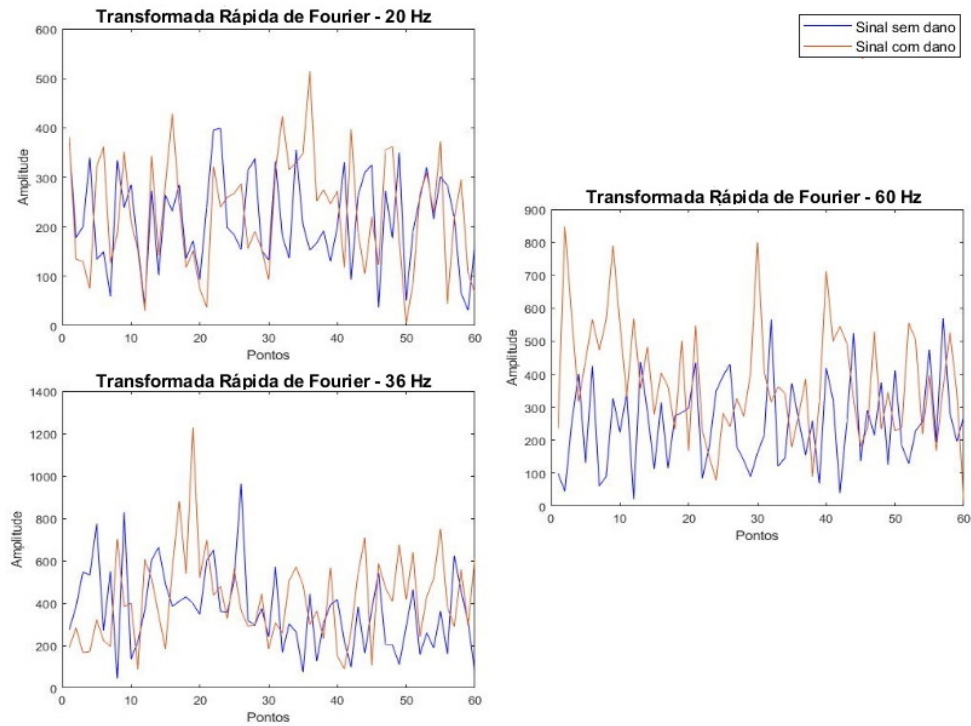
Figura 35 – Espectro de frequência Estudo 3 - sensor 2



fonte: (Autoria própria)

instante.

Figura 36 – Espectro de frequência Estudo 3 - sensor 3

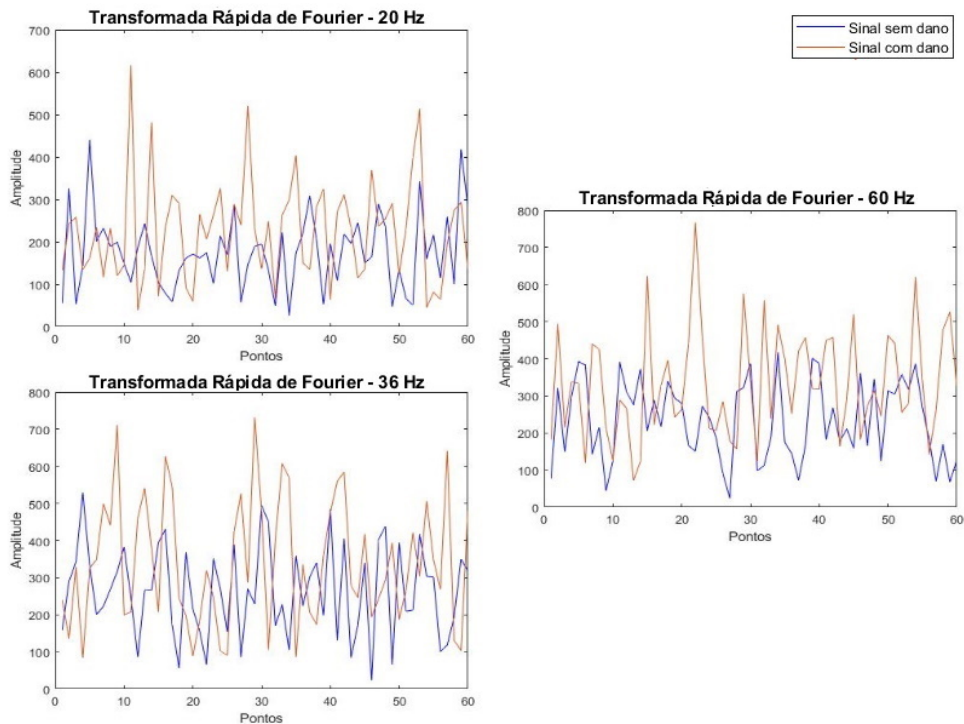


fonte: (Autoria própria)

8.2.3 Espectros do Estudo 11

No estudo 11, descrito na Seção 7.2, tem-se o funcionamento do sistema com a inclusão de duas massas de 10 g, nas posições indicadas na Tabela 2 e Figura 28.

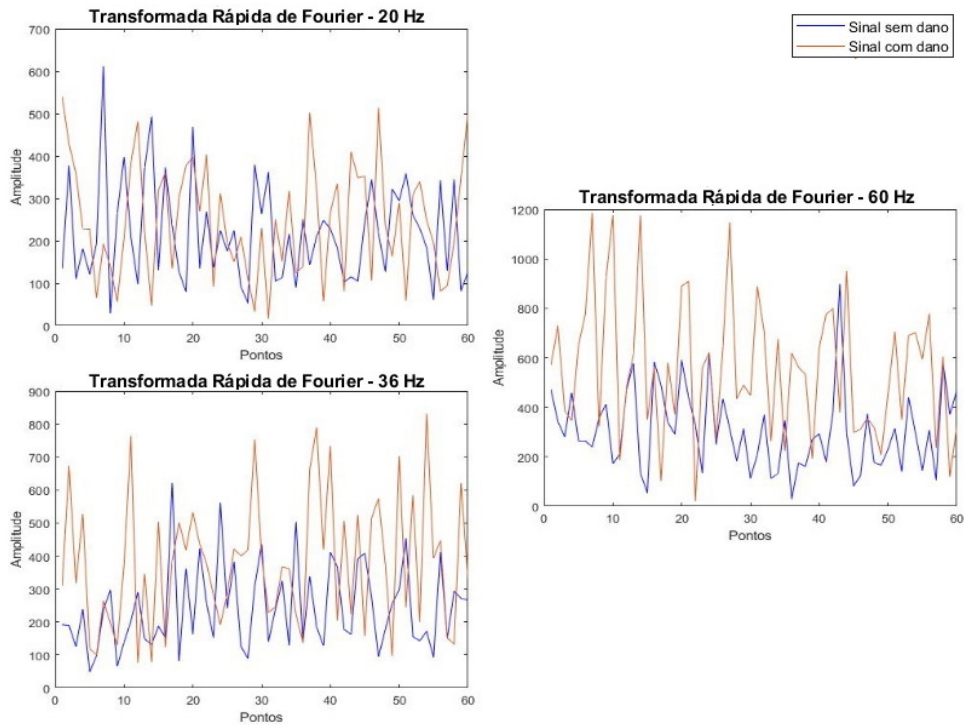
Figura 37 – Espectro de frequência Estudo 11 - sensor 1



fonte: (Autoria própria)

