

DIAGNÓSTICO DE FALHAS EM ESTRUTURAS ISOTRÓPICAS UTILIZANDO SISTEMAS IMUNOLÓGICOS ARTIFICIAIS

Daniela Cabral de Oliveira, danielacaboliveira@gmail.com¹

Fábio Roberto Chavarette, fabioch@mat.feis.unesp.br²

Mara Lúcia Martins Lopes, mara@mat.feis.unesp.br³

¹Universidade Estadual São Paulo (Unesp), Av. Brasil Sul, 56 – Centro, Ilha Solteira – SP, 15385-000

²Universidade Estadual São Paulo Unesp), Av. Brasil Sul, 56 – Centro, Ilha Solteira – SP, 15385-000

³Universidade Estadual São Paulo (Unesp), Av. Brasil Sul, 56 – Centro, Ilha Solteira – SP, 15385-000

Resumo: Este trabalho apresenta uma análise do monitoramento da integridade de estruturas de um material isotrópico (placa de alumínio) realizada através dos sistemas imunológicos artificiais, mais precisamente o algoritmo de seleção negativa. Os dados experimentais foram cedidos por Rosa (2016). Os transdutores piezelétricos (PZTs) foram colados na placa de alumínio com dimensões de 500 x 500 x 2 mm, que atuam como sensores e atuadores ao mesmo tempo. Para manipulação dos dados foram analisados os sinais definindo o primeiro pacote do sinal (first packet), considerando apenas o intervalo de tempo igual ao da força de excitação. Neste caso, não há interferência dos sinais refletidos nas bordas da estrutura. Os sinais são obtidos na situação normal (baseline) e, posteriormente na situação com dano. Foi implementado o algoritmo de seleção negativa que se baseia no processo de reconhecimento de padrões exercido pelo sistema imunológico biológico, sendo elaborado como um modelo computacional.

Palavras-chave: Monitoramento de Integridade de Estrutural, Placa de Alumínio, Sistemas Imunológicos Artificiais, Algoritmo de Seleção Negativa.

1. INTRODUÇÃO

O monitoramento de integridade estrutural (SHM, do inglês Structural Health Monitoring) consiste em detectar falhas em estados iniciais, intervir na propagação e, impedir a ocorrência de catástrofes e/ou acidentes que levam à parada ou à danificação da estrutura (Lima, 2014).

O SHM envolve a observação do sistema estrutural ao longo do tempo através de: medições dinâmicas amostradas periodicamente por meio de sensores, extração das características sensíveis a falha e, finalmente, análise estatística das características para a determinação do estado atual do sistema relativo à integridade (Farrar et al., 2005).

As fases para a implementação do SHM são (Louzada, 2013):

- Aquisição dos dados ou sinais transmitidos pela estrutura a ser monitorada (dados obtidos na forma bruta);
- Transmissão dos dados para o sistema proposto que terá a incumbência de realizar a interpretação;
- Utilização das técnicas de SHM, tais como, NDE (*Nondestructive Evaluation*), sistemas inteligentes, entre outros, para gerar a saída final do sistema.

As técnicas tradicionais possuem um bom aparato instrumental e são bem formuladas para avaliação da integridade estrutural, no entanto, as mesmas não conseguem satisfazer necessidades crescentes da indústria, ainda mais, quando as estruturas estão em movimento (Franco, 2009). 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. No caso das aeronaves na indústria aeronáutica faz-se necessário empregar ferramentas em tempo real.

Sendo assim, o projeto tem como objetivo apresentar uma metodologia para o desenvolvimento de SHM baseado em técnicas de computação inteligente, com intuito de detectar falhas estruturais em aeronave utilizando o algoritmo de sistemas imunológicos artificiais com seleção negativa, que conta com uma das etapas *on-line*.

O Algoritmo de Seleção Negativa (ASN) foi proposto por (Forrest et al., 1994), para detecção de mudanças em estados de sistemas computacionais. Esta técnica se 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 algoritmo é executado em duas fases denominadas sensoriamento e monitoramento (De Castro, 2001).

