

QUANTIFICAÇÃO DE DANO EM UMA PLACA DE MATERIAL COMPÓSITO COM VARIAÇÃO DE TEMPERATURA UTILIZANDO SISTEMA IMUNOLÓGICO ARTIFICIAL

Estevão Fuzaro de Almeida, estevao.fuzaro@unesp.br¹

Lucas Veronez Goulart Ferreira, lucas.goulart@unesp.br¹

Fábio Roberto Chavarette, fabio.chavarette@unesp.br²

¹Universidade Estadual Paulista “Júlio de Mesquita Filho”, Faculdade de Engenharia de Ilha Solteira, Departamento de Engenharia Mecânica, Av. Brasil Sul, 56 - Centro, CEP 15385-000, Ilha Solteira - SP, Brasil.

²Universidade Estadual Paulista “Júlio de Mesquita Filho”, Instituto de Química de Araraquara, Departamento de Engenharia, Física e Matemática, Rua Prof. Francisco Degni, 55 - Quitandinha, CEP 14800-060, Araraquara - SP, Brasil.

Resumo: O conceito de Monitoramento da Integridade Estrutural, mais conhecido como *Structural Health Monitoring* (SHM), é fundamentado nos processos de manutenção e de detecção de falhas, os quais são utilizados majoritariamente nos ambientes industriais e de construção civil. O SHM envolve a observação e análise de uma estrutura ou de um sistema mecânico, avaliando-se a resposta dinâmica obtida por medições periódicas, sendo posteriormente analisadas por processos estatísticos determinando-se, finalmente, a integridade do sistema. Tal tecnologia possibilita detectar falhas em estados iniciais, intervir na sua propagação e, conseqüentemente, impedir que catástrofes e/ou acidentes ocorram levando à parada ou danificação da estrutura. Dentro do ramo de SHM, um dos sistemas mais conceituados é o Sistema Imunológico Artificial (SIA) com base no Algoritmo de Seleção Negativa (ASN). O ASN é baseado na observação do funcionamento do sistema imunológico humano, mais especificamente na seleção negativa das células do tipo T que ocorre no timo, que é um órgão linfático. O processo de funcionamento é dividido em duas etapas: na etapa de Censuramento o SIA é treinado com os sinais coletados da estrutura em condição normal (sinais próprios), sendo estes armazenados em um banco de dados (baseline); já na etapa de Monitoramento, partindo-se de um sinal em situação estrutural de falha e, após verificadas as afinidades desses sinais com o banco de dados, o SIA realiza a separação dos sinais em próprios e não-próprios (não-falha e falha, respectivamente). Para este trabalho, estudou-se o dataset CONCEPT que consiste em uma placa laminada de material compósito sujeita à progressão gradativa de dano aliada às variações de temperatura, apresentando um total de 1100 sinais com dano e 700 sinais saudáveis em diversas temperaturas. Foram utilizados tanto o ASN quanto uma análise estatística utilizando o conceito de Distância Quadrática de Mahalanobis de modo a se comparar e obter um diagnóstico completo da integridade estrutural do sistema visando a detecção, a localização e a quantificação dos danos quando sujeitos à variação de temperatura. Como resultados, o SIA detectou danos em 1183 dos 1800 sinais (11,86% de falsos positivos e 0% de falsos negativos). O algoritmo detectou 100% dos casos com dano e apresentou um acerto global de 98,92%, com tempo de processamento de cerca de 30 segundos, demonstrando a robustez e eficácia do ASN.

Palavras-chave: Monitoramento da Integridade Estrutural, Sistema Imunológico Artificial, Algoritmo de Seleção Negativa, Materiais Compósitos, Distância Quadrática de Mahalanobis.

1. INTRODUÇÃO

Com o crescimento industrial, aumentou-se a quantidade de máquinas e equipamentos nos ambientes fabris; diante disso, houve um significativo aumento em investimentos focados em pesquisas de desenvolvimento tecnológico que visam a obtenção de métodos cada vez mais eficientes de monitoramento da integridade de estruturas, impedindo que danos ocorram, preservando a preservação de vidas e pela minimização de prejuízos econômicos. Tal tecnologia consiste em detectar falhas em estados iniciais, intervir na sua propagação e, conseqüentemente, impedir que catástrofes e/ou acidentes ocorram levando à parada ou danificação da estrutura. Essa área de pesquisa recebe o nome de Monitoramento da Integridade Estrutural, mais conhecida como *Structural Health Monitoring* (SHM) (Zinno *et al.*, 2019).

As estruturas geralmente passam por avaliações e testes de integridade estrutural antes de serem colocadas em uso. As avaliações são feitas em sua maioria de técnicas não-destrutivas (Garnier *et al.*, 2011), visando estimar o grau de

segurança e confiabilidade da estrutura. Alguns exemplos são: inspeção ultrassônica, raios-X, testes de emissão acústica, entre outros. Porém essas técnicas tradicionais não conseguem satisfazer necessidades crescentes da indústria, ainda mais quando o assunto são estruturas em movimento como as máquinas rotativas, que são muito comuns na indústria. Desta forma, os SHM's têm sofrido uma evolução natural devido ao avanço das tecnologias de sensores, materiais inteligentes, processamento de dados e sinais e, principalmente, devido à demanda em se realizar um monitoramento de forma contínua.

