

Sistemas Imunológicos Artificiais com Seleção Negativa Aplicado ao Monitoramento de Integridade Estrutural em uma Ponte Metálica

Artificial Immune Systems with Negative Selection Applied to Structural Integrity Monitoring in a Metallic Bridge

Sistemas Inmunes Artificiales con Selección Negativa Aplicados al Monitoreo de la Integridad Estructural en una Puente Metálica

Recebido: 06/11/2022 | Revisado: 15/11/2022 | Aceitado: 16/11/2022 | Publicado: 23/11/2022

Alyson Aláx Alves dos Santos

ORCID: <https://orcid.org/0000-0003-1866-0026>
Universidade do Estado de Mato Grosso, Brasil
E-mail: alysonalax@hotmail.com

Fábio Roberto Chavarette

ORCID: <https://orcid.org/0000-0002-1203-7586>
Universidade Estadual Paulista, Brasil
E-mail: fabio.chavarette@unesp.br

Simone Silva Frutuoso de Souza

ORCID: <https://orcid.org/0000-0002-4059-0813>
Universidade do Estado de Mato Grosso, Brasil
E-mail: simonefrutuoso.mat@gmail.com

Resumo

Neste artigo apresenta-se um algoritmo de inteligência artificial baseado nos sistemas imunológicos artificiais para análise da integridade estrutural de uma ponte metálica. Inspirando-se em um processo biológico, utiliza-se o algoritmo de seleção negativa para realizar a identificação e caracterização das falhas estruturais. Esta ferramenta auxiliará profissionais, na inspeção de estruturas, de modo a identificar e caracterizar falhas, a fim de realizar manutenção preventiva, assegurar a integridade da estrutura e auxiliar a tomada de decisões. Para validar a metodologia foram utilizados dados reais obtidos a partir de um experimento em laboratório, e a partir deste, foram geradas diversas situações (condição normal e condições em falhas), obtendo-se uma base de dados de sinais, que foram analisados pelo método proposto. Os resultados obtidos pelo algoritmo de seleção negativa apresentam eficiência e robustez. Vale ressaltar que a combinação de inteligência artificial com processamento de sinais permite uma maior qualidade no diagnóstico. Assim este artigo contribui com as linhas de pesquisa em monitoramento de saúde estrutural e inteligência artificial apresentando uma metodologia muito eficiente.

Palavras-chave: Sistemas imunológicos artificiais; Algoritmo de seleção negativa; Análise de integridade estrutural; Ponte metálica.

Abstract

In this paper presents an artificial intelligence system based on artificial immune systems for analyzing the structure of a metal bridge. Inspired by a biological process, the negative selection algorithm is used to carry out the identification and characterization of structural failures. This tool will help identify the maintenance, configurations of structures, the way to identify failures, in order to ensure the health quality of the structure and carry out security decisions. To validate the methodology, were used a real data obtained from laboratory experiment, and from this, several situations were generated (normal and fault conditions), obtaining a database of signals, which were analyzed by the method proposed. The results obtained by the negative selection algorithm are efficient and robustness. It is worth mentioning that artificial intelligence with signal processing allows for a higher quality in the diagnosis. Thus, this article contributes to the lines of research in structural health monitoring and artificial intelligence, presenting a very efficient methodology.

Keywords: Artificial immune systems; Negative selection algorithm; Structural integrity analysis; Metal bridge.

Resumen

Este artículo presenta un algoritmo de inteligencia artificial basado en sistemas inmunes artificiales para analizar la integridad estructural de un puente metálico. Inspirado en un proceso biológico, el algoritmo de selección negativa se utiliza para identificar y caracterizar fallas estructurales. Esta herramienta ayudará a los profesionales en la inspección de estructuras, para identificar y caracterizar fallas, para realizar mantenimientos preventivos, asegurar la integridad

de la estructura y auxiliar en la toma de decisiones. Para validar la metodología se utilizaron datos reales obtenidos de un experimento de laboratorio, ya partir de esto se generaron varias situaciones (condiciones normales y de falla), obteniendo una base de datos de señales, las cuales fueron analizadas por el método propuesto. Los resultados obtenidos por el algoritmo de selección negativa muestran eficiencia y robustez. Cabe mencionar que la combinación de inteligencia artificial con procesamiento de señales permite una mayor calidad en el diagnóstico. Así, este artículo contribuye a las líneas de investigación en monitorización de salud estructural e inteligencia artificial, presentando una metodología muy eficiente.

Palabras clave: Sistemas inmunes artificiales; Algoritmo de selección negativa; Análisis de integridad estructural; Puente metálica.

1. Introdução

A construção civil engloba a confecção de obras como casas, edifícios, pontes, barragens, fundações de máquinas, estradas, aeroportos e outras infraestruturas. Em toda história a construção civil passa por grandes transformações, devido a evolução dos métodos construtivos, de novos sistemas de construção e principalmente materiais diferentes, capazes de atender diversas necessidades e serem aplicados em novos contextos.

De qualquer forma, mesmo com os avanços tecnológicos no desenvolvimento de novas técnicas e materiais, observa-se um grande número de edificações recém-construídas apresentando falhas estruturais. Segundo (Palaia, 2007), isto se deve ao uso inadequado de materiais, falta de cuidados na execução da obra e mesmo adaptações quanto ao seu uso, tudo isto somado à falta de manutenção. Conforme destacado por (Vitório, 2021), tais falhas estruturais são responsáveis pela perda da capacidade de resistência às solicitações em elementos isolados ou em toda a estrutura.

Assim, nas estruturas as falhas podem representar o baixo, ou nenhum desempenho dinâmico da estrutura, em relação à estabilidade e durabilidade da mesma, quando exposta a condições anormais, como, por exemplo, eventos naturais (terremotos, tremores, ventanias, etc.). Portanto, as estruturas expostas a ações de deterioração, necessitam de manutenção e reparo para continuarem a exercer sua função ao longo de sua vida útil e não apresentar quaisquer riscos aos usuários (Meireles, 2010). Logo, em razão de preservar a integridade da estrutura, os métodos de ensaio não-destrutivos são aplicados para análise estrutural.

Os métodos não-destrutivos, visam estimar o grau de segurança e confiabilidade da estrutura. Para isto, existem técnicas tradicionalmente utilizadas como: inspeção visual, inspeção ultrassônica, testes de resistência axial, torsão, radiografia-X, testes de emissão acústica, entre outras técnicas (Lima, 2014). Tais técnicas trazem bons resultados, mas não conseguem satisfazer necessidades crescentes da indústria, tais como: a tomada de decisão em tempo real, automatização dos processos, utilização de materiais inteligentes e quando as estruturas são submetidas a movimento, como vibrações (Franco et al., 2009).

Neste sentido, aplicar métodos de monitoramento inteligentes é essencial. Essa linha de pesquisa atual e importante é denominada de Monitoramento de Saúde Estrutural (Structural Health Monitoring - SHM). Em geral um método de SHM combina conceitos de engenharia, processamento de sinais, ciência dos materiais e técnicas para tomada de decisão, onde este último item pode trabalhar desde métodos baseados em parâmetros químicos, físicos, estatísticos e até uma técnica de inteligência artificial. Assim, tal método é aplicado para a identificação e implementação de estratégias para a sondagem de danos, além de ser capaz de estimar a vida útil das estruturas, detectar e localizar falhas estruturais por meio de sensores, impedância elétrica e entre outros (Chaves et al., 2017).

