

Monitoramento da Integridade de Estruturas Aeronáuticas Utilizando um Método Inteligente Baseado em Sistemas Imunológicos Artificiais

Fernando P. A. Lima[†] **Adriano. S. Souza**[†] **Simone. S. F. Souza**[♦]
Mara. L. M. Lopes^{*} **Fábio R. Chavarette**[†]

[†]Departamento de Engenharia Mecânica, Faculdade de Engenharia de Ilha Solteira (FEIS)

^{*}Departamento de Matemática, Faculdade de Engenharia de Ilha Solteira (FEIS)

[♦]Departamento de Engenharia Elétrica, Faculdade de Engenharia de Ilha Solteira (FEIS)

Universidade Estadual Paulista “Júlio de Mesquita Filho” (UNESP), Ilha Solteira, SP, BRASIL

E-mails: engfernandoparra@gmail.com, eng.adrianosouza@gmail.com,

simonefrutuoso.mat@gmail.com, mara@mat.feis.unesp.br, fabioch@mat.feis.unesp.br

Palavras-chaves: *Monitoramento da Integridade, Estruturas Aeronáuticas, Sistemas Imunológicos Artificiais, Algoritmo de Seleção Negativa.*

Resumo: *Neste artigo apresenta-se um método inteligente baseado nos sistemas imunológicos artificiais para monitoramento da integridade de estruturas aeronáuticas. Desta forma, tomando-se como base um processo biológico do sistema imunológico, utiliza-se o Algoritmo de Seleção Negativa para identificar e caracterizar amostras de falhas estruturais. A principal aplicação deste método é auxiliar profissionais a inspecionar estruturas aeronáuticas, detectar e caracterizar falhas, bem como a tomada de decisões, visando evitar catástrofes. Para avaliar este método, foi realizada a modelagem e simulação de sinais a partir de um modelo genérico utilizando uma viga de alumínio. Os resultados obtidos pelo método são excelentes, apresentando robustez e precisão.*

1 Introdução

Há alguns anos a linha de pesquisa de monitoramento da integridade de estruturas aeronáuticas cresceu se tornando muito importante do ponto de vista econômico e principalmente de segurança. De uma forma genérica, um Sistema de Monitoramento da Integridade de Estruturas (SMIE) deve ser capaz de executar tarefas como: aquisição e processamento de dados, validação e análise, de forma a identificar e interpretar mudanças adversas em uma estrutura, visando facilitar tomada de decisões e garantir segurança [8].

As falhas estruturais podem ocorrer devido a diversos fatores tais como: desgaste de um componente, afrouxamento de uniões aparafusadas, trincas ou mesmo a combinação destes elementos. Independente da origem, na grande maioria dos casos, falha estrutural provoca uma sensível variação dos parâmetros espaciais da estrutura tais como: redução da rigidez estrutural, ligeira redução da massa e um aumento do amortecimento, o que leva a uma mudança do comportamento dinâmico da estrutura. Assim, a variação dos parâmetros espaciais afeta os principais parâmetros dinâmicos, funções de respostas, frequências de ressonância, razão de amortecimento e modos próprios da estrutura [13].

Toda estrutura antes de ser colocada em uso geralmente passa por uma avaliação e testes de integridade. Neste caso uma avaliação não-destrutiva (NDE) é realizada com o objetivo de estimar o grau de segurança e confiabilidade da estrutura. As tradicionais técnicas de avaliação NDE (inspeção ultrassônica, radiografia-X, testes de emissão acústica, etc.) podem possuir um bom aparato instrumental e serem bem formuladas para diversas aplicações, no entanto, estas técnicas não podem satisfazer necessidades crescentes no contexto do monitoramento da integridade de estruturas, quando as mesmas estão em uso [6].

Desta forma, os SMIE veem sofrendo uma evolução natural, devido ao avanço de tecnologias de sensores, materiais inteligentes, processamento de dados e sinais, bem como a crescente demanda de estruturas que necessitem de avaliações em tempo real, como aviões.

Neste contexto, a utilização de sensores inteligentes em conjunto com técnicas inteligentes para análise e tomada de decisões, se tornam possíveis alternativas para os SMIE.

Na literatura existem várias propostas de trabalhos utilizando materiais e sistemas inteligentes em SMIE, os quais apresentam bom desempenho e precisão. Na sequência apresentam-se os trabalhos mais relevantes.

