

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

DANIELA CABRAL DE OLIVEIRA

**DIAGNÓSTICO DE FALHAS EM ESTRUTURAS ISOTRÓPICAS UTILIZANDO
SISTEMAS IMUNOLÓGICOS ARTIFICIAIS COM SELEÇÃO NEGATIVA E
CLONAL**

Ilha Solteira
2019

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

DANIELA CABRAL DE OLIVEIRA

**DIAGNÓSTICO DE FALHAS EM ESTRUTURAS ISOTRÓPICAS UTILIZANDO
SISTEMAS IMUNOLÓGICOS ARTIFICIAIS COM SELEÇÃO NEGATIVA E
CLONAL**

Tese apresentada à Faculdade de Engenharia de Ilha Solteira – UNESP como parte dos requisitos para obtenção do título de doutorado em Engenharia Mecânica.

Prof. Dr. Fábio Roberto Chavarette
Orientador

Mara Lúcia Martins Lopes
Coorientadora

Ilha Solteira

2019

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

Oliveira, Daniela Cabral de.
O482d Diagnóstico de falhas em estruturas isotrópicas utilizando sistemas imunológicos artificiais com seleção negativa e clonal / Daniela Cabral de Oliveira. -- Ilha Solteira: [s.n.], 2019
86 f. : il.

Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Mecânica dos Sólidos, 2019

Orientador: Fábio Roberto Chavarette
Coorientadora: Mara Lúcia Martins Lopes
Inclui bibliografia

1. Monitoramento de integridade estrutural. 2. Estruturas isotrópicas. 3. Sistemas imunológicos artificiais. 4. Algoritmo de seleção negativa. 5. Algoritmo de seleção clonal.

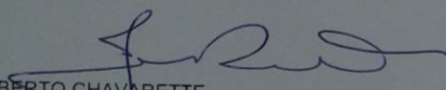

Raiane da Silva Santos

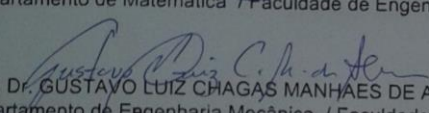
CERTIFICADO DE APROVAÇÃO

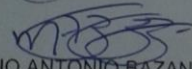
TÍTULO DA TESE: Diagnóstico de Falhas em Estruturas Isotrópicas Utilizando Algoritmos de Sistemas Imunológicos Artificiais com Algoritmos de Seleção Negativa e Seleção Clonal

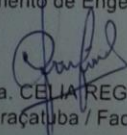
AUTORA: DANIELA CABRAL DE OLIVEIRA
ORIENTADOR: FABIO ROBERTO CHAVARETTE
COORIENTADORA: MARA LUCIA MARTINS LOPES

Aprovada como parte das exigências para obtenção do Título de Doutora em ENGENHARIA MECÂNICA, área: Mecânica dos Sólidos pela Comissão Examinadora:

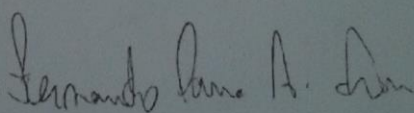

Prof. Dr. FABIO ROBERTO CHAVARETTE
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira


Prof. Dr. GUSTAVO LUIZ CHAGAS MANHAES DE ABREU
Departamento de Engenharia Mecânica / Faculdade de Engenharia de Ilha Solteira


Prof. Dr. MARCIO ANTONIO BAZANI
Departamento de Engenharia Mecânica / Faculdade de Engenharia de Ilha Solteira


Profa. Dra. CELIA REGINA NUGOLI ESTEVAM
FATEC Araçatuba / Faculdade de Tecnologia do Estado de São Paulo

Prof. Dr. FERNANDO PARRA DOS ANJOS LIMA
Câmpus Avançado Tangará da Serra / Instituto Federal de Mato Grosso



Ilha Solteira, 26 de abril de 2019

AGRADECIMENTOS

A Deus.

Ao professor Dr. Fábio Roberto Chavarette, agradeço pela prontidão, afeição, dedicação, e pelas contribuições na minha formação acadêmica, profissional e pessoal.

Agradeço a Deus e aos meus pais, André Luiz de Oliveira e Terezinha Cabral Firmino de Oliveira.

Aos meus colegas do laboratório de sistemas complexos - SISPLEXOS pela ajuda e empenho nas dificuldades encontradas para o desenvolvimento do trabalho.

RESUMO

Este trabalho é dedicado ao desenvolvimento de uma metodologia baseada no monitoramento da integridade estrutural em aeronaves com foco em técnicas de computação inteligente, tendo como intuito detectar, localizar e quantificar falhas estruturais utilizando os sistemas imunológicos artificiais (SIA). Este conceito permite compor o sistema de diagnóstico apto a aprender continuamente, contemplando distintas situações de danos, sem a necessidade de reiniciar o processo de aprendizado. Neste cenário, foi empregado dois algoritmos imunológicos artificiais, sendo o algoritmo de seleção negativa, responsável pelo processo de reconhecimento de padrões, e o algoritmo de seleção clonal responsável pelo processo de aprendizado continuado. Também foi possível quantificar o grau de influência do dano para as cinco situações de danos. Para avaliar a metodologia foi montada uma bancada experimental com transdutores piezelétricos que funcionam como sensor e atuador em configurações experimentais, que podem ser anexadas à estrutura para produzir ou coletar ondas numa placa de alumínio (representando a asa do avião), sendo coletados sinais na situação normal e em cinco situações distintas de danos. Os resultados demonstraram robustez e precisão da nova metodologia proposta.

Palavras-chave: Monitoramento de integridade estrutural. Estruturas isotrópicas. Sistemas imunológicos artificiais. Algoritmo de seleção negativa. Algoritmo de seleção clonal.

ABSTRACT

This work is dedicated to the development of a methodology based on the monitoring of structural integrity in aircraft with a focus on intelligent computing techniques, aiming to detect structural failures using the artificial immune systems (AIS). This concept allows to compose the diagnostic system capable of learning continuously, contemplating different situations of damages, without the need to restart the learning process. In this scenario, two artificial immunological algorithms were employed, the negative selection algorithm, responsible for the pattern recognition process, and the clonal selection algorithm responsible for the continuous learning process. It was also possible to quantify the degree of influence of the damage for the five damage situations. To assess the methodology, an experimental bench was mounted with piezoelectric transducers that act as sensors and actuators in experimental configurations, which can be attached to the structure to produce or collect waves on an aluminum plate (representing the wing of the airplane), being collected signals in the normal situation and in five different situations of damages. The results demonstrate the robustness and accuracy of the proposed new methodology.

Keywords: Structural health monitoring. Isotropic structures. Artificial immune systems. Negative selection algorithm. Clonal selection algorithm.

LISTA DE FIGURAS

Figura 1 – Funcionamento do processo de reconhecimento de padrões e aprendizado SIB	36
Figura 2 – Fase Censoriamento do ASN	40
Figura 3 – Fase Monitoramento do ASN	41
Figura 4 – Fluxograma do algoritmo ASN no SHM	44
Figura 5 – Fluxograma de funcionamento do algoritmo CLONALG	46
Figura 6 – Materiais e equipamentos utilizados no experimento com material isotrópico	49
Figura 7 – Foto da placa utilizada no experimento e placa mostrando posicionamento dos transdutores	50
Figura 8 – Sinais entre atuadores/sensores utilizados na localização dos danos	50
Figura 9 – Posicionamento dos danos	51
Figura 10 – Sinal emitido pelo atuador PZT 5 para 250Mhz, e sinal captado no sensor PZT 9 para situação sem dano (baseline) e para situação com dano 4.	52
Figura 11 – Primeiro pacote do sinal emitido pelo atuador PZT 5 para 250Mhz e sinal captado no sensor PZT 9 para situação sem dano (baseline) e para situação com dano 4.	53
Figura 12 – Sinal emitido pelo atuador PZT 1 para 250Mhz e sinal captado no sensor PZT 2 para situação sem dano (baseline) e para situação com dano 4.	53
Figura 13 – Primeiro pacote do sinal emitido pelo atuador PZT 1 para 250Mhz e sinal captado no sensor PZT 2 para situação sem dano (baseline) e para situação com dano 4.	54
Figura 14 – Sinal emitido pelo atuador PZT 6 para 250Mhz e sinal captado no sensor PZT 8 para situação sem dano (baseline) e para situação com dano 4.	54

Figura 15 – Primeiro pacote do sinal emitido pelo atuador PZT 6 para 250Mhz e sinal captado no sensor PZT 8 para situação sem dano (baseline) e para situação com dano 4.	55
Figura 16 – Fluxograma de funcionamento do algoritmo com aprendizado continuado	56
Figura 17 – Módulo de Censoriamento do ASN	57
Figura 18 – Módulo de Monitoramento do ASN	60
Figura 19 – Anatomia do sistema imunológico biológico	83
Figura 20 – Barreiras do Sistema Imunológico Biológico	85
Figura 21 – Funcionamento do princípio de seleção clonal	87

LISTA DE TABELAS

Tabela 1 – Parâmetros	61
Tabela 2 – Resultados do algoritmo convencional	65
Tabela 3 – Resultados do algoritmo com aprendizado continuado	66
Tabela 4 – Resultados do algoritmo convencional	66
Tabela 5 – Resultados do algoritmo com aprendizado continuado	67
Tabela 6 – Quantificação quanto ao grau de influência do dano 1	68
Tabela 7 – Quantificação quanto ao grau de influência do dano 2	68
Tabela 8 – Quantificação quanto ao grau de influência do dano 3	69
Tabela 9 – Quantificação quanto ao grau de influência do dano 4	69
Tabela 10 – Quantificação quanto ao grau de influência do dano 5	70

LISTA DE SIGLAS

α	Taxa de mutação
Ab	Linfócito
\underline{Ab}_i	Valor nominal da posição i menos o desvio adotado no anticorpo
\overline{Ab}_i	Valor nominal da posição i mais o desvio adotado no anticorpo
Ab_n	Conjunto de linfócitos selecionados
Ab_d	Conjunto de linfócitos gerados para a metadinâmica
Ab_M	Linfócitos de memória
Ab_R	Restante dos linfócitos da população
Abs	Valor absoluto
Ag	Antígeno
Ag_i	Valor nominal da posição i do antígeno
Afr	% de afinidade entre os padrões analisados
An	Número de cadeias normais
APC	Célula Apresentadora de Antígenos
ASC	Algoritmo de Seleção Clonal
ASN	Algoritmo de Seleção Negativa
At	Número de cadeias totais
β	Fator multiplicativo
CLONALG	Algoritmo de seleção clonal
C	População de clones
C^*	Subpopulação de clones maturados
CFRP	Reforçadas com Fibra de Carbono
d	Quantidade de linfócitos que passam pela metadinâmica
ϵ	Desvio
D	Sinal com dano
f	Valor de afinidade de cada linfócito
f^*	Afinidade normalizada
L	Quantidade total de posições

<i>m</i>	Quantidade de mutações para cada linfócito clonado
<i>M</i>	Quantidade de linfócitos de memória
<i>Lamb</i>	Lâmbda
<i>Máximo</i>	Valor máximo da métrica RMSD
<i>Métrica</i>	Métrica RMSD
<i>MHC</i>	Complexo Principal de Histocompatibilidade (Major Histocompatibility Complex)
<i>MHz</i>	Mega Hertz
<i>Mínimo</i>	Valor mínimo da métrica RMSD
<i>n</i>	Quantidade de linfócitos selecionados
<i>N</i>	Quantidade de linfócitos da população
<i>Nc</i>	Quantidade de clones gerados
<i>NDE</i>	Não destrutivo
<i>P</i>	Parâmetro de controle do amortecimento da função exponencial
<i>Pc</i>	Posição casada
<i>PZT</i>	Piezelétrico
<i>R</i>	Conjunto de Detectores
<i>Raiz</i>	Raiz quadrada
<i>RMSD</i>	Valor médio quadrático
<i>S</i>	Cadeias Próprias / Cadeias Protegidas
<i>SD</i>	Sinal sem dano
<i>SHM</i>	<i>Structural Health Monitoring</i>
<i>SIA</i>	Sistemas Imunológicos Artificiais
<i>SIB</i>	Sistema Imunológico Biológico
<i>Soma</i>	Soma
<i>TAf</i>	Taxa de Afinidade

SUMÁRIO

1	INTRODUÇÃO.....	15
1.1	OBJETIVOS E CONTRIBUIÇÕES	19
1.2	PROPOSTA.....	19
1.3	JUSTIFICATIVA.....	19
1.4	ORGANIZAÇÃO DA TESE	20
2	FALHAS ESTRUTURAIS	22
2.1	INTRODUÇÃO.....	22
2.2	CASO DE CATÁSTROFES AERONÁUTICA	22
3	REVISÃO BIBLIOGRÁFICA.....	24
3.1	MONITORAMENTO DE INTEGRIDADE ESTRUTURAL	24
3.2	METODOLOGIAS APLICADAS NO MONITORAMENTO DE INTEGRIDADE ESTRUTURAL.....	26
3.3	EVOLUÇÃO DOS SISTEMAS IMUNOLÓGICOS ARTIFICIAIS	28
4	SISTEMA IMUNOLÓGICO BIOLÓGICO	35
4.1	INTRODUÇÃO.....	35
4.2	FUNCIONAMENTO DO SISTEMA IMUNOLÓGICO BIOLÓGICO	35
5	SISTEMAS IMUNOLÓGICOS ARTIFICIAIS	39
5.1	INTRODUÇÃO.....	39
5.1.1	Algoritmo de Seleção Negativa (ASN).....	39
5.1.2	Critério de Casamento e Taxa de Afinidade	42
5.1.3	Algoritmo de Seleção Clonal (CLONALG)	46
6	MONTAGEM EXPERIMENTAL.....	49
7	MATERIAL E MÉTODOS	56
8	RESULTADOS E DISCUSSÃO.....	64
8.1	RESULTADOS ALGORITMOS ASN E CLONALG.....	64
8.2	RESULTADOS MÉTRICAS GRAU DE INGLUÊNCIA DANO 1	67
8.3	RESULTADOS MÉTRICAS GRAU DE INGLUÊNCIA DANO 2	68
8.4	RESULTADOS MÉTRICAS GRAU DE INGLUÊNCIA DANO 3	69
8.5	RESULTADOS MÉTRICAS GRAU DE INGLUÊNCIA DANO 4	69
8.6	RESULTADOS MÉTRICAS GRAU DE INGLUÊNCIA DANO 5	70

8.7	ASPECTOS POSITIVOS E NEGATIVOS DA METODOLOGIA.....	70
8.7.1	Pontos Positivos da Metodologia.....	70
8.7.2	Pontos Negativos da Metodologia	71
9	CONCLUSÃO	72
9.1	SUGESTÕES PARA TRABALHOS FUTUROS.....	72
	REFERÊNCIAS	73
	 ANEXO A – Sistema Imunológico Biológico	 82

1 INTRODUÇÃO

Veículos terrestres, aéreos, marítimos e espaciais, grandes estruturas, grandes máquinas estão em todos os lugares. A presença de falhas nestes sistemas pode pôr em risco a segurança, podendo inviabilizar suas operações. Falhas estruturais tem o potencial de causar prejuízo financeiro e na pior das situações afetar vidas. Entre 1990 e 2007 houve 1502 comunicados de acidentes de avião no transporte regional no espaço aéreo norte americano, no qual 386 deles (26%) foram fatais, resultando em 1104 mortes (ZHONGQING *et. al*, 2009).

As falhas são resultados da presença de danos estruturais ou acúmulo progressivo de defeitos no material, chegando ao nível crítico, causando colapso. O envelhecimento das aeronaves ou submissão à carga de fadiga e exposição a ambientes corrosivos comprometem a integridade estrutural ocasionando danos e subsequentemente a falha (ZHONGQING *et. al*, 2009).

O monitoramento da integridade de estruturas (do inglês Structural Health Monitoring, SHM) consiste em detectar danos no estado inicial, intervir na propagação e impedir que ocorra parada ou danificação da estrutura. Danos levam às falhas que por sua vez são definidas como modificações no sistema que impossibilitam que o mesmo opere de forma satisfatória e consiga exercer funções (HALL, 1999).

O desafio de projetar um SHM é identificar e analisar os tipos de mudanças na estrutura e a arquitetura desse sistema depende das características da estrutura que pode ser definida de distintas formas. As falhas estruturais em aeronaves ocorrem em consequência de diversos danos na estrutura, tais como: desgastes de componentes; corrosões; cortes; trincas; afrouxamento de uniões aparafusadas; delaminações; aderência de massas (incrustações) ou combinação dos itens anteriores (FRANCO *et. al*, 2009). Na grande maioria dos casos, independente da origem ou intensidade, a concentração dos danos pode desencadear a falha estrutural e comprometer o funcionamento da estrutura. As falhas podem provocar uma sensível variação nos parâmetros espaciais da estrutura, ocasionando redução da rigidez estrutural, redução da massa e aumento do amortecimento, o que modifica o comportamento dinâmico da estrutura (TURRA *et. al*, 2013). Esta variação dos parâmetros espaciais afetam os principais parâmetros dinâmicos, tais

como funções de respostas, frequências de ressonância, razão de amortecimento e modos próprios da estrutura (ZHENG *et. al*, 2004).

O SHM envolve a observação do sistema estrutural ao longo do tempo através de uma malha de sensores com medições de respostas dinâmicas amostradas periodicamente, a partir disso, a extração das características sensíveis ao dano são obtidas e, finalmente, a análise estatística determina o estado atual do sistema relativo à sua integridade (FARRAR *et. al*, 2005).

O SHM pode ser classificado em níveis que se baseiam na capacidade de abrangência, conforme (DOEBLINGS *et. al*, 1998):

- Nível 1 – Detecta a existência do dano;
- Nível 2 – Detecta e localiza o dano;
- Nível 3 – Detecta, localiza e quantifica o dano;
- Nível 4 – Detecta, localiza e quantifica o dano e então estima a vida útil do restante do equipamento.

Inman (2001) acrescentou mais três níveis, englobando a utilização de materiais inteligentes, que:

- Nível 5 – Combina o nível 4 com estruturas inteligentes para autodiagnóstico do dano estrutural;
- Nível 6 – Combina o nível 4 com estruturas inteligentes e controle para formar um sistema de auto reparo estrutural;
- Nível 7 – Combina o nível 1 com controle ativo e estruturas inteligentes para obtenção de um sistema simultâneo de controle e monitoramento.

Louzada (2013) complementa que há quatro fases para a implementação do sistema SHM:

- Na primeira fase ocorre a aquisição dos dados ou sinais transmitidos pela estrutura a ser monitorada. Nesta fase, pode haver a integração de sensores, atuadores, tipos de malhas, etc. Segundo Farrar e Worden (2006) nesta fase é preciso estar atento aos intervalos em que os dados são medidos e a forma em que são coletados.
- Na segunda fase é necessário trabalhar com os dados obtidos na forma bruta. Análise através de filtros a fim de reproduzir ruídos e técnicas de normalização são métodos utilizados. A normalização dos dados é considerada como um processo de identificação das alterações resultantes

de danos causadas pela variação das condições ambientais ou operacionais (FARRAR; WORDEN, 2006). Vale destacar que o pré-processamento dos dados é importante para a eficiência do sistema de SHM.

- Após o pré-processamento dos dados, na terceira fase é realizada a transmissão dos mesmos para o sistema proposto que realiza sua interpretação. No caso do sistema para o diagnóstico de danos, é analisado os dados e traz como resposta se a estrutura monitorada possui dano ou não.
- Na última fase, são empregadas as técnicas de SHM, que podem ser NDE (*Nondestructive Evaluation*), sistemas inteligentes, entre outros, para gerar a saída final do sistema.

A técnica para o monitoramento da estrutura depende da configuração construtiva, do ambiente de experimentação e do tipo de estrutura, que pode se basear em técnicas não-destrutivas, denominadas NDE. Dentre elas, estão: inspeção por partículas magnéticas, correntes de Eddy, análise de deformações, técnicas utilizando fibras ópticas, emissões acústicas, vácuo comparativo, raios-x, líquidos penetrantes, propagação de ondas (ondas Lamb) e impedância eletromecânica (GONSALEZ, 2012).