Os métodos de diagnóstico de falhas estruturais com inteligência artificial, podem ser ferramentas importantes para auxiliar técnicos e engenheiros a identificar e caracterizar falhas estruturais. Assim, este artigo tem como finalidade o desenvolvimento de um sistema de monitoramento de integridade estrutural com inteligência artificial para diagnosticar falhas em uma ponte metálica.

Deste modo, tal inteligência artificial auxiliará na tomada de decisões ao fazer análises contínuas da estrutura, no

planejamento de manutenções corretivas ou preventivas, evitando catástrofes e impedindo possível evolução de falha estrutural que resulte no colapso da estrutura.

Este trabalho se justifica pela necessidade de se automatizar o processo de análise de sinais e tomada de decisões em estruturas, pois os métodos tradicionais de análise estrutural não satisfazem as necessidades crescentes da indústria, e não são capazes de realizar análise em tempo real, e principalmente de estruturas sujeitas a movimento (vibração).

Também se destaca a importância de criação de ferramentas computacionais inteligentes para auxiliar engenheiros e técnicos na análise de falhas estruturais, trazendo robustez, rapidez e eficiência na tomada de decisão.

2. Fundamentação Teórica

2.1 Falhas Estruturais

Falhas estruturais são danos causados na estrutura, que podem ocorrer por mal dimensionamento dos elementos estruturais, escolha de materiais inadequados para a solicitação e entre outros fatores. Esses danos implicam em mudanças físicas e nas características gerais do corpo estrutural, assim, prejudicando o desempenho e reduzindo a vida útil da construção.

Segundo (Gonzalez, 2012), podem ocorrer diversos tipos de danos nas estruturas, como: desgaste de componentes, corrosões, cortes, trincas, fissuras, afrouxamento de uniões aparafusadas, delaminações, dilatações, aderência de massas (incrustações) e combinação dos itens anteriores.

Os efeitos causados por falha estrutural, são associados ao regime elástico da estrutura, apresentando dois tipos de efeitos, sendo eles lineares e não-lineares. Os efeitos lineares são os que agem quando a estrutura linear-elástica volta ao estado inicial, após a ocorrência do dano. Os não-lineares, tratam-se da reação inicial ao dano, a qual a estrutura sofre o impacto e altera suas propriedades físicas (Doebeling et al., 1996).

Dos tipos de falhas estruturais, as mais comuns são trincas e fissuras, que a depender da configuração, podem indicar qual o agente causador, ou a fonte do problema. Tais falhas estruturais, por vezes apresentadas como uma espécie de aviso, podem colocar em risco a vida dos usuários e influenciar negativamente no desempenho de uma edificação e por esse motivo, devem ser empregados métodos de análise e intervenções para diagnosticar e solucionar.

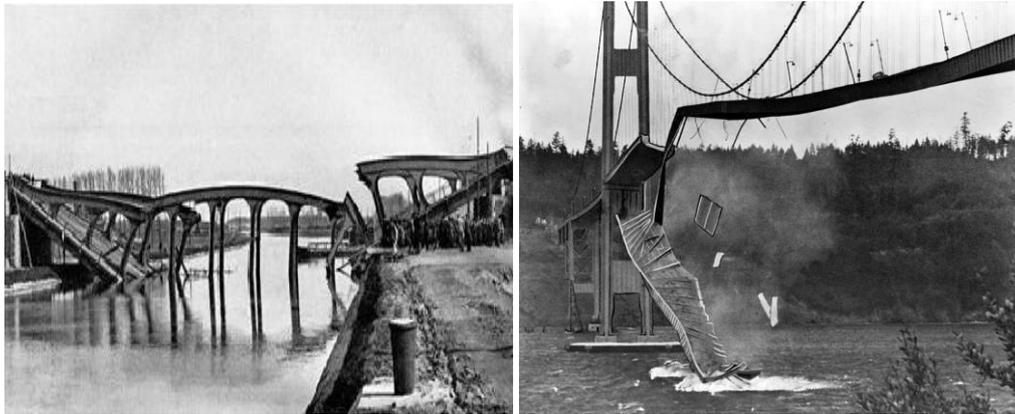
As pontes metálicas estão sujeitas a diversos tipos de falhas estruturais, já que são estruturas expostas a vários tipos de solicitações e meios. Assim, esse tipo de estrutura apresenta desgastes ao longo de sua vida que afetam sua integridade, exigindo manutenções e reparos, para prolongar a vida útil e proteger a estrutura da ponte. Uma parcela das deteriorações existentes na estrutura da ponte, são causadas pelo meio as quais estão inseridas, em razão do próprio rio, um meio úmido ao qual está submetido, que facilita o fenômeno de oxidação no aço e das ações do vento, que podem ser desprezíveis caso barreiras topográficas interfiram na circulação de rajadas de vento ou possuam menor extensão. De contraponto, existem as pontes de longa extensão, que são impactadas pelas cargas do vento (Meireles, 2010).

De acordo com (Vitório, 2021), nem toda falha estrutural resulta em colapso, todavia deve-se analisar a estrutura para evitar quaisquer surpresas, ao realizar um diagnóstico e prognóstico. As manifestações mais comuns de falha estrutural em pontes metálicas, são causadas por: sobrecargas e vibrações excessivas, cargas não previstas, corrosão atmosférica, erros na fase de projeto/execução, uso inadequado, empenamento, problemas nas ligações e fadiga.

2.1.1 Casos de Colapsos em Pontes

Alguns casos de colapsos em pontes tiveram um grande destaque na história, alertando para a necessidade e importância dos sistemas de SHM em tais estruturas. As manifestações para esses eventos são variadas e podem levar ou não a ponte ao colapso. A seguir, a Figura 1 ilustra casos de pontes que colapsaram.

Figura 1 - Exemplos de Colapso em Pontes.



(a) Ponte Hasselt na Bélgica

(b) Ponte Tacoma-Narrows nos EUA

Fonte: Espion (2012); Mundo Educação (2022).

2.2 Monitoramento da Integridade Estrutural (SHM)

Os sistemas de monitoramento da integridade estrutural (SHMs) são tidos como um processo de identificação de falhas estruturais, através de diversas estratégias empregadas na engenharia, em especial na engenharia civil. As técnicas de SHMs são aplicadas como alternativas não-destrutivas de identificação e mapeamento de falhas estruturais. Assim, a função dos sistemas de monitoramento da integridade estrutural é a de diagnosticar a integridade estrutural de um corpo estrutural como um todo, seja por partes separadas ou pelos materiais constituintes em qualquer momento da vida útil da estrutura.

O processo de um sistema SHM consiste em três fases, a observação da estrutura ao longo de sua vida útil, extração de características sensíveis ao dano por meio das medições realizadas durante a observação e análise estatística de forma que seja possível representar o estado atual da estrutura analisada.