Em [9] apresentaram a aplicação de um algoritmo genético em conjunto com uma rede neural para detecção e localização de falhas em um modelo numérico de uma viga. No trabalho [13] os autores utilizaram uma rede multicamadas com treinamento via *backpropagation* para predição de falhas em vigas CFRP (reforçadas com fibra de carbono). Em [7] utilizou-se o método da impedância eletromecânica para monitorar estruturas aeroespaciais com sensores piezelétricos ativos acoplados. No artigo de [12] os autores combinaram a técnica de impedância elétrica com um algoritmo PSO (*Particle Swarm Optimization*) para diagnosticar falhas. Em [2] propõe-se um sistema *fuzzy* para detecção de falhas estruturais usando curvaturas das formas modais. Em [14] foi proposto uma algoritmo genético multinodal para diagnosticar danos em uma ponte de treliça de aço.

Neste artigo, apresenta-se um SMIE baseado nos sistemas imunológicos artificiais para monitorar a integridade de estruturas aeronáuticas. A partir da aquisição e processamento dos sinais, aplica-se o algoritmo de seleção negativa (ASN) [5] para identificar e caracterizar as falhas. Para avaliar este método, utilizou-se uma base de dados de sinais simulados a partir de um modelo numérico de uma viga de alumínio, que neste caso representa uma estrutura aeronáutica. A viga foi modelada através da técnica de elementos finitos e simulada em Matlab [11]. Neste trabalho escolheu-se por empregar os sistemas imunológicos artificiais (SIA) devido as suas características naturais de aprendizagem e reconhecimento de padrões e por apresentarem bom desempenho e eficiência em outros tipos de problemas, conforme destacado em [10].

Este artigo está organizado da seguinte forma: A descrição do algoritmo de seleção negativa (ASN) está na seção 2. Na seção 3 apresentam-se a modelagem e simulações realizadas. Na seção 4 apresenta-se a metodologia proposta. As aplicações e resultados são apresentados na seção 5 e por fim, a seção 6 apresenta a conclusão para este trabalho.

2 Algoritmo de Seleção Negativa

O algoritmo de seleção negativa (ASN) foi proposto por [6] para detecção de mudanças em estados de sistemas, e é baseado na seleção negativa de linfócitos T dentro do timo. Este processo trabalha com a discriminação de células próprias e não-próprias. O algoritmo é executado em duas fases, conforme ilustrado nos fluxogramas apresentados na Figura 1 [4]:

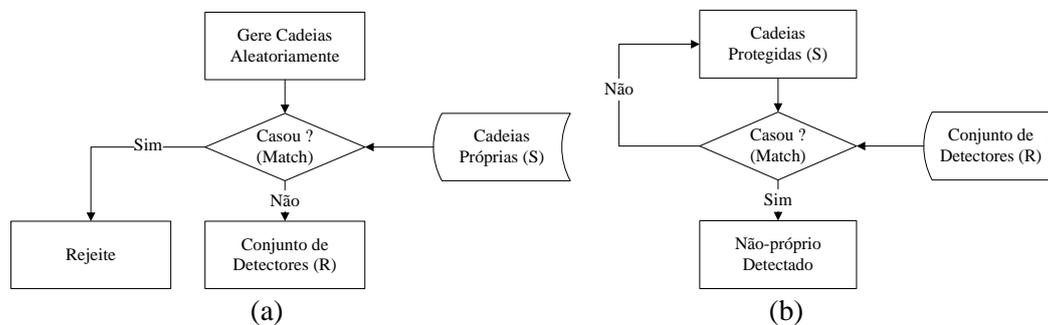


Figura 1: Fluxogramas do ASN.

A fase de sensoriamento do ASN consiste-se basicamente em gerar um conjunto de detectores. Os detectores são análogos às células tipo T, maturadas capazes de reconhecer agentes patogênicos. A fase de monitoramento consiste-se em monitorar um sistema, visando identificar uma mudança no comportamento do mesmo, e assim classificar esta mudança utilizando o conjunto de detectores criados na fase de sensoriamento [3].

3.1 Critério de Afinidade

Para avaliar a afinidade entre as cadeias e afirmar que são semelhantes, utiliza-se um critério conhecido como casamento. O casamento pode ser perfeito ou parcial [10]. Neste trabalho utiliza-se o casamento parcial. No casamento parcial, uma quantidade de pontos entre os padrões deve ter o mesmo valor para se confirmar o casamento, sendo a quantidade (taxa de afinidade) definida previamente. A taxa de afinidade representa o grau de semelhança necessário para ocorrer o casamento entre os dois padrões. A taxa de afinidade é definida através da seguinte relação [1]:

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

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).

