

Monitoramento de integridade estrutural em rotores dinâmicos usando inteligência artificial com aprendizado continuado

Monitoring structural integrity in dynamic rotors using artificial intelligence with continuous learning

Monitoreo de la integridad estructural en rotores dinámicos mediante inteligencia artificial con aprendizaje continuo

Recebido: 23/05/2023 | Revisado: 29/05/2023 | Aceitado: 30/05/2023 | Publicado: 04/06/2023

Robson Aparecido Ferreira

ORCID: <https://orcid.org/0000-0002-1203-7566>

Instituto Federal do Mato Grosso, Brasil

E-mail: robsonferreira493@gmail.com

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

Fernando Parra dos Anjos Lima

ORCID: <https://orcid.org/0000-0001-8671-1476>

Instituto Federal do Mato Grosso, Brasil

E-mail: fernando.lima@ifmt.edu.br

Resumo

Este artigo tem por objetivo o desenvolvimento de um algoritmo de inteligência artificial com aprendizado continuado, inspirado no funcionamento do sistema imunológico biológico, para realizar o monitoramento da integridade estrutural. Este algoritmo inteligente será desenvolvido empregando-se técnicas baseadas nos sistemas imunológicos artificiais (SIA), como o algoritmo de seleção negativa (ASN) e o algoritmo de seleção clonal (ASC). Os SIAs são técnicas promissoras no campo da inteligência artificial, e sua concepção é inspirada nos sistemas imunológicos biológicos, com o objetivo de reproduzir computacionalmente, suas principais características, propriedade, funcionalidades e habilidades. Os sistemas imunológicos artificiais constituem-se de poderosas ferramentas adequadas para realizar tarefas complexas, como diagnósticos, em consequência de ter como principal habilidade a capacidade de identificar mudanças comportamentais. Por ser uma arquitetura estável, confiável e adaptativa, permite a inclusão do módulo de aprendizagem continuada, o qual possibilita que o sistema absorva novas experiências e conhecimento sem a necessidade de reiniciar as células de memória (conhecimento). Deste modo, este sistema se tornará mais eficiente à medida que novas informações são processadas e disponibilizadas. Ou seja, trata-se de um sistema inteligente que busca o aperfeiçoamento com o passar o tempo. Está propriedade é uma vantagem dos SIAs, e deve ser destacada, pois, diferentemente do que ocorre com outras técnicas de inteligência artificial, como, por exemplo, as redes neurais artificiais (RNA), os SIA permitem a possibilidade da aprendizagem de forma contínua.

Palavras-chave: Monitoramento da integridade estrutural; Rotores dinâmicos; Sistemas imunológicos artificiais; Algoritmo de seleção negativa; Algoritmo de seleção clonal; Aprendizado continuado.

Abstract

This paper aims to develop an artificial intelligence algorithm with continuous learning, inspired by the functioning of the biological immune system, to monitor structural integrity. This intelligent algorithm will be developed using techniques based on artificial immune systems (AIS), such as the negative selection algorithm (NSA) and the clonal selection algorithm (ASC). SIAs are promising techniques in the field of artificial intelligence, and their design is inspired by biological immune systems, with the aim of computationally reproducing their main characteristics, properties, functionalities and abilities. Artificial immune systems are powerful tools suitable for performing complex tasks, such as diagnoses, as a result of having the ability to identify behavioral changes as their main ability. Because it is a stable, reliable and adaptive architecture, it allows the inclusion of the continuous learning module, which allows the system to absorb new experiences and knowledge without the need to restart the memory cells (knowledge). In this way, this system will become more efficient as new information is processed and made available. In other words, it is an intelligent system that seeks improvement over time. This property is an advantage of SIAs, and it should be highlighted because, unlike what happens with other artificial intelligence techniques, such as, for example, artificial neural networks (ANN), SIAs allow the possibility of continuous learning.

Keywords: Structural integrity monitoring; Dynamic rotors; Artificial immune systems; Negative selection algorithm; Clonal selection algorithm; Continuing learning.

Resumen

Este artículo tiene como objetivo desarrollar un algoritmo de inteligencia artificial con aprendizaje continuo, inspirado en el funcionamiento del sistema inmunológico biológico, para monitorear la integridad estructural. Este algoritmo inteligente se desarrollará utilizando técnicas basadas en sistemas inmunes artificiales (AIS), como el algoritmo de selección negativa (NSA) y el algoritmo de selección clonal (ASC). Los SIA son técnicas prometedoras en el campo de la inteligencia artificial, y su diseño está inspirado en los sistemas inmunes biológicos, con el objetivo de reproducir computacionalmente sus principales características, propiedades, funcionalidades y habilidades. Los sistemas inmunológicos artificiales son herramientas poderosas adecuadas para realizar tareas complejas, como diagnósticos, como resultado de tener la capacidad de identificar cambios de comportamiento como su principal habilidad. Por ser una arquitectura estable, confiable y adaptativa, permite la inclusión del módulo de aprendizaje continuo, que permite que el sistema absorba nuevas experiencias y conocimientos sin necesidad de reiniciar las celdas de memoria (conocimiento). De esta manera, este sistema será más eficiente a medida que se procese y se ponga a disposición nueva información. En otras palabras, es un sistema inteligente que busca mejorar con el tiempo. Esta propiedad es una ventaja de las SIA, y cabe destacarla porque, a diferencia de lo que ocurre con otras técnicas de inteligencia artificial, como por ejemplo las redes neuronales artificiales (ANN), las SIA permiten la posibilidad de un aprendizaje continuo.

Palabras clave: Monitoreo de integridad estructural; Rotores dinámicos; Sistemas inmunes artificiales; Algoritmo de selección negativa; Algoritmo de selección clonal; Aprendizaje continuo.