Um dos métodos propostos para SHM é composto pelos chamados Sistemas Imunológicos Artificiais (Dasgupta, 2012; Chavarette *et al.*, 2021; Outa *et al.*, 2022), que se baseiam em simular a ação do sistema imunológico humano, cujo princípio básico de funcionamento consiste em diferenciar células próprias do corpo das células intrusas e, a partir dessa diferenciação, tomar ações de combate aos possíveis invasores. É esse tipo de aplicação que é desejada ao se avaliar estruturas, ou seja, a partir do conhecimento prévio de uma situação saudável identificar a situação crítica, que *a priori* é desconhecida, e realizar ações de manutenção e/ou substituição dos componentes estruturais de forma rápida e eficiente.

2. OBJETIVOS

O presente trabalho possui como objetivo geral a implementação de uma abordagem SHM completa para detecção de danos e quantificação de informações orientadas por dados de impedância de uma placa de material compósito sofrendo variação de temperatura e aumento gradual de dano.

Este trabalho apresenta uma proposta de metodologia baseada em técnicas de Computação Inteligente, que estuda métodos de construção de programas capazes de exibir um comportamento inteligente na realização de tarefas complexas. Essas técnicas estão diretamente relacionadas às parcerias entre grupos de pesquisa da FEIS/UNESP.

A partir da integração entre um experimento envolvendo uma estrutura complexa, placa constituída de material compósito, e algoritmos baseados em Sistemas Imunológicos Artificiais, pretendeu-se desenvolver neste trabalho um classificador inteligente de modo a apoiar o processo de decisão visando uma maior confiabilidade no Monitoramento da Integridade Estrutural (SHM).

3. METODOLOGIA

Essa seção apresenta a metodologia que foi empregada no desenvolvimento do Sistema Imunológico Artificial pelo Algoritmo de Seleção Negativa utilizado para avaliar o *dataset* CONCEPT, apresentado em uma seção separada. Os algoritmos utilizados neste trabalho foram implementados em MATLAB®, utilizando-se majoritariamente a biblioteca de estatística e a de geração de números aleatórios.

3.1 Sistema Imunológico Artificial

Os chamados Sistemas Imunológicos Biológicos (SIB) são responsáveis por realizar a proteção dos organismos vivos e para isso necessitam diferenciar as células e moléculas do próprio corpo (do inglês *self*), benignas ao organismo; daquelas que não são próprias do organismo (do inglês *nonself*), malignas ao organismo. Matematicamente falando, os SIB são compostos por diversos parâmetros e funções que trabalham em sincronia de tal modo que o combate a corpos estranhos é realizado de forma sistemática e precisa a nível celular, realizando o que hoje é conhecido como reconhecimento de padrões (Forrest *et al.*, 1993; Dasgupta and Forrest, 1999; Lima, 2013).

Assim nascem os chamados Sistemas Imunológicos Artificiais (SIA), ferramentas computacionais completamente baseadas no funcionamento dos SIB. Aplicam-se os SIA em reconhecimento de padrões, análise de dados, detecção de falhas, aprendizagem de máquina e computação inteligente (de Castro, 2001; Merizio *et al.*, 2019). Algumas das propriedades biológicas do SIB que o SIA busca reproduzir e combinar de modo a trazer eficiência no processo desejado são: memória, organização, aprendizado, adaptação, robustez, tolerância e diversidade; de tal modo que não seja necessário executar o algoritmo do princípio para cada nova entrada de dados, o que levaria a uma perda de tempo de processamento, o qual é uma variável crucial quando se fala em monitoramento contínuo.

3.1.1 Algoritmo de Seleção Negativa

A base biológica do Algoritmo de Seleção Negativa (ASN), conforme apresentada por Forrest *et al.* (1994), é fundamentada na observação do funcionamento do sistema imunológico biológico, mais especificamente na seleção negativa das células do tipo T que ocorre no timo, um órgão do sistema linfático, as quais são responsáveis em categorizar as células como benignas ou malignas. O ASN é dividido em duas principais etapas: Censoriamento e Monitoramento.

Na etapa de Censoriamento ocorre a determinação de um conjunto de vetores próprios protegidos em paralelo através da geração/escolha de cadeias aleatórias. Esse conjunto recebe o nome de *baseline*, sendo composto de dados de referência para o algoritmo. Essa *baseline* é gerada após verificadas as afinidades entre as cadeias geradas/escolhidas aleatoriamente e os sinais próprios, rejeitando as cadeias que apresentarem afinidade inferior ao estipulado (Merizio *et al.*, 2020).