Chaves et al., (2017) afirma que “um sistema de SHM a longo prazo, a saída do processo citado anteriormente é atualizada periodicamente, encaminhando dados referentes ao estado da estrutura, levando em consideração os desgastes normais e as deteriorações ocasionadas pela utilização. O processo de diagnóstico, mapeamento e prognóstico, ocorre após a implementação de variadas ferramentas de detecção, como a integração de sensores, materiais inteligentes, transmissão de dados e processamento de sinais”.

Os SHMs possuem alguns princípios fundamentais, sendo eles associados ao conhecimento de que quaisquer tipos de estrutura podem apresentar falhas e defeitos, independente do material. Tendo tal embasamento, deve-se ter dados de dois estados de uma estrutura, o estado normal e o estado após o dano para que seja possível comparar e avaliar a condição da estrutura. Com esses dados, é introduzido o processo de tomada de decisão inteligente para identificação do grau e tipo de dano, complementado em seguida pela possibilidade de identificação da existência e da localização de um dano.

Assimilado os dados, estes devem ser processados e convertidos em informações que possibilite a identificação de mudanças nas dinâmicas do sistema, responsáveis por determinar a dimensão do dano. Ou seja, os sistemas de SHM passam pela etapa de aquisição de dados, pelo pré-processamento e interpretação dos dados no algoritmo, finalizando com a aplicação das técnicas de tomada de decisões.

Conforme destacado por Hall (1999), um SHM é classificado por níveis, sendo: Nível 1 – Detecta a existência da falha; Nível 2 – Detecta e classifica a falha; Nível 3 – Detecta, classifica e localiza a falha; Nível 4 – Detecta, classifica, localiza e quantifica a falha, apresentado uma estimativa da vida útil da estrutura.

Neste artigo foi desenvolvido um SHM de nível 2, onde ocorre a detecção e classificação das falhas.

2.3 Revisão Bibliográfica

Nesta seção apresentam-se os trabalhos mais relevantes na área de SHM utilizando técnicas de inteligência artificial aplicados ao monitoramento de falhas estruturais em problemas de engenharia.

Na Tabela 1, são apresentados em ordem cronológica, os trabalhos mais relevantes disponíveis na literatura.

Tabela 1 - Revisão bibliográfica.

| Referência | Descrição |
|---------------------------|--|
| (Tebaldi et al., 2006) | Combinaram a técnica de impedância elétrica com abordagens de nuvem de partículas para a quantificação de falhas em estruturas inteligentes. |
| (Silva et al., 2008) | Utilizaram uma técnica experimental de impedância elétrica através de materiais piezelétricos (PZTs) acoplados em estruturas de vigas. |
| (Franco; 2009) | Apresentou um sistema de monitoramento para estruturas aeronáuticas usando impedância eletromecânica. A avaliação da metodologia foi realizada em um painel aeronáutico da EMBRAER e placas de alumínio. |
| (Xiang-Jun et al., 2010) | Apresentou um sistema inteligente utilizando wavelet para avaliar a integridade de estruturas de pontes através dos sinais de vibração. |
| (Wang et al., 2013) | Apresentou um algoritmo genético multimodal para diagnosticar danos em uma ponte de treliça de aço. |
| (Lima; Souza, 2016) | Utilizaram equações diferenciais e métodos finitos para análise de integridade em um edifício. Utilizaram uma rede neural artificial ARTMAP-Fuzzy-Wavelet para diagnosticar e caracterizar falhas estruturais, com taxa de precisão de 99,52%. |
| (Oliveira et al., 2020). | Apresentou um sistema de monitoramento de integridade estrutural para máquinas rotativas. Utilizaram o aprendizado continuado, isto é, o sistema aprende sem a necessidade de reiniciar o aprendizado do sistema com o surgimento de novas falhas a serem diagnosticadas |
| (Gonçalves et al., 2020) | Apresentou um método de impedância eletromagnética em conjunto com o método de krigagem ordinária para diagnosticar e localizar falhas em uma placa de alumínio. |
| (Chavarette et al., 2021) | Utilizaram a transformada wavelet em conjunto com um sistema imunológico artificial para monitoramento de um rotor dinâmico. O método obteve índice de acerto de 100%, demonstrando a eficiência. |

Fonte: Autores.

Conforme observa-se na Tabela 1, na literatura existem diversos trabalhos que usam técnicas de inteligência artificial para desenvolver SHMs. E estes trabalhos empregam os mais diferentes tipos de técnicas, como: redes neurais artificiais, impedância eletromagnética, impedância elétrica, transformada wavelet, nuvem de partículas, entre outros. Isto se deve a eficiência obtida com tais técnicas.

2.4 Algoritmo de Seleção Negativa

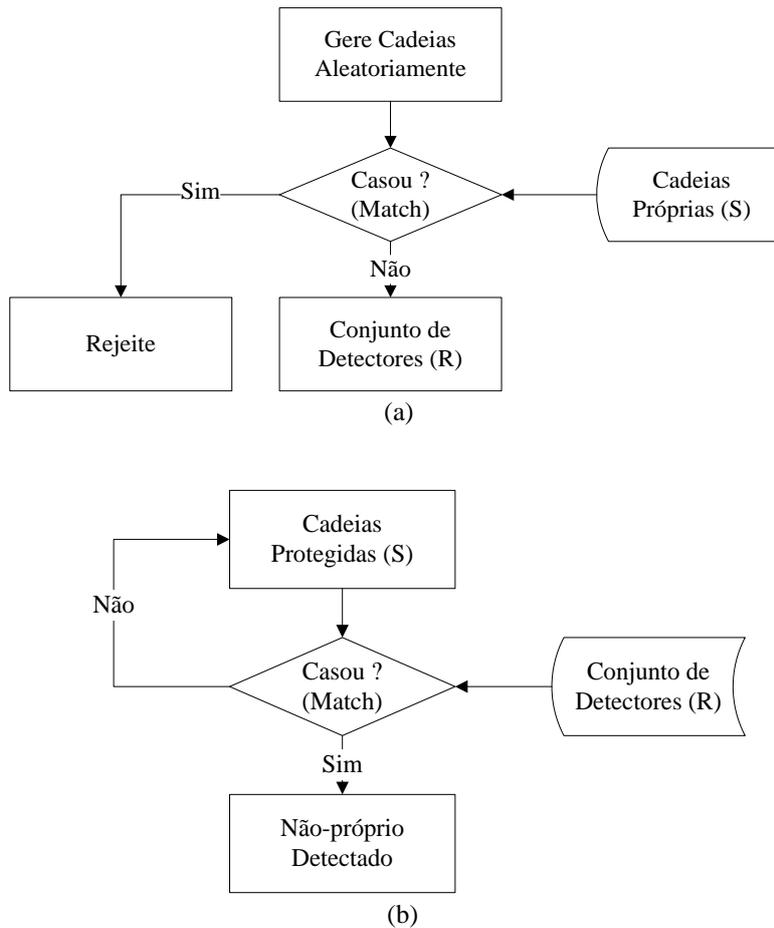
O Algoritmo de Seleção Negativa (ASN) é inspirado na seleção negativa de linfócitos T que ocorre no timo, representando a análise que o organismo realiza para diferenciar as células entre próprias e não-próprias.