1. Introdução

O conceito inicial da revolução industrial teve início com motores a vapor alternativos, elaborados por James Watt em 1780, considerado um sistema dinâmico rotativo e, atualmente, o conceito deste sistema é aplicado em aeronaves, veículos automotivos, motores, entre outros. Diferentes técnicas foram desenvolvidas para que, nos dias atuais, as indústrias que utilizam os sistemas rotativos possam produzir produtos de alta qualidade a baixo custo. Com a introdução do conceito da indústria 4.0, o conceito de automação em processos ficou mais evidente e forte, com isso, técnicas para a detecção de danos e falhas, em estruturas dinâmicas tiveram que ser introduzidas na indústria (Deraemaeker & Worden, 2010; Farrar & Worden, 2013).

O monitoramento da integridade estrutural se consiste em detectar falhas em estados incipientes, intervir na sua propagação e, conseqüentemente, impedir que ocorra a parada ou danificação da estrutura. Está atual e importante linha de pesquisa é denominada monitoramento da integridade estrutural (SHM – Structural Health Monitoring). Conforme destacado em (Hall, 1999), um SHM deve satisfazer os requisitos e tarefas como: realizar a aquisição e processamento de dados; validação e análise de sinais; identificação e caracterização de falhas; interpretação de mudanças adversas em uma estrutura e auxiliar a tomada de decisões.

As falhas estruturais podem ocorrer em consequência de diversos danos na estrutura, tais como: desgaste de componentes; corrosões; cortes; trincas; afrouxamento de uniões aparafusadas; delaminações; aderência de massas (incrustações) ou a combinação destes elementos (Gonzalez, 2012). Na grande maioria dos casos, independente da origem ou intensidade, a concentração destes danos em uma estrutura pode desencadear uma falha estrutural e comprometer o funcionamento da estrutura.

Em um sistema rotativo dinâmico é possível observar dois princípios físicos de falhas, sendo um deles o deslocamento lateral do eixo, e o outro o efeito giroscópico. Estes dois fenômenos são representados por um modelo matemático e podem ter seu comportamento descritos pelo conceito de vibração, que fisicamente falando é retratado como velocidades ou aceleração em direções de vibração. E a partir da vibração pode-se implementar sistemas para diagnosticar e prever o que uma falha pode provocar na estrutura.

As falhas estruturais podem provocar uma sensível variação nos parâmetros espaciais da estrutura, ocasionando redução da rigidez estrutural, redução da massa e também o aumento do amortecimento, o que modifica o comportamento dinâmico da estrutura (Turra et al., 2013). Esta variação dos parâmetros espaciais afeta os principais parâmetros dinâmicos, tais como funções de respostas, frequências de ressonância, razão de amortecimento e modos próprios da estrutura (Zheng et al.,

2004).

Visando contornar estes problemas, toda estrutura, antes de ser colocada em uso, passa por uma avaliação e testes de integridade estrutural. Neste caso são realizadas avaliações não-destrutivas (NDE), visando estimar o grau de segurança e confiabilidade da estrutura. Para isto, existem técnicas tradicionalmente utilizadas como: inspeção ultrassônica, radiografia-X, testes de emissão acústica, entre outras técnicas.

As técnicas tradicionais podem até possuir um bom aparato instrumental e serem bem formuladas para avaliação da integridade estrutural, no entanto, estas técnicas não conseguem satisfazer necessidades crescentes da indústria, ainda mais, quando as estruturas estão em movimento (Franco et al., 2009). Desta forma, os sistemas de monitoramento de integridade estrutural veem sofrendo uma evolução natural, devido ao avanço das tecnologias de sensores, materiais inteligentes, técnicas eficientes de processamento de dados e sinais, e principalmente a crescente demanda de se empregar tais ferramentas em tempo real, como é o caso das aeronaves, tratores, entre outras estruturas.

Neste contexto, uma possível solução, para se desenvolver SHMs modernos e eficientes é a utilização de sensores inteligentes e/ou técnicas de computação inteligentes (redes neurais artificiais (Haykin, 2008; Kartalopoulos, 1996), lógica fuzzy (Zadeh, 1995), sistemas imunológicos artificiais (Castro & Timmis, 2002; Dasgpta, 1998), Santos et al., 2022; Souza et al., 2022a; Souza et al., 2022b), que viabilizam habilidades como a extração de conhecimentos e informações de processos complexos, facilitam a análise de sinais e proporcionam a automatização da tomada de decisões nos SHMs.

Neste sentido, um completo e abrangente sistema, que realize o monitoramento das falhas, deve ser concebido, com o propósito de detectar e classificar diversos tipos de falhas de maneira rápida e eficiente levando em consideração o dinamismo inerente da indústria estrutural.

Basicamente, o sistema inteligente, com o aprendizado continuado, pode ser dividido em seis etapas: (1) aquisição de dados e extração das características do estado operativo da estrutura, (2) módulo detector de novidades, (3) módulo de aprendizado continuado, (4) módulo detector de anormalidades, (5) módulo classificador de defeitos e (6) módulo de atualização de conhecimento. Na primeira etapa será realizado um experimento em laboratório com uma máquina rotativa, nos quais serão simulados eventos de falhas estruturais. Nesta etapa, a partir de um sistema de aquisição de dados realiza-se a captura dos sinais de vibração provenientes de sensores (acelerômetros e giroscópios) alocados na estrutura. Na segunda etapa, ao analisar um sinal, executa-se o módulo de detecção de novidades, onde é realizada uma verificação do sinal em relação ao conjunto de células (conhecimento). Após verifica se o sinal pode ser considerado conhecido ou desconhecido pelo sistema. Caso o sinal já seja conhecido pelo sistema ele é analisado, da forma convencional, avançando-se a etapa 4. Em caso contrário, o sinal é considerado uma novidade. Quando o sistema identifica uma novidade a etapa de aprendizado continuado (3) é acionada com o objetivo de apreender sobre este novo padrão desconhecido pelo sistema, fornecendo conhecimento ao sistema, para que em uma próxima análise do mesmo tipo de padrão desconhecido o sistema seja capaz de efetuar o reconhecimento e classificação desta falha estrutural. Este processo é o denominado aprendizado continuado, e é realizado pelo ASC (Castro & Timmis, 2002; Castro, 2001, Lima, 2016).