No sensoriamento é necessário definir o conjunto de cadeias próprias (S) que se deseja proteger, gerar as cadeias aleatórias e avaliar a afinidade (*match*) entre cada uma delas. Caso a afinidade seja superior ao limiar estipulado, rejeitar a cadeia. Caso contrário, armazene-a no conjunto de detectores (R). No monitoramento é dado o

conjunto de cadeias que se deseja proteger (cadeias protegidas) e avalia 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 (De Castro, 2001). A Figura 1 mostra o fluxograma do algoritmo de seleção negativa nas fases de sensoriamento e monitoramento.




Figura 1 – Fluxograma das fases de (a) sensoriamento e (b) monitoramento do Algoritmo de Seleção Negativa 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). Com finalidade de gerar um conjunto de padrões detectores (R), que possuam a capacidade de identificar o padrão não-próprio, na fase de monitoramento do ASN. A partir da leitura dos dados, escolhem-se cadeias aleatórias e verifica a afinidade entre as cadeias e o conjunto de cadeias próprias (S) comparando-as. Caso a afinidade seja superior ao limiar pré-estipulado (taxa de afinidade), está cadeia é rejeitada. Caso contrário, está cadeia é aceita no conjunto de detectores (R), e será utilizada no processo de classificação durante o monitoramento dos dados. Os detectores são capazes de detectar qualquer elemento não-próprio, uma modificação ou erro nos dados que se deseja monitorar (Lima, et al., 2013).

Na fase de monitoramento os dados são monitorados visando identificar mudanças no comportamento do banco de dados e classificar estas mudanças utilizando o conjunto de detectores criados na etapa de sensoriamento. As cadeias protegidas (S) são comparadas com o conjunto de detectores (R) e avalia-se a afinidade. Se a afinidade entre as cadeias for superior a um limiar pré-estabelecido, o elemento não-próprio é identificado e classificado (De Castro, 2001; Timmis, 2000).

Para avaliação e comprovação da afinidade das cadeias (próprias e não-próprias) utiliza-se um critério conhecido como casamento. 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 definida como a taxa de afinidade (Bradley, Tyrrell, 2002).

A taxa de afinidade (TAf) representa o grau de semelhança necessário para que ocorrer o casamento entre as duas cadeias em análise. A taxa de afinidade é definida conforme a equação:

$$TAf = \left(\frac{An}{At} \right) * 100 \quad (1)$$

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).

No modelo proposto por Lima et al. (2013) há um desvio vinculado ao padrão detector com tolerância para mais e para menos, a qual é possível aceitar a combinação entre os padrões. Este desvio atua individualmente em cada posição i do vetor, permitindo avaliar o casamento ponto por ponto, conforme mostra a equação.

$$\underline{Ab}_i \leq Ag_i \leq \overline{Ab}_i \quad (2)$$

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 vetor estiver dentro do intervalo expresso na equação, pode considerar o casamento para esta posição, sendo possível quantificar a afinidade entre os padrões, analisando posição por posição. A medida de afinidade total utilizada para avaliar os padrões em análise é expressa pela equação conforme proposto por (Bradley, Tyrrell, 2002).

$$Af_T = \frac{\sum_{i=1}^L Pc}{L} * 100 \quad (3)$$

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.

Quando a Af_T é maior ou igual a TAf ocorre o casamento, e são consideradas semelhantes, ou seja, 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 detector não reconhece o padrão, portanto não existe casamento entre os sinais, ou seja, o sinal é classificado como uma anormalidade, ou seja, como falha estrutural. Este módulo retorna um diagnóstico dos sinais analisados em próprios (condição normal da estrutura) e não-próprios (estrutura apresentando a característica de falha).

2. PROCEDIMENTO EXPERIMENTAL

Para o desenvolvimento da metodologia proposta foi utilizado os dados manipulados por Oliveira (2017) que foram obtidos pelos dados experimentais de Rosa (2016). A Figura 2 mostra os equipamentos utilizados 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, 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 2 - (a) Foto dos materiais e equipamentos utilizados no experimento e (b) Ilustração dos materiais e equipamentos utilizados no experimento de Rosa (2016).