As ondas de Lamb são ondas de deformação plana que ocorrem nas superfícies (inferior e superior). As ondas Lamb são capazes de abranger grande área, sendo possível monitorar grandes estruturas com poucos atuadores e sensores em um arranjo bem projetado. O Titanato de Zirconato de Chumbo (PZT) pode ser anexado à estrutura para produzir ou coletar ondas Lamb, agindo tanto como sensor quanto atuador, facilitando a construção de arranjos para o sensoriamento da estrutura. O PZT possui alto desempenho em aplicações de altas frequências, como no caso das ondas Lamb e Impedância Eletromecânica (MARQUI, 2007). O PZT é empregado para conversão da energia mecânica que é resultado da vibração da estrutura à energia elétrica (JAHANGIRI *et. al*, 2016).

Após o sinal ser capturado é possível utilizar sistemas de inteligência artificial para o processamento de sinais, que a partir das informações geradas pelos desvios dos sinais podem determinar a existência ou não de danos, localização e a gravidade (FRANCO *et. al*, 2009). Para se desenvolver sistemas de SHM modernos e eficientes é necessário utilizar sensores inteligentes e/ou técnicas de computação inteligente (rede neurais artificiais (HAYKIN, 2008), lógica fuzzy (ZADEH, 1995),

sistemas imunológicos artificiais (DE CASTRO; TIMMIS, 2003)), que viabilizam a extração de conhecimentos e informações de processos complexos, viabilizando a análise de sinais e proporcionando automatização das tomadas de decisões.

Os sistemas imunológicos artificiais (DASGUPTA, 1998; DE CASTRO; TIMMIS, 2003) possuem características que permitem aplicações em sistemas de diagnóstico, proporcionando estabilidade e plasticidade. A estabilidade é o aprendizado por meio da experiência e a plasticidade é continuação do aprendizado via inclusão de novos padrões sem perder o conhecimento adquirido. O aprendizado continuado pode ser dividido em seis etapas: (1) aquisição de dados e extração das características do estado operativo da estrutura, (2) módulo detector de novidades, (3) módulo de aprendizado continuado, (4) módulo detector de anormalidades, (5) módulo classificador de defeitos e (6) módulo de atualização de conhecimento.

Na primeira etapa é realizada a modelagem numérica e/ou experimento em laboratório. A partir do sistema de aquisição de dados é realizado a captura dos sinais de vibração provenientes de sensores (PZTs) alocados na estrutura. Ao analisar o sinal, é executado o módulo de detecção de novidades, ou seja, verificação do sinal em relação ao conjunto de células (conhecimento). Caso o sinal seja conhecido pelo sistema o mesmo é analisado, da forma convencional, avançando para a etapa 4. Caso contrário, o sinal é considerado uma novidade. Quando o sistema identifica a novidade a etapa de aprendizado continuado é acionada com o objetivo de apreender sobre o novo padrão desconhecido pelo sistema, fornecendo conhecimento ao sistema, para que numa próxima análise do mesmo tipo de padrão desconhecido o sistema seja capaz de efetuar o reconhecimento e classificação da falha estrutural. Este processo é o denominado aprendizado continuado, e é realizado pelo Algoritmo de Seleção Clonal (ASC) (DE CASTRO; TIMMIS, 2003). Na etapa 4, é executado o módulo detector de anormalidades, onde realiza a análise dos sinais visando identificar comportamentos anormais no sistema. Para esta etapa, é empregado o Algoritmo de Seleção Negativa (ASN) (FORREST *et. al*, 1994). Na etapa 5, após identificar a falha, o evento é classificado utilizando o conceito imunológico do ASN. Na etapa 6 é avaliado a necessidade de atualizar o conjunto de células (conhecimento), visando melhorar o processo de detecção e classificação de falhas estruturais.

Os sistemas imunológicos proporcionam qualidade nos resultados e adaptação automática do sistema de diagnóstico à constante evolução do setor aeronáutico, requisitos necessários para o desenvolvimento de SHMs.

1.1 OBJETIVOS E CONTRIBUIÇÕES

O presente trabalho tem como objetivos e contribuições:

- Apresentar novo método de monitoramento da integridade estrutural com treinamento continuado baseado nos algoritmos de seleção negativa e clonal;
- Apresentar resultados visando verificar a eficiência e robustez do método proposto em distintas situações de dano;
- Contribuir com a linha de pesquisa em sistemas inteligentes, apresentando uma estratégia eficiente com aprendizado continuado para problemas de monitoramento de integridade estrutural em aeronaves;
- Contribuir com a linha de pesquisa em SHM, apresentando uma nova abordagem, atendendo aos níveis 1, 2 e 3 no processo de SHM com propósito de detectar, localizar e quantificar diferentes tipos de danos de forma rápida e eficiente levando em consideração o dinamismo inerente da indústria aeronáutica.

1.2 PROPOSTA

O trabalho proposto tem como proposta:

- Apresentar um método computacional para auxiliar a inspeção de estruturas utilizando técnicas de computação inteligente com aprendizado continuado;
- Realizar análise e caracterização de falhas estruturais.

1.3 JUSTIFICATIVA

Os métodos de monitoramento de integridade estrutural convencional não possuem técnicas que atendem as necessidades das indústrias, principalmente as estruturas em movimentos. Desta forma, os sistemas de monitoramento de integridade estrutural vêm sofrendo uma evolução natural devido ao avanço das tecnologias de sensores, materiais inteligentes, técnicas eficientes de processamento de dados e sinais, e principalmente a demanda de empregar ferramentas em tempo real, como é o caso das aeronaves na indústria aeronáutica.

As técnicas inteligentes são ferramentas inspiradas em processos naturais e/ou biológicos e pertencem ao campo da inteligência artificial que vêm apresentando bons resultados em problemas de reconhecimento de padrões, diagnóstico e assim podendo ser utilizadas para resolver problemas de monitoramento e identificação de falhas estruturais. Desta forma, o projeto visa contribuir com a proposta de um sistema inteligente e integrado com capacidade de propor inovações da indústria aeronáutica em tempo real.

Desenvolver um sistema com tais capacidades é uma tarefa complexa e pouco difundida na literatura. Desta forma, justifica-se esta tese de doutorado, com o objetivo de disponibilizar uma nova forma de monitoramento de integridade estrutural, propondo uma abordagem para o desenvolvimento do sistema com aprendizado continuado para realizar o diagnóstico de falhas em aeronaves. Sendo assim, neste trabalho é apresentado uma nova abordagem para o desenvolvimento de um sistema de diagnóstico com aprendizado continuado inspirando-se no funcionamento do sistema imunológico biológico (SIB). Para compor este sistema são empregados dois algoritmos imunológicos artificiais, sendo eles: algoritmo de seleção negativa (ASN), (FORREST *et. al*, 1994) e algoritmo de seleção clonal (CLONALG) (DE CASTRO; VON ZUBEN, 2000).

1.4 ORGANIZAÇÃO DA TESE

Este texto é composto por oito capítulos, conforme descrito a seguir:

Capítulo 1: Introdução

No primeiro capítulo apresenta-se a introdução sobre o problema, objetivos e contribuições, proposta e os fundamentos que justificam o presente trabalho.

Capítulo 2: Falhas Estruturais

O conceito de falhas estruturais, e algumas catástrofes que ocorreram devido as falhas estruturais é apresentado no segundo capítulo.

Capítulo 3: Revisão Bibliográfica

No terceiro capítulo apresenta-se a revisão bibliográfica abordando os trabalhos da literatura sobre métodos e técnicas de monitoramento da integridade de estruturas, destacando os métodos baseados em sistemas inteligentes.

Capítulo 4: Sistema imunológico biológico

Conceito biológico como funcionamento do sistema imunológico biológico é apresentado no quarto capítulo.

Capítulo 5: Sistemas imunológicos artificiais

No quinto capítulo apresenta-se definições de sistemas imunológicos artificiais utilizado para o desenvolvimento dos algoritmos propostos, destacando-se os algoritmos de seleção negativa e clonal.

Capítulo 6: Material e Métodos

À obtenção do banco de dados, manipulação dos sinais através da definição do primeiro pacote, implementação dos algoritmos de seleção negativa e clonal. No módulo de sensoriamento foram gerados os conjuntos de detectores para os sinais sem falha e para as cinco situações distintas de danos, módulo de detecção de novidade, módulo de monitoramento e atualização do conhecimento onde foi possível demonstrar o passo a passo para detecção, localização e o grau de influência (quantificação) dos danos nos sinais é apresentado no sexto capítulo.

Capítulo 7: Resultados e Discussão

No sétimo capítulo apresenta-se os resultados obtidos por meio de tabelas e discussões sobre os testes realizados.

Capítulo 8: Conclusão

As conclusões para esta pesquisa é apresentado no oitavo capítulo.

2 FALHAS ESTRUTURAIS

Neste capítulo é apresentado o conceito de falhas estruturais, dando ênfase em catástrofes que ocorreram devido falhas estruturais em aeronaves.

2.1 INTRODUÇÃO

Projetar um SHM é identificar quais mudanças na estrutura é necessário analisar, bem como, identificá-la. Inspeção não destrutiva são tarefas fundamentais para garantir a operação da aeronave (JUNIOR, 2011).

As falhas estruturais são relacionadas à fabricação ou anomalias do material, tais como: trinca ou fadiga, provocando o dano que pode levar a catástrofes e/ou acidentes.

2.2 CASO DE CATÁSTROFE AERONÁUTICA

Ao longo da história as catástrofes aeronáuticas aconteceram devido às falhas estruturais, um exemplo é o acidente ocorrido em 1988 envolvendo o Boeing 737-200 da Aloha Airlines no Havaí, que despertou o monitoramento de integridade estrutural. As análises das causas do acidente mostraram uma ruptura na fuselagem ocasionando uma descompressão explosiva na cabine de passageiros. Esta falha ocorreu devido aos seguintes fatos: fadiga acumulada pela idade da aeronave, quantidade de voos e corrosão (STASZEWSKI *et. al*, 2004).

As aeronaves militares são projetadas para apresentar alto desempenho em voos, exigindo esforços da estrutura devido a pressão aerodinâmica. Estas aeronaves são caras e para compensar os altos investimentos a estimativa de vida das mesmas devem ser longas. Alguns modelos construídos nas décadas de 50, 60 e 70 foram projetados com estimativa de uso para mais de 40 anos. O tempo de vida útil e as condições em ambientes corrosivos, são fatores que inspiram necessidade de manutenção (STASZEWSKI *et. al*, 2004).

O avião de transporte C-5 Galaxy da força aérea norte-americana a partir de uma falha estrutural caiu no ano de 2006 na base aérea de Dover, no estado de Delaware. O avião C-5, fabricado pela Lockheed Martin, é um dos maiores aviões militares do mundo e é usado para carregar cargas pesadas (FRANCO, 2009).

Em 2009, no voo 2294 da Southwest Airlines, Boeing 737-300, passou por uma rápida descompressão após um buraco ter sido aberto na fuselagem (GONSALEZ, 2012 *apud* VALDUGA, 2011).

Outro acidente aeronáutico ocorrido com o Boeing 737-300 da companhia aérea Southwest Airlines no ano de 2011. Foi aberto um buraco no teto da aeronave, e fez com que a mesma perdesse pressão interna ocasionando um pouso de emergência. Após pousar, foi observado um buraco de aproximadamente 1,5 metros no teto da aeronave.

Sistemas de monitoramento de integridade estrutural instalados na fuselagem das aeronaves poderiam ter evitado os acidentes. O SHM é capaz de detectar a presença do dano em estado inicial e indicar a localização do mesmo (GONSALEZ, 2012).

Perante, estes exemplos, fica evidente o quão as falhas estruturais são problemas para as aeronaves, e é necessário garantir a segurança e integridade das estruturas, e principalmente evitar este tipo de catástrofe.

3 REVISÃO BIBLIOGRÁFICA

Neste capítulo é apresentada a revisão bibliográfica destacando os principais métodos e publicações sobre monitoramento da integridade estrutural.

3.1 MONITORAMENTO DE INTEGRIDADE ESTRUTURAL

Há diferenciadas técnicas utilizadas para monitorar estruturas, permitindo assim um diagnóstico para a realização de reparos. Para obtenção deste diagnóstico é preciso utilizar técnicas de identificação de danos. Existem diversas formas, e uma delas é a supervisão humana, utilizando sentidos (visão, audição e tato) para identificar irregularidades. Outra opção é a utilização de instrumentos de análise, que possibilitam uma abordagem ampla e rigorosa. Estas análises podem ser realizadas por meio de ensaios destrutivos, que inutiliza o corpo de prova após a experimentação, ou ensaios não-destrutivos, que são tipos de experimentação que não danifica ou altere propriedades físicas, químicos, mecânicos ou dimensionais do corpo em estudo (FORNARI JÚNIOR, 2012).

As análises de dados obtido das técnicas de SHM, que são ensaios capazes de extração das informações cujas finalidades permitem a obtenção de informações rotineiras. O processo de ensaios para o critério de especificação ou escolha de materiais necessita de métodos normalizados com objetivo de levantar as propriedades mecânicas e seu comportamento sobre determinadas condições de esforços. A classificação dos ensaios está relacionada a integridade geométrica e dimensional da peça ou componente, chamadas de: ensaios destrutivos e não destrutivos (FRANÇA, 2014).

Ensaio Destrutivo provoca a inutilização parcial ou total da peça como, por exemplo: ensaios de tração, dureza, fadiga e fluência. Esses ensaios são realizados a fim de localizar descontinuidades e/ou defeitos na peça. No caso de ensaios destrutivos, uma amostra do lote é submetida a ensaio, e as outras são consideradas como iguais ou com as mesmas características (FORNARI JÚNIOR, 2012).

Ensaio Não Destrutivo ou Avaliação Não Destrutiva (NDE) não comprometem a integridade da peça, não deixam vestígios da sua utilização na peça ensaiada, com a finalidade de identificar algum tipo de alteração de ordem química ou física, por

exemplo: raios-X; ultrassom e líquidos penetrantes, que tem como função investigar a segurança, integridade e durabilidade das estruturas (SU; YE, 2009). Os ensaios não destrutivos são usados em indústria mecânica, porém em particular se destaca na utilização destes métodos, as indústrias aeronáuticas.

As técnicas de NDE são empregadas onde não é necessário a destruição da peça ou do componente a ser testado, uma vez que após a inspeção, a mesma deve ser recolocada no sistema de origem. Estes ensaios permitem analisar a peça fornecendo informações tanto quantitativas quanto qualitativas (FRANÇA, 2014).

Os ensaios não destrutivos possibilitam a inspeção da peça antes da utilização inicial ou também inspeções contínuas ao longo da vida útil (GARCIA *et. al*, 2000), indicando a propensão de falhas. Com técnica eficiente e aplicação contínua automatizada, é possível identificar danos em seu estágio inicial. Os NDE podem ser caracterizadas como manutenções preditivas que, dependendo do tipo de ensaio aplicado, podem proporcionar baixos custos de utilização, praticidade e rapidez de ensaio (FRANÇA, 2014).

Alguns métodos utilizados em SHM são baseados em sinais de vibração e na hipótese da presença de danos alterar as propriedades físicas ou químicas do sistema, como: redução de rigidez causada pelas trincas e variação de propriedades geométricas que podem provocar mudança nas condições dos contornos e continuidade do sistema. Estas alterações podem comprometer o desempenho futuro da estrutura e resultar na mudança da resposta dinâmica do sistema (MARQUI, 2007).

Lifshitz e Rotem (1969) apud Doebling *et. al* (1998), apresentaram o primeiro trabalho publicado em periódicos sobre a identificação de danos por medidas de vibração. Foi observado a mudança no módulo dinâmico, que representa a inclinação da curva tensão de deformação sob cargas dinâmicas, relacionando esta alteração com a mudança na frequência natural.

No monitoramento de integridade estrutural é comum a utilização de materiais piezelétricos, que são colados nas estruturas. Estes dispositivos são utilizados por serem versáteis em aplicação, podendo atuar tanto como sensor quanto atuador. Os materiais piezelétricos são excelentes em captar ondas ultrassônicas (FRANÇA, 2014).

Na identificação de danos por ondas é utilizado "pitch-catch" (emitir-capturar"). Na configuração pitch-catch, uma vibração (onda acústica) é emitida pela fonte e esta

onda é propagada através do meio até ser captada pelo sensor que está posicionado a certa distância (SU; YE, 2009).

Ondas de Lamb é uma técnica utilizada para identificar descontinuidades, porosidade, descolagem, corrosão, quebras, buracos, delaminação, falhas na matriz, rompimento de fibras, absorção (ex. umidade), desalinhamento de fibras e problemas no processo de cura (SU; YE, 2009).

A técnica de identificação de danos utilizando ondas de Lamb é atrativa perante as outras técnicas de NDE pelas seguintes características (SU; YE, 2009):

- Capacidade de inspecionar uma larga área utilizando poucos transdutores em uma configuração esparsa;
- Habilidade para examinar toda a área da secção transversal da estrutura em termos de múltiplos modos de onda, detectando assim danos internos, bem como na superfície;
- Capacidade de classificar diferentes tipos de dano usando diferentes modos de onda;
- Alta sensibilidade a danos e, portanto, alta precisão na identificação;
- Capacidade de inspecionar estruturas revestidas ou isoladas, como rede de tubos submersos ou soterrados;
- Potencial para integração com estruturas e recursos de engenharia para o desenvolvimento online para a detecção automatizada de danos e;
- Baixo consumo de energia com grande relação custo benefício.

A complexidade na aquisição e interpretação do sinal é um dos desafios e requer cuidado no processamento e análise.

3.2 METODOLOGIAS APLICADAS NO MONITORAMENTO DE INTEGRIDADE ESTRUTURAL

Na sequência, são apresentadas, em ordem cronológica, as publicações relevantes desenvolvidas na área de monitoramento da integridade estrutural para aeronaves.

No trabalho de Friswell e Penny (1998) é explanado uma metodologia de localização de falhas estruturais utilizando algoritmos genéticos com dados de

vibrações. O objetivo do trabalho é identificar a posição das falhas na estrutura e estimar a magnitude das mesmas.

Krawczuk *et. al* (2000) expõem uma aplicação do algoritmo genético em conjunto com rede neural multicamadas para detecção e localização de falhas em um modelo numérico de viga, que representa a asa de uma aeronave.

No trabalho de Lopes Junior *et. al* (2001) é apresentado uma metodologia com combinação da técnica de impedância elétrica com o modelo de diagnóstico, baseado no processo de otimização por algoritmos genéticos, para detecção e localização de falhas estruturais.

Furtado (2004) exhibe uma metodologia para detecção de falhas estruturais aeronáuticas utilizando sensores e atuadores piezelétricos e redes neurais artificiais.

No trabalho de Zheng *et. al* (2004) é mostrado a rede neural multicamadas *backpropagation* para detecção e caracterização de falhas em vigas CFRP (reforçadas com fibra de carbono).

Giurgiutiu e Cuc (2005) narram o método da impedância eletromecânica para o monitoramento da saúde estrutural em placas finas de alumínio e estruturas aeroespaciais com sensores piezelétricos acoplados.

Chen *et. al* (2007) descrevem o algoritmo genético para detecção e localização de falhas estruturais através de sensores piezelétricos acoplados na superfície de estruturas compósitas.

Silva *et. al* (2008) relatam uma técnica experimental de detecção de falhas estruturais baseada em medidas de impedância elétrica obtida através de materiais piezelétricos (PZTs) acoplados em estruturas do tipo vigas.

Chandrashekar; Ganguli (2009) explicam o sistema fuzzy para detecção de falhas estruturais usando curvaturas das formas modais de vibração.

No trabalho de Flynn e Todd (2009) é apontado a técnica de solução ótima para o posicionamento de sensores e atuadores piezelétricos para o monitoramento ativo de estruturas finas tipo placas.

Wang e Tang (2009) mostram a metodologia de detecção de falhas baseado na impedância elétrica usando um modelo capaz de localizar e quantificar falhas estruturais.

Franco (2009) apresenta uma metodologia para monitoramento da integridade de estruturas aeronáuticas baseada na técnica de impedância eletromecânica, através de experimentos no painel aeronáutico da EMBRAER e placas de alumínio.

Baptista (2010) descreve uma contribuição ao SHM baseado em impedância eletromecânica. Nesta tese de doutorado é apresentado modificações e análises para melhorar o método de impedância eletromecânica.

Shen *et. al* (2011) relatam um sistema para identificação e localização de danos em asa de aeronave, neste trabalho é utilizado a rede neural probabilística para realização do processo de diagnóstico.

Gonzalez (2012) demonstra metodologias para o reconhecimento de padrões em sistemas de SHM utilizando a técnica de impedância eletromecânica. Para avaliação das metodologias os dados obtidos experimentalmente em laboratório utilizando um painel aeronáutico.