Já na etapa de Monitoramento, após criação da *baseline* e da definição de um intervalo de aceitação através de um desvio percentual, avalia-se a afinidade entre ela e um conjunto de detectores. Em um primeiro momento esse conjunto é composto exclusivamente pelas cadeias próprias, representantes de uma condição saudável do sistema. Posteriormente, um novo conjunto de detectores é gerado, sendo esse capaz de detectar também as cadeias não-próprias. Na sequência, escolhem-se cadeias aleatórias e assim os detectores passam a agir como as células do tipo T maturadas, seguindo a

seguinte metodologia: verificada a afinidade entre as cadeias aleatórias e o conjunto de cadeias próprias, estabelece-se que, se afinidade for inferior a um limiar pré-estabelecido, a cadeia é rejeitada, categorizando-a como não-própria; do contrário, armazena-se a cadeia no conjunto de detectores, e ela passará a auxiliar nas classificações durante o monitoramento dos dados (Lima, 2016). Análogo aos SIB, os detectores agem como anticorpos e os sinais desconhecidos como antígenos.

As Figs. 1a e 1b apresentam, respectivamente, os fluxogramas referentes ao Censoriamento e ao Monitoramento.




Figura 1: Fluxogramas do Algoritmo de Seleção Negativa.

O critério conhecido como “casamento”, apresentado na etapa de Monitoramento, pode ser perfeito ou parcial. Ele é utilizado de modo a avaliar a afinidade entre as cadeias e verificar se são iguais, semelhantes ou distintas.

Um casamento perfeito ocorre quando duas cadeias são perfeitamente iguais, ou seja, quando as cadeias possuem os mesmos valores em todas as suas posições; já o casamento parcial ocorre quando uma quantidade de posições previamente estabelecida entre as cadeias possuem o mesmo valor. Ao percentual de afinidade entre as cadeias dá-se o nome de taxa de afinidade, sendo uma quantidade que retrata o nível de correspondência entre duas cadeias analisadas (de Castro, 2001; Bradley and Tyrrell, 2002; Lima, 2013). A taxa de afinidade é calculada conforme a Eq. (1).

$$\mathcal{T}_a = \frac{\mathcal{A}_n}{\mathcal{A}_t} \times 100 \quad (1)$$

onde $\mathcal{T}_a$ é a taxa de afinidade dada em porcentagem, $\mathcal{A}_n$ é o número de cadeias próprias/normais e $\mathcal{A}_t$ é o número total de cadeias, abrangendo tanto as próprias quanto as não-próprias.

A taxa de afinidade para um casamento parcial possui um valor mínimo igual a 70%, ou seja, para fazer parte da *baseline* um sinal precisa ter no mínimo 70% de semelhança com os sinais próprios. Isso é aplicado com o intuito de contornar o problema de se ter poucos dados referentes a sinais normais, garantindo uma proporção mínima de 7 para 10 entre $\mathcal{A}_n$ e $\mathcal{A}_t$, trazendo maior confiabilidade ao algoritmo.

O processo de casamento entre duas cadeias é realizado comparando-se, individualmente, cada elemento i do vetor de um sinal desconhecido com cada elemento i de um vetor da *baseline*. Com o objetivo de dinamizar a análise realizada pelo algoritmo, e considerando que a probabilidade de dois sinais serem exatamente iguais é baixa, propõe-se aplicar um desvio percentual superior e inferior sobre o valor nominal criando uma “zona de confiança” (padrão detector), conforme trabalho de Lima (2013) e apresentado na Eq. (2).

$$\mathcal{A}_{bi} \leq \mathcal{A}_{gi} \leq \overline{\mathcal{A}_{bi}} \quad (2)$$

onde $\mathcal{A}_{gi}$ é o valor nominal da posição i do antígeno (padrão em análise), $\mathcal{A}_{bi}$ é o valor nominal da posição i menos o desvio adotado no anticorpo (padrão detector) e $\overline{\mathcal{A}_{bi}}$ é o valor nominal da posição i mais o desvio adotado no anticorpo (padrão detector).

Portanto, quando o valor de uma posição i do antígeno estiver dentro do intervalo da Eq. (2), considera-se que houve casamento naquela posição. Realiza-se então a verificação de afinidade entre duas cadeias: soma-se o número de

casamentos bem-sucedidos dividindo esse resultado pela dimensão total do vetor, obtendo-se um percentual de afinidade, como explicitado na Eq. (3) (Bradley and Tyrrell, 2002).

$$\mathcal{A}_f = \frac{\sum_{i=1}^n \mathcal{P}_c}{n} \times 100 \quad (3)$$

onde $\mathcal{A}_f$ é o percentual de afinidade entre os padrões analisados, n é a dimensão total do vetor e $\mathcal{P}_c$ é o número de casamentos bem-sucedidos.

Assim, quando $\mathcal{A}_f$ for maior ou igual a $\mathcal{T}_a$ consolida-se um casamento parcial entre as cadeias, ou seja, a cadeia é identificada como própria. Caso contrário, o anticorpo (detector) não reconhece o antígeno como sendo próprio, e o casamento não é consolidado, identificando a cadeia como não-própria.