A equação (1) propõe uma relação estatística entre todas as amostras do problema para o cálculo da taxa de afinidade. A expressão (2) representa a forma de quantificar a afinidade total entre os padrões [1]:

$$Af_T = \frac{\sum_{i=1}^L Vc}{L} * 100 \quad (2)$$

sendo:

Af_T : % de afinidade entre os padrões analisados;

L : quantidade total de variáveis;

Vc : variáveis casada;

$\sum_{i=1}^L Vc$: somatória (quantidade) de variáveis casadas.

Desta forma se Af_T for maior ou igual a TAf ocorre o casamento entre os dois padrões (são considerados semelhantes).

3 Modelagem e Simulação

Para avaliar a metodologia proposta neste trabalho, foi utilizado o método de elementos finitos para modelar uma viga de alumínio na condição engastada-livre discretizada com 10 elementos finitos com 2 graus de liberdade cada. As propriedades do material empregado são: módulo de elasticidade $E = 700$ GPa, densidade em massa $\gamma = 2710$ kg/m³. As dimensões são: 500 mm de comprimento, 25 mm de largura e 5 mm de espessura. A figura 2 ilustra a viga modelada.

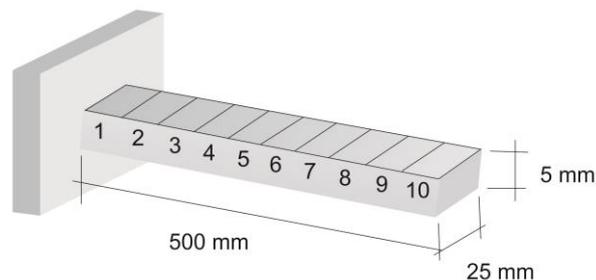


Figura 2: Viga simulada.

Através da viga modelada pela técnica de elementos finitos foram realizadas diversas simulações com diferentes porcentagens de desgastes e localizações das falhas. A base de dados

que foi gerada é constituída de sinais capturados por um acelerômetro fixado na viga. Em todas as simulações a viga foi excitada no 3º grau de liberdade e o sinal foi capturado no 19º grau de liberdade. Desta forma, foram simulados 1500 sinais na estrutura, sendo 400 sinais sem desgaste (condição base-line) e 1400 sinais com desgastes (falhas estruturais). Os sinais em falha foram simulados com níveis de desgaste de 1, 5, 10, 15, 20, 25, 30, 35, 40, 45 e 50% e para cada nível de desgaste a falha foi posicionada em todos os elementos finitos. Na Tabela 1 (a) apresenta-se a quantidade de simulações para cada nível de falha. Na Tabela 1 (b) apresenta-se a quantidade de simulações para cada localização da falha em cada um dos níveis de falha, isto é, para cada nível de falha foram gerados 10 simulações em cada localização.

Tabela 1 – Configurações das simulações.

Nível de Falha	Quantidade de simulações	Localização	Quantidade de simulações
0%	400	1	10
1%	100	2	10
5%	100	3	10
10%	100	4	10
15%	100	5	10
20%	100	6	10
25%	100	7	10
30%	100	8	10
35%	100	9	10
40%	100	10	10
45%	100		
50%	100		
Total	1500	Total	100

(a)

(b)

4 Metodologia Proposta

O sistema de monitoramento da integridade de estruturas aeronáuticas apresentado nesta seção é baseado nos sistemas imunológicos artificiais [4], em especial no algoritmo de seleção negativa [5]. O método proposto se divide em três módulos: aquisição de dados, sensoriamento e o monitoramento dos dados.

Na sequência apresenta-se o sistema de monitoramento da integridade estrutural.

4.1 Sistema de Monitoramento da Integridade Estrutural

O SMIE é composto por três módulos principais, sendo a aquisição de dados, o sensoriamento e o monitoramento.

O módulo de aquisição de dados é composto pelo aparato experimental para capturar os sinais na estrutura, como: sensores, atuadores, acelerômetros, etc.

O módulo de sensoriamento é realizado de forma *off-line* e serve para gerar o conjunto de detectores de falhas que será utilizado no monitoramento dos dados. Neste módulo o conjunto de detectores de falhas é composto por sinais dos diferentes níveis de falhas em diferentes posições da estrutura, que são escolhidos aleatoriamente.