Este algoritmo é executado em duas fases conforme descrito em (Forrest et al., 1994; Lima et al., 2013). Na fase de sensoriamento do ASN, são definidos inicialmente os detectores próprios, que representam a condição normal do problema, sendo conhecido como cadeias próprias (S). O objetivo desta fase é gerar o conjunto de padrões detectores (R), que tenham a capacidade de reconhecer algum padrão não-próprio, na fase de monitoramento.

Na fase de monitoramento, analisa-se os dados visando identificar mudanças no comportamento das amostras e, então, classificar estas mudanças. Assim, analisando-se as cadeias protegidas (S) e comparando-as com o conjunto de detectores (R), avalia-se a afinidade entre as cadeias. Caso a afinidade seja superior a um determinado limiar, então, o elemento não-próprio é detectado e classificado.

Na Figura 2 apresentam-se os fluxogramas do ASN.

Figura 2 - Fluxogramas do ASN.



Fonte: Lima et al. (2013).

Para avaliar a afinidade entre as cadeias (sinais) e assegurar que são semelhantes, utiliza-se um critério denominado casamento. A taxa de afinidade representa o grau de semelhança que deve ocorrer entre as duas cadeias em análise para que o casamento seja confirmado. A taxa de afinidade pode ser arbitrada (atribuído um valor de acordo com o problema) ou calculada através da seguinte equação (Bradley & Tyrrell, 2002):

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

sendo:

TAf : taxa de afinidade;

An : número de cadeias próprias no problema;

At : número total de cadeias no problema.

Através da equação (1), é possível calcular, de forma estatística, o valor da taxa de afinidade para o problema proposto. A expressão (2) representa a forma de quantificar a afinidade total entre os padrões em análise (Bradley & Tyrrell, 2002):

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

sendo:

- Af_T : % de afinidade entre os padrões;
- L : quantidade total de posições do padrão;
- P_c : posição casada;
- $\sum_{i=1}^L P_c$: quantidade de posições casadas.

Desta forma, se Af_T for maior ou igual a Taf ocorre o casamento entre os padrões, ou seja, eles são considerados semelhantes. Caso contrário, não ocorre o casamento entre os sinais.

3. Metodologia

3.1 Bancada Experimental

O experimento para coleta de dados foi desenvolvido pelo Prof. Dr. Fábio Roberto Chavarette, coordenador do grupo de pesquisa Sixplexos (sistemas complexos), pertencente ao laboratório de materiais e sistemas inteligentes do Programa de Pós-Graduação em Engenharia Mecânica (PPGEM) da Universidade Estadual Paulista “Júlio de Mesquita Filho” (UNESP), campus Ilha Solteira-SP.

Para a realização do experimento, foram utilizados materiais de baixo custo para a aquisição dos dados e uma estrutura de ponte metálica construída com perfis de alumínio, ilustrados nas Figuras 3 e 4.

Figura 3 - Materiais utilizados para a confecção do experimento.

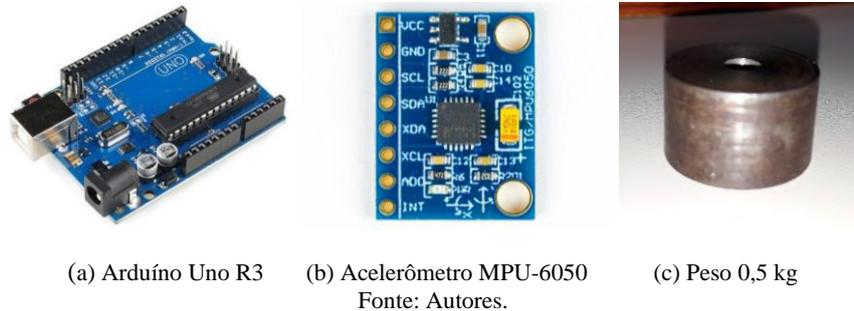


Figura 4 - Estrutura da ponte metálica.



Fonte: Autores.

Inicialmente, apoiou-se a estrutura metálica sobre a bancada experimental, em seguida, fixou-se um motor de indução rotativo sobre a bancada, de forma que ficasse próximo a estrutura metálica. O motor de indução rotativo é o responsável por propagar a excitação sobre a bancada e, por conseguinte, realizar a vibração da estrutura. O motor de indução utilizado possui

frequência máxima de 60Hz, a qual pode ser variada de 2 em 2 Hz. Sua potência é de 0,37Kw, e voltagem de 220V. Na Figura 5, ilustra-se o motor posicionado ao lado da estrutura da ponte metálica.

Figura 5 - Estrutura da ponte metálica com o motor rotativo de vibração.



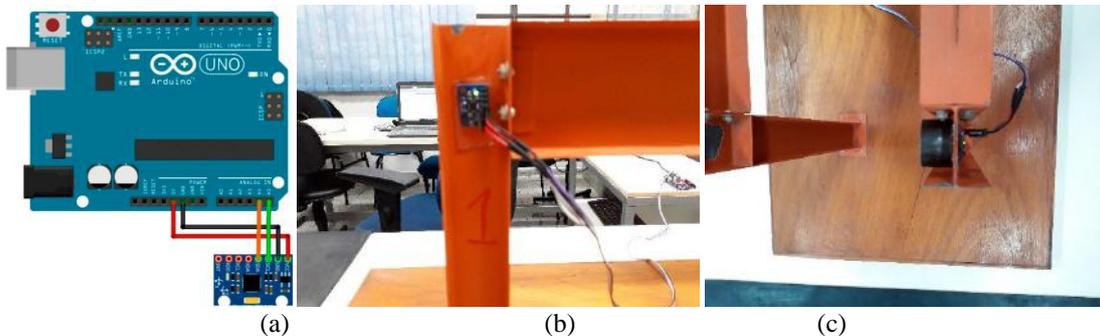
Fonte: Autores.

Posteriormente, conectou-se o Arduino ao computador para leitura dos sinais utilizando o acelerômetro MPU-6050 que é fixado nas partes de alumínio da estrutura da ponte metálica. O Arduino realiza leituras do acelerômetro, capturando a vibração da estrutura ao ser excitada pelo motor rotativo na bancada, e estes dados são armazenados no computador. O motor foi ligado a uma frequência de 40Hz de forma constante para vibrar a bancada e consequentemente, vibrar a estrutura da ponte.

A Figura 6 (a) ilustra a forma de conexão entre o acelerômetro e o Arduino e a Figura 6 (b) ilustra o acelerômetro colado na estrutura para capturar a vibração da ponte metálica.

Para simular a falha na estrutura foi utilizado o método de incrustação ou aderência de massa, colocando-se um peso de 0,5kg na estrutura. A Figura 6 (c) ilustra o peso adicionado a estrutura para simular uma falha estrutural.

Figura 6 - Conexões do acelerômetro e peso de 0,5 kg.