Turra *et. al* (2013) apresentam uma metodologia para detecção de danos em placas de alumínio utilizando a técnica de impedância eletromecânica.

Lima *et. al* (2013) apresentam uma metodologia para o desenvolvimento de SHM em estruturas aeronáuticas baseado no algoritmo de seleção negativa.

Lima *et. al* (2017) apresentam um algoritmo imuno-wavelet aplicado ao problema de diagnóstico de falha em estruturas aeronáuticas.

Lima *et. al* (2018) apresentam um algoritmo híbrido baseado em redes neurais artificiais e transformada wavelet aplicado ao problema de diagnóstico de falhas em estruturas aeronáuticas.

3.3 EVOLUÇÃO DOS SISTEMAS IMUNOLÓGICOS ARTIFICIAIS

Na literatura é encontrado trabalhos teóricos e formulações matemáticas, que propuseram os princípios teóricos para os sistemas imunológicos artificiais.

No trabalho de (BURNET, 1957) foi explanado, de forma teórica uma modelagem do princípio de seleção clonal. Em Jerne (1974) foi proposto a formulação conceitual das redes imunológicas. As duas teorias foram utilizadas anos depois para compor dois métodos importantes no contexto dos sistemas imunológicos artificiais: CLONALG (DE CASTRO; VON ZUBEN, 2000) e rede imunológica aiNet (DE CASTRO; ZUBEN, 2002). Em Hoffmann (1986) foi

apresentada, de forma teórica, a proposta do modelo de uma rede neural artificial inspirada no sistema imunológico biológico. Estes trabalhos teóricos citados foram dados por pesquisadores como os principais trabalhos para a difusão do novo paradigma da teoria dos sistemas inteligentes.

Para compreender o aprendizado e o reconhecimento de padrões do sistema imunológico biológico em Forrest *et. al* (1993) foi proposto o modelo binário para estudar o desenvolvimento de detecção através do algoritmo genético.

O artigo de Forrest *et. al* (1994) foi proposto uma aplicação com apresentação de uma abordagem para detecção de vírus e violação de computadores utilizando um modelo semelhante ao sistema imunológico biológico. Neste trabalho foi utilizado o princípio da seleção negativa descrito no item 5.1.3, descrevendo a estratégia para realizar a detecção de anormalidades em computadores. Ao utilizar conceitos da seleção negativa de linfócitos T, que ocorre no timo, os autores propuseram o algoritmo que passou a ser conhecido na literatura como: “algoritmo de seleção negativa”.

Somayaji *et al* (1997) apresentaram o funcionamento do sistema adaptativo baseado no sistema imunológico adaptativo. Nesse trabalho, foi proposto metáforas baseadas em comparações do sistema biológico com os sistemas computacionais que permitiram implementar características de segurança.

No artigo de Dasgupta e Attoh-Okine (1997) foi mostrado uma técnica imunoinspirada para classificar a atividade da rede de computadores como normal ou anormal. As técnicas foram baseadas no processo de seleção negativa, no modelo da rede imunológica e na análise de diagnóstico de falhas.

Em Dasgupta (1998) foram definidos os aspectos computacionais do sistema imunológico artificial e, partindo destes aspectos, foram propostas aplicações, modelos e fenômenos decorrentes dos sistemas imunológicos biológicos. Este foi o primeiro livro editado sobre o assunto e proporcionou um impacto nas pesquisas.

No trabalho de Dasgupta e Forrest (1999) foi apresentado um algoritmo baseado nos sistemas imunológicos artificiais, em especial no algoritmo de seleção negativa para problemas relacionados a indústrias. Neste trabalho os autores apresentaram ideias e modelos para contornar problemas industriais aplicando conceitos imunológicos.

Dasgupta (1998) apresentou aspectos computacionais do sistema imunológico artificial e, partindo destes princípios, foi proposto aplicações, modelos e fenômenos

decorrentes dos sistemas imunológicos biológicos. Este foi o primeiro livro editado sobre o assunto e assim proporcionou grande impacto nas pesquisas.

No trabalho de Dasgupta e Forrest (1999) foi desenvolvido um algoritmo baseado no sistema imunológico artificial, precisamente o algoritmo de seleção negativa para problemas relacionados as indústrias. Neste trabalho os autores apresentaram ideias e modelos para contornar problemas industriais aplicando conceitos imunológicos.

De Castro e Von Zuben (2000) apresentaram o algoritmo de seleção clonal (CLONALG) descrito no item 5.1.4 aplicado a problemas como reconhecimento de padrões, otimização multimodal e aprendizagem de máquina. Uma nova abordagem utilizando conceitos de rede imunológica foi proposta para fazer clusterização de dados. A rede imunológica (aiNet) foi implementada em associação com uma inferência estatística. Este trabalho propôs uma alternativa às redes neurais artificiais.

Timmis (2000) apresentou uma técnica de análise de dados inspirada no sistema imunológico natural. Nesse trabalho foi definido novos conceitos para os sistemas imunológicos artificiais. O autor obteve bons resultados ao aplicar uma rede imunológica em dois conjuntos de dados.

De Castro (2001) descreveu um novo paradigma dos sistemas imunológicos, chamado engenharia imunológica. O objetivo central foi desenvolver ferramentas utilizando os princípios do sistema imunológico para resolver problemas do mundo real. Nesse trabalho, foram apresentados quatro ferramentas: SAND, CLONALG, ABNET e aiNet. Destas quatro ferramentas, duas ganharam popularidade na literatura, sendo eles: o algoritmo CLONALG e a rede imunológica aiNet. A partir deste trabalho os sistemas imunológicos artificiais ganharam notoriedade e foram difundidos na literatura.

No artigo proposto por De Castro e Von Zuben (2002) foi mostrado outra aplicação da ferramenta aiNet. Neste trabalho a rede imunológica foi aplicada ao problema de mineração de dados.

No livro de De Castro e Timmis (2002) foi descrito um novo paradigma para a inteligência computacional utilizando os sistemas imunológicos artificiais. Os autores abordaram conceitos naturais e artificiais, definindo novos padrões para o novo paradigma chamado Opt-aiNet para otimização combinatorial, compressão e

clusterização de dados. Este método foi baseado nos princípios de seleção clonal e maturação por afinidade.

Cayzer e Aickelin (2002) propuseram um trabalho baseado no sistema imunológico inato, precisamente na medula óssea. Este modelo foi comparado às demais teorias dos sistemas imunológicos, principalmente em detecção de anomalias. O modelo foi um complemento do algoritmo de seleção negativa, além do próprio e não-próprio, foi incluído o falso próprio e falso não-próprio.

Um algoritmo paralelo para otimização de funções inspirado nos sistemas imunológicos artificiais foi apresentado em (WATKINS *et. al*, 2003). No trabalho foi utilizado conceitos como o princípio de seleção clonal e maturação por afinidade para compor o algoritmo.

Meng e Liu (2003) desenvolveram um algoritmo chamado “Immunity Strength Pareto Evolutionary Algorithm (ISPEA)” para resolver problemas de otimização multinodal. Neste trabalho os autores utilizaram conceitos de vacinação.

Um algoritmo para otimização multinodal chamado “MOIA – Multi-Objective Immune Algorithm” foi apresentado em (CHUEH *et. al*, 2003). Os autores utilizaram conceitos como a maturação por afinidade, recombinação genética e a diversificação de anticorpos.

Uma revisão bibliográfica sobre computação natural foi apresentada no livro de (DE CASTRO *et. al*, 2004). A computação natural representa um conjunto de técnicas inspiradas na biologia ou fenômenos da natureza para o desenvolvimento de sistemas computacionais inteligentes, entre estas técnicas está o sistema imunológico artificial.

Após ser difundido o conceito de computação natural, algumas aplicações foram propostas, sendo relevantes para o desenvolvimento deste novo conceito. Destacam-se trabalhos como: Cazangi (2004) a proposta foi utilizar a computação evolutiva no controle de navegação de robôs, em De França (2005) foi aplicado os algoritmos bioinspirados visando a otimização dinâmica e Ferreira (2008) propôs ferramentas de aprendizado de máquina para previsão de perdas comerciais em redes de distribuição de energia elétrica, entre outros trabalhos.

Keko *et. al* (2003) desenvolveu o algoritmo genético com operador de adição imunológico para resolver problemas de roteamento de redes de distribuição. Neste trabalho foi utilizado conceitos de recombinação cruzada através de um operador imunológico.

Um algoritmo adaptativo de seleção clonal para otimização multi-objetivo foi proposto por (GARRETT, 2004). Este algoritmo foi chamado de “Adaptive Clonal Selection” (ACS) e utilizava conceitos baseados no princípio de seleção clonal.

Li *et. al* (2004) desenvolveram um algoritmo para otimizar funções multi-objetivo denominado “Artificial Immune Algorithm for Multi-Objective Optimization (AIAMOO)”. Os autores utilizam conceitos como a supressão de rede e mutação.

Luh e Chueh (2004) propuseram um método para resolver o problema de projeto ótimo de estruturas de treliças (otimização multi-objetivo) chamado “Constrained Multi-Objective Immune Algorithm (CMOIA)”. Neste algoritmo os autores utilizaram recombinação genética, mutação somática, diversificação de anticorpos e conceitos de citocinas.

O algoritmo denominado “Milti-objective Immune System Algorithm (MISA)” foi apresentado por (COELLO; NARELI, 2005). Nesta técnica foi inspirada os conceitos de seleção clonal, mutação uniforme e não-uniforme e pareto dominante.

Campelo *et. al* (2005) apresentaram um método baseado no princípio de seleção clonal para otimizar projetos eletromagnéticos (otimização multi-objetivo). Este método foi chamado de “Real-coded Clonal Selection Algorithm (MISA)”.

Lau e Wong (2005) propuseram um algoritmo para resolver problemas de roteamento dinâmico denominado “Artificial Immune System Dynamic Routing (AISDR)”.

O algoritmo “dopt-aiNet (Artificial Immune Network for Dynamic Optimization) foi proposto por De França *et. al* (2005) para resolver problemas de otimização dinâmica. Neste trabalho foram considerados conceitos como clonagem, duplicação de genes, mutação gaussiana e supressão de células.

Freschi e Repetto (2005) desenvolveram um algoritmo denominado “Vector Artificial Immune System (VAIS)” utilizando conceitos como mutação gaussiana e supressão imunológica.

Lin (2005) propôs um algoritmo baseado na teoria do perigo para otimização dinâmica. Este algoritmo chamou “Real-time Dynamic Danger Theory Model (RDDT)”.

Greensmith e Aickelin (2006) apresentaram uma nova abordagem para a detecção de intrusos em redes de computadores. Nesse trabalho, foi apresentado um método baseado na função de células dendríticas. As células dendríticas são apresentadoras de antígenos para ativação do sistema imunológico biológico.

Coelho e Von Zuben (2006) propuseram um método para problemas de otimização multi-objetivo unidirecional denominado “omni-aiNet”. Neste trabalho foi utilizado teorias como clonagem, hipermutação, seleção e duplicação de genes.

Greensmith (2007) apresentou de forma definitiva o algoritmo baseado no funcionamento das células dendríticas. As células dendríticas pertencem ao sistema imunológico inato, e são responsáveis pela resposta imune. Em certos casos quando as células emitem a resposta imune ocorre à supressão da mesma.

Gong *et. al* (2007) apresentou um método baseado nas teorias de seleção clonal e evolução diferencial para otimização multi-objetivo. Este método é conhecido como “Differential Immune Clonal Selection Algorithm (DICSA)”.

Um algoritmo de otimização para realizar a extinção de ruídos em projetos de filtros foi proposto em Gong *et. al* (2007). Neste trabalho foi utilizado conceitos de seleção clonal e memória imunológica, e este algoritmo ficou conhecido como “Immune Memory Clonal Selection Algorithm (IMCSA)”.

Lau e Tsang (2007) apresentaram uma ferramenta chamada “Suppression Control Algorithm (SCA)” utilizando redes imunológicas.

Dando sequência em seu trabalho os autores Lau e Tsang (2008) propuseram um algoritmo paralelo para controle de supressão em redes imunológicas, este passou a ser chamado de “Parallel Suppression Control Algorithm (PSCA)” e é a continuação do trabalho proposto em 2007.

Um algoritmo evolucionário multi-objetivo foi proposto em (TAN *et. al*, 2008). Neste foi utilizado conceitos como seleção clonal, memória imunológica e norma entropia. O algoritmo ficou conhecido como “Evolutionary Multi-Objective Immune Algorithm (EMOIA)”.

Zhao *et. al* (2008) propuseram o algoritmo “Tabu Search Artificial Immune Algorithm (TS aiNet)” para resolver problemas de otimização multi-objetivo.

Wong e Lau (2009) desenvolveram um algoritmo híbrido para resolver o problema de agendamento de tarefas e reposicionamento de containers multi-objetivo. Neste algoritmo foi utilizado a metaheurística Particle Swarm Optimization (PSO) e uma rede imunológica aiNet.

Silva (2009) desenvolveu um algoritmo imunoinspirado baseado na teoria do perigo e nas células dendríticas. O objetivo do trabalho foi realizar a detecção de intrusos em redes de computadores. O autor propôs uma modificação no algoritmo apresentado em Greensmith (2007), diferentemente do algoritmo original o

coeficiente de maturação do antígeno foi atualizado em cada ciclo do algoritmo, proporcionando precisão no diagnóstico.

Gong *et. al* (2009) propuseram um algoritmo para otimização multi-objetivo chamado “Secondary Response Clonal Multi-Objective Algorithm (SRCMOA)”. Neste trabalho os autores utilizaram a teoria da seleção clonal, resposta secundária e maturação por afinidade para formular o algoritmo.

Wong e Lau (2009) desenvolveram um algoritmo PSO usando o algoritmo de seleção clonal para resolver problemas de otimização multi-objetivo. Este algoritmo foi concebido com base no princípio de seleção clonal.

Vieira (2011) desenvolveu um algoritmo para otimização multi-objetivo de rotas de dutos submarinos através de sistemas imunológicos artificiais.

No artigo de Holanda *et. al* (2013) foi proposto uma aplicação de algoritmo de seleção clonal para estimar harmônicas em sistemas de transmissão de energia elétrica.

Zhang e Hou (2014) propuseram o monitoramento de integridade estrutural (SHM) civil utilizando a abordagem de Sistemas Imunológico Artificial (SIA) para um modelo de três andares e diferentes cenários de danos. A metodologia apresentou resultados satisfatórios para detecção e localização de danos em variados casos.

Anaya *et. al* (2015) demonstraram uma metodologia de detecção de danos baseada em (SIA) como técnica de reconhecimento de padrões e parcelas de afinidade para discriminar diferentes estados estruturais. Os resultados mostraram que a metodologia foi capaz de detectar com precisão os danos.

Shi e Yu (2017) propuseram o monitoramento de integridade estrutural (SHM) civil utilizando o método NDE, sistemas imunológico artificial (SIA) e transformada wavelet para um modelo de quatro andares com 120 graus de liberdade. Os resultados obtidos por meio de simulação computacional foram satisfatórios.

Silva, *et. al* (2019) propuseram um trabalho com objetivo de explorar recursos e alternativas para a biometria facial 3D usando padrões binários baseado em SIA utilizando precisamente o algoritmo de seleção negativa.

4 SISTEMA IMUNOLÓGICO BIOLÓGICO

Neste capítulo é apresentado os conceitos e funcionamento do sistema imunológico biológico, que demonstra o funcionamento biológico do algoritmo artificial proposto no presente trabalho.

4.1 INTRODUÇÃO

Imunologia é uma ciência recente, que estuda o sistema imunológico biológico. A imunologia é a área da medicina, que estuda a reação de substâncias estranhas (patógenos) com capacidade de responder adequadamente. Pesquisas, teorias e descobertas foram desenvolvidas, dentre elas: vacinação contra diversas doenças, síntese de anticorpos, especificidade, seleção clonal e etc.

A palavra Imunologia vem do latim "immunis" ou "immunitas" e significa "isento de carga", sendo interpretada como enfermidade (DE CASTRO, 2001). De forma geral, imune é uma pessoa ou animal, que infectada não desenvolve a doença, pois possui resistência natural ou adaptativa.


O sistema imunológico biológico consiste em defender o organismo contra substâncias nocivas, como: bactérias, vírus, fungos e alguns tipos de vermes. Esse evento ocorre devido ao conjunto de órgãos, células e moléculas responsáveis pela defesa do corpo humano (MACHADO, 2005).

4.2 FUNCIONAMENTO DO SISTEMA IMUNOLÓGICO BIOLÓGICO

O organismo biológico é composto por células e moléculas objetivando respostas a agentes estranhos no organismo, chamados de antígenos.

O SIB é dotado de características como: reconhecimento de padrões, aprendizado e neutralização do agente infeccioso, representando a resposta imunológica ilustrada pela figura 1.

Figura 1. Funcionamento do processo de reconhecimento de padrões e aprendizado SIB



Fonte: Lima (2016) adaptado de De Castro (2001)

O passo (I) representa a exposição do SIB ao antígeno (agente infeccioso). O SIB reage com dois tipos de respostas: resposta imune inata, iniciada no passo (II) e resposta imune adaptativa, iniciada no passo (VII). Caso o processo inicie pelo sistema imune inato (passo (II)), o agente infeccioso é desconhecido pelo SIB e, desta forma, é necessário sinalizar ao organismo para que o sistema imune adaptativo inicie a resposta adaptativa, ou seja, aprender e gerar anticorpos para neutralizar o antígeno. O processo imune inato ocorre quando o antígeno é ingerido pela célula dendrítica APC e fragmentados em peptídeos antigênicos. No passo (III), os fragmentos de peptídeos são ligados nas moléculas Major Histocompatibility Complex (MHC) e apresentados à célula dendrítica. Caso o processo é iniciado por meio do sistema imune adaptativo (passo (VII)) o antígeno

é conhecido pelo SIB, ou seja, é realizado o processo de detecção pelos linfócitos presentes no organismo (DE CASTRO; TIMMIS, 2003; DASGUPTA, 1998).

No passo (IV), os linfócitos T reconhecem os antígenos MCH/peptídeos processados pelas células dendríticas. Nesse momento é determinada a afinidade do linfócito ao agente patogênico. Os linfócitos são ativados pelo agente patogênico se a afinidade ultrapassar certo limiar. Neste passo são diferenciadas as células próprias dos agentes infecciosos (DE CASTRO; TIMMIS, 2003; DASGUPTA, 1998). Com base neste princípio ocorre o reconhecimento de padrões proposto pelo ASN (FORREST *et. al.*, 1994). Após a detecção do antígeno, no passo (V), os linfócitos T são ativados, liberando sinais químicos (linfocina) que sinalizam para o SIB que a célula está infectada. No passo (VI) os linfócitos do tipo B reconhecem a célula infectada e inicia o processo de aprendizado, ou seja, princípio de seleção clonal (passo (VII)). O aprendizado do processo de seleção clonal é realizado no passo (VIII). Neste caso, os linfócitos B reconhecem os antígenos livres sinalizados no organismo, sem a necessidade da ingestão e digestão das células apresentadoras (APC), e assim ocorre o reconhecimento. Quando as células B reconhecem o antígeno é iniciado o processo de seleção clonal, também conhecido como processo de aprendizado continuado (passo (VIII)). Os linfócitos passam pelo processo de clonagem e hipermutação gerando um conjunto de linfócitos B no organismo. Na sequência, ocorre um processo de diferenciação (passo (IX)), em que os linfócitos B com maiores afinidades são separados para o conjunto de memória e os linfócitos B com baixa afinidade são ativados, transformando em plasmócitos (passo (X)). No passo (XI), os antígenos detectados pelo SIB são neutralizados pelos anticorpos, levando a destruição da doença. No passo (XII), os linfócitos separados no processo de diferenciação são transformados em linfócitos de memória substituindo os antigos linfócitos com baixa afinidade. Os novos linfócitos de memória passam a circular pelo organismo garantindo a resposta eficiente e rápida a uma futura exposição ao mesmo tipo de antígeno (agente infeccioso) (LIMA, 2016).

Vale destacar que o processo é realizado com a cooperação entre o conjunto de células formadoras do SIB, sendo cada célula responsável por uma função simples, e, no conjunto, realizam um trabalho complexo (DE CASTRO; TIMMIS, 2003; DASGUPTA, 1998).

