

**Prognose e detecção de falhas em tratores agrícolas utilizando simulação numérica
e algoritmos de sistemas imunológicos artificiais**

**Prognosis and fault detection in agricultural tractors using numerical simulation and
artificial immune system algorithms**

**Pronóstico y detección de fallas en tractores agrícolas mediante simulación numérica y
algoritmos del sistema inmunológico artificial**

Recebido: 14/12/2020 | Revisado: 16/12/2020 | Aceito: 19/12/2020 | Publicado: 23/12/2020

Dionatan Pontes de Oliveira

ORCID: <https://orcid.org/0000-0002-8352-8809>

Instituto Federal de Educação, Ciência e Tecnologia Goiano, Brasil

E-mail: dionatan.oliveira@estudante.ifgoiano.edu.br

Wayrone Klaiton Silva

ORCID: <https://orcid.org/0000-0001-8615-4382>

Instituto Federal de Educação, Ciência e Tecnologia Goiano, Brasil

E-mail: wayrone.klaiton@estudante.ifgoiano.edu.br

Daniela Cabral de Oliveira

ORCID: <https://orcid.org/0000-0002-9647-933X>

Instituto Federal de Educação, Ciência e Tecnologia Goiano, Brasil

E-mail: daniela.cabra@ifgoiano.edu.br

Fábio Roberto Chavarette

ORCID: <https://orcid.org/0000-0002-1203-7586>

Universidade Estadual Paulista, Brasil

E-mail: fabio.chavarette@unesp.br

Daniel Emanuel Cabral de Oliveira

ORCID: <https://orcid.org/0000-0002-3824-994X>

Instituto Federal de Educação, Ciência e Tecnologia Goiano, Brasil

E-mail: daniel.oliveira@ifgoiano.edu.br

Luis Cláudio Villani Ortiz

ORCID: <https://orcid.org/0000-0003-3566-1602>

Instituto Federal de Educação, Ciência e Tecnologia Goiano, Brasil

E-mail: luis.ortiz@ifgoiano.edu.br

Dorgival Fidellis de Souza

ORCID: <https://orcid.org/0000-0001-7030-6302>

Instituto Federal de Educação, Ciência e Tecnologia Goiano, Brasil

E-mail: dorgival.fidellis@ifgoiano.edu.br

João Areis Ferreira Barbosa Júnior

ORCID: <https://orcid.org/0000-0001-5336-4463>

Instituto Federal de Educação, Ciência e Tecnologia Goiano, Brasil

E-mail: joao.areis@ifgoiano.edu.br

Resumo

Diante o avanço tecnológico crescente na agricultura, e tendo em vista promover aumento da produtividade e segurança no trabalho dos indivíduos envolvidos no processo de evolução tecno-agrícola, o presente artigo propõe desenvolver um sistema inteligente de prognose e detecção de falhas aplicado ao processo de monitoramento da integridade estrutural de um trator agrícola e da consequente análise das falhas estruturais, em condições normais de solo e em curto prazo. Para isto, a detecção de falhas na integridade estrutural em tratores agrícolas é obtida para captar dados continuamente para aprendizado da máquina, de modo que um modelo numérico seja criado e alimentado, sob o cálculo de equações diferenciais, afim de mensurar os deslocamentos do trator à medida que os parâmetros de velocidade do trator se alteram e a distância entre aos níveis do solo se intercalam e, assim, resultar em possíveis prognósticos de risco estrutural. Computacionalmente, por via do software Octave, a análise, identificação e classificação dos dados obtidos, é possível com o uso de algoritmos de seleção negativa e seleção clonal. A inspeção da estrutura do trator com foco na melhor conservação do próprio é o ponto principal do estudo, e com a relevante qualidade e consistência da metodologia apresentada e resultante da pesquisa, permite indicar se o trator se encontra em condições normais ou apresenta indícios de falha estrutural, pois, caso haja riscos, a falha pode ser identificada.

Palavras-chave: Trator agrícola; Monitoramento de integridade estrutural; Seleção negativa; Seleção clonal.