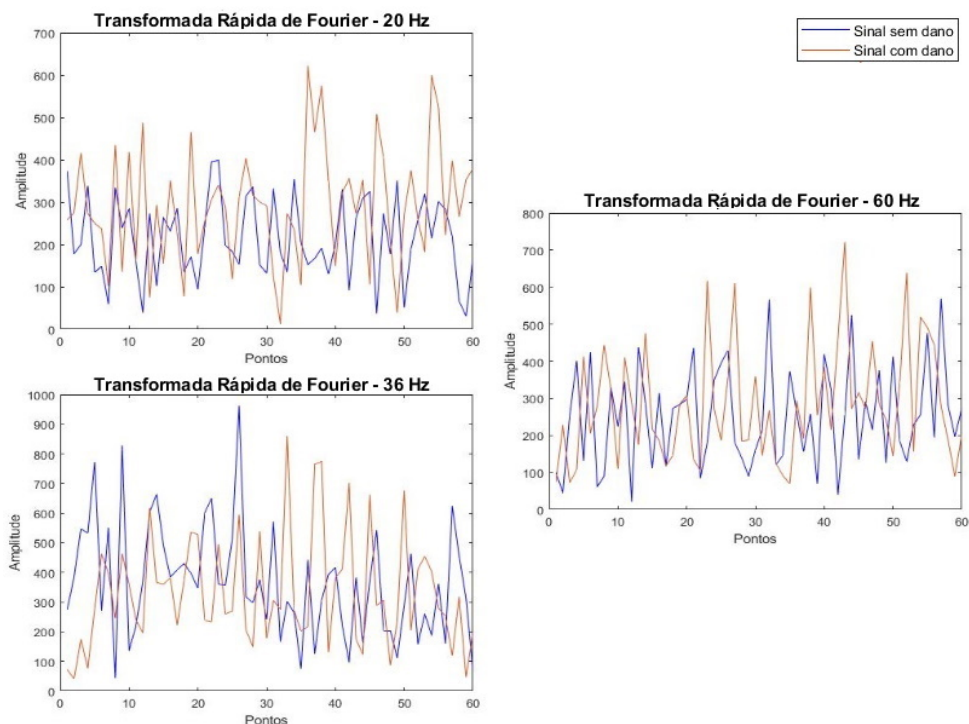
A adição das massas provocam desbalanceamento no sistema, alterando significativamente seu comportamento dinâmico, o que pode ser observado nas Figuras 37, 38 e 39.

Figura 38 – Espectro de frequência Estudo 11 - sensor 2



fonte: (Autoria própria)

Figura 39 – Espectro de frequência Estudo 11 - sensor 3



fonte: (Autoria própria)

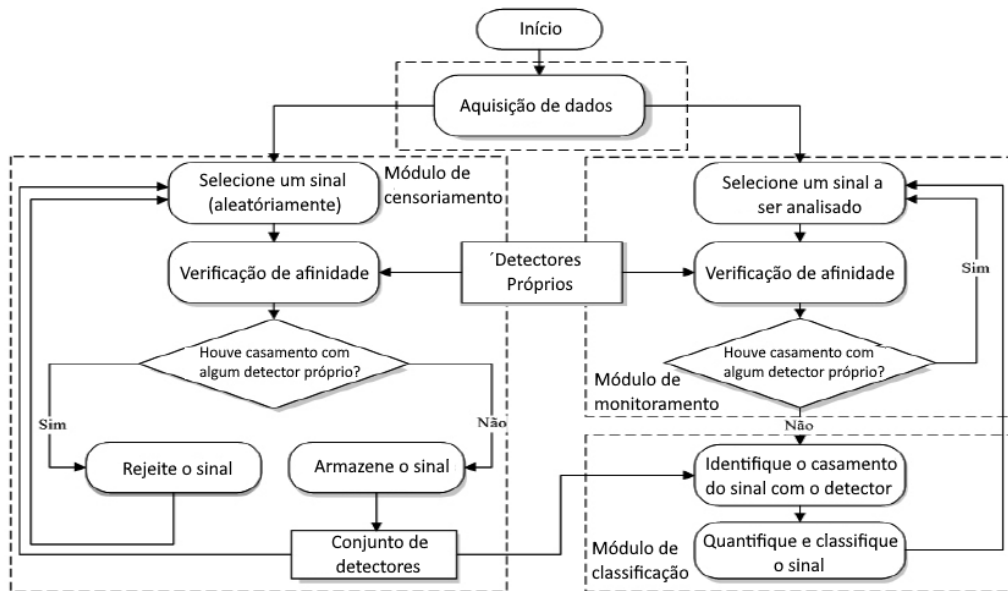
Nas Figuras 37, 38 e 39 estão representados o comportamento do sistema sob o monitoramento do sensor 1, 2 e 3, respectivamente. Os sinais do funcionamento do rotor, com e sem falhas (azul e vermelho), estão sobrepostos sob as mesmas condições de operação para baixa, média e alta frequência. Nota-se que, em todos os sensores, os sinais com danos apresentaram certo aumento dos picos de amplitude, para todas as frequências medidas, quando comparadas seu funcionamento normal.

Com os resultados gráficos apresentados nessa seção, fica claro que, conforme variação das condições iniciais e frequência de excitação, o sistema entrega uma resposta dinâmica diferente. Isso fornece condições favoráveis à aplicação do algoritmo de reconhecimento de padrões, já que ele atua no reconhecimento pico a pico, comparando os sinais bons e ruins, identificando e quantificando as divergências encontradas.

8.3 Etapa 2 - Algoritmo Convencional - ASN

Visando a verificação da capacidade de identificação e classificação de danos do algoritmo de seleção negativa, verificando-se a precisão, eficiência e robustez do SHM proposto, realizou-se os testes do algoritmo sem aprendizado continuado, conforme fluxograma da figura 40, separadamente, para os três sensores, posicionados conforme descrito na Seção 7.2. Para isso, utilizou-se a técnica de validação cruzada, em que o algoritmo foi executado 10 vezes, afim de validar a precisão dos resultados.

Figura 40 – Fluxograma do Algoritmo de Seleção Negativa - ASN



fonte: Adaptado de (OLIVEIRA, 2019)

Inicialmente, aplicou-se o módulo de sensoriamento, conforme descrito na Seção 7.3.1 e ilustrado na Figura 40. De posse dos detectores, realizou-se o monitoramento, descrito na Seção 7.3.4, em que, de forma randomizada, são selecionados um grupo amostral do banco de dados e então realizado o procedimento de identificação, classificação e quantificação dos danos. Os resultados apresentados são referentes à 30% dos danos detectados por cada sensor, o que testa todas as possibilidades de acerto perante o banco de detectores constituído.

8.3.1 Resultado do ASN para o Sensor 1

A capacidade de identificação de danos do ANS para o sensor 1, considerando as quatorze situações de danos descritas na Seção 7.2, pode ser observada na Tabela 4. Note que, o algoritmo conseguiu diferenciar os sinais normais dos anormais com 100% de eficiência, quando os padrões eram conhecidos e faziam parte do banco de detectores.

Tabela 4 – Resultados ASN - Identificação dos danos detectados no Sensor 1

Dados	Padrões	
	Número de sinais	Acertos Referência Cruzada (%)
Baseline	900	100
Danos	12600	100

fonte: (Autoria própria)

O algoritmo convencional, conforme exposto na Tabela 5, apresentou eficiência de 99,04% na média de classificação das falhas. Isso significa que, na média, o algoritmo erra 8 a 9 padrões na hora da classificação para cada dano analisado, totalizando em torno de 121 erros dos 12600 sinais analisados. Isso evidencia a precisão do algoritmo quando os detectores são conhecidos e estão presentes no banco de dados.

Tabela 5 – Resultados ASN - Classificação dos danos detectados no Sensor 1

Dados	Padrões	
	Número de sinais	Acertos Referência Cruzada (%)
Dano 1	900	97,61
Dano 2	900	98,33
Dano 3	900	99,13
Dano 4	900	99,19
Dano 5	900	99,16
Dano 6	900	99,87
Dano 7	900	98,94
Dano 8	900	98,64
Dano 9	900	100
Dano 10	900	98,13
Dano 11	900	99,17
Dano 12	900	99,67
Dano 13	900	99,43
Dano 14	900	99,23
Total	12600	99,04

fonte: (Autoria própria)

8.3.2 Resultado do ASN para o Sensor 2

A capacidade de identificação de danos do ASN para o sensor 2, considerando as quatorze situações de danos descritas na Seção 7.2, pode ser observada na Tabela 6.