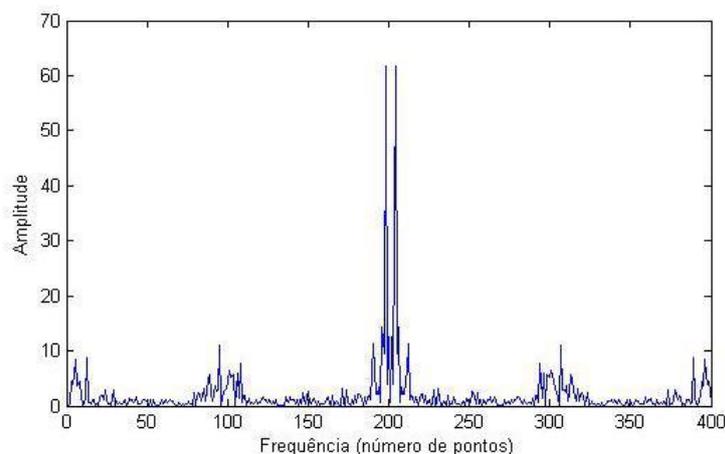


Fonte: Autores.

Para que a coleta do sinal fosse possível, utilizou-se de um algoritmo computacional redigido na linguagem de programação MATLAB®, onde foi realizado o processamento dos sinais aplicando a FFT (*Fast Fourier Transform*), e armazenando em um banco de dados.

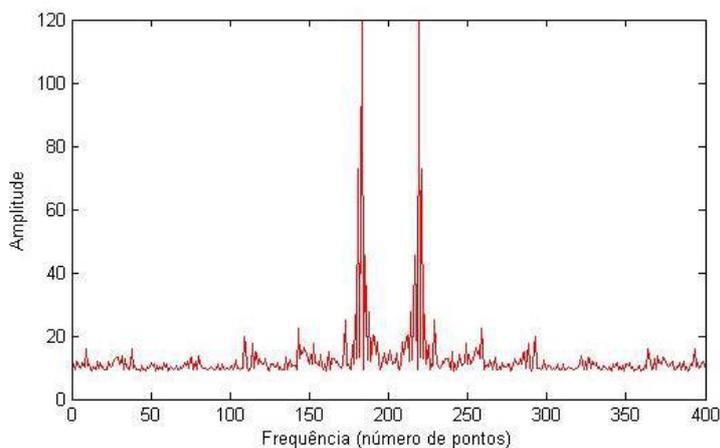
As Figuras 7 e 8 ilustram dois sinais obtidos na estrutura, sendo um em condição normal (Figura 7) e outro com falha estrutural (Figura 8).

Figura 7 - Sinal normal obtido na estrutura.



Fonte: Autores.

Figura 8 - Sinal de falha obtido na estrutura.



Fonte: Autores.

3.1.1 Configuração do Banco de Dados

Para composição do banco de dados foram realizadas leituras de sinais em 6 regiões da estrutura (canto esquerdo, direito e meio, nos dois lados), sendo realizada a coleta de sinais normais e sinais com falha na mesma posição.

A configuração da base de dados é apresentada na Tabela 2.

Tabela 2 - Configuração da base de dados.

| Banco de dados | Valores |
|-----------------|---------|
| Total de Sinais | 240 |
| Sinais normais | 120 |
| Falha região 1 | 20 |
| Falha região 2 | 20 |
| Falha região 3 | 20 |
| Falha região 4 | 20 |
| Falha região 5 | 20 |
| Falha região 6 | 20 |

Fonte: Autores.

O banco de dados foi dividido em 30% dos dados para o Censoriamento do ASN e 70% para o diagnóstico, conforme apresentado na Tabela 3.

Tabela 3 - Divisão 30% - 70%.

| Banco de dados | Censoriamento (30%) | Monitoramento (70%) |
|-----------------|---------------------|---------------------|
| Total de Sinais | 72 | 168 |
| Sinais normais | 36 | 84 |
| Falha região 1 | 6 | 14 |
| Falha região 2 | 6 | 14 |
| Falha região 3 | 6 | 14 |
| Falha região 4 | 6 | 14 |
| Falha região 5 | 6 | 14 |
| Falha região 6 | 6 | 14 |

Fonte: Autores.

3.2 Algoritmo Proposto

O sistema de análise da integridade estrutural proposto neste artigo consiste-se em três módulos principais: aquisição de dados, censoriamento e monitoramento do algoritmo de seleção negativa.

O módulo de aquisição de dados é composto pelo aparato experimental para excitar, e também capturar os sinais de comportamento da estrutura, como: sensores, atuadores e acelerômetros, etc. A partir deste módulo obtém-se os sinais de resposta em frequência para serem utilizados como entrada no ASN.

A partir dos dados de vibração obtidos no experimento, utiliza-se a FFT (transformada rápida de Fourier) para obter a resposta em frequência. A resposta em frequência é obtida através dos sinais da velocidade e do deslocamento da estrutura ao ser excitada. Esta etapa foi desenvolvida em MATLAB®, utilizando uma biblioteca pronta.

No módulo de censoriamento é gerado o conjunto de detectores de falhas que será utilizado no monitoramento dos dados. Este processo é realizado de forma off-line. O conjunto de detectores de falhas é composto por sinais dos diferentes tipos de falhas na estrutura, que são escolhidos aleatoriamente. O número de sinais escolhidos como detector, tanto próprio, quanto não próprio é um parâmetro a ser definido pelo programador ou executor do programa. Conforme ilustrado na Figura 9, na fase de aprendizado o sistema será iniciado pela leitura dos sinais do banco de dados e definido o conjunto de detectores próprios.