Na etapa 4, executa-se o módulo detector de anormalidades, onde se realiza a análise dos sinais visando identificar comportamentos anormais no sistema. Para esta etapa, emprega-se o ASN (Forrest, et al., 1994). A aplicação deste conceito terá como principal objetivo a busca por anormalidades características que possam identificar a ocorrência de uma falha estrutural. Após identificar uma possível falha, na etapa 5, utilizando também o conceito imunológico do ASN, classificará tal evento. Adicionalmente, existe o módulo de atualização de conhecimento (6), que tem por função, avaliar se existe a necessidade de atualizar o conjunto de células (conhecimento), visando melhorar o processo de detecção e classificação de falhas estruturais.

Os Sistemas imunológicos artificiais (Castro, 2001; Dasgupta, 2006) possuem características que permitem sua


aplicação em modernos sistemas de diagnóstico, proporcionando estabilidade e plasticidade. A estabilidade é a capacidade de aprender por meio da experiência e a plasticidade é a capacidade de continuar a aprender via inclusão de novos padrões sem perder o conhecimento previamente adquirido. Ou seja, este é o grande diferencial dos sistemas imunológicos artificiais, em relação às redes neurais artificiais, pois podem realizar a aprendizagem de forma contínua, o que é conhecido também como treinamento continuado em redes neurais (Barros, 2014, Marchiori et al., 2011). Na maioria das redes neurais, a inclusão de um novo padrão de treinamento requer a reinicialização do processo, destruindo o conhecimento previamente adquirido. Os sistemas imunológicos podem proporcionar qualidade nos resultados e permitem a adaptação automática do sistema de diagnóstico à constante evolução do setor industrial, requisitos essenciais para o desenvolvimento de SHMs modernos.

2. Bancada Experimental

Para o desenvolvimento deste estudo, utilizou-se uma bancada experimental (Figura 1), construída com base no projeto de Heney Homan Jeffcott (1919). A bancada é composta pelos equipamentos descritos a seguir:

- 1- Inversor de frequência Schneider Altivar 312 com alternância de 0 a 60 Hz;
- 2- Motor elétrico de 2 HP e 60 Hz de frequência;
- 3- Acoplamento flexível Rex Omega (Standard);
- 4- Mancal de bomba d'água Mark adaptado;
- 5- Disco de aço com 48 furos divididos em duas camadas;


Figura 1 - Bancada Experimental.



Fonte: Autores.

Para coleta de dados, utilizou-se um sensor acelerômetro MPU6050 de três eixos, na posição indicada na Figura 2 (a) e um microcontrolador modelo Arduino UNO, Figura 2 (b).

Figura 2 - Sensor MPU6050 e Arduino UNO.




(a)

(b)

Fonte: Autores.

Na etapa de aquisição e monitoramento de dados, foram realizados dois testes, um deles com o disco livre de desbalanceamento (Figura 3 (a)), sendo a condição normal, e no outro com duas medidas de desbalanceamento (conjunto composto por 2 parafusos, porcas e arruelas.), com 10 g cada, nas posições indicadas na Figura 3 (b), sendo essa a condição em falha. Nesses testes foram observados o comportamento da estrutura em três frequências, sendo elas 10Hz, 30Hz e 60Hz.

Figura 3 - Bancada Experimental.



Fonte: Autores.

Para cada condição experimentada foram coletados 50 sinais de aceleração, e posteriormente aplicou-se a transformada rápida de Fourier (FFT), gerando-se uma base de dados de sinais de vibração do rotor em condição normal e falha. A configuração da base de dados é apresentada a seguir:

Tabela 1 - Configuração da base de dados.


Condição	Número de Sinais
Normal	50
Falha 10 Hz	50
Falha 30 Hz	50
Falha 60 Hz	50
Total	200

Fonte: Autores.

3. Sistema Imunológico Biológico (SIB)

O SIB é a principal defesa do organismo contra diversos agentes infecciosos que invadem o corpo humano. Neste caso, o SIB deve agir imediatamente, reagir eficazmente contra os intrusos e identificá-los para proteger o corpo humano da ameaça (prova de doença). Um organismo biológico, especialmente o humano, é constituído por várias células e moléculas que funcionam harmoniosamente e tendem a reagir a fatores estranhos encontrados no organismo, os chamados aos antígenos. O SIB tem funções essenciais, como reconhecimento de padrões, aprendizado e neutralização de patógenos. Todas essas etapas constituem uma resposta imunológica, que pode ser ilustrada de forma simplificada na Figura 4 (Castro; Timmis, 2002; Dasgupta, 1998).

Figura 4 - Funcionamento do SIB.



Fonte: Autores.

A etapa (I) representa a exposição do SIB ao antígeno (agente infeccioso). Basicamente, o SIB pode responder com dois tipos de respostas, a resposta imune inata iniciada na fase (II) e a resposta imune adaptativa iniciada na fase (VII). Quando o processo é iniciado pelo sistema imune inato (fase (II)), o agente infeccioso é considerado a causa desconhecida da SIB e, portanto, deve ser reconhecido pela célula infectada e sinalizado ao organismo para que o sistema imune adaptativo aja. A resposta inicia uma resposta adaptativa (aprende e produz anticorpos para neutralizar o antígeno). Quando o processo é desencadeado pelo sistema imune adaptativo (fase (VII)), o SIB reconhece o antígeno e os linfócitos de memória do organismo realizam o processo de reconhecimento (Castro; Timmis, 2002; Dasgupta, 1998). Na fase II, o processo imune inato se inicia quando uma célula dendrítica (APC - célula apresentadora de antígeno) engole um antígeno (agente infeccioso). Nesta fase, os antígenos são clivados, fragmentados em peptídeos antigênicos. Os fragmentos peptídicos da fase (III) se ligam às moléculas do MHC (Major Histocompatibility Complex) e estão localizados na superfície da célula dendrítica.