Os únicos parâmetros do ASN que são manualmente inseridos pelo usuário são: a porcentagem de sinais saudáveis que serão utilizados para compor a *baseline*, separando-se os dados saudáveis em dados de treinamento e de teste; e o desvio percentual do padrão detector. Os demais parâmetros são dependentes das dimensões do *dataset* utilizado e foram devidamente tratados para que não precisem ser alterados manualmente.

3.2 Distância Quadrática de Mahalanobis

Em estatística, a Distância Quadrática de Mahalanobis (DQM) é uma medida de distância introduzida pelo matemático indiano Prasanta Chandra Mahalanobis (Mahalanobis, 1936). Ela é baseada nas correlações entre variáveis com os quais distintos padrões podem ser identificados e analisados. É uma estatística útil para determinar a similaridade entre uma amostra desconhecida e uma conhecida.

A DQM é uma generalização multi-dimensional da ideia de se medir quantos desvios padrões um ponto P está distante da média de uma distribuição D . Essa distância é zero quando P coincide com a média de D e ela cresce conforme P se distancia da média ao longo de cada eixo componente principal. Se cada um desses eixos for redimensionado de modo a ter variância unitária, a DQM corresponde simplesmente a distância Euclidiana em um espaço transformado. Assim, conclui-se que a DQM é uma distância adimensional, invariante à escala e leva em conta as correlações do *dataset*.

Formalmente, a distância de Mahalanobis entre um grupo de dados com média $\vec{\mu} = (\mu_1, \mu_2, \mu_3, \dots, \mu_n)^\top$ e matriz de covariância $\mathcal{S}$ para um vetor multivariável $\vec{x} = (x_1, x_2, x_3, \dots, x_n)^\top$ é definida pela Eq. (4).

$$\mathcal{D}_M(\vec{x}) = \sqrt{(\vec{x} - \vec{\mu})^\top \mathcal{S}^{-1} (\vec{x} - \vec{\mu})} \quad (4)$$

A distância de Mahalanobis pode também ser definida como uma medida de desigualdade entre dois vetores aleatórios $\vec{x}$ e $\vec{y}$ com a mesma distribuição e matriz de covariância $\mathcal{S}$, conforme Eq. (5).

$$d(\vec{x}, \vec{y}) = \sqrt{(\vec{x} - \vec{y})^\top \mathcal{S}^{-1} (\vec{x} - \vec{y})} \quad (5)$$

Se a matriz de covariância é a matriz identidade, a DQM coincide com a distância Euclidiana. Se a matriz de covariância é diagonal, então a medida de distância resultante é chamada distância euclidiana normalizada, conforme Eq. (6).

$$d(\vec{x}, \vec{y}) = \sqrt{\sum_{i=1}^n \frac{(x_i - y_i)^2}{s_i^2}} \quad (6)$$

onde s_i é o desvio-padrão de x_i e y_i no conjunto amostral.

3.2.1 Tipos de *threshold*

Neste trabalho foram utilizadas duas abordagens a fim de se definir um limiar (*threshold*) para a DQM, visando-se separar os sinais saudáveis dos sinais com dano. Estas abordagens são: Empírica e Regra da Faixa Interquartil (IQR).

A abordagem Empírica adota a maior DQM da *baseline* como sendo um limiar de classificação, ou seja, sinais cuja DQM são maiores que esse limiar são classificados como sinais com dano e, sinais cuja DQM são menores ou iguais a esse limiar são classificados como sinais saudáveis.

Já a abordagem da Regra da Faixa Interquartil (IQR Rule - *interquartile range rule*) utiliza de dados estatísticos referentes às DQMs dos sinais que compõem a *baseline* para formar um limiar de classificação (UCL - *upper limit control*) que é calculado conforme Eq. (7).

$$UCL = Q_1 + 1,5 \times (Q_3 - Q_1) \quad (7)$$

onde UCL é o limiar via Regra IQR, Q_1 é o primeiro quartil das DQMs dos sinais e Q_3 é o terceiro quartil das DQMs dos sinais. A lógica de classificação segue o mesmo princípio da abordagem Empírica, avaliando-se quais sinais possuem a DQM maior ou menor que esse limiar.

4. DATASET ESTUDADO

O *dataset* CONCEPT utilizado para a obtenção dos resultados apresentados bem como as informações técnicas sobre o experimental podem ser encontrados em detalhes no seguinte link do GitHub: CONCEPT.

Utilizou-se para esse estudo o *dataset* CONCEPT que consiste em uma placa laminada de *carbon-epoxy*. Ela é composta de dez camadas unidirecionalmente orientadas ao longo de 0° com 4 sensores PZT SMART da *Accelent Technologies*. Ela possui 6,35 mm de diâmetro e 0,25 mm de espessura com uma condição de contorno livre. O PZT 1 é usado como atuador com um sinal de entrada do tipo *tone burst* de cinco ciclos aplicado com 35 V de amplitude e frequência central de 250 kHz (da Silva, 2018; da Silva *et al.*, 2019; Paixão, 2020; Paixão *et al.*, 2020b,a; da Silva *et al.*, 2021). A Fig. 2 apresenta a estrutura avaliada.




Figura 2: Estrutura CONCEPT.