O módulo de monitoramento é composto por duas etapas, sendo a detecção e a classificação da falha. Os sinais em falhas são detectados através da avaliação e verificação do casamento com o conjunto de detectores próprios (sinais base-line), assim realiza-se a detecção de sinais em falha. Na sequência, ao identificar um sinal não-próprio (sinal com falha) realiza-se uma avaliação deste sinal, comparando-o com o conjunto de detectores de falhas, desta forma, ao ocorrer um casamento, o sinal é classificado com a classe do detector acionado. O monitoramento dos sinais é realizado de forma *online*.

O fluxograma do funcionamento do SMIE é apresentado na figura 3.

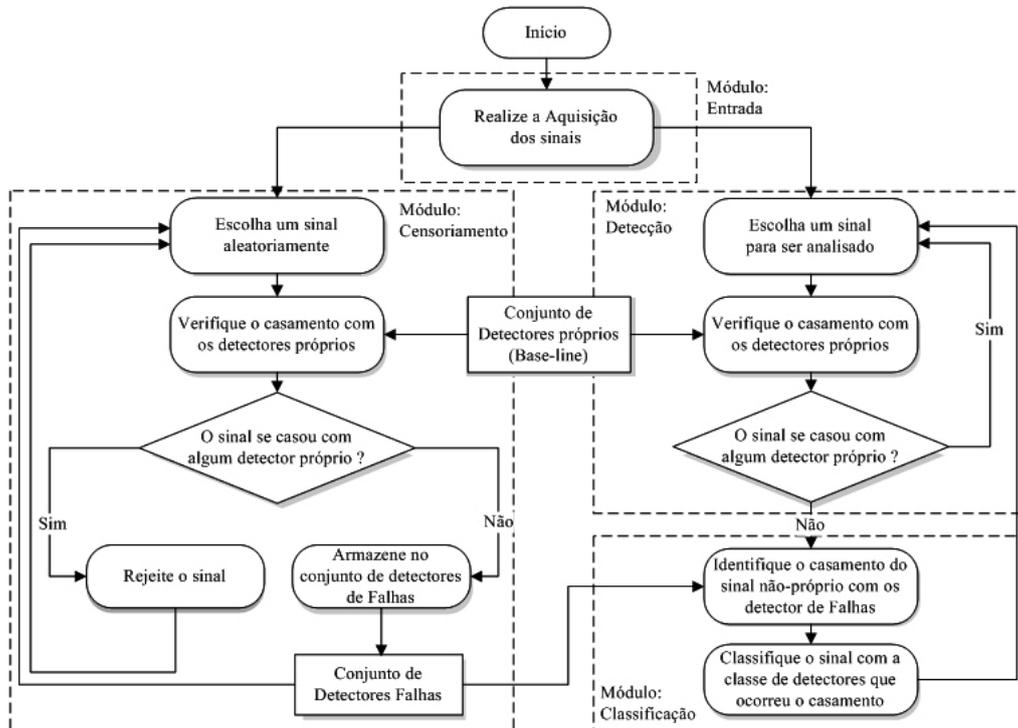


Figura 3: Fluxograma do SMIE.

5 Aplicações e Resultados

Nesta seção apresentam-se os resultados obtidos com a aplicação do SMIE na base de dados simulada. Todos os testes foram realizados utilizando um PC Intel Core 2 Duo 1.9 GHz, 2 GB de Memória RAM, e sistema operacional Windows 7 Ultimate 32 bits. O algoritmo foi desenvolvido em MATLAB [11].

Nos testes realizados o objetivo foi avaliar a metodologia proposta, verificando a eficiência, precisão e o tempo computacional em relação a diferentes configurações do conjunto de detectores. Utilizou-se como parâmetro uma taxa com um valor fixo de 73,33% (calculado com a equação (1)). Foram gerados três conjuntos de detectores (*I*, *II* e *III*) utilizando 10%, 20% e 30% das amostras de cada padrão, totalizando 110, 220 e 330 detectores respectivamente. Sendo que para cada configuração cada padrão foi definido 1, 2 e 3 detectores respectivamente. A base de dados simulada conta com 110 padrões de falhas.

Na Tabela 2 apresentam-se os resultados obtidos pelo sistema de monitoramento da integridade de estruturas quando aplicado aos dados da viga de alumínio.

Tabela 2 - Resultados obtidos pelo método.

Diagnóstico	Conjunto de detectores		
	<i>I</i>	<i>II</i>	<i>III</i>
Amostras testadas	1500	1500	1500
Classificações Corretas	1482	1495	1500
Classificações Erradas	18	5	0
Acerto (%)	98,88	99,66%	100%
Tempo (ms)	160,5	163,4	162,8

Cada teste foi executado 20 vezes a fim de garantir a veracidade dos resultados. Foi possível observar que o sistema de monitoramento da integridade de estruturas apresenta um bom desempenho (índice de acerto igual a 100% na melhor configuração), e que a quantidade de detectores influencia diretamente no reconhecimento das falhas. Sugere-se utilizar 30% das informações da base de dados para gerar o conjunto de detectores, visando proporcionar

robustez ao sistema. Quanto mais conhecimento, mais eficiente é o processo de reconhecimento e classificação.