Então, na etapa (IV), os linfócitos T com moléculas receptoras em sua superfície podem reconhecer/identificar os diferentes antígenos/peptídeos MCH processados pelas células dendríticas, ou seja, quando ocorre a ligação (combinação), ocorre o reconhecimento. antígeno e, assim, o estado do linfócito muda para um estado de ativação. Essa etapa representa a diferenciação auto/não auto do organismo, que separa suas células dos agentes infecciosos (Castro; Timmis, 2002; Dasgupta, 1998). Com base nesse princípio de reconhecimento de padrões, o ASN foi proposto. Após o reconhecimento do antígeno na fase (V), os linfócitos T são ativados, secretando sinais químicos (linfocinas) que sinalizam para outros componentes do SIB que o antígeno foi encontrado ou simplesmente que a célula está infectada. Ao sinalizar para a célula infectada (fase (VI)), os linfócitos do tipo B podem reconhecer a célula infectada e iniciar o aprendizado ou princípio mais conhecido de seleção clonal (fase (VII)). Nesse caso, os linfócitos B podem reconhecer antígenos livres que são sinalizados no corpo sem serem ingeridos e digeridos pelas células apresentadoras (APCs) e, assim, ocorre o reconhecimento.

Quando as células B reconhecem um antígeno (por meio de células de sinalização ou de memória), inicia-se um processo de seleção clonal, também conhecido como aprendizado (fase (VIII)). Nesta fase, os linfócitos passam por um processo de clonagem e hipermutação, resultando na formação de alguns linfócitos B no organismo. Em seguida, ocorre um

processo de diferenciação (fase (IX)), onde os linfócitos B de alta afinidade são separados em um grupo de memória e os linfócitos B de baixa afinidade são ativados e se tornam plasmócitos (fase (X)), que secretam anticorpos. Os anticorpos criados na etapa (XI) neutralizam os antígenos detectados pelo SIB, resultando na destruição da ameaça (doença). Na fase (XII) do processo de diferenciação, os linfócitos diferenciados tornam-se linfócitos de memória e passam a fazer parte dos linfócitos de memória, substituindo os antigos linfócitos de baixa afinidade. Novos linfócitos de memória começam a circular por todo o corpo, proporcionando uma resposta eficaz e rápida a futuras exposições ao mesmo tipo de antígeno (agente infeccioso).

Ressalte-se que todo o processo é realizado em colaboração entre as células que compõem o SIB, sendo que cada uma delas é responsável por uma função relativamente simples e no total realiza um trabalho bastante complexo (Castro; Timmis, 2002; Dasgupta, 1998).

4. Algoritmo de Seleção Negativa (ASN)

Um algoritmo de seleção negativa (ASN) foi proposto para detectar mudanças em sistemas de computação (Forrest et al., 1994). É inspirado na seleção negativa de linfócitos T no timo, que representa a análise que o corpo faz para distinguir entre células próprias e não próprias. Este algoritmo funciona em duas etapas conforme descrito por Forrest et al., (1994); Lima e outros, (2013):

1. Censoriamento

a) Determine seu conjunto de correntes (S) que deseja proteger;
b) Gere cadeias aleatórias e avalie a afinidade entre elas e suas próprias cadeias (Match). Se a afinidade for maior que o limite especificado, a string deverá ser rejeitada. Caso contrário, ele deve ser armazenado na matriz de ponteiros (R).

2. Monitoramento

a) Dado um conjunto de cadeias protegidas, estime a afinidade entre cada cadeia e os detectores. Se a afinidade for maior que um limite predeterminado, um elemento inadequado é detectado. Na fase de censura do ASN, os próprios detectores são inicialmente definidos, representando o estado normal do problema, ou seja, os circuitos certos (S). O objetivo desta etapa é criar um conjunto de padrões detectores (R) que tenham a capacidade de detectar qualquer padrão inapropriado na etapa de rastreamento de dados. Na fase de monitoramento, os dados são monitorados para detectar mudanças no comportamento das amostras e classificar essas mudanças usando os detectores criados na fase de censura. Assim, analisando as cadeias protegidas (S) e comparando-as com um conjunto de detectores (R), avalia-se a afinidade entre cada cadeia. Se a afinidade for maior que um determinado limite, um elemento não próprio é detectado e classificado.

Um critério chamado equivalência é usado para avaliar a afinidade entre as cadeias e garantir sua similaridade. O casamento pode ser total ou parcial. Neste artigo, optamos por utilizar a compatibilidade parcial proposta por (Bradley, Tyrrell, 2002), onde a razão de afinidade representa o grau de similaridade que deve existir entre duas cadeias analisadas para confirmar a compatibilidade.

A relação de afinidade é definida pela seguinte equação (Bradley, Tyrrell, 2002):

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

sendo:

Af : taxa de afinidade;

An : número de cadeias normais;

At : número de cadeias total.

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;

Pc : posição casada;

$\sum_{i=1}^L Pc$: 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.