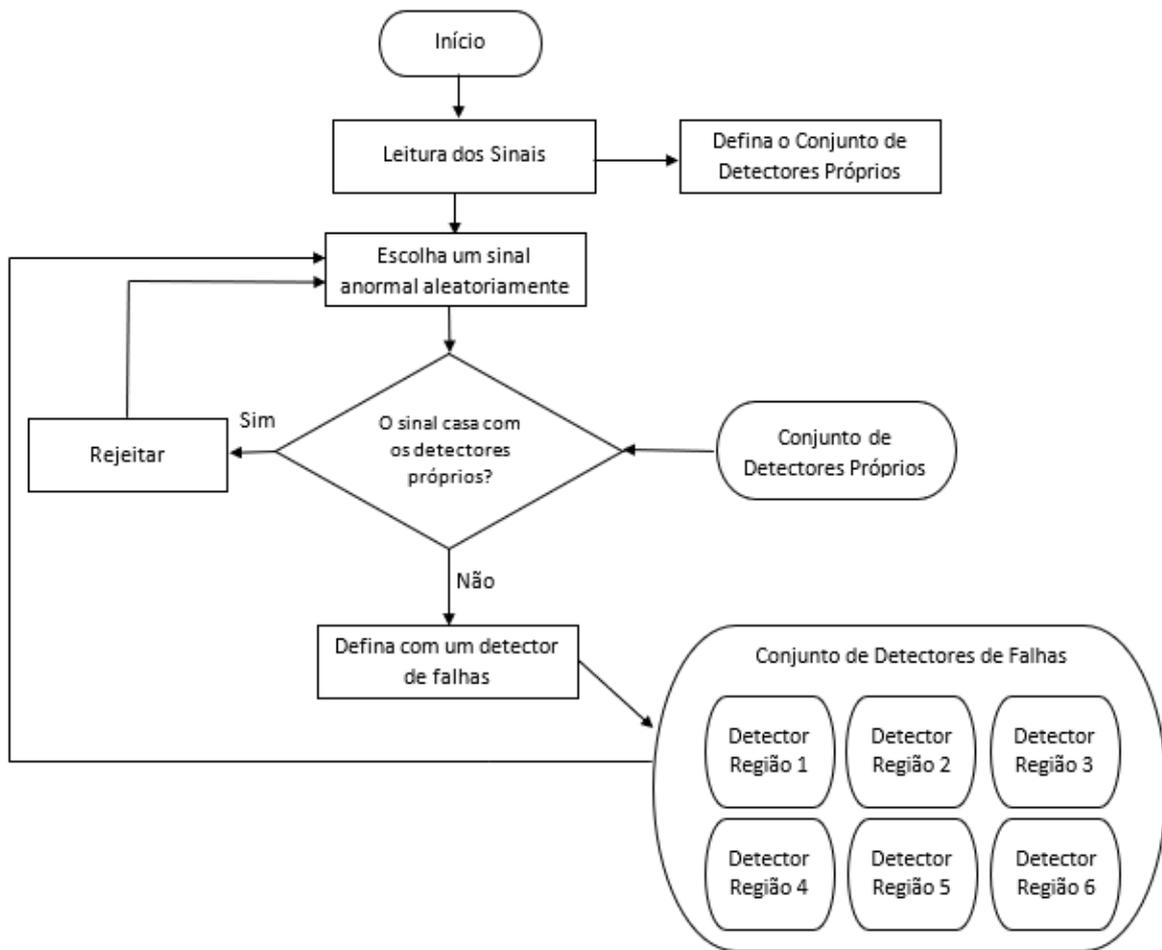
Posteriormente, usando os sinais anormais, separados por tipo de falha (uma classe de cada vez), são criados os conjuntos de detectores para os 6 tipos de falhas. Ao final do processo obtém-se os 2 conjuntos de detectores, sendo o conjunto de detectores próprios e detectores de falha. Estes conjuntos de detectores serão usados no monitoramento como conhecimento da inteligência artificial. O número de detectores da condição normal e dos tipos de falhas é definido pelo executor do programa, e geralmente é 30% dos dados totais do problema, e para este caso são os valores apresentados na Tabela 3, que representam 30% dos dados.

O fluxograma das fases de censoriamento é apresentado na Figura 9.

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 com base na discriminação próprio/não-próprio.

Caso o sinal identificado seja próprio o mesmo é classificado instantaneamente como a condição normal da estrutura. Caso contrário, o sinal representa uma condição anormal (não-próprio), desta forma, realiza-se uma avaliação deste sinal, comparando-o com o conjunto de detectores de falhas, de forma que ocorra um casamento do sinal com uma classe de detectores, o sinal é classificado com a classe do detector acionado. O monitoramento dos sinais é realizado de forma online.

Figura 9 - Fluxograma do sensoriamento do ASN.



Fonte: Autores.

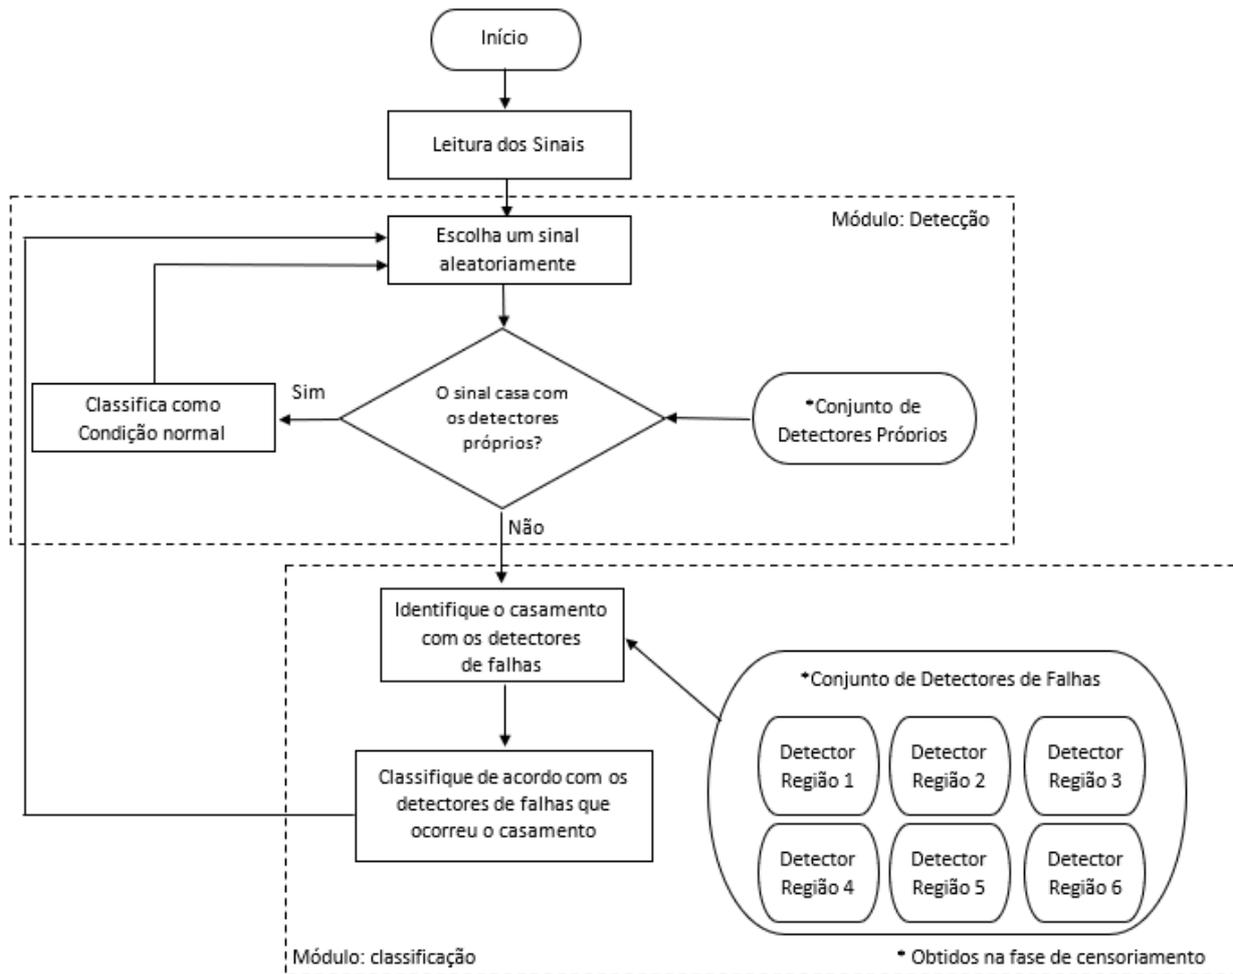
O fluxograma das fases de monitoramento é apresentado na Figura 10.

O módulo de monitoramento faz análise de 70% dos dados disponíveis. Assim para este caso, o sistema analisa 168 sinais. Estes sinais são diferentes dos usados para a fase de sensoriamento.