Abstract

In view of the growing technological advance in agriculture, and with a view to promoting increased productivity and job security for individuals involved in the techno-agricultural evolution process, this article develops an inteligente diagnostic system, proposing artificial

immunological algorithms, inspired by the Immune System Biological, to apply to the process of monitoring the structural integrity of an agricultural tractor and the consequent analysis of structural failures, under normal soil conditions and in the short term. For this, the detection of failures in structural integrity in agricultural tractors is obtained to capture data continuously for machine learning, so that a numerical model is created and fed, under the calculation of differential equations, in order to measure the displacements of the tractor as the tractor speed parameters change and the distance between ground levels are interspersed and, thus, result in possible structural risk prognoses. Computationally, through the Octave software, the analysis, identification and classification of the obtained data is possible with the use of negative selection and clonal selection algorithms. The inspection of the tractor structure with a focus on better conservation is the main point of the study, and with the relevant quality and consistency of the methodology presented and resulting from the research, it allows to indicate whether the tractor is in normal conditions or shows signs of failure structural, because if there are risks, the failure can be identified.

Keywords: Agricultural tractor; Structural integrity monitoring; Negative selection; Clonal selection.

Resumen

Ante el creciente avance tecnológico en la agricultura, y con miras a promover una mayor productividad y seguridad laboral para las personas involucradas en el proceso de evolución tecnoagrícola, este artículo desarrolla un sistema de diagnóstico inteligente, proponiendo algoritmos inmunológicos artificiales, inspirados en el Sistema Inmunológico Biológico, para aplicar al proceso de monitoreo de la integridad estructural de un tractor agrícola y el consecuente análisis de fallas estructurales, en condiciones normales de suelo y en el corto plazo. Para ello, la detección de fallas en la integridad estructural en tractores agrícolas se obtiene para capturar datos de manera continua para el aprendizaje automático, de manera que se crea y alimenta un modelo numérico, bajo el cálculo de ecuaciones diferenciales, con el fin de medir los desplazamientos del tractor a medida que los parámetros de velocidad del tractor cambian y la distancia entre los niveles del suelo se intercalan y, por lo tanto, resultan en posibles pronósticos de riesgo estructural. Computacionalmente, a través del software Octave, el análisis, identificación y clasificación de los datos obtenidos es posible con el uso de algoritmos de selección negativa y selección clonal. La inspección de la estructura del tractor con foco en una mejor conservación es el punto principal del estudio, y con la relevante calidad y consistencia de la metodología presentada y resultado de la investigación,

permite indicar si el tractor se encuentra en condiciones normales o presenta signos de avería estructural, porque si hay riesgos, se puede identificar la falla.

Palabras clave: Tractor agrícola; Monitoreo de integridad estructural; Selección negativa; Selección clonal.

1. Introdução

Na agricultura, o crescimento da produção depende fortemente, entre outros fatores, do nível de tecnologia empregado nos equipamentos e tecnologias utilizadas nos processos de cultivo, possibilitando a expansão da produtividade, segurança, confiabilidade e aumento da lucratividade. Os tratores agrícolas são equipamentos fundamentais, e utilizados em todo tipo de plantio. Os tratores modernos são projetados para satisfazer exigências de custos e de produtividade, de modo que, sejam capazes de operar com o máximo desempenho nas tarefas do campo. No entanto, em certas condições do traçado e velocidade, o trator pode apresentar instabilidade devido ao solo irregular, e gerar vibrações em sua estrutura que são prejudiciais à sua integridade, que em casos extremos pode causar acidente operacional, através do tombamento ou até a danificação da estrutura (Khoury et al., 2004).

Em áreas, como na agricultura, tem-se atividades importantes que dependem da integridade da estrutura utilizada no processo, garantindo segurança, produtividade e prevenção de acidentes/catástrofes (Franco et al., 2009).

Neste sentido, novas tecnologias fazem se necessário em prol de resolver falhas de integridade estrutural, detectando falhas em estados iniciais, intervindo na propagação e impedindo no avanço das falhas. Sendo assim, os sistemas de monitoramento da integridade estrutural, também conhecido como Structural Health Monitoring (SHM) realizam tarefas como: aquisição e processamento de dados, validação e análise, detecção, caracterização e interpretação de mudanças adversas em uma estrutura, de modo a auxiliar a tomada de decisões e identificar falhas estruturais (Hall, 1999).