5. Algoritmo de Seleção Clonal

O algoritmo de seleção clonal, CLONALG (*Clonal Selection Algorithm*), foi proposto originalmente em Castro; Zuben, (2000). O algoritmo CLONALG para problemas de reconhecimento de padrões e aprendizagem pode ser descrito conforme os passos a seguir (Castro; Zuben, 2000; Castro, 2001):

Passo I: Inicialização: gere uma população ($Ab=Ab\{M\}+Ab\{R\}$) aleatoriamente com N linfócitos para cada antígeno (Agi). N é dado por $M+R$;

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

Passo III: Seleção: os n linfócitos com maior valor de afinidade f em relação a (Agi) são selecionados para compor uma subpopulação ($Ab\{n\}$);

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

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

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

Passo VII: Re-seleção: da população madura C^* , re-selecione os n melhores linfócitos maturados compondo a subpopulação ($Ab\{n\}$). Desta subpopulação escolha os melhores linfócitos para entrarem no conjunto de memória ($Ab\{M\}$). Um linfócito entra em no conjunto de memória quando apresenta altas taxas de afinidade, podendo substituir algum linfócito de memória;

Passo VIII: Metadinâmica: substitua d anticorpos de ($Ab\{R\}$) por ($Ab\{d\}$) novos indivíduos, induzindo diversidade no repertório. Os anticorpos com menores afinidades são escolhidos para serem substituídos.

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

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

Vale ressaltar que para problemas de aprendizado o passo VIII (metadinâmica) não é executado, desta forma o parâmetro $d=0$.

6. Metodologia

Nesta seção apresenta-se a metodologia proposta para resolver o problema de monitoramento estrutural em rotores dinâmicos com um algoritmo de reconhecimento de padrões com aprendizado continuado. A estratégia metodológica utilizada para desenvolver este trabalho é a pesquisa e desenvolvimento (P&D), juntamente com análise qualitativa e quantitativa (Pereira et al., 2018). A metodologia de P&D propõe a construção de produtos, como o software desenvolvido neste trabalho. E as metodologias quali-quantitativas são utilizadas para avaliar a eficiência e qualidade do algoritmo proposto.

6.1 Base de Dados

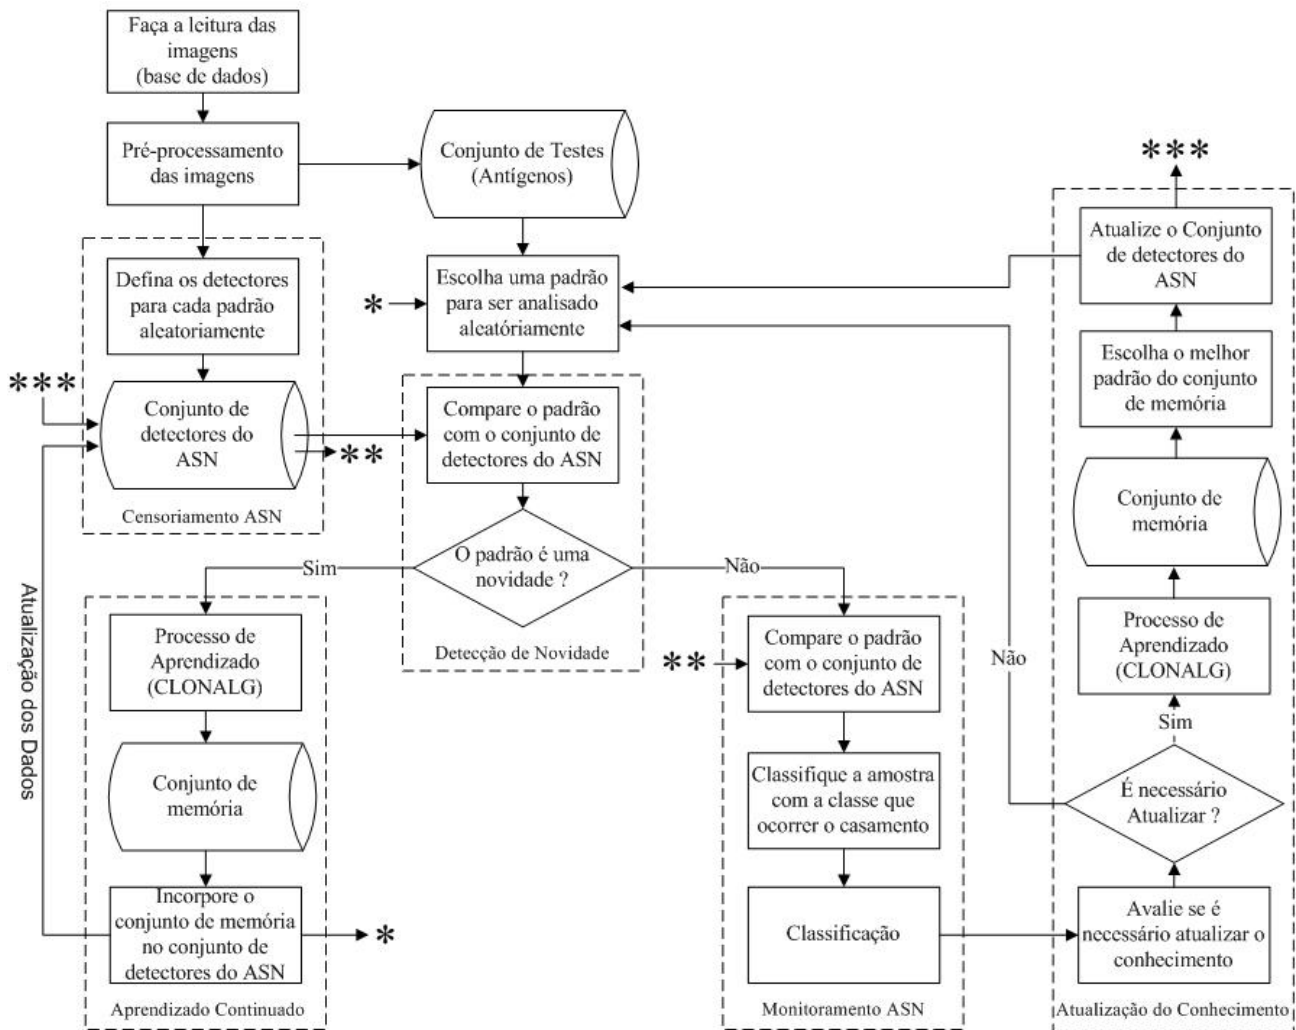
Para esta aplicação foi utilizada a base de dados obtida a partir da bancada experimental explicada na seção 2 deste trabalho. Ao total foram gerados 200 sinais, sendo 50 na condição normal, isto é, o rotor balanceado. E 150 sinais do rotor em condição em falha, sendo 50 sinais para a frequência de 10 Hz, 50 sinais para a frequência de 30 Hz e 50 sinais para a frequência de 60 Hz.