Tabela 6 – Resultados ASN - Identificação dos danos detectados no Sensor 2

Dados	Padrões	
	Número de sinais	Acertos Referência Cruzada (%)
Baseline	900	100
Danos	12600	100

fonte: (Autoria própria)

Note que, o algoritmo conseguiu diferenciar os sinais normais dos anormais com 100% de eficiência, quando os padrões eram conhecidos e faziam parte do banco de detectores.

O algoritmo convencional, conforme exposto na Tabela 7 apresentou eficiência de 98,92% na média de classificação das falhas. Isso significa que, em média, o algoritmo erra de 9 a 10 padrões na hora da classificação para cada dano analisado, totalizando em torno de 136 erros dos 12600 sinais analisados. Isso evidencia a precisão do algoritmo quando os detectores são conhecidos e estão presentes no banco de dados.

Tabela 7 – Resultados ASN - Classificação dos danos detectados no Sensor 2

Dados	Padrões	
	Número de sinais	Acertos Referência Cruzada (%)
Dano 1	900	99,03
Dano 2	900	98,03
Dano 3	900	98,48
Dano 4	900	99,32
Dano 5	900	99,80
Dano 6	900	99,38
Dano 7	900	99,39
Dano 8	900	97,23
Dano 9	900	98,69
Dano 10	900	98,66
Dano 11	900	99,58
Dano 12	900	99,81
Dano 13	900	99,23
Dano 14	900	98,23
Total	12600	98,92

fonte: (Autoria própria)

8.3.3 Resultado do ASN para o Sensor 3

A capacidade de identificação de danos do algoritmo de seleção negativa para o sensor 3, considerando as quatorze situações de danos descritas na Seção 7.2, pode ser observada na Tabela 8. Note que, o algoritmo de seleção negativa conseguiu diferenciar os sinais normais dos anormais com 100% de eficiência, quando os padrões eram conhecidos e faziam parte do banco de detectores.

Tabela 8 – Resultados ASN - Identificação dos danos detectados no Sensor 3

Dados	Padrões	
	Número de sinais	Acertos Referência Cruzada (%)
Baseline	900	100
Danos	12600	100

fonte: (Autoria própria)

O algoritmo convencional, conforme exposto na Tabela 9 apresentou eficiência de 99,10% na média de classificação das falhas. Isso significa que, em média, o algoritmo erra de 8 a 9 padrões na hora da classificação para cada dano analisado, totalizando em torno de 113 erros dos 12600 sinais analisados. Isso evidencia a precisão do algoritmo quando os detectores são conhecidos e estão presentes no banco de dados.

Tabela 9 – Resultados ASN - Classificação dos danos detectados no Sensor 3

Dados	Padrões	
	Número de sinais	Acertos Referência Cruzada (%)
Dano 1	900	98,91
Dano 2	900	97,92
Dano 3	900	99,71
Dano 4	900	99,31
Dano 5	900	99,74
Dano 6	900	98,50
Dano 7	900	99,04
Dano 8	900	97,51
Dano 9	900	98,39
Dano 10	900	99,92
Dano 11	900	98,54
Dano 12	900	99,46
Dano 13	900	99,62
Dano 14	900	99,77
Total	12600	99,10

fonte: (Autoria própria)

8.3.4 Resultado do ASN para o Sensor 1 - Sem um dano

Outra hipótese analisada nessa pesquisa, que faz parte do cotidiano operacional das máquinas e equipamentos mecânicos, é a capacidade de identificação e classificação de danos do ASN quando os padrões são desconhecidos e não estão presentes no banco de detectores. Para essa análise, excluiu-se de forma aleatória os dados de um dano, após a fase de sensoriamento. Realizou-se o processo de reconhecimento de padrões, em que os resultados de identificação dos danos estão apresentados na Tabela 10. Note que, o SHM foi incapaz de identificar os danos que não estavam presentes no banco de detectores, apresentando eficiência média de 92,94%.

Tabela 10 – Resultados ASN - Identificação dos danos detectados no Sensor 1 - sem um dano

Dados	Padrões	
	Número de sinais	Acertos Referência Cruzada (%)
Baseline	900	100
Danos	12600	92,94

fonte: (Autoria própria)

A classificação dos danos, sem a presença do dano 4, excluído antes da fase de monitoramento, está representado na Tabela 11.

Tabela 11 – Resultados ASN - Classificação dos danos detectados no Sensor 1 - sem um dano

Dados	Padrões	
	Número de sinais	Acertos Referência Cruzada (%)
Dano 1	900	97,43
Dano 2	900	97,61
Dano 3	900	99,98
Dano 4	900	0,00
Dano 5	900	99,58
Dano 6	900	98,90
Dano 7	900	98,90
Dano 8	900	98,00
Dano 9	900	98,90
Dano 10	900	97,87
Dano 11	900	99,80
Dano 12	900	99,18
Dano 13	900	99,81
Dano 14	900	99,78
Total	12600	91,84

fonte: (Autoria própria)

Nessas condições, a eficiência do algoritmo foi de 91,84% na média de classificação das falhas. Isso significa que o algoritmo errou um total de 1028 sinais, dos 12600 analisados.

Com base na verificação da incapacidade do ASN em identificar padrões que não constam no banco de detectores, afim de melhorar a robustez do SHM proposto, evidenciou-se a necessidade de implementação do algoritmo CLONALG.

8.4 Etapa 3 - Algoritmo de Seleção Negativa com Aprendizagem Continuada

A implementação do módulo de aprendizagem visa assegurar a confiabilidade do ASN, pois garante que, mesmo em situações novas de operação da máquina (dano

desconhecido), o algoritmo seja capaz de aprender sobre aquele dano, indentificá-lo, classificá-lo e armazená-lo para uma próxima análise. Para isso, considerando os três sensores, excluiu-se os dados de um dos danos (dano 4) e utilizou-se o algoritmo de reconhecimento de padrões CLONALG, conforme procedimentos descritos na Seção 7.3.3. Os resultados estão apresentados nas seções seguintes.

8.4.1 Resultados do ASN + CLONALG - Sensor 1

A capacidade de identificação de danos do algoritmo de seleção negativa com aprendizagem continuada para o sensor 1, considerando-se as quatorze situações de danos descritas na Seção 7.2, pode ser observada na tabela 12.

Tabela 12 – Resultados ASN com aprendizagem continuada - Identificação dos danos no Sensor 1

Dados	Padrões	
	Número de sinais	Acertos Referência Cruzada (%)
Baseline	900	100
Danos	12600	100

fonte: (Autoria própria)

Note que, o algoritmo conseguiu diferenciar os sinais normais dos anormais com 100% de eficiência, mesmo quando os padrões eram desconhecidos. A eficiência do ASN com aprendizado, com relação à classificação dos danos, está apresentada na Tabela 13.

Tabela 13 – Resultados ASN + CONALG - Classificação dos danos detectados no Sensor 1

Dados	Padrões	
	Número de sinais	Acertos Referência Cruzada (%)
Dano 1	900	99,27
Dano 2	900	99,73
Dano 3	900	98,82
Dano 4	900	99,99
Dano 5	900	97,69
Dano 6	900	98,20
Dano 7	900	98,01
Dano 8	900	98,92
Dano 9	900	99,28
Dano 10	900	98,58
Dano 11	900	98,63
Dano 12	900	98,08
Dano 13	900	98,30
Dano 14	900	98,52
Total	12600	98,72

fonte: (Autoria própria)

Observe que, o ASN com aprendizado continuado apresentou eficiência de 98,72% na média de classificação das falhas, isso significa que, em média, o algoritmo erra de 11 a 12 padrões na hora da classificação para cada dano analisado, totalizando em torno de 161 erros dos 12600 sinais analisados. Isso evidencia a precisão do algoritmo, mesmo quando os detectores são desconhecidos e não estão presentes no banco de dados.

8.4.2 Resultados do ASN + CLONALG - Sensor 2

A capacidade de identificação de danos do ASN com aprendizado para o sensor 2, considerando-se as quatorze situações de danos, encontra-se na Tabela 14.