As saídas são coletadas em PZT 2, PZT 3 e PZT 4 com uma taxa de amostragem de 5 MHz e tempo de amostragem de 200 ms com todos os canais medidos sincronizados. A aquisição de dados foi controlada pelo *Labview* usando um *NI USB 6353* da *National Instrument* (NIDAQ) e um osciloscópio *DSO7034B Keysight*; a placa passou por um teste de temperatura controlada, sendo conduzido dentro de uma câmara térmica da *Thermotron*. Sete níveis de temperatura de 0°C a 60°C com uma variação de 10°C foram avaliados.

O dano é simulado pela inserção de uma massa adesiva industrial na placa da superfície. Esta massa adicional localizada simula mudanças locais no amortecimento da placa, o que tem algumas semelhanças com a delaminação em estruturas compostas. A progressão do dano é simulada pelo aumento da área coberta pela massa industrial. As condições testadas são apresentadas na Tab. 1.

Tabela 1: Condições estruturais avaliadas da CONCEPT.

Condição	H	D_1	D_2	D_3	D_4	D_5	D_6	D_7	D_8	D_9	D_{10}	D_{11}
A [%]	0	0,196	0,282	0,384	0,502	0,785	1,13	1,53	0,95	2,01	2,27	2,54

5. RESULTADOS E DISCUSSÕES

Em um primeiro momento realizou-se a leitura dos dados. O *dataset* é composto por 700 sinais saudáveis em 7 condições de temperatura (100 sinais para cada condição); e por 1100 sinais com dano em 11 condições de dano (100 sinais para cada condição). Além disso, há dados referentes a cada um dos PZTs, em um total de 1000 pontos experimentais por execução e por PZT. Como o PZT 1 representa a entrada, a leitura de dados é feita compensando o sinal deste nos sinais dos PZTs 2, 3 e 4, “normalizando-os”. Tem-se assim uma matriz de sinais global com dimensões $1000 \times 3 \times 1800$ abrangendo, respectivamente, os 1000 pontos experimentais, os PZTs 2-3-4 e os 1800 sinais.

Após a leitura global, realiza-se a separação entre matrizes de sinais saudáveis e matrizes de sinais com dano, para que possa ser realizado o treinamento do algoritmo. Para esse estudo, iniciando-se a fase de sensoriamento, utilizaram-se somente 10% dos sinais saudáveis para comporem a *baseline*, num total de 70 sinais, escolhidos aleatoriamente independentemente da temperatura. Estabeleceu-se um desvio percentual de 1%, conforme Eq. (2) e, como a taxa de afinidade teórica nesse caso é menor que 70%, devido a quantidade reduzida de sinais saudáveis em relação ao total de sinais (700 em 1800, representando apenas 40%), fixou-se uma taxa de afinidade de 70%, que é o mínimo aceitável para garantir um casamento parcial.

Definida a *baseline*, obtêm-se os desvios superior e inferior para cada um dos pontos do *dataset*, iniciando-se a fase de monitoramento na sequência. É nessa fase em que todos os sinais são avaliados e separados com base na afinidade que possuem com a *baseline*. Um sinal é classificado como próprio somente se a taxa de afinidade for maior que 70% para todos os PZTs.

Na sequência avalia-se a posição do dano através do cálculo da variância que, conforme apresentado por Merizio *et al.* (2020), é uma boa métrica por conseguir detectar situações anormais nos sinais com dano. Normalmente, o valor da variância é maior para os casos com dano.

Os resultados obtidos são gerados em forma de relatório dentro do próprio algoritmo e estão apresentados a seguir:

- O tempo de processamento foi de apenas 32 segundos;
- Dos 1800 sinais, classificaram-se como saudáveis 617 sinais. Sendo 700 o número real de sinais saudáveis;
- Foram detectadas **falhas** nos sinais: 132, 222, 294, 296 a 297, 300, 302 a 353, 356 a 368, 370, 372 a 373, 375 a 379, 381 a 382, 392, 396, 701 a 1800;
- Dos quais 83 é o número de falsos positivos (11,86%) e 0 é o número de falsos negativos (0,00%);
- A falha está localizada no caminho entre os PZTs 1 - 2;
- Foram utilizados 10,0% dos sinais saudáveis com 1,0% de desvio. A taxa de afinidade utilizada foi de 70,00%;
- O percentual de acerto do SIA foi de 98,92% com detecção de falha de 100,00%.

A Matriz de Confusão para o SIA é dada pela Tab. 2 a seguir.

Tabela 2: Matriz de Confusão pelo SIA.

		Condição Real	
		Com Dano	Saudável
Predição	Com Dano	1100	83
	Saudável	0	617

Nota-se de imediato que grande parte dos sinais falsos positivos correspondem a temperatura de 30°C em um total de 77 sinais, representando cerca 93% dos falsos positivos. Esse comportamento é devido a característica do sinal colhido, que pode ser observado na Fig. 3 (foram plotados apenas 5 sinais para cada condição de modo a facilitar a visualização).




Figura 3: Visualização dos dados.