No experimento foi utilizado uma placa de alumínio com dimensões de 500 x 500 x 2mm, 9 transdutores de PZTs que cobrem a superfície da estrutura, sendo responsáveis pela geração e captação do sinal de resposta, como mostrado na Fig. 3. A sequência de medidas utiliza 1 PZT como atuador e os outros 8 como sensores. Existem 9 possibilidades de atuadores gerando 8 caminhos e consequentemente 72 caminhos.




Figura 3 - (a) Foto da placa utilizada no experimento e (b) Ilustração da placa mostrando posicionamento dos transdutores de Rosa (2016).

Na Figura 4, P_{48} significa que o atuador é o PZT4 e o sensor é o PZT8. De uma maneira geral P_{ij} , significa que o atuador está na posição i e o sensor na posição j . A Figura 4 mostra o posicionamento da falha.




Figura 4 - Ilustração do posicionamento da falha de Rosa (2016).

Os sinais foram obtidos nas frequências de 200, 250 e 300 kHz para 5 diferentes situações de falhas, porém os dados utilizados nos testes foram os sinais obtidos para uma situação de falha na frequência de 250 kHz. A Figura 5 mostra o gráfico do sinal emitido pelo atuador 4 e recebido pelo sensor 8 para frequência de 250Khz. Este caminho foi escolhido para mostrar a influência da falha. O sinal vermelho representa o sinal *baseline* e o sinal azul representa o sinal com falha.




Figura 5 - Sinal emitido pelo atuador 4 para 250 kHz e sinal captado no sensor 8 de Oliveira (2017).

O presente trabalho utilizou os dados obtidos por Oliveira (2017). Para manipulação dos dados foram analisados os sinais definindo o primeiro pacote do sinal (first packet), isto é, considera-se 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 falha (*baseline*) e, posteriormente na situação de falha.

O primeiro pacote, ou seja, 81 pontos de um sinal senoidal janelado com 5 ciclos foi definido devido as reflexões que o mesmo pode sofrer na estrutura e a falha, o restante do sinal, além das reflexões, tem os outros modos de onda que chegam ao sensor e, assim, dificultam a análise. Seguidamente, foram gerados gráficos que mostram claramente quando existem diferenças entre o *baseline* e o sinal atual (ou sinal a ser analisado) captado pelo sensor, conforme mostrado na Figura 6.




Figura 6 - Sinal emitido pelo atuador 4 para 250 kHz e sinal captado no sensor 8 de Oliveira (2017).

3. METODOLOGIA PROPOSTA

Foi desenvolvido um Sistema de Análise da Integridade Estrutural de um material isotrópico (SAIEMI) baseado em Sistema Imunes Artificiais, mais precisamente o Algoritmo de Seleção Negativa. O SAIEMI é constituído de três etapas:

1. Primeira etapa: Esta etapa contempla a aquisição dos dados o qual são obtidos pelo aparato experimental na realização do experimento descrito na seção 2. Os dados representam sinais de resposta em frequência que foram utilizados no Algoritmo de Seleção Negativa;
2. Segunda etapa: O módulo de sensoriamento do Algoritmo de Seleção Negativa é iniciado gerando o conjunto de detectores de falhas que foi utilizado na fase de monitoramento. O processo de geração do conjunto de detectores é realizado de forma *off-line*;
3. Terceira etapa: O módulo de monitoramento do Algoritmo de Seleção Negativa teve por objetivo verificar através da avaliação de afinidade com o conjunto de detectores próprios (sinais *baseline*) se o sinal a ser analisado é um sinal próprio. Este procedimento é realizado através da discriminação do próprio/não próprio do Algoritmo de Seleção Negativa. Caso o sinal analisado seja identificado como um sinal próprio este é então classificado como um sinal normal, ou seja, estrutura normal. Caso contrário, o sinal será classificado como não próprio indicando uma falha na estrutura. Esta etapa é realizada de forma *on-line*.