Tabela 14 – Resultados ASN com aprendizagem continuada - Identificação dos danos detectados no Sensor 2

Dados	Padrões	
	Número de sinais	Acertos Referência Cruzada (%)
Baseline	900	100
Danos	12600	100

fonte: (Autoria própria)

Note que, o algoritmo de seleção negativa conseguiu diferenciar os sinais normais dos anormais com 100% de eficiência, mesmo quando os padrões não eram conhecidos. A eficiência do ASN com aprendizagem continuada, com relação a classificação dos danos, está apresentada na Tabela 15.

Tabela 15 – Resultados ASN + CONALG - Classificação dos danos detectados no Sensor 2

Dados	Padrões	
	Número de sinais	Acertos Referência Cruzada (%)
Dano 1	900	99,74
Dano 2	900	99,99
Dano 3	900	99,66
Dano 4	900	98,89
Dano 5	900	98,49
Dano 6	900	99,61
Dano 7	900	99,38
Dano 8	900	98,41
Dano 9	900	99,97
Dano 10	900	98,84
Dano 11	900	99,99
Dano 12	900	99,59
Dano 13	900	98,24
Dano 14	900	98,82
Total	12600	99,26

fonte: (Autoria própria)

O algoritmo apresentou eficiência de 99,26% na média de classificação das falhas, isso significa que, em média, o algoritmo erra de 6 a 7 padrões na hora da classificação para cada dano analisado, totalizando em torno de 93 erros dos 12600 sinais analisados, evidenciando a precisão do algoritmo, mesmo quando os detectores são desconhecidos, ou seja, não estão presentes no banco de dados.

8.4.3 Resultados do ASN + CLONALG - Sensor 3

A capacidade de identificação de danos do ASN com aprendizagem continuada para o sensor 1, considerando-se as quatorze situações de danos descritas na Seção 7.2, pode ser observada na Tabela 16. Note que o algoritmo conseguiu diferenciar os sinais normais dos anormais com 100% de eficiência, mesmo quando os padrões não eram conhecidos.

Tabela 16 – Resultados ASN com aprendizagem continuada - Identificação dos danos detectados no Sensor 3

Dados	Padrões	
	Número de sinais	Acertos Referência Cruzada (%)
Baseline	900	100
Danos	12600	100

fonte: (Autoria própria)

A eficiência do ASN com aprendizagem continuada, com relação a classificação dos danos, está apresentada na Tabela 17.

Tabela 17 – Resultados ASN + CONALG - Classificação dos danos detectados no Sensor 3

Dados	Padrões	
	Número de sinais	Acertos Referência Cruzada (%)
Dano 1	900	98,96
Dano 2	900	98,96
Dano 3	900	99,23
Dano 4	900	99,17
Dano 5	900	97,91
Dano 6	900	99,50
Dano 7	900	99,54
Dano 8	900	98,84
Dano 9	900	97,92
Dano 10	900	99,68
Dano 11	900	99,72
Dano 12	900	98,78
Dano 13	900	98,11
Dano 14	900	98,81
Total	12600	98,94

fonte: (Autoria própria)

Observe que, o algoritmo apresentou eficiência de 98,94% na média de classificação das falhas, isso significa que, em média, o algoritmo erra de 9 a 10 padrões na hora da classificação para cada dano analisado, totalizando em torno de 134 erros dos 12600 sinais analisados, evidenciando a precisão do algoritmo, mesmo quando os detectores são desconhecidos, ou seja, não estão presentes no banco de dados.

8.5 Etapa 4 - Quantificação dos danos - Métrica RMSD

A quantificação tem como objetivo a verificação do grau de divergência dos sinais não próprios com referência aos sinais próprios, sendo uma ferramenta independente dos algoritmos inteligentes aplicados nessa pesquisa. A técnica utilizada baseou-se nos conceitos do método Root Mean Square Deviation - RMSD, descrito na Seção 7.3.6. Os resultados, para os 14 danos estudados, foram divididos em três categorias de danos (Pequeno, Médio e Grande) e estão apresentados nas próximas seções, para os três sensores.

8.5.1 Grau de influência Sensor 1

A quantificação do grau de influência dos danos com relação ao valor de referência (sinais próprios) para o sensor 1, conforme categorias estabelecidas pela RMSD, encontra-se representada na Tabela 18. Para esse sensor, os valores concentraram-se no nível baixo, com percentual médio de 87,08 %. O nível intermediário teve percentual médio de 12,62 %, e o nível alto 0,31 %.

Tabela 18 – Quantificação de danos detectados no Sensor 1

Sinais	Quantificação de danos - Percentual		
	Pequeno (%)	Médio (%)	Grande (%)
Dano 1	79,22	20,45	0,33
Dano 2	84	16	0
Dano 3	78,33	21,67	0
Dano 4	99,89	0	0,11
Dano 5	80,67	19,33	0
Dano 6	82,67	17,33	0
Dano 7	99,11	0	0,89
Dano 8	82,67	17,33	0
Dano 9	85,33	14,56	0,11
Dano 10	85,78	14,22	0
Dano 11	85,78	14,22	0
Dano 12	86,67	13,33	0
Dano 13	91,89	8,11	0
Dano 14	97,11	0,11	2,78

fonte: (Autoria própria)

8.5.2 Grau de influência Sensor 2

A quantificação do grau de influência do dano com relação ao valor de referência (sinais próprios) para o sensor 2 está representado na Tabela 19.

Tabela 19 – Quantificação de danos detectados no Sensor 2

Sinais	Quantificação de danos - Percentual		
	Pequeno (%)	Médio (%)	Grande (%)
Dano 1	100	0	0
Dano 2	100	0	0
Dano 3	100	0	0
Dano 4	100	0	0
Dano 5	99,89	0,11	0
Dano 6	99,56	0	0,44
Dano 7	100	0	0
Dano 8	100	0	0
Dano 9	99,89	0	0,11
Dano 10	100	0	0
Dano 11	100	0	0
Dano 12	100	0	0
Dano 13	100	0	0
Dano 14	100	0	0

fonte: (Autoria própria)

Os valores da quantificação concentraram-se no nível baixo, com percentual médio de 99,95 %. O nível intermediário percentual médio de 0,01 %, e o nível alto 0,04 %.

8.5.3 Grau de influência Sensor 3

A quantificação do grau de influência no sensor 3 está representado na Tabela 20.

Tabela 20 – Quantificação de danos detectados no Sensor 3

Sinais	Quantificação de danos - Percentual		
	Pequeno (%)	Médio (%)	Grande (%)
Dano 1	78,11	21,89	0
Dano 2	100	0	0
Dano 3	84,78	15,22	0
Dano 4	75,89	24,11	0
Dano 5	71,56	28,44	0
Dano 6	100	0	0
Dano 7	72	28	0
Dano 8	81,22	18,78	0
Dano 9	78,22	21,78	0
Dano 10	80,56	19,44	0
Dano 11	83,67	16,33	0
Dano 12	80,33	19,67	0
Dano 13	97,34	0,44	2,22
Dano 14	99,67	0,33	0

fonte: (Autoria própria)

Para esse sensor, os valores concentraram-se no nível mais baixo com percentual médio de 84,53 %. O nível intermediário apresentou percentual médio de 15,31 %, e o nível alto 0,16 %.

Com base nos resultados apresentados nessa seção, é possível observar que o nível de ruído pode variar conforme o posicionamento do sensor, o que está diretamente relacionado com os modos de vibrar de cada componente de um sistema dinâmico.

De modo geral, para as condições de operação estabelecidas, os resultados apresentaram grau de criticidade baixo, ou seja, os danos não estão provocando consideráveis desníveis das funcionalidades do equipamento.

8.6 Discussões

A eficiência do algoritmo convencional ASN, quando os dados monitorados encontravam-se presentes no banco de detectores, atingiu o índice de 100% na identificação dos danos. Quando excluído um dos danos do banco de detectores, o ASN não conseguiu identificá-lo, apresentando taxa de acerto de 92,94%.