6.2 Sistema de Monitoramento com Aprendizado Continuado

O sistema de monitoramento com aprendizado continuado proposto nesta seção é inspirado no processo de reconhecimento de padrões e aprendizado realizado pelo SIB apresentado na seção 3 deste trabalho. Para formular e reproduzir computacionalmente o processo biológico apresentado anteriormente emprega-se o ASN e o CLONALG.

O sistema de monitoramento é composto por seis módulos, sendo o pré-processamento, o sensoriamento do ASN, o módulo de detecção de novidade, o módulo de aprendizado, o monitoramento do ASN e por fim o módulo de atualização de conhecimento. O diagrama de blocos deste algoritmo é apresentado na Figura 5.

Figura 5 - Funcionamento do sistema com aprendizado contínuo.



Fonte: Autores.

Conforme ilustrado na Figura 5, inicialmente realiza-se a leituras dos sinais (base de dados). Na sequência, executa-se o pré-processamento, de modo a extrair o sinal de frequência cada padrão. Em um processo off-line realiza-se o módulo de sensoriamento do ASN. Neste momento são definidos detectores para os padrões aleatoriamente. A quantidade de detectores a ser definida para cada padrão é um parâmetro e depende do operador do sistema. Todos os detectores escolhidos aleatoriamente formam o conjunto de detectores do ASN. O conjunto de detectores do ASN é utilizado no módulo de detecção de novidade e monitoramento do ASN.

Após realizar o processo em modo off-line executa-se o monitoramento em modo online. Assim, a partir da leitura dos sinais obtém-se o conjunto de testes (antígenos). Este conjunto é formado por todos os padrões disponíveis da base de dados. Na sequência escolhe-se aleatoriamente um padrão para ser analisado.

Ao escolher um padrão para ser analisado, executa-se o módulo de detecção de novidade, onde é realizada uma comparação do padrão em análise com o conjunto de detectores do ASN. Verifica-se ocorre o casamento do padrão com algum detector. Caso ocorra o casamento, o padrão em análise é conhecido pelo sistema, ou seja, não é uma novidade. Caso contrário, o padrão é considerado uma novidade, ou simplesmente, desconhecido pelo sistema.

Quando o sistema identifica uma novidade o módulo de aprendizado contínuo é acionado com o objetivo de apreender sobre o novo antígeno (padrão em análise), ocorrendo o processo de aprendizado, que é realizado pelo CLONALG.

O CLONALG tem por objetivo gerar um conjunto de memória (conhecimento) a partir de um padrão desconhecido (antígeno). Este processo segue basicamente os passos apresentados na seção 5 deste trabalho. Inicialmente define-se uma população de linfócitos que é gerada aleatoriamente. Na sequência, selecionam-se os n melhores linfócitos com maiores valores de afinidade em relação ao antígeno para o processo de clonagem e hipermutação. A mutação é um processo evolutivo, que tem por objetivo realizar pequenas modificações na estrutura dos linfócitos, de forma, que seja possível elevar a afinidade em relação ao antígeno.

Após realizar a maturação dos linfócitos, os n melhores clones maturados são re-selecionados para serem incorporados na população novamente. Os linfócitos selecionados substituem os piores linfócitos da população. Na sequência, os melhores linfócitos da população são separados para o conjunto de memória. O processo se repete até o critério de parada ser satisfeito. Para este artigo o critério de parada é quando todos os linfócitos do conjunto de memória atingem uma afinidade de no mínimo 85% com o antígeno.

Ao finalizar o processo de aprendizado o CLONALG apresenta um conjunto de memória (conhecimento) em relação ao antígeno desconhecido. Este conjunto de conhecimento é incorporado ao conjunto de detectores do ASN, fornecendo conhecimento ao sistema, para que em uma próxima análise do mesmo tipo de antígeno o sistema seja capaz de efetuar o reconhecimento. Este processo é o denominado aprendizado continuado.

Quando o módulo de detecção de novidades não identifica uma novidade, ou seja, quando o antígeno já é conhecido pelo ASN, o processo ocorre conforme o algoritmo convencional. Sendo assim, deve-se comparar o padrão em análise com o conjunto de detectores do ASN e avaliar o casamento e a afinidade, de forma que seja possível classificar o padrão de acordo com a classe que ocorrer o casamento.

Após ter classificado o padrão em análise o sistema finaliza o processo de monitoramento do ASN.

Adicionalmente existe o módulo de atualização de conhecimento, que tem por função, avaliar se existe a necessidade de atualizar o conjunto de detectores do ASN (conhecimento), visando melhorar o processo de detecção. Neste caso utiliza-se como critério o casamento dos detectores com o padrão antígeno. Caso todos os detectores se casem como o padrão antígeno não é necessário atualizar o conjunto de detectores do ASN para o padrão classificado.

Caso existam detectores do ASN que não se casem com o padrão classificado, ocorre o processo de atualização de conhecimento. Quando o ASN não consegue reconhecer o padrão com todos os detectores é necessário atualizar o conjunto de detectores do ASN, visando melhorar o processo de reconhecimento e utilizar o antígeno para aprender (obter conhecimento). Caso seja necessário atualizar o conhecimento, executa-se o processo de aprendizado realizado pelo CLONALG conforme descrito anteriormente, igual ao processo realizado no módulo de aprendizado continuado.