A capacidade do SIB de reconhecer e neutralizar agentes infecciosos no organismo depende da habilidade de detectar elementos não-próprios nocivos ao sistema. Em Hofmeyr e Forrest (1999) é destacado fatores que tornam o processo de reconhecimento de elementos não-próprios complexo:

- O número de padrões não-próprios no organismo humano (aproximadamente 10^{16}) é maior que o número de padrões próprios (aproximadamente 10^6);
- O ambiente é distribuído;
- O organismo deve continuar funcionando;
- Os recursos disponíveis para combater os agentes infecciosos agressores são escassos.

A quantidade de padrões próprios no organismo representa aproximadamente 30% dos padrões no organismo. Para contornar esta dificuldade, o sistema imunológico biológico é distribuído, em camadas de defesa, e com funções específicas para identificar os elementos não-próprios, discriminando-os dos elementos próprios. O sistema imunológico biológico possui a capacidade de reconhecer 100% dos antígenos presentes no organismo. As moléculas de anticorpos e os receptores de linfócitos T no organismo reconhecer a molécula própria ou não-própria, até mesmo aquelas artificialmente sintetizadas (DE CASTRO, 2001).

Para o funcionamento apropriado do sistema imunológico, é preciso diferenciar as células e moléculas do próprio organismo, chamadas de “próprias”, das moléculas estranhas, chamadas “não-próprias”, que são, a princípio, indistinguíveis. Se o sistema imunológico não fizer essa separação, então uma resposta imunológica é desencadeada contra os elementos próprios, causando doenças autoimunes (DE CASTRO, 2001). O sistema imunológico possui dois mecanismos conhecidos por seleção positiva e seleção negativa, que tem como função evitar que os linfócitos auto específicos se tornem auto agressivos, ou seja, evitar que os linfócitos sejam acionados para neutralizar elementos próprios do organismo, como se fossem agentes infecciosos (DE CASTRO, 2001).

Os princípios da seleção positiva e seleção negativa dão origem aos algoritmos de seleção positiva (DE CASTRO, 2001) e o algoritmo de seleção negativa (FORREST *et. al*, 1994).

5 SISTEMAS IMUNOLÓGICOS ARTIFICIAIS

Neste capítulo é apresentado os sistemas imunológicos artificiais (SIA), com foco nos conceitos e no algoritmo de seleção negativa e seleção clonal.

5.1 INTRODUÇÃO

Pesquisadores especializados em computação, começaram a inspirar em fenômenos da natureza para planejar formas eficientes de resolver problemas em diversas áreas. Destacam-se os que estudam os mecanismos biológicos de defesa do corpo humano, que buscam conceitos e teorias de proporcionam o desenvolvimento e concepção de novos algoritmos e técnicas para solução de problemas (DE CASTRO; TIMMIS, 2003).

Foram desenvolvidas propostas, arquiteturas e modelos aplicados aos princípios imunológicos no desenvolvimento de ferramentas computacionais, que representam funcionalidades, propriedades e mecanismos dos sistemas imunológicos biológicos. Estas ferramentas são conhecidas como Sistemas Imunológicos Artificiais (SAI) (DE CASTRO, 2001).

Os sistemas imunológicos artificiais são aplicados em diferentes áreas, as principais são: reconhecimento de padrões, análise de dados, clusterização, segurança computacional, memórias associativas, programação, computação evolutiva, detecção de danos e anomalias, otimização de processos, controle, robótica e aprendizagem de máquina (DE CASTRO, 2001).

5.1.1 Algoritmo de Seleção Negativa (ASN)

O algoritmo de seleção negativa (ASN) é o principal método do Sistema Imunológico Artificial (SIA), inspirado pelo comportamento de auto e não discriminação observado no Sistema Imunológico de Mamíferos (MIS). Ramo da computação bioinspirada com aplicação em diferentes domínios especialmente na detecção de intrusão (RADAME; CHIKHI, 2017).

O ASN foi proposto por Forrest *et. al* (1994), para detecção de mudanças em estados de sistemas computacionais. Esta técnica inspira no processo de seleção negativa de linfócitos T, que ocorre no timo, este processo representa a

discriminação que o organismo realiza com as células do corpo, entre próprias e não-próprias. O ASN é uma técnica que se baseia no processo de reconhecimento de padrões exercido pelo sistema imunológico biológico, sendo elaborado como um modelo computacional. O algoritmo é executado em duas fases, como descrito na sequência (DE CASTRO; TIMMIS, 2003; LIMA *et. al*, 2013).

Censoriamento:

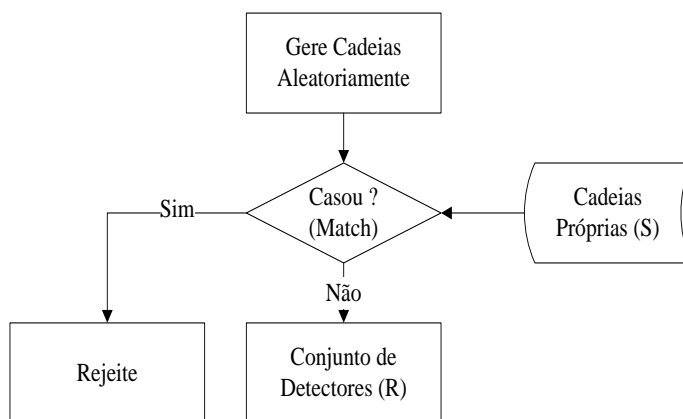
- Definir o conjunto de cadeias adequadas (S) que se deseja proteger;
- Gerar cadeias aleatórias e avaliar a afinidade (*match*) entre cada uma delas e as cadeias próprias. Caso a afinidade seja superior ao limiar estipulado, rejeitar a cadeia. Caso contrário, armazene-a no conjunto de detectores (R).

Monitoramento:

- Dado o conjunto de cadeias que se deseja proteger (cadeias protegidas), avaliar a afinidade entre cada uma delas e o conjunto de detectores. Se a afinidade for superior ao limiar preestabelecido, então o elemento não-próprio é identificado.

A figura 2 ilustra o fluxograma do algoritmo ASN na fase de censoriamento.

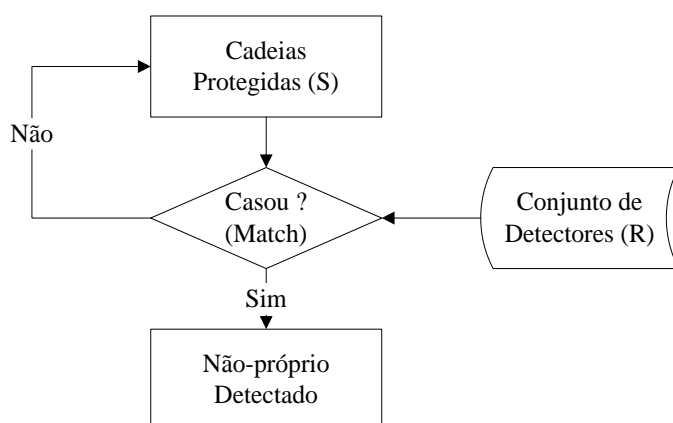
Figura 2 – Fase Censoriamento do ASN



Fonte: Adaptado de De Castro (2001)

Já a figura 3 ilustra o fluxograma do algoritmo ASN na fase de monitoramento.

Figura 3 – Fase Monitoramento do ASN



Fonte: Adaptado de De Castro (2001)

Na fase de sensoriamento do ASN, são definidos os detectores próprios, que representam a condição normal do organismo, conhecidas como cadeias próprias (S). Nesta fase é gerado o conjunto de padrões detectores (R), com capacidade de reconhecer o padrão não-próprio na fase de monitoramento dos dados. Após a leitura dos dados, são escolhidas as cadeias aleatoriamente e verificadas a afinidade comparando as cadeias ao conjunto de cadeias próprias (S). Supondo que a afinidade seja superior ao limiar preestabelecido, a cadeia é rejeitada. Caso contrário, a cadeia é aceita no conjunto de detectores (R), e é utilizada para fazer as classificações durante o monitoramento dos dados. Os detectores são análogos às células do tipo T maturadas capazes de reconhecer agentes patogênicos, isto é, detectar o elemento não-próprio, a modificação ou erro nos dados que se deseja monitorar (LIMA *et. al*, 2013).

Na fase de monitoramento, objetiva identificar mudanças no comportamento das amostras e, então, classificá-las utilizando o conjunto de detectores criados na fase de sensoriamento. Assim, as cadeias protegidas (S) são analisadas e comparadas com o conjunto de detectores (R), a afinidade entre as cadeias são verificadas. Caso a afinidade seja superior ao determinado limiar, então, o elemento não-próprio é detectado e classificado (DE CASTRO; TIMMIS, 2003).

As cadeias no ASN são classificadas em dois tipos: antígenos (Ag) e linfócitos (Ab). O Ag é o sinal a ser analisado ou desconhecido pelo ASN e pode ser representado pela equação 1. Os detectores, ou linfócitos (Ab) são expressos conforme a equação 2 definidas por De Castro e Timmis (2003) e Lima *et. al* (2013).

$$Ag = Ag_1, Ag_2, Ag_3, Ag_4, \dots, Ag_L \quad (1)$$

$$Ab = Ab_1, Ab_2, Ab_3, Ab_4, \dots, Ab_L \quad (2)$$

Sendo: L a dimensão do espaço dos linfócitos (Ab) e dos antígenos (Ag). Ressaltando que as fases de censuriamento e de monitoramento do ASN são realizadas de modo *off-line* e em *on-line*, respectivamente (DE CASTRO; TIMMIS, 2003).

5.1.2 Critério de Casamento e Taxa de Afinidade

Para avaliar a afinidade das cadeias (antígeno e anticorpo) e atestar se são semelhantes, utiliza-se um critério conhecido como casamento, que tem o mesmo significado que combinação. O casamento pode ser perfeito ou parcial. O casamento perfeito é quando duas cadeias analisadas são iguais. Neste trabalho, escolheu-se utilizar o conceito do casamento parcial, apenas uma quantidade de posições entre os padrões deve possuir o mesmo valor para se confirmar o casamento. Esta quantidade é conhecida como a taxa de afinidade (BRADLEY; TYRRELL, 2002; LIMA *et.al*, 2013).

A taxa de afinidade representa o grau de semelhança necessário para ocorrer o casamento entre as duas cadeias em análise. A taxa de afinidade é definida pela equação 3 (BRADLEY; TYRRELL, 2002):

$$TAf = \left(\frac{An}{At} \right) * 100 \quad (3)$$

Sendo:

TAf : taxa de afinidade;

An : número de cadeias normais no problema (cadeias próprias);

At : número total de cadeias no problema (cadeias próprias e não-próprias).

Através da equação 3 é possível quantificar de forma correta o valor da taxa de afinidade para o problema proposto. Conforme destacado em (LIMA, *et. al*, 2013), a equação 3 permite calcular uma taxa de afinidade segura, que fornece precisão e eficiência ao diagnóstico.

Para verificar a combinação entre os sinais do presente trabalho foi utilizado o conceito de casamento parcial também proposto por Bradley e Tyrrell (2002). Para dar dinamismo ao diagnóstico foi proposto um desvio vinculado ao anticorpo (padrão detector), isto é, uma tolerância para mais e para menos, a qual é possível aceitar a combinação entre os padrões, conforme apresentado na equação 4. Este desvio atua individualmente em cada posição i do vetor, permitindo verificar o casamento em cada posição.

$$\underline{Ab}_i \leq Ag_i \leq \overline{Ab}_i \quad (4)$$

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 da posição i do antígeno estiver no intervalo expresso na equação 4 considera-se o casamento para esta posição. Assim é possível quantificar a afinidade entre os padrões, analisando posição por posição. A expressão pela equação 5 representa a afinidade total entre os dois padrões em análise (BRADLEY; TYRRELL, 2002):

$$Af_T = \frac{\sum_{i=1}^L Pc}{L} * 100 \quad (5)$$

Sendo:

Af_T : % de afinidade entre os padrões analisados;

L : quantidade total de posições;

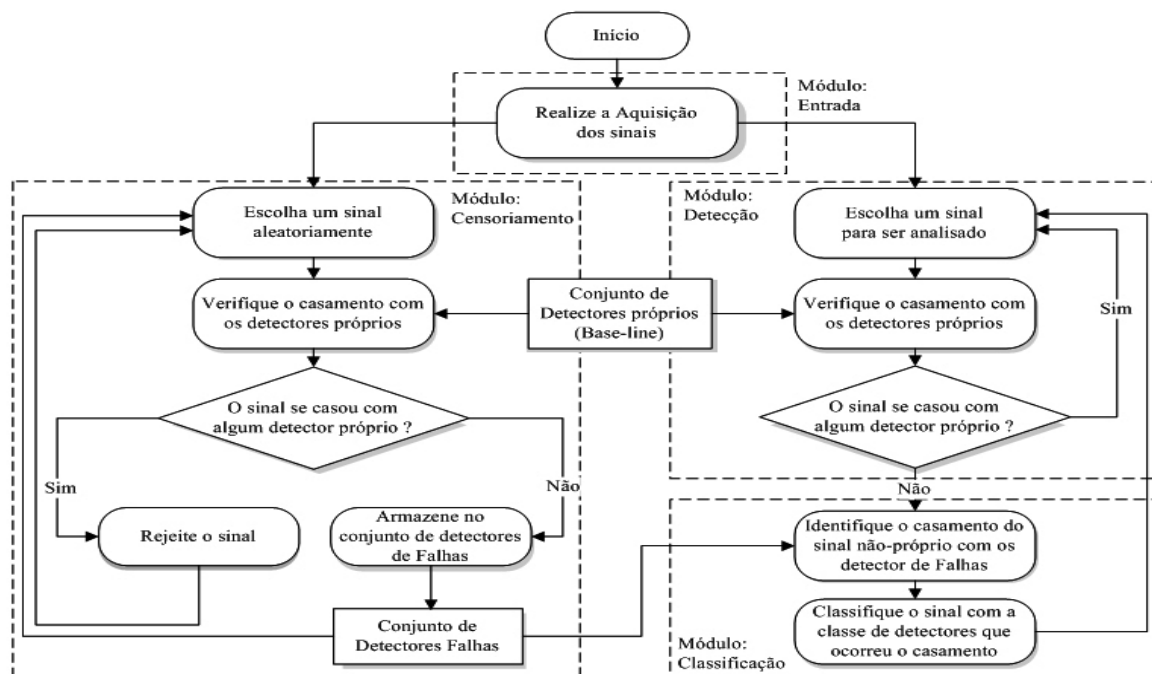
Pc : posição casada;

$\sum_{i=1}^L Pc$: somatório (quantidade) das posições casadas.

Portanto se Af_T for maior ou igual a TAf ocorre o casamento entre os dois padrões, ou seja, os dois são semelhantes, e, os sinais em análise são considerados iguais, desta forma, o mesmo é classificado como a condição normal

da estrutura, pois apresenta as características do conjunto de detectores próprios. Caso a Af_T seja menor que a TAf , o anticorpo (detector) não reconhece o antígeno, portanto não existe casamento entre os sinais, assim, o sinal é classificado como uma anormalidade, ou seja, como uma falha estrutural. Este módulo retorna um diagnóstico dos sinais analisados em próprios (condição normal da estrutura) e não-próprios (condição com dano da estrutura). A figura 4 ilustra o fluxograma de funcionamento do algoritmo de seleção negativa no SHM. Neste trabalho foram definidos detectores próprios e detectores de danos com cinco situações distintas, conforme modelo proposto por Lima *et. al* (2014).

Figura 4 – Fluxograma do algoritmo ASN no SHM



Fonte: Adaptado de De Castro (2001)

O módulo de aquisição de dados: foi composto pelo aparato experimental para capturar os sinais na estrutura, como: sensores, atuadores, materiais piezelétricos (LIMA, *et. al*, 2014).

O módulo de sensoriamento: foi realizado de forma *off-line* e gerado o conjunto de detectores próprios e o conjunto de detectores de falhas utilizados no monitoramento dos dados. O conjunto de detectores próprios foi constituído de sinais que possuem a característica normal da estrutura, ou seja, sem falha (*baseline*). Já o conjunto de detectores de falhas foi constituído por sinais de falhas

utilizadas como detectores durante a fase de monitoramento para caracterizar as falhas detectadas. Em resumo, este procedimento foi dividido em duas etapas, leitura dos sinais, que criou os detectores e o módulo de sensoriamento, onde foi escolhido os sinais aleatoriamente e verificado o casamento em relação ao conjunto de detectores próprios. Caso o critério de afinidade seja satisfeito, os sinais foram rejeitados, pois possuía características próprias. Caso contrário, os sinais foram armazenados no conjunto de detectores de falhas que foram utilizados no monitoramento do sistema (LIMA, *et. al*, 2014).

Vale ressaltar que a quantidade de detectores utilizados foi determinada pelo operador do SHM. No entanto, recomenda-se utilizar 30% dos dados disponíveis. O critério de casamento utilizado foi o casamento parcial proposto por Bradley e Tyrrell (2002), no qual deve ser utilizado o desvio de 3% (LIMA *et. al*, 2013).

O módulo de monitoramento: foi dividida em três etapas: módulo de entrada ou leitura dos sinais (via sistema de aquisição de dados), módulo de detecção, responsável por realizar a discriminação próprio/não-próprio, identificando as falhas, e, finalmente, o módulo de classificação, responsável por caracterizar as falhas estruturais (LIMA, *et. al*, 2014).

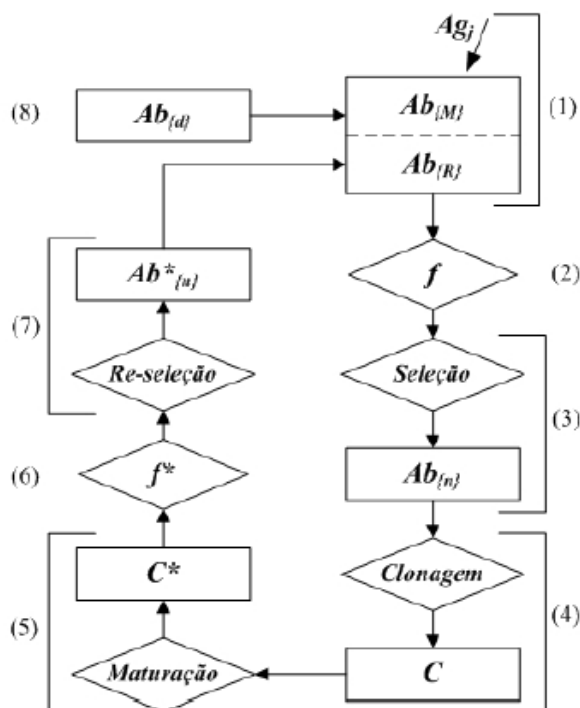
Neste trabalho no módulo de sensoriamento foi possível gerar o conjunto de detectores próprios e detectores de falhas que foram utilizados no monitoramento dos dados. O conjunto de detectores próprios foi constituído de sinais que possuem características normais da estrutura, ou seja, sem falha (baseline). Já o conjunto de detectores de falhas foram constituídos por sinais de falhas utilizadas como detectores durante a fase de monitoramento para caracterizar e detectar as cinco situações de falhas distintas. O procedimento foi dividido em três etapas: leitura dos sinais, módulo de sensoriamento e verificação do casamento em relação ao conjunto de detectores próprios. Caso o critério de afinidade foi satisfeito, os sinais foram rejeitados, pois possuíam características próprias. Caso contrário, os sinais foram armazenados no conjunto de detectores de falhas que foram utilizados no monitoramento do sistema. No módulo de monitoramento foi dividida em três etapas: módulo de entrada, módulo de detecção e módulo de classificação dos sinais conforme as cinco situações de falhas distintas.

5.1.3 Algoritmo de Seleção Clonal (CLONALG)

O algoritmo de seleção clonal, CLONALG (*Clonal Selection Algorithm*), foi proposto originalmente em De Castro e Zuben (2000). Diferente do que foi proposto em Forrest *et. al*, (1994), nesse algoritmo são consideradas duas características centrais do princípio de seleção clonal: (1) maturação e (2) seleção proporcional à afinidade. Duas versões do algoritmo estão disponíveis na literatura, sendo uma para resolver os problemas de aprendizagem de máquina e reconhecimento de padrões e outra para resolver problemas de otimização (DE CASTRO, 2001).

O algoritmo CLONALG, para problemas de reconhecimento de padrões e aprendizagem de máquina, é ilustrado no fluxograma apresentado na Figura 5.