O algoritmo de seleção negativa com aprendizado continuado, para todas as condições estabelecidas, conseguiu identificar o tipo de sinal monitorado, diferenciando os sinais normais dos sinais com danos. Portanto, nota-se uma eficiência de 100% no quesito identificação de falhas, proposto no SHM dessa pesquisa.

Com base na eficiência dos métodos apresentados nas seções 8.3 e 8.4, afim de facilitar o entendimento, na tabela 21 tem-se o resumo dos resultados obtidos na classificação dos danos pelo ASN com e sem aprendizado.

Tabela 21 – Resumo da classificação de danos

Técnica utilizada	Total de Acertos - Percentual	
	ASN - (%)	ASN + CLONALG (%)
Sensor 1	91,84	98,72

fonte: (Autoria própria)

As técnicas apresentada na colunas 2 e 3 da tabela, referem-se respectivamente, ao algoritmo de seleção negativa faltando um dos danos no banco de detectores (ASN -) e algoritmo de seleção negativa com aprendizado continuado (ASN + CLONALG). Nota-se um aumento de 6,88% na eficiência do acerto médio percentual de classificação do ANS+CLONALG, quando comparado com o algoritmo sem aprendizado (ANS). A combinação entre os algoritmos proporcionou melhoria na eficiência do projeto SHM, possibilitando um diagnóstico com aperfeiçoamento constante.

9 Conclusões

A proposta principal deste trabalho foi o projeto de um SHM capaz de detectar, classificar e quantificar danos em um rotor dinâmico com desbalanceamento. Como ferramenta de programação, utilizou-se o software GNU Octave, com base nos algoritmos de seleção negativa (ASN) e seleção clonal (CLONALG).

Identificou-se, através dos gráficos da Seção 8.2, a divergência de comportamento da dinâmica do sistema com e sem falha, substanciando a possibilidade de atuação do algoritmo de reconhecimento de padrões.

O algoritmo de seleção negativa (ASN) apresentou-se como boa alternativa para identificação de falhas. Porém, sua eficiência é dependente da robustez do banco de detectores, já que, ficou evidenciado na Seção 8.3.4, a incapacidade de reconhecimento de danos que não são previamente conhecidos e fazem parte desse banco.

O módulo de aprendizado, desenvolvido com base no algoritmo CLONALG, foi capaz de aprender, identificar, classificar e quantificar o dano desconhecido (excluído antes da fase de monitoramento), armazenando-o no banco de detectores para o caso de reincidência do defeito. Esse procedimento, além de tornar a análise mais confiável e robusta, garante um diagnóstico com melhoria contínua.

Deste modo, é correto afirmar que as técnicas de computação inteligente abordadas nesse trabalho, atenderam à proposição estabelecida, apresentando bom grau de confiabilidade e robustez no monitoramento da integridade estrutural de máquinas rotativas, o que contribui com uma área de pesquisa crescente no mundo inteiro, ou seja, Sistemas de Monitoramento de Integridade Estrutural (SHM).

9.1 Sugestões de Melhoria

- Sugere-se o aperfeiçoamento dos níveis de abrangência do problema (3 a 7), o que permite atuar em tempo real no tratamento do dano, através de materiais inteligentes.
- Estruturar o armazenamento dos dados em nuvem e aplicar-se o monitoramento estrutural em tempo real, possibilitando-se a implementação da técnica em vários seguimentos da engenharia.
- Aplicar os conceitos desenvolvidos em estruturas industriais de campo, evidenciando a aplicabilidade da técnica e a influência do meio sobre os sensores utilizados.

Referências

- ABRAMAN, A. Situação da manutenção no Brasil. *Anais do 26º Congresso Brasileiro de Manutenção*, 2011. 17, 26
- ALVES, D. A. *Técnicas de Detecção de Falhas em Barras do Rotor nos Motores de Indução Trifásicos*. Dissertação (Mestrado) — Universidade Federal de São João del-Rei, 2017. 17
- ARANGIO, S.; BONTEMPI, F.; CIAMPOLI, M. Structural integrity monitoring for dependability. *Structure and Infrastructure Engineering*, London, v. 7, n. 1-2, p. 75–86, 2011. 38
- AZANK, A. *Peça quebra e caminhão fica sem eixo no meio de rodovia em Bauru*. 2014. TV TEM/G1. Disponível em: <<http://glo.bo/1mV2gVK>>. Acesso em: 18 maio. 2020. 34
- BACCARINI, L. M. R. *Detecção e diagnóstico de falhas em motores de indução*. Tese (Doutorado) — Universidade Federal de Minas Gerais, 2005. 25
- BALBINOT, A.; BRUSAMARELLO, V. J. *Instrumentação E Fundamentos de Medidas. Volume 2*. [S.l.]: Grupo Gen-LTC, 2000. 32, 33
- BANDEIRA, G.; ABREU, G.; GIANELLI, R. Vibração e ruído em manutenção preditiva. *Bauru: Universidade Estadual Júlio de Mesquita Filho*, 2010. 29, 30
- BENEDETTI, J. A. *Manutenção centrada em confiabilidade e análise de vibração*. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Sul, 2002. 28
- BETTA, G. et al. A dsp-based fft-analyzer for the fault diagnosis of rotating machine based on vibration analysis. *IEEE Transactions on Instrumentation and Measurement*, New York, v. 51, n. 6, p. 1316–1322, 2002. 18, 25
- BITENCOURT, T. F.; JÚNIOR, V. S. Monitoramento da integridade estrutural de aeronaves. *Horizonte Científico*, Uberlândia, 2009. 25
- BONNETT, A. H.; SOUKUP, G. C. Analysis of rotor failures in squirrel-cage induction motors. *IEEE Transactions on Industry Applications*, New York, v. 24, n. 6, p. 1124–1130, 1988. 26
- BRADLEY, D. W.; TYRRELL, A. M. Immunotronics-novel finite-state-machine architectures with built-in self-test using self-nonsel self differentiation. *IEEE Transactions on Evolutionary Computation*, New York, v. 6, n. 3, p. 227–238, 2002. 47
- BRITO, J. N. et al. *Desenvolvimento de um sistema inteligente híbrido para diagnóstico de falhas em motores de indução trifásicos*. Tese (Doutorado) — University of Campinas, Brazil, 2002. 53
- CASTRO, L. N. D.; ZUBEN, F. J. V. The clonal selection algorithm with engineering applications. In: *Proceedings of GECCO*. [S.l.: s.n.], 2000. v. 2000, p. 36–39. 48, 49

- CASTRO, L. N. de; TIMMIS, J. Artificial immune systems: a novel approach to pattern recognition. University of Paisley, 2002. 49
- CHANDRASHEKHAR, M.; GANGULI, R. Structural damage detection using modal curvature and fuzzy logic. *Structural Health Monitoring*, London, v. 8, n. 4, p. 267–282, 2009. 38
- CHAVES, J. S. et al. Rede neural artificial artmap-fuzzy aplicada no reconhecimento de falhas estruturais. *Revista Iberoamericana de Ingeniería Mecánica*, Universidad Nacional de Educacion a Distancia (UNED), v. 21, n. 1, p. 3, 2017. 39
- CHEN, X.-j. et al. Application of wavelet analysis in vibration signal processing of bridge structure. In: IEEE. *2010 international conference on measuring technology and mechatronics automation*. [S.l.], 2010. v. 1, p. 671–674. 38
- CHOW, M.-Y. Guest editorial special section on motor fault detection and diagnosis. *IEEE Transactions on Industrial Electronics*, New York, v. 47, n. 5, p. 982–983, 2000. 26
- CONTRERAS-MEDINA, L. M. et al. Fpga based multiple-channel vibration analyzer embedded system for industrial applications in automatic failure detection. In: IEEE. *2008 International Symposium on Industrial Embedded Systems*. [S.l.], 2008. p. 229–232. 18
- COSTA, C. d.; MATHIAS, M. Análise de vibrações mecânicas com fpga. *Saber Eletrônica*, São Paulo, v. 429, 2008. 30, 31
- COTA, R. E. *Análise dinâmica de rotores em balanço utilizando procedimentos computacionais e experimentais*. Dissertação (Mestrado) — Universidade Federal de Minas Gerais, 2008. 22, 24
- FERREIRA, F. J. T. E. *Strategies to improve the performance of three-phase induction motor driven systems*. Tese (Doutorado) — University of Coimbra, 2009. 17
- FILHO, F. d. C. d. O. *Sistema de aquisição de dados para monitoramento e predição de falhas em motores elétricos*. Dissertação (Mestrado) — Universidade Federal da Bahia, 2007. 27
- FLYNN, E. B.; TODD, M. D. Optimal placement of piezoelectric actuators and sensors for detecting damage in plate structures. *Journal of Intelligent Material Systems and Structures*, London, v. 21, n. 3, p. 265–274, 2010. 38
- FORREST, S. et al. Self-nonsel self discrimination in a computer. In: IEEE. *Proceedings of 1994 IEEE computer society symposium on research in security and privacy*. [S.l.], 1994. p. 202–212. 45, 57
- FRANÇA, F. O. de; ZUBEN, F. J. V.; CASTRO, L. N. de. An artificial immune network for multimodal function optimization on dynamic environments. In: *Proceedings of the 7th annual conference on Genetic and evolutionary computation*. [S.l.: s.n.], 2005. p. 289–296. 50
- FRANCO, V. R. *Monitoramento da integridade em estruturas aeronáuticas*. Dissertação (Mestrado) — Universidade Estadual Paulista (UNESP), 2009. 38