6 Conclusão

O SMIE proposto neste artigo apresentou excelentes resultados, obtendo um índice de acerto de 100% para a melhor configuração do sistema. A fase de geração de detectores é a que demanda maior tempo computacional, no entanto é executada de forma off-line não acarretando prejuízo ao algoritmo. A fase de monitoramento do sistema, a partir da aquisição dos sinais, é realizada rapidamente, com tempo inferior a 170 milésimos de segundo, o que credencia o SMIE a ser uma ferramenta utilizada em tempo real. Desta forma, conclui-se que o SMIE proposto com base nos sistemas imunológicos artificiais é bastante eficiente, confiável, robusto e preciso para realizar o monitoramento da integridade de estruturas aeronáuticas.

Agradecimentos

Os autores agradecem a CAPES e CNPQ (proc. nº 301769/2012-5) pelo apoio financeiro de pesquisa.

Referências

- [1] D. W. Bradley and A. M. Tyrrell. Immunotronics - Novel Finite-State-Machine Architectures with Built-In Self-Test Using Self-Nonself Differentiation. *IEEE Transactions on Evolutionary Computation*. Vol. 6, pp. 227–238 (2002).
- [2] M. Chandrashekhar; R. Ganguli. Structural damage detection using modal curvature and fuzzy logic. *Structural Health Monitoring, USA*, v. 8, n. 4, p. 267-282, (2009).
- [3] D. Dasgupta. “Artificial Immune Systems and Their Applications”. Springer-Verlag New York, Inc., Secaucus, NJ, USA, 1998.
- [4] L. N. de Castro. “Engenharia Imunológica: Desenvolvimento e Aplicação de Ferramentas Computacionais Inspiradas em Sistemas Imunológicos Artificiais”. Tese de Doutorado, Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, Brasil, 2001.
- [5] S. Forrest; A. Perelson; L. Allen and R. Cherukuri. Self-Nonself Discrimination in a computer, *Proc. do IEEE Symposium on Research in Security and Privacy*, pp. 202-212 (1994).
- [6] V. R. Franco; D. D. Bueno; M. J. Brennan; A. A. Cavalini JR.; C. G. Gonzalez; V. Lopes JR. Experimental damage location in smart structures using Lamb waves approaches. In: *Brazilian Conference on Dynamics, Control and Their Applications – DINCON*. p. 1-4. (2009).
- [7] V. Giurgiutiu. Tuned lamb wave excitation and detection with piezoelectric wafer active sensors for structural health monitoring. *Journal of Intelligent Material Systems and Structures, USA*, v. 16, n. 4, p. 291–305, (2005).
- [8] S. R. Hall. The effective management and use of structural health data. In: *International Workshop on Structural Health Monitoring*, p. 265-275. (1999).
- [9] M. Krawczuk; W. Ostachowicz; G. Kawiecki. Detection of delaminations in cantilevered beams using soft computing methods. In: *Conference on System Identification and Structural Health Monitoring*, Madrid, p. 243–252 (2000).
- [10] F. P. A. Lima. “Analysis of Voltage Disturbances in Distribution Electrical Systems Based on Artificial Immune Systems”, Dissertation, University Estadual Paulista - UNESP, Ilha Solteira, March-2013, 169 p.
- [11] Matlab (2011). 7.8 Version, Mathworks Company.
- [12] A. Tebaldi; L. S. COELHO; V. LOPES JR. Detecção de falhas em estruturas inteligentes usando otimização por nuvem de partículas: fundamentos e estudo de casos. *Revista Controle & Automação, Brasil*, v.17, n. 3, p. 312–330, 2006.
- [13] S. Zheng; X. Wang; L. Liu. Damage detection in composite materials based upon the computational mechanics and neural networks. In: *European Workshop on Structural Health Monitoring, Munich*, p. 609–615 (2004).
- [14] F. L. Wang; T. H. T. Chan; D. P. Thambiratnam and A. C. C. Tan. Damage Diagnosis for Complex Steel Truss Bridges Using Multi-Layer Genetic Algorithm. *Journal of Civil structural Health Monitoring, Springer-Verlag*, p. 117–217, (2013).