Figura 5 – Fluxograma de funcionamento do algoritmo CLONALG



Fonte: Adaptado de De Castro (2001)

O algoritmo CLONALG pode ser descrito conforme os passos apresentados a seguir (DE CASTRO, 2001; DE CASTRO, TIMMIS, 2002):

Passo I: Inicialização: gere uma população ($Ab = Ab_M + Ab_R$) aleatoriamente com n linfócitos para cada antígeno (Ag_i). N é dado por $M+R$;

Passo II: Avaliação da afinidade: cada antígeno (Ag_i) é apresentado a todos os linfócitos da população (Ab) em um processo de avaliação da afinidade. Um vetor

de afinidade f é determinado;

Passo III: Seleção: os n linfócitos com maior valor de afinidade f em relação a (Ag_i) são selecionados para compor uma subpopulação (Ab_n);

Passo IV: Clonagem: os n linfócitos selecionados prolifera (clonagem) proporcionalmente às suas afinidades ao antígeno (Ag_i), gerando uma população C de clones. Quanto maior a afinidade f , maior é o número de clones de cada um dos n linfócitos selecionados;

Passo V: Hipermutação: em seguida, a população C de clones é submetida ao processo de maturação de afinidade gerando uma nova população C^* , onde cada linfócito sofre uma mutação com uma taxa inversamente proporcional a sua afinidade f ;

Passo VI: Avaliação da afinidade: determine a afinidade f^* entre o conjunto C^* de clones mutados e o antígeno (Ag_i);

Passo VII: Resseleção: da população madura C^* , resseleccione os n melhores linfócitos maturados compondo a subpopulação (Ab_n). Desta subpopulação escolha os melhores linfócitos para entrarem no conjunto de memória (Ab_M). Um linfócito entra no conjunto de memória quando apresenta altas taxas de afinidade, podendo substituir algum linfócito de memória;

Passo VIII: Metadinâmica: substitua d anticorpos de (Ab_R) por (Ab_d) novos indivíduos, induzindo diversidade no repertório. Os anticorpos com menores afinidades são escolhidos para serem substituídos.

Passo IX: Repita os passos de II a VIII até satisfazer o critério de parada.

Ao final do processo iterativo o conjunto de memória (Ab_M) possui M linfócitos com altas taxas de afinidade em relação ao antígeno (Ag_i). Este conjunto de memória pode ser utilizado pelo ASN para detectar e classificar o antígeno aprendido no processo de seleção clonal.

Vale ressaltar que para problemas de aprendizado o passo VIII (metadinâmica) não é executado, desta forma o parâmetro $d = 0$. A quantidade N_c de clones gerada no Passo IV para cada linfócito i é dada pela equação 6 (DE CASTRO, 2001):

$$N_{ic} = \text{round}(BN / i) \quad (6)$$

Sendo:

β : fator multiplicador entre [0,1];

N : quantidade total de linfócitos da população Ab ;

round : operador de arredondamento para o inteiro mais próximo;

A taxa de mutação (α) de cada clone é definida pela equação 7 (DE CASTRO, 2001):

$$a = \exp(-pfn) \quad (7)$$

Sendo:

p : parâmetro de controle de amortecimento da função exponencial;

fn : valor normalizado da afinidade f ;

O valor normalizado da afinidade f , pode ser calculado conforme apresentado na equação 8:

$$fn = (f / f_{\max}) \quad (8)$$

Sendo:

f : valor da afinidade;

f_{\max} : valor máximo da afinidade;

Desta forma, cada clone sofre um processo de mutação dado por (DE FRANÇA *et al.*, 2005):

$$m = \text{round}(a * N(0,1)) \quad (9)$$

Sendo:

m : quantidade de mutações;

round : operador de arredondamento para o inteiro mais próximo;

α : taxa de mutação;

N : variável randômica gaussiana de média zero e desvio padrão = 1.

Nesta seção foram apresentados os algoritmos imunológicos artificiais utilizados para o desenvolvimento do método proposto nesta tese de doutorado.

6 MONTAGEM EXPERIMENTAL

Neste capítulo é comentado a bancada experimental, aquisição de sinais, manipulação dos sinais e banco de dados.


Para o desenvolvimento da metodologia proposta foram utilizados os dados manipulados por Oliveira (2018) que foram obtidos pelos dados experimentais de Rosa (2016). Os dados foram utilizados nos módulos de sensoriamento, detecção de novidade, aprendizado contínuo e monitoramento dos algoritmos de seleção negativa e seleção clonal para detecção dos danos estruturais mecânicos.

Neste trabalho foi usado as medidas experimentais da placa de alumínio obtidos por Rosa (2016).


A figura 6 ilustra os equipamentos operados nos testes experimentais. Os equipamentos utilizados foram: Corpo de prova: Placa de Alumínio; 9 Transdutores PZTs modelo T110-H4e-62 fabricado pela Piezo Systems, Inc.; Epóxi aeronáutico Henkel Hysol EA 9320NA para fixação dos transdutores; Massa adesiva Hexcel para simulação da delaminação; Placa de Aquisição Acellent ScanGenie II e Software de aquisição ACCESS 2.1 para aquisição dos sinais; Placa Protoboard MSB-400 para entrada dos canais; Software de processamento MATLAB® versão R2013a como sistema de processamento e Câmara climática Thermotron SM-8 como ambiente para os ensaios.

Figura 6 -Materiais e equipamentos utilizados no experimento com material isotrópico: (a) foto dos materiais e equipamentos utilizados no experimento e (b) ilustração dos materiais e equipamentos utilizados no experimento

(a)



(b)




Fonte: Rosa (2016)


No experimento foi utilizada uma placa de alumínio com dimensões de 500 x 500 x 2mm, 9 transdutores de PZTs que cobrem a superfície da estrutura, como ilustrado na figura 7. A sequência de medidas utiliza 1 PZT como atuador e outros 8 como sensores. Existem 9 possibilidades de atuadores gerando 8 sinais, portanto 72 sinais. Como ilustrado na figura 8, que foram designados como sinais de propagação.

Figura 7 - (a) Foto da placa utilizada no experimento e (b) Ilustração da placa mostrando posicionamento dos transdutores

(a)



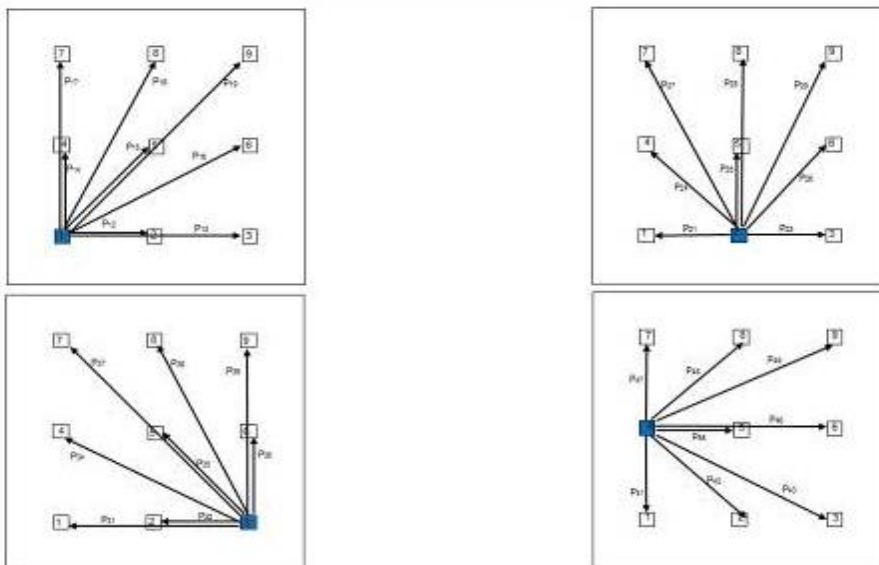
(b)



Fonte: Rosa (2016)

O quadrado de cor azul ilustra o atuador, enquanto os outros 8 transdutores atuam como sensores. Cada quatro apresenta 8 sinais.

Figura 8 - Sinais entre atuadores/sensores utilizados na localização dos danos

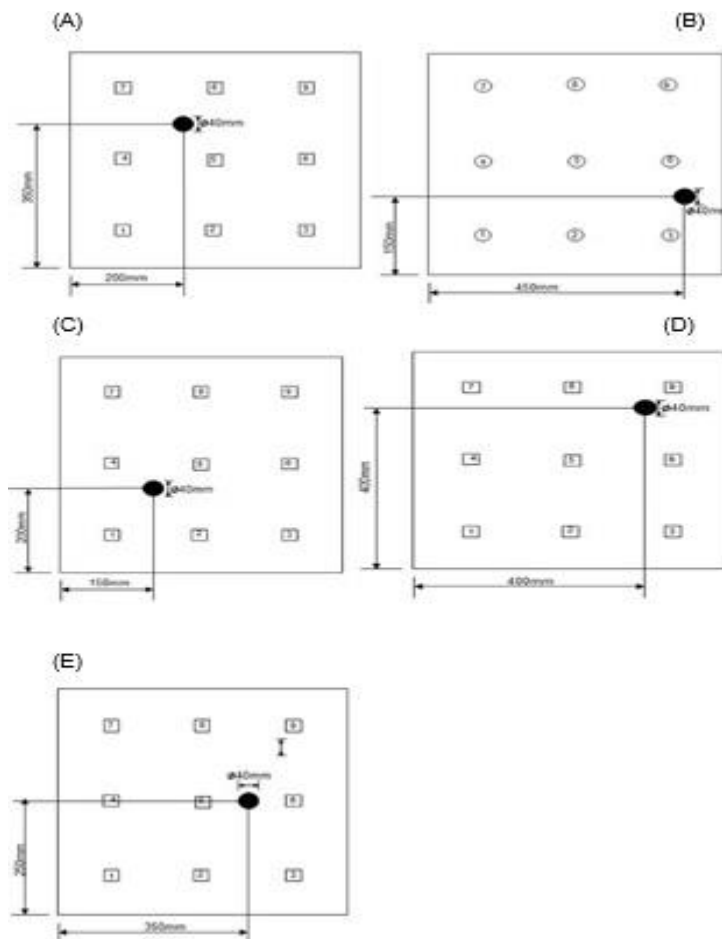


Fonte: Rosa (2016)

Na figura 9, P_{12} significa que o atuador foi o PZT1 e o sensor foi o PZT2. De maneira geral P_{ij} , significa que o atuador estava na posição i e o sensor na posição j . Para a análise da localização dos danos foram definidos cinco pontos onde foram colocados os danos em cinco situações distintas. Os danos foram simulados pela adição de massa adesiva de 15g. O posicionamento dos danos é ilustrado pela figura 9. A figura 9A mostra o posicionamento do dano 1, 9B do dano 2, 9C do dano 3, 9D do dano 4 e 9E do dano 5.

Para localização dos danos na estrutura, foi utilizado a análise dos sinais gerados da propagação de ondas de Lamb para cada sinal do arranjo. A geração e aquisição dos sinais foi utilizada a placa da Accelent modelo ScanGenie-II Battery Edition juntamente com o software ACESS 2.1.

Figura 9 - Ilustração do posicionamento dos danos: (A) dano 1, (B) dano 2, (C) dano 3, (D) dano 4 e (E) dano 5



Fonte: Rosa (2016)

Os sinais foram obtidos nas frequências de 200, 250 e 300 kHz. O sinal de excitação foi o Burst 5, isto é, um sinal senoidal janelado com 5 ciclos, para todas as


frequências. A frequência de amostragem para os testes foi de 3MHz e o número de pontos de aquisição foi 1000. Para cada medida, foi considerada uma média de 10 sinais.

Na manipulação dos dados foram analisados os sinais definindo o primeiro pacote do sinal (first packet), isto é, foi considerado apenas o intervalo de tempo em que o sinal chega ao sensor sem reflexões e um tempo igual ao tempo de excitação. Os sinais foram obtidos na situação sem dano (*baseline*) e, posteriormente nas cinco situações de danos distintas.

O primeiro pacote, ou seja, 81 pontos do sinal senoidal janelado com 5 ciclos foi definido devido as reflexões que o mesmo pode sofrer na estrutura e o dano, o restante do sinal, além das reflexões, tem os outros modos de onda que chegam ao sensor e, assim, dificultam a análise. Em seguida foram gerados gráficos que mostraram claramente quando existem diferenças entre o *baseline* e o sinal atual (ou sinal a ser analisado) captado pelo sensor, conforme ilustrado nas figuras 10 a 13.

A figura 10 ilustra o gráfico do sinal P₅₉, isto é, sinal emitido pelo atuador 5 e recebido pelo sensor 9. Este sinal foi escolhido para mostrar a influência do dano 4 neste sinal. O sinal vermelho representou o sinal baseline e o sinal azul representou o sinal com dano.

Figura 10 - Sinal emitido pelo atuador PTZ 5 para 250 kHz, e sinal captado no sensor PTZ 9 para a situação sem dano (baseline) e para a situação com dano 4




Fonte: Oliveira (2017)

A análise foi realizada considerando toda a faixa de frequência. No entanto, esta análise foi difícil e sendo assim foi considerado apenas o primeiro pacote do sinal,

como ilustra a figura 11. Como a onda chegou primeiro no sensor, ainda não há outras influências além do dano.


Figura 11 - Primeiro pacote do sinal emitido pelo atuador PTZ 5 para 250 kHz e sinal captado no sensor PTZ 9 para a situação sem dano (baseline) e para a situação com dano 4



Fonte: Oliveira (2017)

A figura 12 ilustra o gráfico do sinal P_{12} , isto é, atuador 1 e sensor 2 para o dano 4. Este sinal demonstrou a baixa interferência do dano, pois o dano foi encontrado distante do sinal. O sinal vermelho representou o sinal baseline e o sinal azul representa o sinal com dano.


Figura 12 - Sinal emitido pelo atuador PTZ 1 para 250 kHz e sinal captado no sensor PTZ 2 para a situação sem dano (baseline) e para a situação com dano 4



Fonte: Oliveira (2017)

A figura 13 ilustra o gráfico do primeiro pacote do sinal a ser analisado.


Figura 13 - Primeiro pacote do sinal emitido pelo atuador PTZ 1 para 250 kHz, e sinal captado no sensor PTZ 2 para a situação sem dano (baseline) e para a situação com dano 4



Fonte: Oliveira (2017)

A figura 14 ilustra o gráfico do sinal P_{68} do atuador 6 e sensor 8 para o dano 4. O sinal vermelho representou o sinal baseline e o sinal azul representou o sinal com dano. Embora, o dano foi localizado próximo do sinal, a variação do sinal não é grande.


Figura 14 - Sinal emitido pelo atuador PTZ 6 para 250 kHz, e sinal captado no sensor PTZ 8 para a situação sem dano (baseline) e para a situação com dano 4



Fonte: Oliveira (2017)

A figura 15 ilustra o gráfico do primeiro pacote do sinal a ser analisado.

Figura 15 - Primeiro pacote do sinal emitido pelo atuador PTZ 6 para 250 kHz e sinal captado no sensor PTZ 8 para a situação sem dano (baseline) e para a situação com dano 4



Fonte: Oliveira (2017)

A definição do primeiro pacote foi realizada para os 72 sinais. Os sinais próximos dos danos sofreram maiores variações. Existem também sinais que sofreram pequenas variações e outros sinais que não sofreram nenhuma interferência do dano. As variações nos sinais puderam ser devidas, também, a fatores externos, como variações de cargas e de temperaturas.

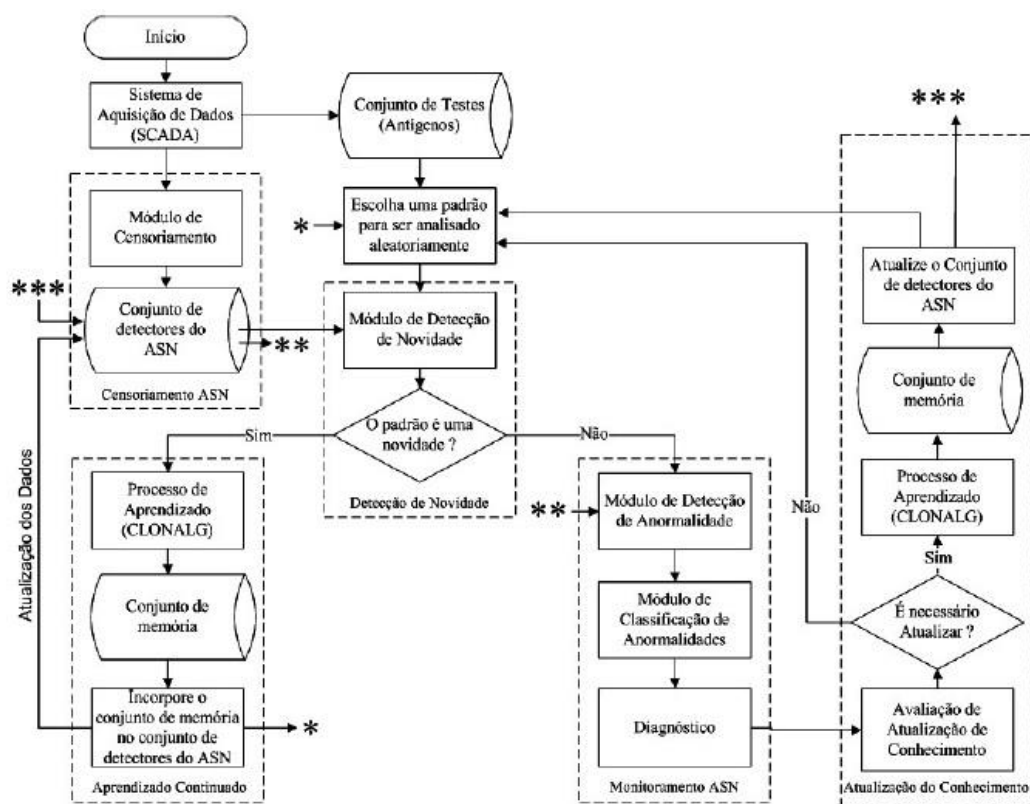
Após a definição do primeiro pacote foram desenvolvidos os algoritmos de sistemas imunológicos artificiais, precisamente os algoritmos de seleção negativa e seleção clonal.

7 MATERIAL E MÉTODOS

O sistema de monitoramento de integridade de estruturas (SHM) foi composto de seis módulos principais: sistema de aquisição dos dados, módulo de sensoriamento do SHM, módulo de detecção de novidade, módulo de aprendizado contínuo, módulo de monitoramento do ASN e módulo de atualização do conhecimento.

A figura 16 ilustra o emprego do ASN para o processo de detecção e localização das falhas e o CLONALG para a estratégia de aprendizado contínuo.

Figura 16 – Fluxograma de funcionamento do algoritmo com aprendizado contínuo



Fonte: Lima (2016)

Sistema de aquisição dos dados: os dados foram adquiridos através da base de dados obtidos por Oliveira (2017). Estes dados foram utilizados nos módulos: sensoriamento do ASN, detecção de novidade, aprendizado contínuo, monitoramento do ASN e atualização do conhecimento.

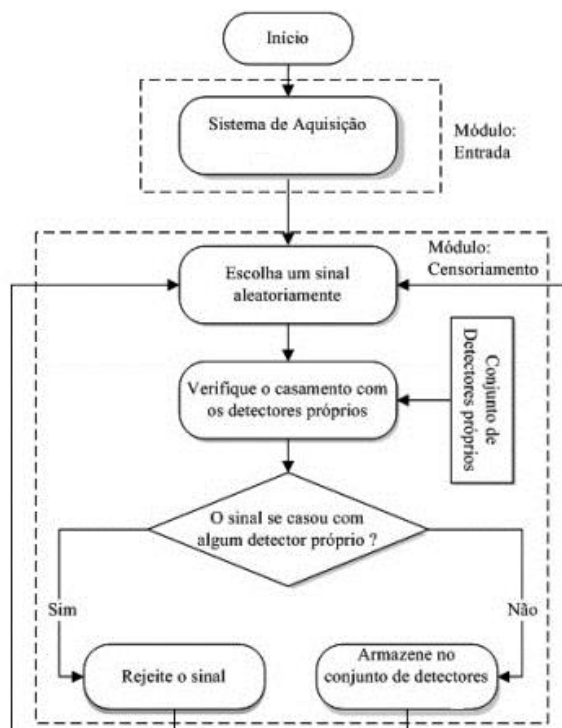
Módulo de sensoriamento do ASN: O sistema de diagnóstico foi executado em duas fases, sendo uma fase on-line e outra off-line. No processo *off-line* foi executado o aprendizado (treinamento) inicial do sistema, denominado de módulo

de sensoriamento. Neste processo, foram definidos os detectores próprios, formando o conjunto de detectores do ASN. Este conjunto de detectores próprios foi o conhecimento do sistema inteligente, para tomada de decisões na fase on-line.