- FRISWELL, M.; PENNY, J.; GARVEY, S. A combined genetic and eigensensitivity algorithm for the location of damage in structures. *Computers Structures*, Elmsford, v. 69, n. 5, p. 547–556, 1998. 37
- FURTADO, R. M. *Identificação de falhas estruturais usando sensores e atuadores piezelétricos e redes neurais artificiais*. Dissertação (Mestrado) — Universidade Estadual Paulista (Unesp), 2004. 37
- GIURGIUTIU, V.; CUC, A. Embedded non-destructive evaluation for structural health monitoring, damage detection, and failure prevention. *Shock and Vibration Digest*, Washington, v. 37, n. 2, p. 83, 2005. 38
- GONÇALVES, G. H. et al. Análise, processamento e prognose de falhas em motores de combustão (otto) através de vibração: aplicação de sistemas imunológicos artificiais. *Research, Society and Development*, Vargem Grande Paulista, v. 10, n. 4, p. e5110413741–e5110413741, 2021. 40
- GONSALEZ, C. G. Metodologias para reconhecimento de padrões em sistemas shm utilizando a técnica da impedância eletromecânica (e/m). Universidade Estadual Paulista (Unesp), 2012. 38
- GOPALAKRISHNAN, S. et al. *Computational techniques for structural health monitoring*. [S.l.]: Springer, 2011. 36
- HALL, S. The effective management and use of structural health data. In: *Proceedings of the 2nd International Workshop on Structural Health Monitoring*. [S.l.: s.n.], 1999. p. 265–275. 17
- HEALTH, N. I. O. *Understanding the Immune System How It Works*. 2007. NIH Publication No. 07-5423. Disponível em: <<https://www.immunomix.com/pdf/1.%20Immune%20system%20overview-%20understanding%20the%20immune%20system.pdf>>. Acesso em: 21 maio. 2020. 41
- HOLANDA, S. M. S. *Aplicação da manutenção preditiva por análise de vibrações em equipamentos de trens urbanos com plano de manutenção proposto*. Dissertação (Mestrado) — Universidade Federal de Pernambuco, 2016. 18, 31, 32
- INMAM, D. J. Smart structures: example and new problems. *Congresso Brasileiro de Engenharia Mecânica – COBREM*, n. 16, p. 26–30, 2001. 36
- INMAN, D. J. *Vibrações Mecânicas*. [S.l.]: Elsevier Editora Ltda., 2018. v. 4. 28, 29
- LEE, J.; KIM, S. Structural damage detection in the frequency domain using neural networks. *Journal of Intelligent Material Systems and Structures*, London, v. 18, n. 8, p. 785–792, 2007. 38
- LIMA, F. et al. Monitoring and fault identification in aeronautical structures using an wavelet-artificial immune system algorithm. In: *Probabilistic prognostics and health management of energy systems*. [S.l.]: Springer, 2017. p. 203–219. 39
- LIMA, F. P. d. A. *Análise de distúrbios de tensão em sistemas de distribuição de energia elétrica baseada em sistemas imunológicos artificiais*. Dissertação (Mestrado) — Universidade Estadual Paulista (UNESP), 2013. 39, 47, 57, 60

- LIMA, F. P. d. A. *Diagnóstico de distúrbios de tensão em sistemas de distribuição baseado num sistema imunológico artificial com aprendizado continuado*. Tese (Doutorado) — Universidade Estadual Paulista, 2016. 43, 45, 46, 47, 56, 57
- LIMA, F. P. d. A. *Novas Abordagens Híbridas Inteligentes Aplicadas ao Diagnóstico de Falhas Estruturais Utilizando Sistemas Imunológicos Artificiais, Redes Neurais Artificiais e Transformada Wavelet*. Tese (Pós-Doutorado) — Universidade Estadual Paulista, 2018. 17, 39
- LIMA, F. Parra dos A. et al. Artificial immune systems with negative selection applied to health monitoring of aeronautical structures. In: TRANS TECH PUBL. *Advanced Materials Research*. [S.l.], 2014. v. 871, p. 283–289. 39
- LOPES, V. et al. Damage detection in structures by electrical impedance and optimization technique. In: SPRINGER. *IUTAM Symposium on Smart Structures and Structronic Systems*. [S.l.], 2001. p. 239–246. 37
- LOURENÇO, R. F. B. *Análise computacional do comportamento dinâmico de um sistema vibro-impacto*. Dissertação (Mestrado) — Universidade Estadual Paulista (UNESP), 2017. 28
- LOURENÇO, R. F. B. et al. Analysis and recognition of standards in intelligent hybrid systems using natural computing. *Journal of Applied and Computational Mechanics*, Ahvaz, v. 7, n. 3, p. 1764–1773, 2021. 40
- LOUZADA, D. R. *Deteção E Caracterização De Danos Estruturais Através De Sensores A Rede De Bragg E Redes Neurais Artificiais*. Tese (Doutorado) — Pontifícia Universidade Católica do Rio de Janeiro, 2013. 37
- MACHADO, R. B. *Uma abordagem de detecção de intrusão baseada em sistemas imunológicos artificiais e agentes móveis*. Dissertação (Mestrado) — Universidade Federal de Santa Catarina, 2005. 41, 42, 45
- MAIO, C. E. B. *Técnicas para monitoramento de integridade estrutural usando sensores e atuadores piezoelétricos*. Dissertação (Mestrado) — Universidade de São Paulo, 2011. 25, 36
- MALANGE, F. C. V. *Rede Neuro-Fuzzy-Wavelet para detecção e classificação de anomalias de tensão em sistemas elétricos de potência*. Tese (Doutorado) — Universidade Estadual Paulista (UNESP), 2010. 38
- MARTINS, V. *Caminhão quebra em ladeira e desce avenida desgovernado em Piracicaba*. 2013. Piracicaba em Alerta/G1. Disponível em: <<http://glo.bo/1i1CNsI>>. Acesso em: 18 maio. 2020. 34
- MATOS, B. G. G. d. *Controlador e accionador para motor DC em malha fechada*. Dissertação (Mestrado), 2008. 33
- MELLIS, F. *Gol inspeciona motores de aviões após acidente com morte nos EUA*. 2018. R7 - economia. Disponível em: <<https://noticias.r7.com/economia/gol-inspeciona-motores-de-avioes-apos-acidente-com-morte-nos-eua-26042018>>. Acesso em: 19 maio. 2020. 35