4. APLICAÇÃO E RESULTADOS

No experimento foi utilizado uma placa de alumínio com dimensões de 500 x 500 x 2mm, 9 transdutores de PZTs que cobrem a superfície da estrutura, como mostrado na Figura 3. A sequência de medidas utiliza 1 PZT como atuador e os outros 8 como sensores. Existem 9 possibilidades de atuadores gerando 8 sinais e consequentemente 72 sinais. O banco de dados utilizado foi de 72 sinais *baseline* e 72 sinais com falha. Os sinais analisados consideram apenas o primeiro pacote (*first packet*), pois é a parte do sinal que melhor representa as alterações devido a falha. Este estudo de monitoramento estrutural visa detectar falhas em estruturas aeronáuticas em tempo real.

Para efetuar as fases de sensoriamento e monitoramento foram utilizados os dados obtidos do experimento para uma falha que correspondem a 144 sinais, sendo que 72 sinais são ditos próprios (sinais normais - *baseline*) e 72 são não-próprios (sinais com falha) e cada sinal foi representado por 81 pontos.

Neste trabalho foi utilizado um método para realizar o monitoramento de integridade estrutural, baseado em técnicas de computação inteligente sendo os sistemas imunológicos artificiais, precisamente, o algoritmo de seleção negativa.

Foram realizados diferentes testes (três testes) com a finalidade de avaliar a metodologia proposta no processo de análise e monitoramento da integridade estrutural verificando a eficiência do sistema em relação as diferentes configurações do conjunto de detectores do algoritmo de seleção negativa, que são as informações que representam o conhecimento do sistema. Para melhor reconhecimento dos sinais por parte do algoritmo de seleção negativa nos testes foram adotados a taxa de afinidade com valores de 20%, 22,2% e 34,4%, respectivamente, desvio padrão de 3% e população entre 20% a 30%. Os testes realizados estão descritos na Tab. 1.

Tabela 1. Descrição dos Testes Realizados

Testes	Número Total de Sinais	Sinais Próprios	Sinais Não-Próprios	Tempo de Processamento
1	144	15	60	0,743
2	144	20	70	0,461
3	144	21	40	0,402

Para o problema proposto o algoritmo de seleção negativa obteve um acerto de 100%, sendo que a fase de treinamento é a que demanda maior tempo computacional, já a fase de monitoramento é realizada rapidamente, com tempo inferior a 0,402 milésimos de segundo, o que facilita sua aplicação em tempo real. Deve-se destacar que os parâmetros utilizados nos algoritmos propostos precisam ser cuidadosamente calibrados, pois um parâmetro mal escolhido pode prejudicar o desempenho do sistema.

As classificações obtidas através do algoritmo de seleção negativa estão ilustrados na Tab. 2.

Tabela 2. Taxa de acertos obtidos nos testes realizados.

Testes	Acerto (%)
1	89,33
2	91,11
3	100,00

Pode-se observar através da Tab. 2 que o sistema de análise da integridade estrutural realizada em um material isotrópico (placa de alumínio) apresenta um bom desempenho (índice de acerto igual a 100% na melhor configuração) e que a quantidade de detectores influencia diretamente no processo de diagnóstico da falha, ou seja, mais eficiente é o processo do algoritmo de ASN. Desta forma, sugere-se utilizar 30% das informações do conjunto de dados para gerar o conjunto de detectores, visando proporcionar uma melhor robustez do sistema. Quanto mais conhecimento disponível, mais eficiente é o processo de diagnóstico do SHM.

Por fim, destaca-se que o SHM proporciona a aplicação em tempo real, já que as decisões precisam ser tomadas em tempo hábil para evitar tragédias e catástrofes.

5. CONCLUSÃO

Neste trabalho, foi possível obter um acerto mínimo de 89,33% e máximo de 100%. Nota-se que a quantidade de detectores influencia diretamente no processo de diagnóstico de falhas, conforme parâmetros estabelecidos por (Lima, 2014). Logo, é possível concluir que o algoritmo de seleção negativa expressa precisão e confiabilidade quando atendido os parâmetros de desvio menor que 10% e uma quantidade de detectores obtidos com 30% dos dados.