Após realizar o processo de aprendizado e gerar o conjunto de memória do padrão antígeno, deve-se escolher o melhor linfócito do conjunto de memória e atualizar o conjunto de detectores do ASN. A atualização se dá na substituição de um detector que não se casou com o padrão antígeno. Este detector é substituído pelo melhor linfócito do conjunto de memória gerado no processo de aprendizado realizado pelo CLONALG.

A atualização de conhecimento só ocorre quando existe a necessidade de reforçar o conhecimento do ASN, ou seja, quando algum detector não satisfaz o critério de afinidade, não se casando com o antígeno. Desta forma, este detector é substituído por um novo detector gerado em um processo de aprendizado, denominado atualização de conhecimento. O processo ilustrado na Figura 5 é repetido até que todos os antígenos sejam analisados.

O algoritmo foi desenvolvido em Python 3.11 (Python, 2022).

7. Resultados

Nesta seção apresentam-se os resultados obtidos com a aplicação da metodologia proposta na base de dados de sinais

obtidos na bancada experimental. A metodologia proposta foi avaliada, verificando-se a eficiência, precisão e robustez no processo de monitoramento de falhas estruturais. Para fazer uma comparação justa foi utilizado um algoritmo sem aprendizado e comparou-se o resultado com o aprendizado continuado. Foram utilizados os parâmetros apresentados na Tabela 2.

Tabela 2 – Parâmetros.

Parâmetros	ASN sem Aprendizado Continuado	ASN com Aprendizado Continuado
TA_f	85,00%	70,00%
N	-	12
M	-	5
R	-	6
n	-	2
β	-	0,5
ρ	-	3
d	-	0

Fonte: Autores.

Os parâmetros apresentados na Tabela 2 foram obtidos através de um processo de testes empírico. Para cada padrão adotou-se uma quantidade de detectores igual a 30%, ou 15 detectores, pois é a configuração que favorece a melhor eficiência do ASN.

Visando avaliar o desempenho dos módulos de detecção de novidade, aprendizado continuado e atualização do conhecimento no algoritmo proposto neste trabalho, foi realizada a fase de sensoriamento em ambos os sistemas (sem e com aprendizado continuado) excluindo uma falha, sendo os sinais com a frequência de 10 Hz.

Desta forma, é garantido que os algoritmos iniciam o processo de monitoramento online sem o prévio conhecimento sobre estes padrões.

Seguindo as configurações e parâmetros apresentados anteriormente, o algoritmo de reconhecimento de padrões sem o aprendizado continuado obteve os resultados apresentados na Tabela 3.

Tabela 3 – Resultados para o sistema sem aprendizado continuado.

Sinais	Padrões Testados	Padrões Acertados	Acerto (%)
Normal	50	50	100,00
Falha 10 Hz	50	0	00,00
Falha 30 Hz	50	50	100,00
Falha 60 Hz	50	49	98,00
Total	200	149	74,50

Fonte: Autores.

Pode-se observar na Tabela 3 que o sistema de reconhecimento não consegue identificar o padrão que foi excluído do processo de sensoriamento, ou seja, sem conhecimento prévio sobre o padrão, o sistema não é capaz de identificar este tipo de padrão.

Na Tabela 4 apresentam-se os resultados obtidos pelo sistema de reconhecimento de padrões com aprendizado continuado. As configurações e parâmetros são as mesmas utilizadas pelo algoritmo ASN convencional.

Tabela 4 – Resultados para o sistema com aprendizado continuado.

Sinais	Padrões Testados	Padrões Acertados	Acerto (%)
Normal	50	50	100,00
Falha 10 Hz	50	49	98,00
Falha 30 Hz	50	50	100,00
Falha 60 Hz	50	50	100,00
Total	200	199	99,50

Fonte: Autores.

Através dos resultados expressos na Tabela 4, é possível visualizar que o sistema com aprendizado continuado foi capaz de aprender sobre o padrão desconhecido, e a partir disto, identificá-lo em uma próxima análise. Também é possível observar que o módulo de atualização de conhecimento contribuiu para o ASN, de forma, que a taxa de acerto de um padrão fosse aumentada, mesmo que o sistema já tinha um conhecimento prévio sobre o padrão. Isto se deve ao fato de que o sistema atualiza o conjunto de detectores do ASN no processo de monitoramento online, proporcionando um reforço e uma melhoria no conhecimento.

Comparando as Tabelas 3 e 4 observa-se que houve uma melhoria na detecção, isto é, o sistema de reconhecimento de padrões com aprendizado continuado foi capaz de evoluir, aprendendo com a experiência, e passou a reconhecer padrões que anteriormente não eram reconhecidos. Observa-se também que o padrão excluído do processo de sensoriamento não foi reconhecido pelo primeiro sistema, apresentado 0% de acerto. Posteriormente, utilizando o sistema com aprendizado continuado, o padrão passou a ser identificado, com uma taxa de acerto de 100,00%.

8. Conclusão

Neste trabalho, foi apresentada uma nova abordagem para o desenvolvimento de um sistema de reconhecimento de padrões com aprendizado continuado inspirado no SIB. A metodologia proposta foi aplicada ao problema de monitoramento de falhas estruturais em um rotor dinâmico, um problema clássico na literatura, de forma a avaliar a sua eficiência. Visando obter parâmetros comparativos, o sistema de reconhecimento de padrões com aprendizado continuado, foi comparado com o sistema de reconhecimento convencional (ASN), ou seja, sem aprendizado continuado. Um padrão foi excluído do processo de sensoriamento de ambos os sistemas, objetivando-se avaliar o aprendizado continuado, e desta forma, o algoritmo convencional apresentou 74,5% de acerto em todos os padrões testados. Já o algoritmo de reconhecimento de padrões com aprendizado continuado apresentou 99,5% de acerto em todos os padrões. Vale ressaltar que o módulo de aprendizado continuado dotou o sistema com a capacidade de aprender continuamente, identificando os padrões desconhecidos.