- MONTEIRO, L. H. A. *Sistemas dinâmicos*. [S.l.]: Editora Livraria da Física, 2002. 21
- NTSB/REUTERS. *Gol inspeciona motores de aviões após acidente com morte nos EUA*. 2018. R7 - economia. Disponível em: <<https://noticias.r7.com/economia/gol-inspeciona-motores-de-avioes-apos-acidente-com-morte-nos-eua-26042018>>. Acesso em: 19 maio. 2020. 35
- OLIVEIRA, D. C. d. *Diagnóstico de falhas em estruturas isotrópicas utilizando sistemas imunológicos artificiais com seleção negativa e clonal*. Tese (Doutorado) — Universidade Estadual Paulista, 2019. 37, 40, 49, 58, 67
- OUTA, R. *Prognose e detecção de falhas em um rotor dinâmico, utilizando regressão linear e sistemas imunológicos artificiais*. Tese (Pós-Doutorado) — Universidade Estadual Paulista, 2019. 21, 39
- PANDEY, P.; BARAI, S. Multilayer perceptron in damage detection of bridge structures. *Computers Structures*, Elmsford, v. 54, n. 4, p. 597–608, 1995. 37
- PAULA, F. S. d. *Uma arquitetura de segurança computacional inspirada no sistema imunológico*. Tese (Doutorado) — Universidade Estadual de Campinas, 2004. 41, 42
- RANKINE, W. M. On the centrifugal force of rotating shafts. *Van Nostrand's Eclectic Engineering Magazine (1869-1879)*, New York, v. 1, n. 7, p. 598, 1869. 21, 22
- RAO, S. S. *Vibrações Mecânicas*. [S.l.]: Pearson education, 2008. v. 4. 28
- RYTTER, A. *Vibrational based inspection of civil engineering structures*. Tese (Doutorado) — Dept. of Building Technology and Structural Engineering, Aalborg University, 1993. 36
- SANTIAGO, D. F. de A. *Diagnostico de falhas em maquinas rotativas utilizando transformada de wavelet e redes neurais artificiais*. Tese (Doutorado) — University of Campinas, Brazil, 2004. 38
- SHEN, T. et al. Damage location and identification of the wing structure with probabilistic neural networks. In: IEEE. *2011 Prognostics and System Health Managment Confernece*. [S.l.], 2011. p. 1–6. 38
- SILVA, F. D. G. d. *Monitoramento e análise da integridade de um trator utilizando redes neurais ARTMAP-Fuzzy*. Dissertação (Mestrado) — Universidade Estadual Paulista (Unesp), 2016. 39
- SILVA, J. G. B. d. *Aplicação da Análise de componentes Principais (PCA) no diagnóstico de defeitos de rolamentos através da assinatura elétrica de motores de indução*. Tese (Doutorado) — Universidade Federal de Itajubá, 2008. 25, 26, 27
- SILVA, L. N. d. C. *Engenharia imunológica: desenvolvimento e aplicação de ferramentas computacionais inspiradas em sistemas imunológicos artificiais*. Tese (Doutorado) — Universidade Estadual de Campinas, 2001. 42, 45, 48, 49, 50
- SILVA, S. D.; JUNIOR, M. D.; JUNIOR, V. L. Structural health monitoring in smart structures through time series analysis. *Structural Health Monitoring*, London, v. 7, n. 3, p. 231–244, 2008. 38

- SONG, B. I.; SEZEN, H.; GIRIUNAS, K. A. Collapse performance evaluation of steel buildings after loss of columns. In: *Structures Congress 2012*. [S.l.: s.n.], 2012. p. 213–224. 39
- SOUZA, A. dos Santos e et al. Analysis of structural integrity using an artmap-fuzzy artificial neural network. In: TRANS TECH PUBL. *Advanced Materials Research*. [S.l.], 2014. v. 838, p. 3287–3290. 39
- SOUZA, S. S. et al. Monitoring of structural integrity using unsupervised data clustering techniques. *International Journal of Pure and Applied Mathematics*, Citeseer, v. 104, n. 1, p. 119–133, 2015. 39
- TEBALDI, A. *Detecção de falhas estruturais usando sensores e atuadores piezelétricos e algoritmos genéticos*. Dissertação (Mestrado) — Universidade Estadual Paulista (UNESP), 2004. 37
- TEBALDI, A.; COELHO, L. d. S.; JUNIOR, V. L. Detecção de falhas em estruturas inteligentes usando otimização por nuvem de partículas: fundamentos e estudo de casos. *Sba: Controle & Automação Sociedade Brasileira de Automatica*, Campinas, v. 17, p. 312–330, 2006. 38
- TIMMIS, J. *Artificial immune systems: A novel data analysis technique inspired by the immune network theory*. Tese (Doutorado) — University of Wales, 2000. 41
- TURRA, A. E. et al. Detecção de dano em placas de alumínio utilizando impedância eletromecânica. *Proceeding Series of the Brazilian Society of Computational and Applied Mathematics*, São Carlos, v. 1, n. 1, 2013. 17, 39
- VALLES-NOVO, R. et al. Empirical mode decomposition analysis for broken-bar detection on squirrel cage induction motors. *IEEE Transactions on Instrumentation and Measurement*, New York, v. 64, n. 5, p. 1118–1128, 2014. 17
- VANCE, J. M.; ZEIDAN, F. Y.; MURPHY, B. G. *Machinery vibration and rotordynamics*. [S.l.]: John Wiley & Sons, 2010. 21, 22
- WANG, F. et al. Damage diagnosis for complex steel truss bridges using multi-layer genetic algorithm. *Journal of Civil Structural Health Monitoring*, Berlin, v. 3, n. 2, p. 117–127, 2013. 39
- WANG, X.; TANG, J. Damage identification using piezoelectric impedance approach and spectral element method. *Journal of Intelligent Material Systems and Structures*, London, v. 20, n. 8, p. 907–921, 2009. 38
- WORDEN, K.; DULIEU-BARTON, J. M. An overview of intelligent fault detection in systems and structures. *Structural Health Monitoring*, New York, v. 3, n. 1, p. 85–98, 2004. 25
- WYLIE, M.; PLEYDELL, M. Network management data acquisition and analysis. In: IET. *IET Road Transport Information and Control-RTIC 2008 and ITS United Kingdom Members' Conference*. [S.l.], 2008. p. 1–3. 57
- XIE, Y. Investigation of broken rotor bar faults in three-phase squirrel-cage induction motors. *Finite Element Analysis—From Biomedical Applications to Industrial Developments*, p. 477–498, 2012. 18

YOON, S. Y.; LIN, Z.; ALLAIRE, P. E. *Control of surge in centrifugal compressors by active magnetic bearings: Theory and implementation*. [S.l.]: Springer Science & Business Media, 2012. [23](#), [24](#)

ZHENG, S.; WANG, X.; LIU, L. Damage detection in composite materials based upon the computational mechanics and neural networks. In: *European Workshop on Structural Health Monitoring, Munich*. [S.l.: s.n.], 2004. p. 609–615. [17](#)

APÊNDICE A – Produção Científica

Nesse apêndice apresenta-se a produção científica desenvolvida no período de realização do doutorado.

A.1 Publicação de artigos

A.1.1 Periódicos Nacionais

DEA, T. H. G. ; LOURENCO, R. F. B. ; CHAVARETTE, F. R. ; OUTA, R. ; SILVA, M. D. G. . ANÁLISE DINÂMICA EXPERIMENTAL DE ROTORES DESBALANCEADOS. COLLOQUIUM EXACTARUM, v. 13, p. 13-18, 2022.

DOWGLAS DE GOIS SILVA, MICHAEL ; ROBERTO CHAVARETTE, FÁBIO ; BAPTISTA FERREIRA JUNIOR, MILTON ; FRANCISCO BORGES LOURENCO, RODRIGO . ANÁLISE DA INTEGRIDADE E DA INSTABILIDADE DINÂMICA DE UM SISTEMA MECÂNICO SUJEITO A BIFURCAÇÃO DO TIPO BUTTERFLY. COLLOQUIUM EXACTARUM, v. 12, p. 14-22, 2021.