Na Figura 10 apresenta-se a fase de monitoramento onde são testados os sinais para o diagnóstico. Inicialmente faz-se a leitura dos sinais, posteriormente escolhe-se aleatoriamente um sinal para passar pelo módulo de detecção. Neste módulo o sinal é comparado com o conjunto de detectores próprios, caso haja o casamento entre eles, o sinal é diagnosticado como condição normal, pois há evidências de normalidade.

Caso contrário, o sinal é passado para o módulo de classificação, pois uma anormalidade foi detectada. No módulo de classificação o sinal é comparado com o conjunto de detectores de falhas e quando ocorrer o casamento, o sinal é classificado conforme o tipo de falha do detector que casou com o sinal. Assim ocorre a detecção e classificação dos sinais. Ao final o sistema apresenta o diagnóstico.

Figura 10 - Fluxograma do monitoramento do ASN.



Fonte: Autores.

4. Resultados

Nesta seção apresentam-se os resultados obtidos com a aplicação do algoritmo nos dados obtidos no experimento realizado em laboratório. O algoritmo foi desenvolvido em MATLAB®.

Nos testes realizados o objetivo foi avaliar a metodologia proposta no processo de análise e monitoramento da integridade estrutural, verificando a eficiência, precisão e o tempo computacional. Utilizou-se como parâmetro uma taxa de afinidade (TA_f) com um valor fixo de 70%.

A base de dados obtida a partir do experimento conta com 6 padrões de falhas na ponte metálica e condição normal totalizando 7 tipos de padrões distintos. Ao total foram capturados 240 sinais, sendo 120 sinais em condição normal e 20 sinais em falha para condição de falha.

Para uso no algoritmo os dados foram separados em 30% para o sensoriamento e 70% para o monitoramento. Isto é, 72 sinais para o sensoriamento, sendo 32 normais e 6 para cada tipo de falha, e 168 sinais para o monitoramento, sendo 84 normais e 14 para cada tipo de falha.

Visando testar a eficiência e robustez do algoritmo foi realizado um teste de referência cruzada executando o programa 20 vezes e os resultados são apresentados na Tabela 4.

Tabela 4 - Resultados obtidos pelo método.

| Banco de dados | Monitoramento | Acerto (%) | Tempo (ms) |
|-------------------|---------------|------------|------------|
| Amostras testadas | 168 | 100% | 120,4 |
| Sinais normais | 84 | 100% | |
| Falha região 1 | 14 | 100% | |
| Falha região 2 | 14 | 100% | |
| Falha região 3 | 14 | 100% | |
| Falha região 4 | 14 | 100% | |
| Falha região 5 | 14 | 100% | |
| Falha região 6 | 14 | 100% | |

Fonte: Autores.

Os valores apresentados na Tabela 4, representam os resultados do teste cruzado que foi realizado, ao executar 20 vezes o sistema, a fim de garantir a veracidade dos resultados. É possível observar que o sistema de análise da integridade estrutural da ponte metálica apresenta um desempenho excelente, com índice de acerto de 100%. E em todas as vezes que o programa foi executado o resultado foi o mesmo.

Assim, destaca-se a eficiência do algoritmo proposto e ressalta-se que o tempo apresentado na Tabela 4, representa a média de tempo gasto para analisar e processar cada sinal.

4.1 Comparação com a Literatura

Nesta seção apresenta-se um estudo comparativo com os resultados de outros autores. Para esta comparação, levou-se em consideração a acurácia total das metodologias de detecção e classificação de falha estrutural.

A Tabela 5 mostra a comparação entre o acerto total obtido pelo método proposto e os principais métodos disponíveis na literatura.

Tabela 5 – Estudo Comparativo.

| Referência | Tipo de Dados | Técnica Usada | Acerto (%) |
|--------------------------------|---------------|----------------------------------|------------|
| (Roseiro et al., 2005) | Experimental | Multilayer Perceptron | 98,52 |
| (Chandrashekar; Ganguli, 2009) | Simulado | Fuzzy | 98,74 |
| (Wang et al., 2013) | Experimental | Algoritmo Genético Multiobjetivo | 93,70 |
| (Lima et al., 2016) | Simulado | ARTMAP-Fuzzy-Wavelet | 99,52 |
| (Chavez et al., 2017) | Simulado | ARTMAP-Fuzzy | 100,00 |
| (Souza et al. 2021) | Experimental | Sistema Imunológico Artificial | 99,11 |
| Este Trabalho | Experimental | Algoritmo de Seleção Negativa | 100,00 |

Fonte: Autores.

Na Tabela 5, observa-se que o método proposto nesta pesquisa obteve um índice de acerto alto (100%) e quando comparado a outros métodos, apresentam resultados semelhantes. É importante ressaltar que a partir da comparação dos resultados obtidos, fica claro que uma aplicação em um problema real terá uma boa eficiência, mas vale ressaltar que ao utilizar dados experimentais já corrobora esta afirmação.

Conforme apresentado na Tabela 5, o trabalho de (Roseiro et al., 2005) aplica uma técnica de Multilayer Perceptron a placas de compósito laminado em estruturas aeronáuticas, utilizando dados experimentais. Já o trabalho de (Chandrashekar; Ganguli, 2009) aplica a técnica de lógica fuzzy para identificação de falhas em construção civil. O trabalho de (Wang et al., 2013) aplica a técnica de algoritmo genético multiobjetivo para diagnóstico de falhas estruturais em pontes de treliça. Em (Lima et al., 2016) é aplicada a técnica de uma rede neural ARTMAP-Fuzzy-Wavelet para identificação de falhas em um edifício. Em (Chavez et al., 2017) aplicou-se uma rede neural ARTMAP-Fuzzy para dados simulados a partir de um modelo numérico de um edifício. No trabalho de (Souza et al., 2021) foi aplicada a técnica de Sistemas Imunológicos Artificiais para

diagnóstico de falhas em uma viga metálica.

Assim, pode-se constatar que dentre os trabalhos selecionados para o estudo comparativo, destaca-se a aplicação das técnicas de inteligência artificial. Isto se deve, ao desempenho e eficiência de tais técnicas.

Desta forma, o trabalho proposto foi comparado com os principais trabalhos disponíveis na literatura, que apresentam dados de acurácia em seus resultados, e conforme ressaltado anteriormente os resultados são excelentes e semelhantes aos disponíveis nos melhores trabalhos da literatura.

Por fim, conforme destacado por Lima et al. (2013), o algoritmo de seleção negativa é uma técnica de inteligência artificial que quando aplicada a problemas de reconhecimento de padrões, sempre apresenta bons resultados. Isto se deve a sua natureza biológica.

5. Conclusão

Neste artigo foi apresentada uma nova abordagem para desenvolver um sistema de análise da integridade estrutural de uma ponte metálica, no qual empregou-se um algoritmo imunológico artificial de seleção negativa, que apresentou excelentes resultados, obtendo um índice de acerto de 100% para a melhor configuração do sistema. A fase de geração de detectores (sensoriamento) demanda maior tempo computacional, no entanto não prejudica o algoritmo, pois é executada de forma off-line. O monitoramento do sistema, a partir da aquisição dos sinais, é realizado rapidamente, com tempo inferior a 120 milésimos de segundo, isto possibilita a aplicação do algoritmo em problemas que seja necessário tomar decisões em tempo real.