O conjunto de detectores próprios constituídos de 81 sinais que possuem a característica normal da estrutura, ou seja, sem dano (baseline) e 405 sinais que possuem as características dos danos, ou seja, as cinco situações distintas de danos apresentadas na figura 9.

Neste contexto, foi gerado o conjunto de detectores próprios escolhidos aleatoriamente entre sinais normais e sinais com danos não repetidos no banco de dados. Os dados foram comparados, ponto a ponto, com os detectores próprios. Caso o casamento foi encontrado, o vetor aleatório foi rejeitado, pois foi constatado características próprias. Caso contrário, foi aceito, sendo armazenado como detector próprio no conjunto de detectores próprios. O processo de sensoriamento é ilustrado na figura 17.

Figura 17 – Módulo de Sensoriamento do ASN



Fonte: Adaptado de Lima (2016)

Após o conjunto de detectores obtido, o mesmo foi utilizado nas etapas do sistema de diagnóstico, tais como: detecção de novidade, módulo de aprendizado continuado, módulo de monitoramento do ASN e módulo de atualização do

conhecimento. Depois de realizar o processo em modo off-line foi executado o processo de monitoramento em modo on-line.

Módulo de detecção de novidade: A priori, no processo de monitoramento on-line do sistema foi obtido o conjunto de testes (antígenos). Este conjunto foi formado por todos os sinais disponíveis da base de dados. Logo em seguida, foi escolhido, aleatoriamente, um sinal para ser analisado. Este sinal foi submetido ao módulo de detecção de novidade.

Na etapa de detecção de novidade, foi realizada uma comparação do sinal em análise com o conjunto de detectores do ASN. Posteriormente, foi verificado se ocorreu o casamento do sinal com algum detector. Caso ocorreu o casamento, o sinal em análise foi conhecido pelo sistema, ou seja, não foi uma novidade. Caso contrário, o sinal foi considerado uma novidade, ou seja, desconhecido pelo sistema.

Quando o sistema identificou uma novidade, a etapa de aprendizado continuado foi acionada com o objetivo de aprender sobre o novo antígeno (sinal em análise), ocorrendo o processo de aprendizado, que foi realizado pelo algoritmo CLONALG. Já quando o sinal foi conhecido pelo sistema, ele foi analisado pelo módulo de monitoramento do ASN descrito a seguir.

Módulo de Aprendizado Continuado: O algoritmo CLONALG teve por objetivo gerar um conjunto de memória (conhecimento) a partir de um sinal desconhecido (antígeno). Este processo segue basicamente os passos apresentados na seção 5.1.3 deste trabalho.

No começo, foi definida uma população de linfócitos gerada aleatoriamente. Para quantificar a afinidade entre os linfócitos da população (Ab) e o antígeno foi utilizada a equação 3. Na sequência, foi selecionado n melhores linfócitos com maiores valores de afinidade em relação ao antígeno para o processo de clonagem e hipermutação. A quantidade de clones foi calculada pela equação 6 e a quantidade de mutações que foram realizadas nos clones foram determinadas pelos cálculos das equações 7 a 9. A mutação foi um processo evolutivo, que teve como objetivo realizar pequenas modificações na estrutura dos linfócitos, de forma que foi possível elevar a afinidade em relação ao antígeno.

Nesta metodologia, como os sinais analisados foram expressos por meio de vetores com números reais positivos e negativos, por isso foi necessário utilizar uma técnica de mutação para tal situação. Desta forma, foi utilizada a técnica de

mutação indutiva (WYLIE; SHAKHNOVICH, 2012), técnica utilizada em algoritmos evolutivos para resolver este tipo de problema. Sendo assim, o processo de mutação consistiu em realizar uma mutação utilizando a equação 10 ou equação 11, em uma posição do sinal (linfócito) escolhida aleatoriamente.

$$Abi' = Abi + \alpha * (Abi - Agi), Abi > 0 \quad (10)$$

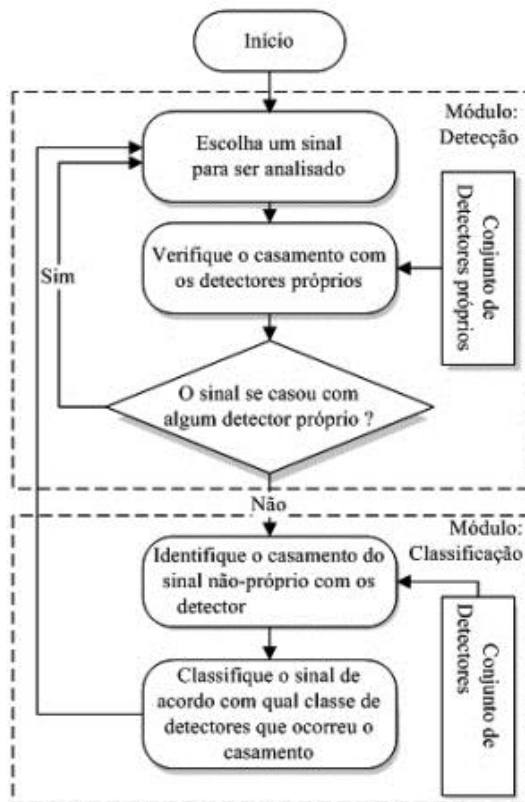
$$Abi' = Abi + \alpha * (Agi - Abi), Abi < 0 \quad (11)$$

Após realizar a maturação dos linfócitos, os n melhores clones maturados foram resseleccionados para serem incorporados na população novamente. Os linfócitos selecionados substituíram os piores linfócitos da população. Na sequência, os melhores linfócitos da população foram separados para o conjunto de memória. O processo foi repetido até quando o critério de parada foi satisfeito. Nesta pesquisa, o critério de parada foi determinado pelo número iterações.

Ao finalizar o processo de aprendizado o algoritmo CLONALG, um conjunto de memória (conhecimento) em relação ao antígeno desconhecido foi obtido. Este conjunto de conhecimento foi incorporado ao conjunto de detectores do ASN, fornecendo conhecimento ao sistema, para que numa próxima análise do mesmo tipo de antígeno o sistema seja capaz de efetuar o reconhecimento e classificação deste dano. O processo foi denominado aprendizado continuado.

Módulo de monitoramento do ASN: Quando, na etapa de detecção de novidades, não foi identificada uma novidade, ou seja, quando o antígeno já foi conhecido pelo ASN, o processo ocorre em consonância com o fluxograma ilustrado na figura 18, da mesma forma que o ASN convencional apresentada em Lima (2013).

Figura 18 – Módulo de Monitoramento do ASN



Fonte: Adaptado de Lima (2016)

Dessa forma, foi comparado o sinal em análise com o conjunto de detectores do ASN e avaliado o casamento e a afinidade, de forma que foi possível detectar o sinal com falha e posteriormente classificá-lo de acordo com as cinco situações de dano.

Após ser analisado foi finalizado o processo de monitoramento do ASN.

Módulo de atualização do conhecimento: Após realizar o processo de aprendizado e obtido um conjunto de linfócitos de memória do sinal antígeno (sinal em aprendizado), foi atualizado o conjunto de detectores do ASN. A atualização ocorreu pela substituição de um detector que não se casou com o padrão antígeno. Este detector foi substituído pelo melhor linfócito do conjunto de memória gerado no processo de aprendizado realizado pelo CLONALG.

Assim, foi comparado o sinal em análise com o conjunto de detectores do ASN e avaliado o casamento e a afinidade, de forma que foi possível detectar a anormalidade e posteriormente classificar o sinal de acordo com as cinco situações distintas de dano que ocorreu o casamento. Após o sinal ser analisado, o processo

de monitoramento do ASN foi finalizado. Em seguida, foi possível classificar os sinais para as cinco situações distintas de danos quanto ao grau de influência (pequeno, médio e grande).

Para efetuar os testes nos módulos de sensoriamento, detecção de novidade, aprendizado continuado, monitoramento e atualização do conhecimento foram utilizados os dados manipulados por Oliveira (2017) para as cinco situações distintas de danos e a situação normal (baseline) que corresponderam a 486 pontos dos sinais, sendo que 81 pontos para cada sinais próprios (sinais normais - baseline) e 405 pontos para cada sinais não-próprios (sinais com danos).

Para o bom funcionamento do algoritmo imunológico, com aprendizado continuado, foram necessários alguns parâmetros do ASN e do CLONALG. Após realizar diversos testes, os parâmetros que apresentaram o melhor desempenho para o sistema são apresentados na tabela 1. Vale ressaltar, que os parâmetros apresentados foram obtidos por meio de testes empíricos. O valor da taxa de afinidade TAf foi definido pelo valor de 30% devido as características dos sinais serem semelhantes.

Tabela 1 - Parâmetros

Parâmetros	ASN sem Aprendizado Continuado	ASN com Aprendizado Continuado
N	-	20
n	-	4
β	-	0.3
d	-	0
desvio	0.3	0.3
afinidade	30%	30%
roh	-	3

Fonte: Elaborado pelo autor

O valor do desvio foi atribuído em 3% de acordo com sugestões encontradas na literatura, como em (LIMA *et. al*, 2013). Ressalta-se que para as cinco situações distintas de danos testadas foram utilizadas os parâmetros apresentados na Tabela 1, comprovando a robustez do algoritmo proposto.

O sistema foi submetido a uma fase de testes e configurações de parâmetros, isto é, teste de referência cruzada, em que o sistema foi executado 30 vezes para

garantir a precisão dos resultados. Para as classificações dos sinais quanto ao grau de influência foi definido a métrica valor médio quadrático (RMSD) conforme ilustra a equação 12 para as cinco situações distintas de danos. A métrica proporcionou bons resultados para manipulação dos sinais conforme descrito pela autora Oliveira (2017). O índice i representa a linha e o índice j representa a coluna da matriz de normalização.

$$Soma = Abs(SD(j,i)^2 - D(j,i)^2) \quad (12)$$

Sendo:

Soma : soma;

Abs : valor absoluto;

SD : sinal sem dano;

D : sinal com dano;

Após calcular o valor quadrático dos sinais foi calculado a raiz quadrada dos sinais e assim determinar a normalização definida pela métrica RMSD conforme ilustra a equação 13.

$$Métrica = Raiz (Soma/81) \quad (13)$$

Sendo:

Métrica : métrica RMSD;

Raiz : raiz quadrada;

Em seguida foram definidos os valores máximos e mínimos para as cinco situações de danos e dividido em três partes conforme mostra a equação 14.

$$Métrica = (Máximo - Mínimo)/3 \quad (14)$$

Sendo:

Métrica : métrica;

Máximo : valor máximo da métrica RMSD;

Mínimo : valor mínimo da métrica RMSD;

Sendo assim, a equação 13 determinou a normalização dos dados pela métrica RMSD e os valores normalizados foram utilizados pela equação 14 que determinou a métrica quanto ao grau de influência dos danos.

Conforme a metodologia proposta por Lima (2014) foi possível detectar e localizar os danos para as cinco diferentes situações, demonstrando o percentual de acerto e nos casos que o percentual não foi de 100% foi possível mostrar quais sinais que o algoritmo errou na detecção e localização dos danos. Com objetivo de aumentar a robustez da metodologia foi possível quantificar os sinais quanto ao grau de influência (pequeno, médio e grande) dos danos para as cinco distintas situações. O grau de influência foi determinado pelas equações 12 e 14 que representaram a influência dos danos nos sinais, ou seja, quanto maior for a diferença das amplitudes dos sinais maior foi o grau de influência. A quantificação retratou quantos sinais foram quantificados como pequeno, médio e grande quanto ao grau de influência para as cinco situações de dano e não retratou a gravidade do dano.

Neste capítulo foi apresentado a descrição do funcionamento do algoritmo inteligente e a métrica utilizada para determinar a quantificação do grau de influência do dano proposto neste trabalho.

8 RESULTADOS E DISCUSSÃO

A metodologia proposta foi avaliada, verificando-se a eficiência, precisão e robustez no processo de monitoramento de integridade estrutural utilizando o algoritmo convencional (sem aprendizado continuado proposto e apresentado em detalhes em Lima (2013) e o algoritmo com o aprendizado continuado.

Visando avaliar o desempenho dos módulos de detecção de novidade, aprendizado continuado e atualização do conhecimento no algoritmo proposto neste trabalho, foi realizada a fase de sensoriamento em ambos os sistemas (sem e com aprendizado continuado) excluindo-se dois padrões, sendo escolhidos os danos 1 e 5.

Neste caso, foram escolhidos 2 situações de danos. No entanto, qualquer situação de dano poderia ser escolhido. Desta forma, garante-se que o algoritmo inicie o processo de monitoramento on-line sem o prévio conhecimento sobre estes padrões.

Para efetuar os testes nas fases de sensoriamento, detecção de novidade, aprendizado continuado e monitoramento foram utilizados os dados manipulados por Oliveira (2017) para as cinco situações de falhas que correspondem a 486 pontos dos sinais, sendo que 81 pontos dos sinais próprios (sinais normais - baseline) e 405 pontos dos sinais não-próprios (sinais com falhas).

Vale ressaltar que para todas as cinco distintas situações de dano testadas foram utilizados os parâmetros apresentados na Tabela 1, comprovando a robustez dos algoritmos propostos.

Seguindo estas configurações e parâmetros para ambos os sistemas de diagnóstico, as situações de danos foram analisados e os resultados são apresentados a seguir.

8.1 RESULTADOS ALGORITMOS ASN E CLONALG

Para obter os resultados, o sistema foi submetido numa fase de testes e parametrização. Os resultados foram obtidos por testes de validação cruzada, em que o sistema foi executado 30 vezes para garantir a precisão dos resultados. Para realização dos testes foi determinado a taxa de afinidade de 30% e desvio de 3%. Assim foi possível observar que o sistema de análise da integridade estrutural

realizada no material isotrópico (placa de alumínio) apresentou bom desempenho (índice de acerto igual a 100,00% na melhor configuração), e que as quantidades de detectores influenciam diretamente no reconhecimento dos danos.

Ao aplicar o algoritmo de seleção negativa, no conjunto de testes das cinco situações de dano, foram obtidos os resultados apresentados na Tabela 2.

Tabela 2 – Resultados do algoritmo convencional – 4 situações de dano e 1 sem dano

Padrões	Padrões Testados	Padrões Acertados	Acertos (%)
Baseline	81	68	83,95
Dano 1	81	81	100,00
Dano 2	81	81	100,00
Dano 3	81	81	100,00
Dano 4	81	81	100,00
Dano 5	0	0	0
Total	405	392	96,79

Fonte: Elaborado pelo autor.

Pode-se observar na tabela 2 que o algoritmo de seleção negativa não conseguiu identificar o padrão que foi excluído do processo de sensoriamento, ou seja, sem conhecimento prévio do dano. Sendo assim, o SHM não foi capaz de identificar o dano 5, onde não houve nenhum acerto.

A tabela 3, apresenta os resultados obtidos pelo monitoramento de integridade estrutural com aprendizado continuado na mesma condição da tabela 2.

As configurações e parâmetros foram as mesmas utilizadas pelo algoritmo ASN convencional conforme descrito anteriormente.

Tabela 3 – Resultados do algoritmo com aprendizado continuado – 4 situações de dano e 1 sem dano

Padrões	Padrões Testados	Padrões Acertados	Acertos (%)
Baseline	81	81	100,00
Dano 1	81	81	100,00
Dano 2	81	81	100,00
Dano 3	81	81	100,00
Dano 4	81	81	100,00
Dano 5	81	81	100,00
Total	486	486	100,00

Fonte: Elaborado pelo autor.

Perante os resultados expressos na tabela 3, foi possível visualizar que o sistema com aprendizado continuado foi capaz de aprender o dano desconhecido e, a partir disto, diagnosticou o dano na próxima análise. Também foi possível observar que o módulo de atualização de conhecimento contribuiu para o ASN, de forma que a taxa de acerto da Baseline atingiu 100% de acerto, mesmo que o sistema já havia um conhecimento prévio sobre esse padrão. Isto se deve ao fato do SHM atualizar o conjunto de detectores do ASN no processo de monitoramento on-line, proporcionando um reforço e melhoria no conhecimento.

Ao aplicar o algoritmo de seleção negativa, no conjunto de testes das cinco situações de dano, foram obtidos os resultados apresentados na Tabela 4.

Tabela 4 – Resultados do algoritmo convencional – 3 situações de dano e 1 sem dano

Padrões	Padrões Testados	Padrões Acertados	Acertos (%)
Baseline	81	81	100,00
Dano 1	0	0	0
Dano 2	81	81	100,00
Dano 3	81	81	100,00
Dano 4	81	81	100,00
Dano 5	0	0	0
Total	324	311	63,99

Fonte: Elaborado pelo autor.

Pode-se observar na tabela 4 que o algoritmo de seleção negativa não conseguiu

identificar os padrões excluídos do processo de sensoriamento, ou seja, sem conhecimento prévio do dano. Sendo assim, o SHM não identificou os danos 1 e 5, onde não houve nenhum acerto.

A tabela 5, apresenta os resultados obtidos pelo monitoramento de integridade estrutural com aprendizado continuado na mesma condição da tabela 4.

As configurações e parâmetros foram as mesmas utilizadas pelo algoritmo ASN convencional conforme descrito anteriormente.

Tabela 5 – Resultados do algoritmo com aprendizado continuado – 3 situações de dano e 1 sem dano

Padrões	Padrões Testados	Padrões Acertados	Acertos (%)
Baseline	81	81	100,00
Dano 1	81	81	100,00
Dano 2	81	81	100,00
Dano 3	81	81	100,00
Dano 4	81	81	100,00
Dano 5	81	81	100,00
Total	486	486	100,00

Fonte: Elaborado pelo autor.

Comparando as tabelas 4 e 5 foi possível observar que o algoritmo de seleção negativa convencional não reconheceu os padrões excluídos do processo de sensoriamento, apresentado 0% de acerto. Posteriormente, foi utilizado o sistema com aprendizado continuado e os padrões foram identificados, com uma taxa de acerto de 100,00% para as cinco situações distintas de danos.

8.2 RESULTADOS MÉTRICA GRAU DE INFLUÊNCIA DANO 1

Uma das contribuições deste trabalho foi quantificar o grau de influência do dano, por meio da métrica RMSD e das amplitudes dos sinais conforme demonstrado pela equação 14, dividindo em três parâmetros: pequeno, médio e grande.

Os resultados das quantificações dos sinais quanto ao grau de influência (pequeno, médio e grande) foram de 100% de acerto para as cinco situações de danos.

Para o dano 1 foram classificados 6 sinais com grau de influência grande, 22 sinais com grau de influência médio e 44 sinais com grau de influência pequeno, conforme ilustra a tabela 6.

Tabela 6 –Quantificação quanto ao grau de influência do dano 1

Danos	Sinais	Classificações	Percentuais
1	6	Grande	8,33
1	22	Médio	30,55
1	44	Pequeno	61,11
Total	72		100,00

Fonte: Elaborado pelo autor.

O algoritmo quantificou corretamente os sinais quanto ao grau de influência para o dano 1.

8.3 RESULTADOS MÉTRICA GRAU DE INFLUÊNCIA DANO 2

Os resultados das quantificações dos sinais quanto ao grau de influência (pequeno, médio e grande) foram de 100% de acerto para as cinco situações de danos.

Para o dano 2 foram classificados 3 sinais com grau de influência grande, 6 sinais com grau de influência médio e 66 sinais com grau de influência pequeno, conforme ilustra a tabela 7.

Tabela 7 –Quantificação quanto ao grau de influência do dano 2

Danos	Sinais	Classificações	Percentuais
2	3	Grande	4,16
2	6	Médio	8,33
2	63	Pequeno	87,50
Total	72		100,00

Fonte: Elaborado pelo autor.

O algoritmo quantificou corretamente os sinais quanto ao grau de influência para o dano 2.

8.4 RESULTADOS MÉTRICA GRAU DE INFLUÊNCIA DANO 3

Os resultados das quantificações dos sinais quanto ao grau de influência (pequeno, médio e grande) foram de 100% de acerto para as cinco situações de danos.

Para o dano 3 foram classificados 2 sinais com grau de influência grande, 1 sinais com grau de influência médio e 69 sinais com grau de influência pequeno, conforme ilustra a tabela 8.