Os SHM's convencionais precisam de melhorias, e diante desta situação as técnicas de computação inteligente podem sanar tais deficiências. As técnicas inteligentes são instrumentos motivadas em processos naturais e/ou biológicos, apresentando bons resultados em reconhecimento de padrões e prognose, e assim, podem ser adaptadas ou combinadas.

Os SHM's modernos utilizam técnicas inteligentes tais como: redes neurais artificiais Haykin (2008) & Kartalopoulos (1996), lógica *fuzzy* Zadeh (1995), sistemas imunológicos artificiais De Castro & Von Zuben (2000) e Dasgupta (1998), que viabilizam habilidades

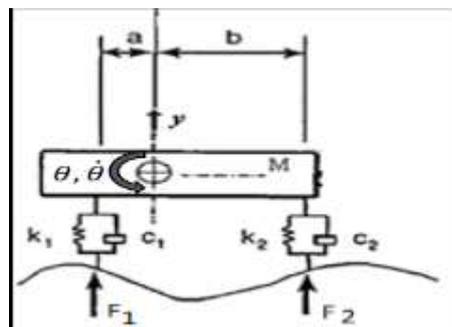
como a extração de conhecimentos, reconhecimento de padrões e automatização da tomada de decisão em tempo real.

Diante do exposto acima, o presente artigo visa desenvolver um sistema inteligente de SHM, propondo uma abordagem com simulação numérica que captam dados para realizar a prognose e detecção de falhas em tratores agrícolas. O sistema de prognose e detecção de falhas é composto com um aprendizado continuado, sendo empregados dois algoritmos imunológicos artificiais, sendo eles: algoritmo de seleção negativa (ASN) e algoritmo de seleção clonal.

2. Material e Métodos

Para o desenvolvimento da simulação numérica foram utilizadas as seguintes metodologias. O trator agrícola foi representado através de um modelo matemático, construído através de equações diferenciais, conforme ilustrado pela Figuras 1.

Figura 1 – Modelo dinâmico do trator agrícola.



Fonte: Sakai (2006).

A Figura 1 ilustra o modelo dinâmico do trator agrícola. Os dados foram obtidos através de simulações realizadas no modelo numérico, sendo representado através de equações diferenciais.

Durante o trabalho no campo as rodas traseiras e dianteiras do trator podem perder o contato com o chão. Este fenômeno pode ocorrer de 3 modos, principais, assumindo por simplicidade rigidezes de flexão de eixos e de torção estrutural infinitas. Tais modos são definidos quando:

- somente as rodas dianteiras perdem contato com o chão (o trator empina a frente);

- somente as rodas traseiras perdem o contato com o chão (o trator empina a traseira);
- as rodas traseiras e dianteiras perdem o contato com o chão ao mesmo tempo (o trator dá um salto).

As alterações nos parâmetros estruturais do trator como massa. Amortecimento ou rigidez são situações que precedem o evento de tombamento, que define uma falha de operação do sistema.

Para se obter respostas do sistema nas operações especificadas foi adotada o sistema dinâmico, na qual apresenta M como sendo a massa total do trator. Os pneus foram modelados por molas lineares e por amortecimento viscoso colocados em paralelo. Então, $k1$ e $k2$ foram as rigidezes das molas, $c1$ e $c2$ foram os coeficientes de amortecimento viscoso; y foi o deslocamento vertical do centro de gravidade do trator; θ foi o deslocamento angular do centro de gravidade do trator em relação ao eixo lateral; a foi a distância entre o centro de gravidade e rodas frontais e b foi a distância entre o centro de gravidade e rodas traseiras, $F1$ e $F2$ foram as excitações devido desníveis do solo.

Segundo Sakai (2006) a força de equilíbrio na direção vertical e do momento do salto é equacionado pelas equações 9:

$$\left\{ \begin{array}{l} m\ddot{y} - F_1(y, \dot{y}, \theta, \dot{\theta}) - F_2(y, \dot{y}, \theta, \dot{\theta}) + mg = 0 \\ J\ddot{\theta} - aF_1(y, \dot{y}, \theta, \dot{\theta}) + bF_2(y, \dot{y}, \theta, \dot{\theta}) = 0 \end{array} \right\} \quad (1)$$