Desta forma, conclui-se que o algoritmo proposto neste artigo é bastante eficiente, confiável, robusto e preciso para realizar a análise da integridade estrutural de pontes metálicas. Ressalta-se que o algoritmo imunológico artificial utilizado apresentou facilidade na detecção e classificação das falhas estruturais, isto devido a sua capacidade de análise ponto-a-ponto. Este artigo contribui para esta linha de pesquisa, apresentando um novo método para analisar falhas em estruturas prediais utilizando técnicas baseadas em sistemas inteligentes.

5.1 Sugestões para Trabalhos Futuros

Como sugestões para trabalhos futuros tem-se os seguintes tópicos:

- Aplicar o SHM proposto no monitoramento e análise de falhas em outros problemas, tais como: edifícios e estruturas aeronáuticas;
- agregar um módulo wavelet ao SHM proposto para realizar um pré-processamento nos sinais do banco de dados, visando realizar o diagnóstico no mundo wavelet;
- investigar a possibilidade de aplicação do SHM proposto em ambiente de caráter antecipatório;
- aplicar o conceito de aprendizagem contínua, proporcionando que novas falhas estruturas sejam contempladas, sem a necessidade de reiniciar o processo de aprendizado, ou seja, capacitar o sistema em caráter adaptativa.

Referências

- Bradley, D. W., & Tyrrell, A. M. (2002). Immunotronics - Novel Finite-State-Machine Architectures with Built-In Self-Test Using Self-Nonself Differentiation. *IEEE Trans. on Evolutionary Computation*, 6 (3), 227-238.
- Chandrashekhar, M., & Ganguli, R. (2009). Structural damage detection using modal curvature and fuzzy logic, *Structural Health Monitoring*, 8 (1), 267-282.
- Chavarette, F. R., et al. (2021). Reconhecimento de falhas estruturais utilizando sistema imunológico artificial Wavelet. *Colloquium Exactarum*, 12 (1), 82-88.
- Chaves, J. S., Lopes, M. L. M., Chavarette, F. R., & Lima, F. P. A. (2017). Rede Neural Artificial ARTMAP-Fuzzy Aplicada no Reconhecimento de Falhas Estruturais. *Revista Iberoamericana de Ingeniería Mecánica*, 21 (1), 03-11.

- Doebling, S. W., Farrar, C., Prime, M. B., & Shevitz, D. W. (1996). Damage Identification and Health Monitoring of Structural and Mechanical Systems from Changes in their Vibration Characteristics: A Literature Review.
- Espion, B. (2012). The Vierendeel bridges over the Albert Canal, Belgium – their significance in the story of brittle failures. *Steel Construction*, 5 (1), 1-6.
- Franco, V. R. (2009). *Monitoramento da integridade de estruturas aeronáuticas*. 2009. 205 f. Dissertação (Mestrado em Engenharia Mecânica) - Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira.
- Forrest, S., Perelson, A., Allen, L., & Cherukuri, R. (1994). Self-Nonself Discrimination in a Computer, *Proc. of IEEE Symposium on Research in Security and Privacy*. 202-212.
- Gonçalves, D. R., Moura Junior, J. R. V., & Pereira, P. E. C. (2020). Monitoramento de integridade estrutural baseado em impedância eletromecânica utilizando o método de krigagem ordinária. 36 (2).
- Gonzalez, C. G. (2012). *Metodologias para reconhecimento de padrões em sistemas de SHM utilizando a técnica da impedância eletromecânica (EM)*. 2012. 117 f. Dissertação (Mestrado em Engenharia Mecânica) - Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira.
- Hall, S. R. (1999). The effective management and use of structural health data. *Proc. of International Workshop on Structural Health Monitoring*, VirginiaTech Publisher, 265-275.
- Lima, F. P. A. (2014). *Monitoramento e Identificação de Falhas em Estruturas Aeronáuticas e Mecânicas Utilizando Técnicas de Computação Inteligente*. 2014. 72 f. Dissertação (Mestrado em Engenharia Mecânica) - Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira.
- Lima, F. P. A., Lotufo, A. D. P., & Minussi, C. R. (2013). Artificial Immune Systems Applied to Voltage Disturbance Diagnosis in Distribution Electrical Systems, *PowerTech-2013*, Grenoble, France, 1-6.
- Lima, F. P. A., & Souza, S. S. F. (2016). Rede neural artificial ARTMAP-Fuzzy-Wavelet aplicada no reconhecimento de falhas estruturais. *Revista Engenharia em Ação UniToledo*, Araçatuba, SP, 1 (1), 36-53.
- MATLAB 7.8 version, Mathworks Company.
- Meireles, A. P. C. (2010). *Levantamento e diagnóstico de uma ponte metálica antiga*. 2010. Dissertação (Mestrado Integrado em Engenharia Civil) - Faculdade de Engenharia da Universidade do Porto, Porto, Portugal.
- Mundo Educação. <<https://mundoeducacao.uol.com.br/fisica/ponte-tacoma-narrows.htm>>.
- Oliveira, D. C., Chavarette, F. R., & Outa, R. (2020). Monitoramento de integridade estrutural de um rotor utilizando algoritmos de sistemas imunológicos artificiais com seleção negativa e seleção clonal. *Research, Society and Development*, 9 (7).
- Palaia, L. (2007). Structural Failure Analysis of timber floors and roofs in ancient buildings at Valencia (Spain). *Proc. of International Conference on Mechanical Behavior and Failures of the Timber Structures*, Florence, 1–11.
- Roseiro, L., Ramos, U., & Leal, R. (2005). Neural Networks in Damage Detection of Composite Laminated Plates, *Proc. of the 6th International Conference on Neural Networks*, 115-119.
- Silva, S., Dias Júnior, M., & Lopes Júnior, V. (2008). Structural health monitoring in smart structures through time series analysis. *Structural Health Monitoring*, London, 7 (3), 231-244.
- Souza, S. S. F., Campos, M. B. P., Chavarette, F. R., & Lima, F. P. A. (2021). A New Approach Experimental to Diagnosis of The Failures in Mechanical Structures Using the Artificial Immune Algorithm with Negative Selection. *Brazilian Journal of Development*, 7 (1), 66372-66392.
- Tebaldi, A., Coelho, L. S., & Lopes Junior., V. (2006). Detecção de falhas em estruturas inteligentes usando otimização por nuvem de partículas: fundamentos e estudo de casos. *Revista Controle & Automação*, São Paulo, 17 (3), 312–330.
- Vitório, J. A. P. (2021). Uma análise das falhas estruturais em Obras de Arte Especiais. *Proc. of XII Congresso Brasileiro de Pontes e Estruturas (CBPE)*. Universidade de Pernambuco.
- Xiang-Jun, C., Zhan-Feng, G., & Qiang, G. (2010). Application of wavelet analysis in vibration signal processing of bridge structure. *Proc. of International Conference on Measuring Technology and Mechatronics Automation*, VirginiaTech Publisher, 671–674.
- Wang, F. L., Chan, T. H. T., Thambiratnam, D. P., & Tan, A. C. C. (2013). Damage diagnosis for complex steel truss bridges using multi-layer genetic Algorithm. *Journal of Civil structural Health Monitoring*, Inglaterra, 3 (2), 117–217.