Existem duas regiões praticamente distintas: a composta pela elipse vermelha - - - corresponde a maioria dos dados saudáveis e a elipse preta - - - corresponde a maioria dos sinais com dano. Nota-se que o único sinal saudável que está fora dessas regiões, é justamente o sinal correspondente a 30°C, representado pela linha contínua em ciano —. Dessa forma, mesmo que a seleção aleatória de sinais para compôr a *baseline* tenha coletado algum sinal a 30°C, o algoritmo não é capaz de classificar tal sinal como próprio, dada essa proximidade perante os sinais com dano.

Porém, mesmo com cerca de 12% de falsos positivos, cabe frisar que a detecção do SIA é de 100%, ou seja, todas as condições com dano são identificadas, não havendo ocorrência de falsos negativos. Essa taxa de detecção se mostrou persistente para diversas execuções do algoritmo, demonstrando a robustez do método empregado.

Na sequência, visando-se uma otimização do método, realizou-se uma análise dos sinais, com o intuito de se aplicar a Distância Quadrática de Mahalanobis e realizar um processo de rotulação dos sinais, identificando a severidade de cada uma das condições. Esse processo é realizado extraindo-se duas *features*: *Root Mean Square* (RMS) e Variância, calculando-se a média de ambas na sequência, linearizando-as. As Figs. 4 e 5 apresentam, respectivamente, as médias da RMS e da Variância para os sinais em diferentes condições estruturais, totalizando 100 pontos para cada uma das condições.




Figura 4: Média dos RMS dos sinais em diferentes condições estruturais.




Figura 5: Média das Variâncias dos sinais em diferentes condições estruturais.

Nota-se que, ao se utilizar tal métrica, obtêm-se regiões bem definidas. Porém, o sinal com dano estrutural do tipo 11 acaba se misturando com a região de dados saudáveis para ambas as *features*. Isso acabará prejudicando um pouco a análise ao se empregar a Distância Quadrática de Mahalanobis.

Na sequência é obtida a DQM através da utilização tanto do RMS quanto da Variância. Para cálculo de um *threshold* foram utilizadas duas abordagens: empírica (maior valor saudável) e a regra interquartil (IQR). A Fig. 6 apresenta a DQM obtida com ambos os *thresholds*.

Os resultados obtidos foram:

- Probabilidade de detecção (Empírico): 92,91%
- Probabilidade de detecção (UCL IQR): 99,91%
- Porcentagem de Falso Negativo (Empírico): 7,09%
- Porcentagem de Falso Negativo (UCL IQR): 0,09%
- Porcentagem de Falso Positivo (Empírico): 0,48%
- Porcentagem de Falso Positivo (UCL IQR): 9,37%

As Matrizes de Confusão para cada método estão nas Tabs. 3 e 4.

Comparando-se as três abordagens adotadas (SIA, Empírica e IQR), nota-se que a abordagem empírica, apesar da redução significativa da falsos positivos, com apenas 0,48% do total de sinais, apresenta-se como sendo a pior pois faz com que surjam muitos falsos negativos, o que apresenta um risco muito elevado em uma análise real de SHM, representando cerca de 7% do total de casos.




Figura 6: Distância Quadrática de Mahalanobis da placa CONCEPT.

Tabela 3: Matriz de Confusão pelo método Empírico.

Predição	Condição Real	
	Com Dano	Saudável
Com Dano	1022	3
Saudável	78	697

Tabela 4: Matriz de Confusão pelo IQR.

Predição	Condição Real	
	Com Dano	Saudável
Com Dano	1099	59
Saudável	1	641

Já a abordagem pela IQR apresenta resultados equilibrados, com redução de falsos positivos em relação ao SIA. Porém acaba se mostrando falha por apresentar um falso negativo, condição que não pode ocorrer em sistemas reais, como explicado anteriormente. Apesar da alta probabilidade de detecção, a repetição sistemática (5 vezes) dessa abordagem mostrou-se incerta, com detecção variando entre 94,5% a 99,9%, não sendo atingida em nenhuma repetição uma detecção de 100%.

Por fim, avalia-se a abordagem via Sistema Imunológico Artificial como sendo a mais confiável visto que, apesar do maior número de falsos positivos (com 24 a mais do que pela IQR), a probabilidade de detecção é de 100%, ou seja, todas as condições com dano foram detectadas. Ao contrário dos casos anteriores, essa abordagem atingiu uma probabilidade de detecção de 100% em todas as 5 repetições realizadas, variando-se somente o número de falsos positivos, comprovando a robustez do método.

6. CONSIDERAÇÕES FINAIS

O Sistema Imunológico Artificial tem como principal função automatizar o trabalho existente na análise de sinais visando o monitoramento da integridade estrutural. Em cerca de 30 segundos foi possível se realizar uma análise completa sobre as condições estruturais da placa CONCEPT, seja quando sujeita a diferentes tipos de dano ou quando sujeita a temperaturas diferentes, obtendo-se um relatório completo dos dados.