Tabela 8 –Quantificação quanto ao grau de influência do dano 3

Danos	Sinais	Classificações	Percentuais
3	2	Grande	2,77
3	1	Médio	1,38
3	69	Pequeno	95,83
Total	72		100,00

Fonte: Elaborado pelo autor.

O algoritmo quantificou corretamente os sinais quanto ao grau de influência para o dano 3.

8.5 RESULTADOS MÉTRICA GRAU DE INFLUÊNCIA DANO 4

Os resultados das quantificações dos sinais quanto ao grau de influência (pequeno, médio e grande) foram de 100% de acerto para as cinco situações de danos.

Para o dano 4 foram classificados 4 sinais com grau de influência grande, 2 sinais com grau de influência médio e 66 sinais com grau de influência pequeno, conforme ilustra a tabela 9.

Tabela 9 –Quantificação quanto ao grau de influência do dano 4

Danos	Sinais	Classificações	Percentuais
4	4	Grande	5,55
4	2	Médio	2,77
4	66	Pequeno	91,66
Total	72		100,00

Fonte: Elaborado pelo autor.

O algoritmo quantificou corretamente os sinais quanto ao grau de influência para o dano 4.

8.6 RESULTADOS MÉTRICA GRAU DE INFLUÊNCIA DANO 5

Os resultados das quantificações dos sinais quanto ao grau de influência (pequeno, médio e grande) foram de 100% de acerto para as cinco situações de danos.

Para o dano 5 foram classificados 5 sinais com grau de influência grande, 6 sinais com grau de influência médio e 61 sinais com grau de influência pequeno, conforme ilustra a tabela 10

Tabela 10 –Quantificação quanto ao grau de influência do dano 5

Danos	Sinais	Classificações	Percentuais
5	5	Grande	6,94
5	6	Médio	8,33
5	61	Pequeno	84,72
Total	72		100,00

Fonte: Elaborado pelo autor.

O algoritmo quantificou corretamente os sinais quanto ao grau de influência para o dano 5.

Essa metodologia pode ser caracterizada como inovadora e robusta aplicada aos sistemas de SHM completando o mesmo com a detecção, localização com aprendizado continuado e quantificação quanto ao grau de influência para cinco situações distintas de danos.

8.7 ASPECTOS POSITIVOS E NEGATIVOS DA METODOLOGIA

Após a realização dos testes e obtenção dos resultados, foram identificados os aspectos positivos e negativos dos algoritmos propostos, estes são apresentados a seguir:

8.7.1 Pontos Positivos da Metodologia

- O algoritmo proposto apresentou excelente taxa de precisão;
- O algoritmo requer baixo tempo de processamento computacional;
- Este algoritmo tem a capacidade de identificar padrões desconhecidos (danos);

- Este método tem a capacidade de continuamente melhorar/reforçar o conhecimento e, permanentemente, aprender sem reinicializar o processo de aprendizagem.

8.7.2 Pontos Negativos da Metodologia

- O algoritmo proposto tem vários parâmetros que devem ser calibrados cuidadosamente para uma boa eficiência.

9 CONCLUSÃO

Neste trabalho, foi desenvolvido um sistema inovador de monitoramento de integridade estrutural capaz de detectar, localizar e quantificar falhas em estrutura aeronáutica através de sistemas imunológicos artificiais com o algoritmo de seleção negativa e seleção clonal.

Foi possível comprovar no ASN por meio dos testes realizados que quanto maior foi o conhecimento obtido no módulo de sensoriamento, maior foi a eficiência no processo de reconhecimento e classificação do algoritmo no módulo de monitoramento.

Perante, os testes realizados foi possível comprovar que o aprendizado continuado aprende o dano desconhecido e melhora os resultados em uma próxima análise.

O módulo de atualização de conhecimento contribuiu para o aprendizado continuado, de forma que a taxa de acerto aumentou e isto se deve ao fato de que no sistema seja atualizado o conjunto de detectores do ASN no processo de monitoramento on-line, proporcionando melhoria e robustez no conhecimento.

Verificou-se que a quantidade de detectores influencia diretamente no processo de diagnóstico de falhas e o teste de referência cruzada proporciona confiabilidade e rapidez.

Desta forma, conclui-se que o algoritmo proposto neste trabalho baseado em técnicas de computação inteligentes foram eficientes, confiáveis, robustos e precisos para realização do monitoramento de integridade estrutural em estruturas isotrópicas e que o trabalho contribui para a área de pesquisa em SHM, apresentando uma nova abordagem contribuindo para a quantificação do grau de influência dos danos.

9.1 SUGESTÕES PARA TRABALHOS FUTUROS

- Aplicar outra metodologia de inferência como Fuzzy ou regressão linear para validar a influência do grau de influência dos danos;
- Prosseguir com os níveis de abrangência do SHM (nível 4).

REFERÊNCIAS

- ABBAS, A. K.; LICHTMAN, A. H.; PILLAI S. **Imunologia celular e molecular**. 6. ed. Rio de Janeiro: Elsevier, 2008. p. 576.
- ANAYA, M.; TIBADUIZA, D. A.; POZO, F. A. bioinspired methodology based on an artificial system for damage detection in structural health monitoring. **Shock & Vibration**, Nova Iorque, v. 10, n. 40, p. 1-2, 2015. DOI 10.1155 ID 648097.
- BAPTISTA, F. G. **Uma contribuição aos sistemas de monitoramento de integridade estrutural baseados na impedância eletromecânica**. 2010. 93 f. Tese (Doutorado em Engenharia Elétrica) - Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, de Ilha Solteira, 2010.
- 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, 2002. p. 227-238.
- BURNET, F. M. **A modification of Jerne's theory of antibody production using the concept of clonal selection**. US National Library of Medicine National Institutes of Health, Bethesda MD, 20: 67-69. 1957.
- CAMPELO, F.; GUIMARAES, F.G.; IGARASHI, H.; RAMIREZ, J.A. A clonal selection algorithm for optimization in electromagnetics. **IEEE Transactions on Magnetics**, Japão, v. 41, 2005. p. 1736 – 1739.
- CAZANGI, R. R. **Uma proposta evolutiva para controle inteligente em navegação autônoma de robôs**. 2004. Tese (Doutorado) - Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 2004.
- CAYZER, S.; AICKELIN, U. The danger theory and its application to artificial immune systems. *In* Proceedings Internet Conference on Artificial Immune Systems (Icaris-2002), 1, 2002, Canterbury. **Proceedings** [...] Canterbury: Canterbury University of Kent at Canterbury, 2002. p. 141–148.
- CHANDRASHEKHAR, M.; GANGULI, R. Structural damage detection using modal curvature and fuzzy logic. **Structural Health Monitoring**, London, v. 8, n. 4, 2009. p. 267-282.
- CHEN, H. G.; YAN, Y. J.; CHEN, W. H.; JIANG, J. S.; YU, L.; WU, Z. Y. Early damage detection in composite wingbox structures using Hilbert-Huang transform and genetic algorithm. **Structural Health Monitoring**, London, v. 6, n. 4, 2007. p. 281-297.
- CHUEH, C. H.; LUH, G. C.; LIU, W.W. MOIA: Multi-objective Immune Algorithm. **Engineering Optimization**, London, v. 35, n. 2, p. 143-164, 2003.
- COELLO, C. A.; NARELI, C. C. Solving multi objective optimization problems using an artificial immune system. **Genetic Programming and Evolvable Machines**, New York, v. 6, n. 2, 2005. p. 163-190.

COELHO, G.P.; VON ZUBEN, F.J. Omni-aiNet: An Immune-Inspired Approach for Omni Optimization. *In*: BERSINI, H.; CARNEIRO, J. (ed.) **ICARIS 2006**. [S. l.]: LNCS, 2006. v. 4163, p. 294-308.

DASGUPTA, D.; ATTOH-OKINE, N. Immunity-based systems: a survey. *In*: SYSTEMS, MAN, AND CYBERNETICS, 1997. COMPUTATIONAL CYBERNETICS AND SIMULATION, IEEE INTERNATIONAL CONFERENCE, 1997, Memphis. **Proceedings** [...] Memphis: IEEE, 1997. v. 1, p. 369–374, 1997.

DASGUPTA, D. **Artificial immune systems and their applications**. New York: Springer- Verlag, 1998.

DASGUPTA, D. **Immunity-based intrusion detection systems**: a general framework, [S.l.: s. n.], 1999.

DASGUPTA, D.; FORREST, S. Artificial immune systems in industrial applications. *In*: IPMM99, 1999, [S. l.]. **Proceedings** [...] [S. l: s. n.], 1999.

DASGUPTA, D.; YU, S.; NINO, F. Recent Advances in Artificial Immune Systems: Models and Applications. **Soft Computing Journal**, Heidelberg, v. 11, p. 1574-1587, 2011.

DE CASTRO, L. N. **Engenharia imunológica**: desenvolvimento e aplicação de ferramentas computacionais inspiradas em sistemas imunológicos artificiais. 2001. 286 f. Tese (Doutorado) - Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 2001.

DE CASTRO, L. N.; HRUSCHKA, E. R.; ROSATELLI, M. C.; CAMPELLO, R. J. G. B. Computação natural: uma breve visão geral. *In*: Workshop em Nanotecnologia e Computação Inspirada na Biologia, 1, 2004, Rio de Janeiro. **Anais** [...] Rio de Janeiro, 2004. p.345.

DE CASTRO, L. N.; TIMMIS, J. **Artificial immune systems**: a new computational intelligence approach. New York: Springer, 2002. p.357.

DE CASTRO, L. N.; TIMMIS, J. Artificial Immune Systems as a Novel Soft Computing Paradigm. **Soft Computing Journal**, Heidelberg, v. 7, n. 8, p. 526- 544, 2003.

DE CASTRO, L. N.; VON ZUBEN, F. J. The clonal selection algorithm with engineering applications. *In*: WORKSHOP PROCEEDINGS OF GECCO, WORKSHOP ON ARTIFICIAL IMMUNE SYSTEMS AND THEIR APPLICATIONS, 2000, Las Vegas. **Proceedings** [...] Las Vegas: [s. n.], 2000. p. 36-39.

DE CASTRO, L. N.; VON ZUBEN, F. J. AiNet: an Artificial Immune Network for Data Analysis. *In*: HABASS, H. A.; SARKER, R. A.; NEWTON, C. S. **Data mining**: a heuristic approach. Hershey: Idea Group Publishing, 2002. p. 231–259.

DE CASTRO L. N.; VON ZUBEN F. J. Sistemas imunológicos artificiais. **Ciência Hoje**, São Paulo, v. 35, n. 205, p. 40, 2004.

DE FRANÇA, F. O. **Algoritmos bio-inspirados aplicados à otimização dinâmica**. 2005. 90 f. Dissertação (Mestrado) - Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 2005.

DE FRANCA, F. O.; VON ZUBEN, F. J.; DE CASTRO, L. N. AN ARTIFICIAL Immune Network for Multimodal Function Optimization on Dynamic Environments. *In: GECCO, 2005, Washington. Proceedings [...]* Washington: [s. n.], 2005. p. 289–296.

DOEBLING, S. W.; FARRAR, C. R.; PRIME, M. B. A summary review of vibration-based damage identification methods. **The Shock and Vibration Digest**, Thousand Oaks, v. 30, n. 2, p. 91-105, 1998.

FARRAR, C. R.; LIEVEN, N. A. J.; BEMENT, M. T. An introduction to damage prognosis. *In: INMAN, D. J.; FARRAR, C. J.; LOPES JUNIOR, V.; STEFFEN JUNIOR, V. Damage prognosis for aerospace, civil and mechanical systems*. England: John & Sons, 2005. p. 1-12.

FARRAR, C. R.; WORDEN, K. **An introduction of structural health monitoring: philosophical transactions of the royal society A**. [S.l.: s.n.], 2006. p. 303-315.

FLYNN, E.; TODD, M. Optimal placement of piezoelectric actuators and sensors for detecting damage in plate structures. **Journal of Intelligent Material Systems and Structures**, London, v. 21, n. 1, p. 1-10, 2009.

FERREIRA, H. M. **Uso de ferramentas de aprendizado de máquina para prospecção de perdas comerciais em distribuição de energia elétrica**. 2008. 105 f. Dissertação (Mestrado) -Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 2008.

FORNARI JR., C. C. M.; GRISON E. C.; HOINACKI E. **Identificação de materiais poliméricos e substâncias correlatas**. Rio de Janeiro: Wak, 2012.

FORREST, S. A.; PERELSON, A. L.; CHERUKURI, R. Self-nonsel discrimination in a computer. *In: PROCEEDINGS OF THE IEEE SYMPOSIUM ON RESEARCH IN SECURITY AND PRIVACY, 1994, Oakland. Proceedings [...]*, 1994. p. 202-212.

FORREST, S. A.; JAVORNIK B.; SMITH R. E. PERELSON A. S. Using genetic algorithms to explore pattern recognition in the immune system. **Evolutionary Computation**, Cambridge, v. 1, n. 3, p.191-211, 1993.

FRANÇA, A. A. **Detecção e localização de danos em materiais compósitos aplicado em aeronaves utilizando redes neurais artificiais**. 2014. 98 f. Dissertação (Mestrado em Engenharia Mecânica) Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2014.

FRANCO, V. R. **Monitoramento da integridade de estruturas aeronáuticas**. 2009. 205 f. Dissertação (Mestrado em Engenharia Mecânica) - Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2009.

FRANCO, V. R.; BUENO, D. D.; BRENNAN, M. J.; CAVALINI, J. R.; GONSALEZ, C. G.; LOPES JUNIOR, V. Experimental Damage Location in Smart Structures using Lamb Waves Approaches. *In*: BRAZILIAN CONFERENCE ON DYNAMICS, CONTROL AND THEIR APPLICATION – DINCON, 2009, Bauru. **Proceedings** [...] [S. l.: s. n.], 2009. p. 1- 4.

FRESCHI, F.; REPETTO M. Multiobjective optimization by a modified artificial immune system algorithm. *In*: INTERNATIONAL CONFERENCE ON ARTIFICIAL IMMUNE SYSTEMS, 4th, Banff, Alberta. **Proceedings** [...] [S. l.]: Lecture Notes in Computer Science 3627, 2005. p. 248-261.

FRISWELL, M. I.; PENNY, J. E. T. The practical limits of damage detection and location using vibration data. *In*: VPI&SU SYMPOSIUM ON STRUCTURAL DYNAMICS AND CONTROL, 11, 1997, Blacksburg. **Proceedings** [...] Blacksburg: VirginiaTech Publisher, 1997. p. 1-10.

FURTADO, R. M. **Identificação de falhas estruturais usando sensores e atuadores piezelétricos e redes neurais artificiais**. 2004. 144 f. Dissertação (Mestrado em Engenharia Mecânica) - Faculdade de Engenharia, Universidade Estadual Paulista- UNESP, Ilha Solteira, 2004.

GARCIA A.; SPIN J. A.; SANTOS C. A. **Ensaios dos materiais**. Rio de Janeiro: Livros Técnicos e Científicos, 2000. p. 247.

GARRETT, S. M. Parameter-free, adaptive clonal selection, *In*: CONGRESS ON EVOLUTIONARY COMPUTING (CEC 2004), 2004, Portland Oregon. **Proceedings** [...] Portland Oregon: [s. n.], 2004. v. 1, p. 1052-1058.

GIURGIUTIU, V.; CUC, A. Embedded non-destructive evaluation for structural health monitoring, damage detection, and failure prevention. **The Shock and Vibration Digest**, Ipswich, v. 37, n. 2, p. 83-105, 2005.

GONSALEZ, C. G. **Metodologias para reconhecimento de padrões em sistemas SHM utilizando a técnica da impedância eletromecânica (E/M)**. 2012. 116 f. Dissertação (Mestrado em Engenharia Mecânica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira 2012.

GREENSMITH, J. **The dendritic cell algorithm**. 2007. 90 f. Philosophical Doctor (Thesis) - University of Nottingham, Nottingham, 2007.

GREENSMITH, J.; AICKELIN, U. Dendritic cells for syn scan detection. *In*: GECCO 07, 2010, **Proceedings** [...], New York, 2010. p. 49–56.

GONG, M.; ZHANG, L.; JIAO, L.; MA, W. Differential immune clonal selection algorithm. *In*: INTERNATIONAL SYMPOSIUM ON INTELLIGENT SIGNAL PROCESSING AND COMMUNICATION SYSTEMS – ISPACS, 2007. **Proceedings** [...] [S. l.: s. n.], 2007. p. 666-669.

GONG, M.; JIAO, L.; ZHANG, L.; DU, H. Immune secondary Response and Clonal Selection Inspired Optimizers. **Progress in Natural Science**, London, v. 19, n. 2, p. 237-253, 2009.

HALL S. R. The effective management and use of structural health data. *In*. INTERNATIONAL WORKSHOP ON STRUCTURAL HEALTH MONITORING, 2., 1999, New York. **Proceedings** [...] New York: Virginia Tech Publisher, 1999. p. 265-275.

HAYKIN, S. **Neural networks and learning machines**. 3. ed. New York: Prentice-Hall, 2008. 936 p.

HOFFMANN, G. W. A neural network model based on the analogy with the immune system. **Journal of Theoretical Biology**, London, v. 122, p.33-67, 1986.

HOFMEYR, S. A.; FORREST, S. **Immunity by design**: an artificial immune system. [S. l.: s. n.], 1999.

HOLANDA, L; RABELO, R.; LEMOS, M.; BARBOSA, D. Power system harmonics estimation using clonal selection algorithm. **IEEE Latin America Transactions**, New York, v. 11, p. 525-531, 2013.

KRAWCZUK, M.; OSTACHOWICZ, W.; KAWIECKI, G. Detection of delaminations in cantilevered beams using soft computing methods. *In*: CONFERENCE ON SYSTEM IDENTIFICATION AND STRUCTURAL HEALTH MONITORING, 3, 2000, Madrid. **Proceedings** [...] Madrid: Universidad Complutense de Madrid, 2000. p. 243–252.

KEKO H.; SKOK M.; SKRLEC D. Artificial immune systems in solving routing problems. *In*: EUROCON. COMPUTER AS A TOOL. THE IEEE REGION 8, 2003, [S. l.]. **Proceedings** [...] [S. l.: s. n.], 2003. v. 1, p. 62 -66.

INMAM, D. J. Smart structures: example and new problems. *In*: CONGRESSO BRASILEIRO DE ENGENHARIA MECÂNICA – COBREM, 16., 2001, Uberlândia. **Anais** [...] Uberlândia: ABREM, 2001. p. 26-30.

JAHANGIRI, V.; MIRAB, H.; FATHI, R.; ETTEFAGH, M. M. TLP Structural Health Monitoring Based on Vibration Signal of Energy Harvesting System. **Latin American Journal of Solids and Structures**, Rio de Janeiro, v. 13, n. 5, 2016.

JERNE, N. K. **Towards a network theory of the immune system**. *Ann*: Immunol. Inst. Pasteur, 1974. p. 373-389.

JUNIOR, F. G. Damage tolerant design and nondestructive inspection keys to Aircraft Airworthiness. *In*: THE INTERNATIONAL SYMPOSIUM ON AIRCRAFT AIRWORTHINESS, 2nd, 2011, [S. l.]. **Proceedings** [...] [S. l.: s. n.], 2011. p. 236-246.

LAU, Y. K. H.; TSANG, W. W. P. A parallel computation-based immunological framework for global optimization. *In: INTERNATIONAL CONFERENCE ON OPTIMIZATION: TECHNIQUES AND APPLICATIONS (ICOTA7)*, 7th, 2007, Japan. **Proceedings** [...] Japan: [s. n.], 2007. p. 229-233.

LAU, Y. K. H.; TSANG, W. W. P. A parallel immune optimization algorithm for numeric function optimization. **Evolutionary Intelligence**, Heidelberg, v. 1, n. 3, p. 171-185, 2008.

LAU, Y.K.H., WONG, E.Y.C. An AIS-Based Dynamic Routing (AISDR) Framework. *In: JACOB, C. et. al. ICARIS*. Canada: [s. n.], 2005. p. 56-71.

LIN, H. A. Real-time Dynamic Danger Theory Model for Anomaly Detection in File Systems, MSc. Thesis, August 2005, 89 f. Department of Computer Science, University of York, 2005.

LI, C. H.; ZHU, Y. F.; MAO, Z. Y. A novel artificial immune algorithm applied to solve optimization problems. *In: CONTROL, AUTOMATION, ROBOTICS AND VISION CONFERENCE*, 2004. **Proceedings** [...] [S. l.]: ICARCV, 2004. p. 232 – 237.