Pode-se afirmar através dos resultados obtidos dos testes realizados (Tab. 2) que quanto mais conhecimento o algoritmo de seleção negativa obtém em sua fase de censuriamento, mais eficiente se torna o processo de reconhecimento e classificação do algoritmo.

Desta forma, conclui-se que o algoritmo proposto neste trabalho baseado em técnicas de computação inteligentes são eficientes, confiáveis, robustos e precisos para realizar o monitoramento de integridade de estruturas e que o trabalho contribui para a área de pesquisa em SHM, apresentando uma nova abordagem para realizar o monitoramento de estruturas utilizando sistemas imunológicos artificiais.

6. REFERÊNCIAS

- Bradley, D. W.; Tyrell, A. M. Immunotronics - novel finite-state-machine architectures with built-in self-test using self-nonsself differentiation. IEEE Transactions on Evolutionary Computation, New York, v. 6, p. 227-238, 2002.
- De Castro, L. N. Engenharia imunológica: desenvolvimento e aplicação de ferramentas computacionais inspiradas em sistemas imunológicos artificiais. 2001.
- 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.
- Forrest, S. A.; Perelson, A. L.; Cherukuri, R. Self-nonsself discrimination in a computer. In: Proceedings of the IEEE Symposium on research in security and privacy, 1994, Oakland. Proceedings of the Oakland: IEEE, 1994. p. 202-212.
- 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, s/n, p.283-289. 2013.
- Lima, F. P. A., Monitoramento e Identificação de Falhas em Estruturas Aeronáuticas e Mecânicas Utilizando Técnicas de Computação Inteligente, 2014, 16, 42.
- 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.
- Oliveira, D. C, Localização de danos em estruturas isotrópicas com a utilização de aprendizado de máquina. 2017. 125 f.
- Rosa, V. A. M; Localização de danos em estruturas anisotrópicas com a utilização de ondas guiadas. 2016. 81 f.
- Timmis, J. I. Artificial immune systems: a novel data analysis technique inspired by the immune network theory. Tese (Doctor of Philosophy of the University of Wales) - Department of Computer Science, University of Wales, Aberystwyth, 2000.

7. RESPONSABILIDADE AUTORAL

“Os autores são os únicos responsáveis pelo conteúdo deste trabalho”.

DIAGNOSIS OF FAULTS IN ISOTROPIC STRUCTURES USING ARTIFICIAL IMMUNOLOGICAL SYSTEMS

Daniela Cabral de Oliveira, danielacaboliveira@gmail.com¹

Fábio Roberto Chavarette, fabioch@mat.feis.unesp.br²

Mara Lúcia Martins Lopes, mara@mat.feis.unesp.br³

¹São Paulo State University (Unesp), Av. Brasil Sul, 56 – Center, Ilha Solteira – SP, 15385-000

²São Paulo State University (Unesp), Av. Brasil Sul, 56 – Center, Ilha Solteira – SP, 15385-000

³São Paulo State University (Unesp), Av. Brasil Sul, 56 – Center, Ilha Solteira – SP, 15385-000

Abstract. *This work presents the structural health monitoring analysis of an isotropic material (aluminium plate) performed through a artificial immune system, more precisely, the negative selection algorithm. The experimental data were provided by Rosa (2016). Piezoelectric transducers were glued on the aluminium plate whose dimensions were 500x500x2mm, which work as sensors and actuators at the same time. To manipulate the data the signals were analysed by defining their first packet, considering only time interval equal to the excitation force. In this case, there is not interference of the reflected signals on the edges of the structure. The signals are obtained in the normal situation (baseline) and, afterwards, in the damage situation. The negative selection algorithm was implemented which is based on the process of pattern recognition performed by the biological immune system, and is modeled computationally.*

Keywords: *Structural Health Monitoring, Aluminium Plate, Artificial Immune System, Negative Selection Algorithm.*