Diferentemente das Redes Neurais, os Sistemas Imunológicos Artificiais não precisam serem re-executados quando se deseja avaliar uma nova condição, pois a *baseline* mantém-se intacta. Isso poupa tempo e faz com que o banco de dados se torne cada vez mais rico e completo, de tal forma que nenhuma condição com dano seja passível de aceitação. Além disso, dada a sua velocidade de processamento, pode-se aplicá-lo em situações de monitoramento contínuo, como na aviação e em pás de turbinas eólicas, por exemplo.

Como proposta de desenvolvimento de trabalhos futuros, sugere-se que sejam também explorados os mesmos tipos de danos do *dataset* CONCEPT, porém em temperaturas diferentes da ambiente. Isso fará com que o algoritmo de SIA tenha um treinamento mais completo de forma a abranger a maioria da situações enfrentadas na realidade em se tratando de materiais compósitos.

Uma abordagem mais aprofundada, que também deve ser citada e que será realizada em trabalhos futuros, seria a otimização do algoritmo existente através da aplicação da metodologia Clonal-G, cujo princípio de funcionamento é baseado na replicação e desenvolvimento de anticorpos que o corpo humano realiza ao se tomar vacina, por exemplo.

7. AGRADECIMENTOS

Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), Processo No. 88887.639569/2021-00, pelo apoio financeiro e moral na realização deste trabalho. Os autores também gostariam de agradecer aos idealizadores do experimento CONCEPT pelo compartilhamento do *dataset* utilizado neste trabalho.

8. REFERÊNCIAS

- Bradley, D.W. and Tyrrell, A.M., 2002. "Immunotronics-novel finite-state-machine architectures with built-in self-test using self-nonsel self differentiation". *IEEE Transactions on Evolutionary Computation*, Vol. 6, No. 3, pp. 227–238.
- Chavarette, F.R., Outa, R. and Gonçalves, A.C., 2021. "Prognose de falhas em um reator do reator tubular com escoamento pistonado utilizando sistemas imunológicos artificiais". *The Journal of Engineering and Exact Sciences*, Vol. 7, No. 2. doi:10.18540/jcecvl7iss2pp12366-01-10e. URL <https://doi.org/10.18540/jcecvl7iss2pp12366-01-10e>.
- da Silva, S., 2018. "Data-driven model identification of guided wave propagation in composite structures". *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, Vol. 40, No. 11, p. 543. ISSN 1806-3691. doi: 10.1007/s40430-018-1462-4. URL <https://doi.org/10.1007/s40430-018-1462-4>.
- da Silva, S., Paixao, J., Rebillat, M. and Mechbal, N., 2019. "Data-driven autoregressive model identification for structural health monitoring in anisotropic composite plates". In *IX ECCOMAS Thematic Conference on Smart Structures and Materials - SMART 2019*. A. Benjeddou, N. Mechbal and JF Deü.
- da Silva, S., Paixão, J., Rébillat, M. and Mechbal, N., 2021. "Extrapolation of ar models using cubic splines for damage progression evaluation in composite structures". *Journal of Intelligent Material Systems and Structures*, Vol. 32, No. 3, pp. 284–295.
- Dasgupta, D., 2012. *Artificial immune systems and their applications*. Springer Science & Business Media.
- Dasgupta, D. and Forrest, S., 1999. "Artificial immune systems in industrial applications". In *Proceedings of the Second International Conference on Intelligent Processing and Manufacturing of Materials. IPMM'99 (Cat. No. 99EX296)*. IEEE, Vol. 1, pp. 257–267.
- de Castro, L.N., 2001. "Engenharia imunológica: desenvolvimento e aplicação de ferramentas computacionais inspiradas em sistemas imunológicos artificiais". *Universidade Estadual de Campinas, Campinas-SP*, p. 29.
- Forrest, S., Javornik, B., Smith, R.E. and Perelson, A.S., 1993. "Using genetic algorithms to explore pattern recognition in the immune system". *Evolutionary computation*, Vol. 1, No. 3, pp. 191–211.
- Forrest, S., Perelson, A.S., Allen, L. and Cherukuri, R., 1994. "Self-nonsel self discrimination in a computer". In *Proceedings of 1994 IEEE computer society symposium on research in security and privacy*. Ieee, pp. 202–212.
- Garnier, C., Pastor, M.L., Eyma, F. and Lorrain, B., 2011. "The detection of aeronautical defects in situ on composite structures using non destructive testing". *Composite structures*, Vol. 93, No. 5, pp. 1328–1336.
- Lima, F.P.A., 2013. *Análise de distúrbios de tensão em sistemas de distribuição de energia elétrica baseada em sistemas imunológicos artificiais*. Master's thesis, Universidade Estadual Paulista (UNESP), Ilha Solteira, SP - Brazil.
- Lima, F.P.A., 2016. *Diagnóstico de distúrbios de tensão em sistemas de distribuição baseado num sistema imunológico artificial com aprendizado continuado*. Ph.D. thesis, Universidade Estadual Paulista (UNESP), Ilha Solteira, SP - Brazil.
- Mahalanobis, P., 1936. "On the generalized distance in statistic divergence in relation to breeding system in some crop plants". *Indian Journal of Genetics*, Vol. 26, pp. 188–198.
- Merizio, I.F., Chavarette, F.R., Moro, T.C. and Outa, R., 2020. "Detecção de falhas por meio acústico utilizando algoritmo de seleção negativa". *Colloquium Exactarum*. ISSN: 2178-8332, Vol. 12, No. 3, pp. 61–70.
- Merizio, I.F., Chavarette, F.R. and Outa, R., 2019. "Caracterização de um tubo de impedância acústica via computação natural". *Colloquium Exactarum*. ISSN: 2178-8332, Vol. 11, No. 4, pp. 62–72.
- Outa, R., Chavarette, F.R., Mishra, V.N., Gonçalves, A.C., Garcia, A., da Silva Pinto, S., Rathour, L. and Mishra, L.N., 2022. "Analysis and prognosis of failures in intelligent hybrid systems using bioengineering: Gear coupling". *The Journal of Engineering and Exact Sciences*, Vol. 8, No. 1. doi:10.18540/jcecvl8iss1pp13673-01-18e. URL <https://doi.org/10.18540/jcecvl8iss1pp13673-01-18e>.
- Paixão, J., da Silva, S., Figueiredo, E., Radu, L. and Park, G., 2020a. "Delamination area quantification in composite structures using gaussian process regression and auto-regressive models". *Journal of Vibration and Control*, p. 1077546320966183.
- Paixão, J.A., da Silva, S. and Figueiredo, E., 2020b. "Damage quantification in composite structures using autoregressive models". In *Proceedings of the 13th International Conference on Damage Assessment of Structures*. Springer, pp. 804–815.
- Paixão, J.A.S., 2020. *Damage quantification in laminated composites using gaussian process regression model*. Master's thesis, Universidade Estadual Paulista (UNESP).
- Zinno, R., Artese, S., Clausi, G., Magarò, F., Meduri, S., Miceli, A. and Venneri, A., 2019. "Structural health monitoring (shm)". In *The Internet of Things for Smart Urban Ecosystems*, Springer, pp. 225–249.