SILVA, M. D. G. ; CHAVARETTE, F. R. ; LOURENCO, R. F. B. . ANÁLISE DO COMPORTAMENTO DINÂMICO DE UM SISTEMA MECÂNICO SUJEITO A BIFURCAÇÃO INSTÁVEL. RESEARCH, SOCIETY AND DEVELOPMENT, V. 9, P. 424973763, 2020.

LOURENCO, R. F. B.; CHAVARETTE, F. R. ; SILVA, M. D. G. ; SILVA, D. M. ; ALVES, J. L. S. . CONTROLE LINEAR ÓTIMO APLICADO EM ESTRUTURAS VIBRO-IMPACTO. RESEARCH, SOCIETY AND DEVELOPMENT, V. 9, P. E90973708, 2020.

A.1.2 Periódicos Internacionais

LOURENCO, R. F. B.; CHAVARETTE, F. R. ; OUTA, R. ; GONCALVES, A. C. . ANALYSIS AND RECOGNITION OF STANDARDS IN INTELLIGENT HYBRID SYSTEMS USING NATURAL COMPUTING. JOURNAL OF APPLIED AND COMPUTATIONAL MECHANICS, V. 7, P. 1764-1773, 2021.

A.2 Participação em Eventos

ENCONTRO NACIONAL DE ENSINO, PESQUISA E EXTENSÃO DA UNOESTE. ANÁLISE DINÂMICA EXPERIMENTAL DE ROTORES DESBALANCEADOS. 2021. (CONGRESSO).

III CONGRESSO DE ENSINO, PESQUISA E EXTENSÃO / XV CONGRESSO DE INICIAÇÃO CIENTÍFICA DA UNIVERSIDADE DE RIO VERDE - UNIRV. ANÁLISE DINÂMICA COMPUTACIONAL DE ESTRUTURAS SOB IMPACTOS. 2021. (CONGRESSO).

XL CONGRESSO NACIONAL DE MATEMÁTICA APLICADA E COMPUTACIONAL - CNMAC 2021. DETECÇÃO DE FALHAS EM UM SISTEMA ROTATIVO UTILIZANDO SISTEMAS IMUNOLÓGICOS ARTIFICIAIS. 2021. (CONGRESSO).

ENCONTRO NACIONAL DE ENSINO, PESQUISA E EXTENSÃO DA UNOESTE. 2020. (CONGRESSO).

XI MOSTRA DE EXTENSÃO DA UFMT. 2020. (EXPOSIÇÃO).

XI SEREX - SEMINÁRIO REGIONAL DE EXTENSÃO UNIVERSITÁRIA DA REGIÃO CENTRO-OESTE. 2020. (SEMINÁRIO).

A.3 Apresentação de Trabalhos

A.3.1 CNMAC 2021

BORGES, RODRIGO; CHAVARETTE, F. R. ; OUTA, R. ; SILVA, M. D. G. ; SILVA, D. M. . DETECÇÃO DE FALHAS EM UM SISTEMA ROTATIVO UTILIZANDO SISTEMAS IMUNOLÓGICOS ARTIFICIAIS. 2021. (Apresentação de Trabalho/Congresso).

A.3.2 ENEPE 2021

DEA, T. H. G. ; LOURENCO, R. F. B. ; SILVA, R. O. ; SILVA, M. D. G. ; CHAVARETTE, F. R. ; OUTA, R. . ANÁLISE DINÂMICA EXPERIMENTAL DE ROTORES DESBALANCEADOS. 2021. (Apresentação de Trabalho/Congresso).

A.3.3 CEPEX 2021

SANTOS, S. J. R. ; LOURENCO, R. F. B. ; CHAVARETTE, F. R. ; SILVA, E. R. ; COSTA, F. M. ; SILVA, D. M. . ANÁLISE DINÂMICA COMPUTACIONAL DE ESTRUTURAS SOB IMPACTOS. 2021. (Apresentação de Trabalho/Congresso).

A.3.4 ENEPE 2020

SILVA, M. D. G. ; CHAVARETTE, F. R. ; FERREIRA JUNIOR, M. B. ; LOURENCO, R. F. B. . ANÁLISE DA INTEGRIDADE E DA INSTABILIDADE DINÂMICA DE UM SISTEMA MECÂNICO SUJEITO A BIFURCAÇÃO DO TIPO BUTTERFLY. 2020. (Apresentação de Trabalho/Congresso).

A.3.5 CEPEX 2020

MEDEIROS, D. R. ; LOURENCO, R. F. B. ; SILVA, D. M. ; SILVA, E. R. ; SILVA, M. D. G. ; COSTA, F. M. . ANÁLISE COMPUTACIONAL DO COMPORTAMENTO DINÂMICO DE UMA ESTRUTURA SUJEITA A ABALOS SÍSMICOS. 2020. (Apresentação de Trabalho/Congresso).

A.4 Resumos Publicados em Anais de Eventos

MEDEIROS, D. R. ; LOURENCO, R. F. B. ; SILVA, D. M. ; SILVA, E. R. ; SILVA, M. D. G. ; COSTA, F. M. . ANÁLISE COMPUTACIONAL DO COMPORTAMENTO DINÂMICO

DE UMA ESTRUTURA SUJEITA A ABALOS SÍSMICOS. In: XIV COGRESSO DE INICIAÇÃO CIÊNTIFICA DA UNIVERSIDADE DE RIO VERDE, 2020, Rio Verde. ANAIS DO XIV COGRESSO DE INICIAÇÃO CIÊNTIFICA DA UNIVERSIDADE DE RIO VERDE, 2020. v. 14. p. 129-136.

SANTOS, S. J. R. ; LOURENCO, R. F. B. ; CHAVARETTE, F. R. ; SILVA, E. R. ; COSTA, F. M. ; SILVA, D. M. . ANÁLISE DINÂMICA COMPUTACIONAL DE ESTRUTURAS SOB IMPACTOS. In: XV Congresso de Iniciação Científica da Universidade de Rio Verde, 2021, Rio Verde. Anais do XV Congresso de Iniciação Científica da Universidade de Rio Verde, 2021. v. 15. p. 169-174.

A.5 Orientação de Iniciação Científica - Concluída

THALES HENRIQUE GOMES DÉA. ANÁLISE DINÂMICA EXPERIMENTAL DE FALHAS EM ROTORES. 2021. INICIAÇÃO CIENTÍFICA. (GRADUANDO EM ENGENHARIA MECÂNICA) - UNIVERSIDADE DE RIO VERDE. ORIENTADOR: RODRIGO FRANCISCO BORGES LOURENÇO.

SAUL JOSÉ RODRIGUÊS DOS SANTOS. DINÂMICA COMPUTACIONAL DE ESTRUTURAS SOB IMPACTOS. 2021. INICIAÇÃO CIENTÍFICA. (GRADUANDO EM ENGENHARIA MECÂNICA) - UNIVERSIDADE DE RIO VERDE. ORIENTADOR: RODRIGO FRANCISCO BORGES LOURENÇO.

DIEGO REZENDE MEDEIROS. ANÁLISE COMPUTACIONAL DO COMPORTAMENTO DINÂMICO DE UMA ESTRUTURA SUJEITA A ABALOS SÍSMICOS. 2020. INICIAÇÃO CIENTÍFICA. (GRADUANDO EM ENGENHARIA CIVIL) - UNIVERSIDADE DE RIO VERDE. ORIENTADOR: RODRIGO FRANCISCO BORGES LOURENÇO.

A.6 Orientação de Iniciação Científica - Em andamento

MATHEUS HENRIQUE JUNQUEIRA DE MORAES. ANÁLISE DE VIBRAÇÕES EM MÁQUINAS ROTATIVAS DESBALANCEADAS. 2022. INICIAÇÃO CIENTÍFICA. (GRADUANDO EM ENGENHARIA MECÂNICA) - UNIVERSIDADE DE RIO VERDE. ORIENTADOR: RODRIGO FRANCISCO BORGES LOURENÇO.