Através dos resultados obtidos, observa-se que o sistema de reconhecimento de padrões com aprendizado continuado possui um desempenho (eficiência, precisão e robustez) melhor em relação ao sistema sem aprendizado continuado (ASN). Desta forma, conclui-se que o aprendizado continuado proposto neste artigo proporcionou bastante precisão, robustez e eficiência ao sistema, permitindo importantes aplicações.

Como trabalhos futuros pretende-se estender o problema abordado neste trabalho com outras técnicas computacionais, e aplicar transformada wavelet no processamento dos sinais.

Agradecimentos

Os autores agradecem ao Instituto Federal de Educação, Ciência e Tecnologia do Mato Grosso (IFMT) pelo auxílio financeiro obtido no edital da PROPES 20/2022. E também agradecem a Fundação de Amparo à Pesquisa de Mato Grosso (FAPEMAT) pela concessão de bolsa de estudo de iniciação científica.

Referências

- Barros, A. C., Tonelli-Neto, M. S., Decanini, J. G. M. S & Minussi, C. R. (2014). Detecção e Classificação de Distúrbios de Tensão em Sistemas de Distribuição de Energia Elétrica Usando uma Rede Neural ARTMAP Euclidiana Modificada com Treinamento Continuado, Anais do SBAI - Simpósio Brasileiro de Automação Inteligente, 1-6.
- 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.
- Castro, L. N. & Von Zuben, F. J. The clonal selection algorithm with engineering applications. In: Proceedings of GECCO, Workshop on Artificial Immune Systems and Their Applications, Las Vegas, 36-39.
- Castro, L. N. (2001). *Immune engineering: development and application of computational tools inspired by artificial immune systems*. PhD. Thesis. UNICAMP. Campinas, São Paulo, Brazil. (In Portuguese).
- Castro, L. N. & Timmis, J. (2002). *Artificial Immune Systems: A New Computational Intelligence Approach*, Springer, 1st edition.
- Dasgupta, D. (1998). *Artificial Immune Systems and Their Applications*, Springer, New York, USA.
- Dasgupta, D. (2006). Advances in Artificial Immune Systems. *IEEE Computational Intelligence Magazine*, 40-49.
- Deraemaeker, A. & Worden, K. (2010). *New Trends in Vibration Based Structural Health Monitoring*. New York, Springer Wien, 311p.
- Farrar, C.R. & Worden, K. (2013). *Structural Health Monitoring: A Machine Learning Perspective*. Chichester, John Wiley, 643p.
- Franco, V. R., Bueno, D. D., Brennan, M. J., Cavalini JR., A. A., Gonzalez, C. G. & Lopes Junior, V. (2009). Experimental damage location in smart structures using Lamb waves approaches. In: *Brazilian Conference on Dynamics, Control and Their Applications*, 1-4.
- 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.
- Gonzalez, C. G. (2012). Metodologias para reconhecimento de padrões em sistemas de SHM utilizando a técnica da impedância eletromecânica (E/M). 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. In: *International Workshop on Structural Health Monitoring, 2., 1999*, New York. Proceedings... New York: VirginiaTech Publisher, 265-275.
- Haykin, S. (2008). *Neural networks and learning machines*. (3a ed.), Prentice-Hall, 936p.
- Jeffcott, H. H. (1919). The lateral vibration of loaded shafts in the neighborhood of a whirling speed — The effect of want of balance, *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*. 37 (219), 304-314.
- Kartalopoulos, S. V. (1996). *Understanding Neural Networks and Fuzzy Logic: Basic Concepts and Applications*, IEEE Press, Piscataway, NJ, USA.
- Lima F. P. A. (2016). Diagnóstico de distúrbios de tensão em sistemas de distribuição baseado num sistema imunológico artificial com aprendizado continuado. 2016, 103 f. Tese (Doutorado Engenharia Elétrica) - Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira.
- Marchiori, S. C., Silveira, M. C. G., Lotufo, A. D. P., Minussi, C. R. & Lopes, M. L. M. (2011). Neural network based on adaptive resonance theory with continuous training for multi-configuration transient stability analysis of electric power systems, *Applied Soft Computing*, 11 (1), 706-715.
- Pereira A. S. et al. (2018). Metodologia da pesquisa científica. FSM. https://www.ufsm.br/app/uploads/sites/358/2019/02/Metodologia-da-Pesquisa-Cientifica_final.pdf
- Python 3.11 version, release data on oct. 2022.
- Santos, A. A. A., Chavarette, F. R., & Souza, S. S. F. (2022). Artificial Immune Systems with Negative Selection Applied to Structural Integrity Monitoring in a Metallic Bridge. *Research, Society and Development*, 11 (1), 1-15.
- Souza, S. S. F., Chavarette, F. R., & Lima, F. P. A. (2022a). Wavelet Artificial Immune System Algorithm Applied to the Faults Aeronautical Structural Monitoring. *Brazilian Journal of Development*, 8 (1), 27193-27210.
- Souza, S. S. F., Chavarette, F. R., & Lima, F. P. A. (2022b). Artificial Immune Systems Applied to Clinical Diagnosis of Breast Cancer Samples. *Research, Society and Development*, 11 (1), p. 1-14.
- Turra, A. E., Baptista, F. G., Lopes Junior, V. & Vieira, J. (2013). Detecção de dano em placas de alumínio utilizando impedância Eletromecânica. In: *Simpósio Brasileiro de Automação Inteligente*, 1-6.
- Zadeh, L. A. (1995). Fuzzy sets, *Information and Control*, 8 (3), 338-353.
- Zheng, S., Wang, X. & Liu, L. (2004). Damage detection in composite materials based upon the computational mechanics and neural networks. In: *European Workshop on Structural Health Monitoring*, 609-615.