9. RESPONSABILIDADE AUTORAIS

Os autores são os únicos responsáveis pelo conteúdo deste trabalho.

DAMAGE QUANTIFICATION IN A TEMPERATURE VARYING COMPOSITE PLATE USING ARTIFICIAL IMMUNE SYSTEM

Estevão Fuzaro de Almeida, estevao.fuzaro@unesp.br¹

Lucas Veronez Goulart Ferreira, lucas.goulart@unesp.br¹

Fábio Roberto Chavarette, fabio.chavarette@unesp.br²

¹São Paulo State University “Júlio de Mesquita Filho”, Engineering Faculty of Ilha Solteira, Department of Mechanical Engineering, 56 Brasil Sul Blvd. - Center, ZIP 15385-000, Ilha Solteira - SP, Brazil.

²São Paulo State University “Júlio de Mesquita Filho”, Chemistry Institute of Araraquara, Department of Engineering, Physics and Mathematics, 55 Prof. Francisco Degni St., Quitandinha, ZIP 14800-060, Araraquara - SP, Brazil.

Abstract: *The concept of Structural Health Monitoring (SHM), is based on maintenance and failure detection processes, which are mostly used in industrial and construction environments. SHM involves the observation and analysis of a structure or mechanical system, evaluating the dynamic response obtained by periodic measurements, which are then analyzed by statistical processes to finally determine the integrity of the system. Such technology makes it possible to detect failures in early states, intervene in their propagation, and, consequently, prevent catastrophes and/or accidents from occurring, leading to the shutdown or damage of the structure. Within the field of SHM, one of the most highly regarded systems is the Artificial Immune System (AIS) based on the Negative Selection Algorithm (NSA). The NSA is based on the observation of the functioning of the human immune system, more specifically on the negative selection of T cells that occurs in the thymus, which is a lymphatic organ. The operation process is divided into two stages: in the Censoring stage, AIS is trained with the signals collected from the structure in normal condition (own signals), which are stored in a database (baseline); in the Monitoring stage, starting from a signal in structural failure situation and, after checking the affinities of these signals with the database, AIS performs the separation of signals into own and non-own (non-failure and failure, respectively). For this work, we studied the CONCEPT dataset, which consists of a laminated plate of composite material subjected to gradual damage progression combined with temperature variations, presenting a total of 1100 signals with damage and 700 healthy signals at various temperatures. Both the NSA and a statistical analysis using the concept of Mahalanobis Squared Distance were used in order to compare and obtain a complete diagnosis of the structural integrity of the system aiming at the detection, localization and quantification of damage when subjected to temperature variation. As results, AIS detected damage in 1183 out of 1800 signals (11.86% false positives and 0% false negatives). The algorithm detected 100% of the cases with damage and presented an overall accuracy of 98.92%, with a processing time of about 30 seconds, demonstrating the robustness and effectiveness of the NSA.*

Keywords: *Structural Health Monitoring, Artificial Immune System, Negative Selection Algorithm, Composite Materials, Mahalanobis Distance.*