LIMA, F. P. A., CHAVARETTE, F. R., SOUZA, S. S. F., LOPES, M. L. M. Monitoring and Fault Identification in Aeronautical Structures Using an Wavelet-Artificial Immune System Algorithm. *In: EKWARO, T; GONÇALVES, A. C; ALEMAYEHU, F. M. (org). Probabilistic prognostics and health management of energy systems*. 12 ed. São Paulo: Springer International Publishing, 2017. v. 1, 2017. p. 1-17.

LIMA, F. P. A.; CHAVARETTE, F. R.; SOUZA, A. S. E.; SOUZA, S. S. F.; LOPES, M. L. M. Artificial immune systems applied to the analysis of structural integrity of a building. **Applied Mechanics and Materials**, Yandong Wang, v. 472, p. 544-549. 2014.

LIMA, F. P. A.; CHAVARETTE, F. R.; SOUZA, A. S. E., SOUZA, S. S. F., LOPES, M. L. M. Artificial immune systems with negative selection applied to health monitoring of aeronautical structures. **Advanced Materials Research**, Hong King, v. 871, p. 283-289, 2013.

LIMA, F. P. A. **Diagnóstico de distúrbios de tensão em sistemas de distribuição baseado num sistema imunológico artificial com aprendizado continuado**. 2016. 101 f. Tese (Doutorado Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2016.

LIMA F. P. A.; CHAVARETTE, F. R.; SOUZA S. S. F. Diagnosis of Failures in Aeronautical Structures Using a New Approach Hybrid Based in Artificial Neural Networks and Wavelet Transform. **International Journal of Pure and Applied Mathematics**, Sofia, v. 120, p. 273-282, 2018.

LOPES JUNIOR, V.; TURRA, A. E.; MÜLLER, H. H.; BRUNZEL, F.; INMAN, D. J. A new methodology of damage detection by electrical impedance and optimization technique. *In: CONFERENCE ON DYNAMIC PROBLEM IN MECHANICS – DINAME*, 13., 2001, Florianópolis. **Proceedings** [...] Florianópolis: ABCM, 2001. p. 311-316.

LOUZADA, D. R. **Detecção e caracterização de danos estruturais através de sensores a rede Bragg e redes neurais artificiais**. 2013. 173 f. Tese (Doutorado em Engenharia Mecânica) – Faculdade de Engenharia Mecânica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2013.

LUH, G. C.; CHUEH, C. H. Multi-objective optimal design of truss structure with immune algorithm. **Computers & Structures**, New York. v. 82, 2004. p. 829-844.

MACHADO, R. B. **Uma abordagem de detecção de intrusão baseada em sistemas imunológicos artificiais e agentes móveis**. 2005. 164 f. Dissertação (Mestrado em Ciência da Computação) - Universidade Federal de Santa Catarina, Florianópolis, 2005.

MARQUI, C. R. **Modelagem de estruturas piezelétricas para aplicação em localização de danos**. 2007. 220 f. Dissertação (Mestrado em Engenharia Mecânica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2007.

MENG, H.; LIU, S. ISPEA: improvement for the strength Pareto evolutionary algorithm for multiobjective optimization with immunity. *In: FIFTH INTERNATIONAL CONFERENCE – ICCIMA*, 2003, New York. **Proceedings** [...] [S. l.: s. n.], 2003. p. 368-372.

OLIVEIRA, D. C. **Localização de danos em estruturas isotrópicas com a utilização de aprendizado de máquina**. 2017. 125 f. Dissertação (Mestrado Engenharia Mecânica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2017.

ROSA, V. A. M. Localização de danos em estruturas anisotrópicas com a utilização de ondas guiadas. 2016. 81 f. Dissertação (Mestrado Engenharia Mecânica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2016.

SHEN, T.; WAN, F.; SONG, B.; WU, Y. Damage Location and Identification of the Wing Structure With probabilistic neural Networks. *In: PROGNOSTICS & SYSTEM HEALTH MANAGEMENT CONFERENCE - PHM*, 1, 2011, Hong Kong. **Proceedings** [...] Hong Kong: University of Hong Kong, 2011. p. 1–6.

SHI, A.; YU, X. Structural damage assessment using artificial immune systems and wavelet decomposition. *In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS - IJCNN*, 2017, [S. l.]. **Proceedings** [...] [S. l.: s. n.], 2017. DOI 10.1109/IJCNN.7965861.

SILVA, G. C. **Detecção de intrusão em redes de computadores**: algoritmo imunoinspirado baseado na teoria do perigo e célula dendríticas. 2009. 136 f. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal de Minas Gerais, Belo Horizonte, 2009.

SILVA, S.; DIAS JÚNIOR, M.; LOPES JÚNIOR, V. Structural health monitoring in smart structures through time series analysis. **Structural Health Monitoring**, London, v. 7, n. 3, p. 231-244, 2008.

SOMAYAJI, A.; HOFMEYR, S.; FORREST, S. Principles of a computer immune system. *In*: PROCEEDINGS NSPW'97 OF THE SECOND NEW SECURITY PARADIGMS WORKSHOP, 1997, New York. **Proceedings [...]** New York: ACM, 1997. p. 75–82.

STASZEWSKI, W.; BOLLER, C; TOMLINSON, G. R. **Health monitoring of aerospace structures: smart sensor technologies and signal processing**. Health monitoring of aerospace structures: smart sensor technologies and signal processing. Chichester: John Wiley & Sons, 2004. p. 266.

SU, Z.; YE, L. **Identification of damage using lamb waves**. New York: Springer, 2009. p. 346. (Lecture Notes in Applied and Computational, 48).

TAN, K. C.; GOH, C. H.; MAMUN, E. Z. E. An Evolutionary Artificial Immune System for Multi-Objective Optimization. **European Journal of Operational Research**, Amsterdam, v. 187, 2008. p. 371 – 392.

TIMMIS, J. I. **Artificial immune systems**: a novel data analysis technique inspired by the immune network theory. 2000. 98 f. Tese (Doctor of Philosophy of the University of Wales) - Department of Computer Science, University of Wales, Aberystwyth, 2000.

TIMMIS, J.; HONE, A.; STIBOR, T.; CLARK, E. **Theoretical advances in artificial immune systems**. Science Direct, 2008. p. 11-32.

TURRA, A. E; BAPTISTA, F. G; LOPES JUNIOR, V; VIEIRA, J. Detecção de dano em placas de alumínio utilizando impedância Eletromecânica. *In*: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE- SBAI, 11., 2013, Fortaleza. **Proceedings [...]** [S. l.: s. n.], 2013. p. 1-6.

VIEIRA I. N. **Otimização multi-objetivo de rotas de dutos submarinos através de sistemas imunológicos artificiais**. 2011. 172 f. Tese (Doutorado) - Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2011.

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. 1, p. 907-921, 2009.

WATKINS A., BI, X., PHADKE, A. Parallelizing an immune-inspired algorithm for efficient pattern recognition. *In: INTELLIGENT ENGINEERING SYSTEMS THROUGH ARTIFICIAL NEURAL NETWORKS*, 2003, [S. l.]. **Proceedings** [...] [S. l.: s. n.], 2003. p. 225-230.

WYLIE, C. S.; SHAKHNOVICH, E. I. Mutation induced extinction infinite populations: lethal mutagenesis and lethal isolation. **PLoS Computational Biology**, New York, v. 8, p. 1-6, 2012.

WONG, E. Y. C.; LAU, H. Y. K. Advancement in the Twentieth century in artificial immune systems for optimization: review and future outlook. **IEEE International Conference on System, Man and Cybernetics**, San Antonio, TX., USA, p. 4195-4202, 2009.

ZADEH, L. A. Fuzzy sets. **Information and Control**, New York, v. 8, n. 3, p. 338-353, 1995.

ZHANG, J.; HOU, Z. Application of artificial immune system in structural health monitoring. **Journal of Structures**, New York, p. 14, 2014. DOI 10.1155 ID 709127.

ZHAO, Y.; YIN, Y.; FU, D.; ZHOU, Z.; YIN, P.; WANG, J. Application of improved artificial immune network algorithm to optimization. *In: INTERNATIONAL SYMPOSIUM – ISSCAA*, 2nd., 2008. **Proceedings** [...] [S. l.: s. n.], 2008. p. 1-6.

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*, 2004, Munich. **Proceedings** [...] [S. l.: s. n.], 2004. p. 609-615.

ZHONGQING, S.; WANG, X.; YU, L. C. L.; CHEN, Z. On selection of data fusion schemes for structural damage evaluation. **Structural Health Monitoring**, Cambridge, v. 8, n. 3, p. 223-241, 2009.

ANEXOS A – SISTEMAS IMUNOLÓGICOS BIOLÓGICOS

A1 ANATOMIA DO SISTEMA IMUNOLÓGICO BIOLÓGICO

A anatomia do sistema imunológico biológico é composta por camadas com funções específicas por De Castro (2001), sendo que o aprendizado ocorre no primeiro contato com o agente infeccioso desconhecido. Após a eliminação da infecção, o conhecimento é armazenado na memória imunológica, proporcionando a resposta rápida e eficiente no segundo contato com o mesmo agente infeccioso (MACHADO, 2005).

Os sistemas imune inato e adaptativo compõem o sistema imunológico biológico. O sistema imune inato é a primeira linha de defesa, com a capacidade limitada em diferenciar agentes infecciosos externos. O ser humano já nasce com o sistema inato que não se altera ao longo da vida. O sistema imune adaptativo se caracteriza pela capacidade de realizar discriminações específicas de agentes externos, proporcionando memória imunológica e produção de respostas especializadas (MACHADO, 2005). O sistema imune adaptativo é composto por glóbulos brancos (linfócitos), destacando os linfócitos do tipo T e tipo B. No corpo humano essas células são produzidas na medula óssea e existem milhões de linfócitos circulando pelo corpo por meio do sistema linfático, caracterizado como detectores móveis e independentes que cooperam na detecção e eliminação de invasores (MACHADO, 2005; ABBAS *et. al*, 2008).

Os linfócitos do tipo B são oriundos da medula óssea, do inglês “Bone Marrow”, por este fato se denomina linfócitos B. São células que amadurecem e crescem fora do Timo, e trabalham principalmente secretando substâncias solúveis chamadas de anticorpos dentro dos fluídos do corpo, também conhecido como imunidade adaptativa (MACHADO, 2005). Já células T são chamadas assim devido a maturação ocorrer no Timo. Essa classe de linfócitos atuam diretamente sobre células do corpo atacadas por patógenos (vírus, parasitas ou fungos). Ambas as células, atuam no reconhecimento de agentes infecciosos externos (DE CASTRO, 2001).

A1.1 ÓRGÃOS DO SISTEMA IMUNOLÓGICO BIOLÓGICO

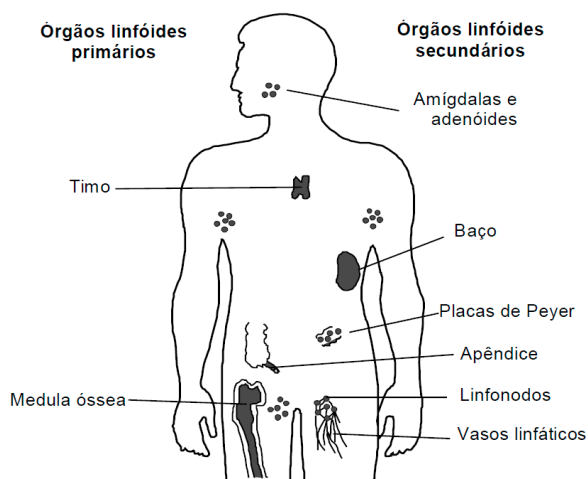
Os órgãos e tecidos que compõem o sistema imunológico biológico são distribuídos pelo corpo humano. Estes órgãos pertencem ao sistema linfático, pois estão relacionados com o crescimento, produção e desenvolvimento de linfócitos (DE CASTRO; VON ZUBEN, 2004).

Os órgãos linfóides são classificados em primários e secundários. Os primários se responsabilizam pela produção e maturação de linfócitos, incluindo o timo e a medula óssea. Os secundários são responsáveis por estimularem a produção de anticorpos, dentre eles estão: as adenóides, baço, placas de peyer, apêndice, linfonodos e vasos linfáticos (DE CASTRO, 2001).

O conjunto de órgãos está distribuído pelo corpo humano conforme ilustrado na figura 19.

- Medula óssea: é o local da hematopoese, ou seja, a geração dos elementos celulares do sangue, incluindo hemácias, monócitos, leucócitos polimorfonucleares (granulócitos), linfócitos B e plaquetas. Nos mamíferos, a medula óssea é responsável pelo desenvolvimento das células B e fonte de células-tronco que dão origem aos linfócitos T após a migração para o timo;
- Timo: órgão localizado na porção superior do tórax onde ocorre o desenvolvimento das células T. As células migram para o timo a partir da medula óssea, e assim se multiplicam e amadurecem, transformando-se em células T.

Figura 19 – Anatomia do sistema imunológico biológico



Fonte: Adaptado de De Castro (2001)


Órgãos linfoides primários: (DE CASTRO, 2001).

- Amígdalas e Adenoides: células linfoides organizadas como parte do sistema imune associada a mucosas ou ao intestino;
- Linfonodos: sistema de vasos que coletam o fluido extracelular dos tecidos, fazendo-o retornar ao sangue. Este fluido celular é produzido por filtração do sangue e é denominado de linfa. É também o ambiente onde ocorre a resposta imune adaptativa;
- Apêndice e Placas de Peyer: linfonodos especializados em células imunológicas destinadas a proteção do sistema gastrointestinal;
- Baço: maior órgão linfóide secundário. É o único órgão linfóide entreposto na corrente sanguínea constituído no local onde os linfócitos combatem os organismos que invadem a corrente sanguínea. Contém a polpa vermelha responsável pela remoção das células sanguíneas envelhecidas, e a polpa branca de células linfoides responde aos antígenos levados ao baço pelo sangue;
- Vasos linfáticos: rede de canais que transporta a linfa para o sangue e órgãos linfoides. Os vasos aferentes drenam o líquido dos tecidos e carregam as células portadoras dos antígenos dos locais de infecção para os órgãos linfáticos (linfonodos). Nos linfonodos, as células apresentam o antígeno aos linfócitos que estão recirculando, os quais elas ajudam a ativar. Os linfócitos específicos passam pelo processo de proliferação e diferenciação, eles deixam os linfonodos como células efetoras através dos vasos linfáticos.

A1.1.1 BARREIRAS DO SISTEMA IMUNOLÓGICO BIOLÓGICO

O sistema imunológico biológico possui uma arquitetura composta por múltiplas camadas, conforme ilustrado na figura 20.

Figura 20 – Barreiras do sistema imunológico biológico



Fonte: Adaptado de De Castro (2001)

A anatomia distribuída em níveis possibilita que os linfócitos detectores estejam distribuídos pelo organismo, facilitando a identificação dos agentes infecciosos (HOFMEYR; FORREST, 1999). Os níveis ilustrados na figura 20 são descritos a seguir (DE CASTRO, 2001):

- Barreiras físicas: a pele funciona como uma espécie de escudo protetor contra os invasores infecciosos ou não infecciosos;
- Barreiras bioquímicas: fluidos como saliva, suor, lágrimas, ácidos estomacais e temperatura corporal podem proporcionar condições impróprias para a sobrevivência de agentes infecciosos no organismo;
- Sistema imune inato: é a primeira linha de defesa contra os agentes infecciosos comuns. As células do sistema imune inato são capazes de digerir materiais biológicos e moléculas, limpando o organismo, inclusive de agentes infecciosos neutralizados;
- Sistema imune adaptativo: é a segunda linha de defesa contra os agentes infecciosos, sendo responsável pela imunidade adquirida durante a vida do organismo. Quando o sistema é exposto aos agentes infecciosos o sistema imune adaptativo deve agir tomando decisões para gerar uma resposta e neutralizar os agentes desconhecidos.

A1.2 – SISTEMA IMUNOLÓGICO INATO E ADAPTATIVO

O sistema imunológico biológico é o mecanismo de defesa do organismo contra os agentes infecciosos com capacidade de realizar dois tipos de respostas, uma rápida e efetiva e outra eficaz, porém lenta, e duradoura. Estes dois tipos de respostas são efetuadas pelo sistema imunológico inato e adaptativo (DE CASTRO; TIMMIS, 2002). O sistema inato compreende a genética herdada ao nascer e é a primeira linha de defesa após a entrada do agente infeccioso no organismo. Suas características permitem resposta rápida, que proporciona ao sistema adaptativo tempo para gerar sua resposta (MACHADO, 2005).

O sistema adaptativo aprende a reconhecer os agentes infecciosos e armazena o conhecimento em memória para futuras respostas. O aprendizado ocorre no primeiro contato com o agente externo (HOFMEYR; FORREST, 1999). O sistema imune adaptativo é realizado pelos linfócitos, ou seja, pelas células B e T. Todo o processo imunológico adaptativo está relacionado com a detecção, geração de anticorpos e incorporação do conhecimento (MACHADO, 2005). As crianças recém-nascidas possuem respostas imunológicas fracas, entretanto são protegidas nos primeiros meses de vida pela imunidade inata recebida da mãe. Essa imunidade pode ser reforçada por meio de vacinas e amamentação (MACHADO, 2005). As vacinas são compostas de agentes infecciosos mortos, modificados que não produzem infecção ou por vírus vivos enfraquecidos ou atenuados.

A1.3 PRÍNCÍPIO DE SELEÇÃO CLONAL

O linfócito é ativado no organismo, mediante o reconhecimento do agente infeccioso. O mesmo gera clones a fim de criar células efetoras para neutralizar o agente infeccioso. O princípio da seleção clonal é a produção de células efetoras em quantidades suficientes para combater os agentes infecciosos no organismo (DE CASTRO, 2001).

O sistema imunológico biológico possui células efetoras de dois tipos: células de ataque (plasmócitos) e células de memória (memória imunológica). As células efetoras representam os linfócitos ativados após o processo de clonagem.


O princípio de seleção clonal está associado às características da resposta imune adaptativa contra o agente infeccioso. Este princípio estabelece que apenas a célula reconhece o agente infeccioso e se prolifera pelo processo de clonagem, transformando em célula efetora capaz de distribuir anticorpos pelo organismo. Estas células são chamadas de plasmócitos (DE CASTRO, 2001).

Os linfócitos B proliferam e se diferenciam em plasmócitos ou células B de memória. As células de memória circulam pelo sangue, vasos linfáticos e tecidos, com o objetivo de reconhecer o agente infeccioso que quando re-expostas, diferenciam em plasmócitos capazes de produzir anticorpos iguais aos que estimularam a resposta primária (DE CASTRO, 2001).

A seleção clonal ocorre com a ativação dos linfócitos B ou com os linfócitos T. As células T não geram anticorpos, porém estimulam as células B a executarem o processo de seleção e clonagem.

A figura 21 ilustra o funcionamento do princípio de seleção clonal.

Figura 21. Funcionamento do princípio de seleção clonal.



Fonte: Adaptado de De Castro (2001)

As principais características da teoria da seleção clonal são (DE CASTRO, 2001; MACHADO, 2005):

- Eliminação ou inativação de novos linfócitos diferenciados capazes de reagir com antígenos próprios;

- A interação da molécula estranha com o receptor de linfócito;
- Restrição fenotípica do padrão para cada célula diferenciada e retenção do padrão pelos descendentes clonais;
- Geração de variações genéticas aleatórias, através do mecanismo de hipermutação somática, expressas sob a forma de diferentes anticorpos.

A1.4 MATURAÇÃO POR AFINIDADE

A resposta imunológica auxiliada pelas células T, e pelo repertório das células B ativadas por antígenos é baseada pelos mecanismos: hipermutação somática e edição de receptores (DE CASTRO, 2001). Somente os descendentes com alta afinidade antigênica são selecionados para fazer parte do conjunto de células de memória.

Os anticorpos presentes na resposta de memória (resposta secundária ou adaptativa) maiores afinidades do que os anticorpos das respostas primárias (resposta inata). Este fenômeno pertence às respostas dependentes das células T, sendo chamado de maturação por afinidade.

O processo de maturação é realizado pela expansão clonal dos linfócitos B com o objetivo de ocasionar mudança nas células visando provocar o aumento da afinidade do anticorpo. As células descendentes com altas afinidades antigênicas são selecionadas para fazerem parte do conjunto de memória. As células com baixa afinidade são eliminadas de forma a não contribuir com o conjunto de memória (DE CASTRO, 2001).