Onde: J é o momento angular de inércia do centro de massa: $F_1(\cdot)$ e $F_2(\cdot)$ são as cargas dinâmicas nos pneus do trator, respectivamente, dianteiro e traseiro do trator, dadas pelas equações 10 e 11:

$$F_1(y, \dot{y}, \theta, \dot{\theta}) = -k_1(y + a\theta - h_1(t)) - c_1(\dot{y} + a\dot{\theta} - \dot{h}_1(t)) \quad (2)$$

$$F_2(y, \dot{y}, \theta, \dot{\theta}) = -k_2(y - b\theta - h_2(t)) - c_2(\dot{y} - b\dot{\theta} - \dot{h}_2(t)) \quad (3)$$

Nas equações 2 e 3 $h_1(t)$ e $h_2(t)$ são excitações periódicas que simularão os desníveis da superfície: onde: $\omega = \frac{2\pi v}{L}$ e $\phi = \frac{2\pi W_B}{L}$.

Observa-se que quando o trator:

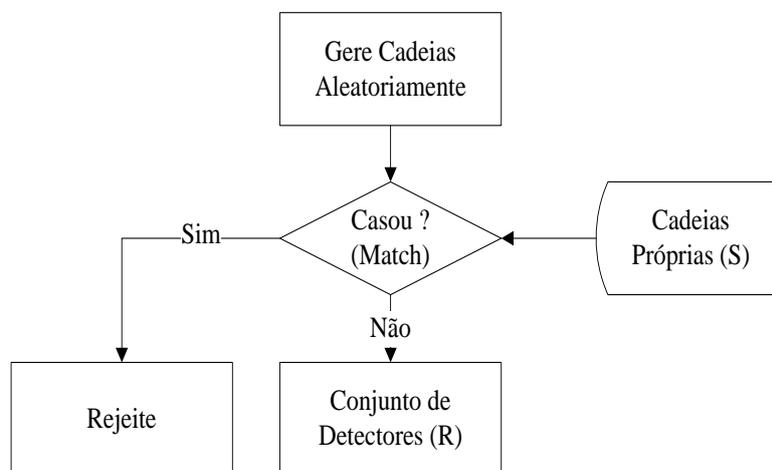
- empina a frente ($F_1(\cdot) = 0$).
- empina a traseira ($F_2(\cdot) = 0$).
- dá um salto ($F_1(\cdot) = F_2(\cdot) = 0$).

Após a captura dos dados por meio do modelo numérico através das equações diferenciais, foram utilizados os algoritmos de sistemas imunes artificiais, rigorosamente, os algoritmos de seleção negativa e seleção clonal nos processos de prognose e detecção de falhas estruturais em um trator agrícola.

O algoritmo de seleção negativa (ASN) é inspirado no processo de seleção negativa de linfócitos T, no qual o organismo classifica as células do corpo, entre próprias e não-próprias. Neste sentido, o ASN é utilizado no processo de reconhecimento de padrões, sendo elaborado como um retrato computacional.

O ASN é composto por duas fases, sendo elas as fases de sensoriamento e monitoramento. As Figuras 2 e 3 ilustram os fluxos das atividades das fases de sensoriamento e monitoramento respectivamente.

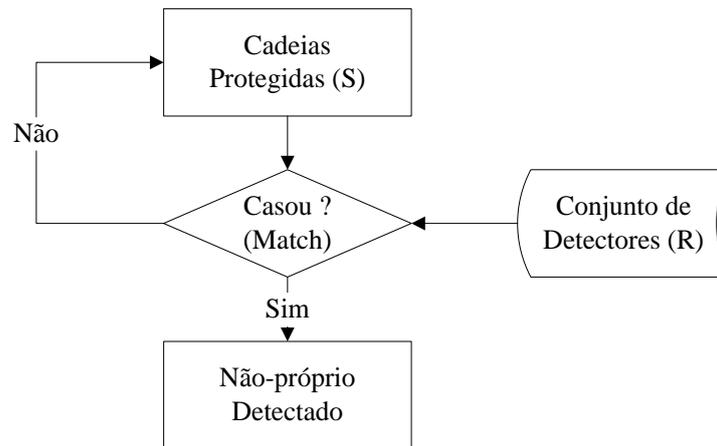
Figura 2 – Fase sensoriamento do ASN.



Fonte: Adaptado de De Castro (2001)

Já a Figura 3 ilustra o fluxo das atividades do algoritmo ASN na fase de monitoramento.

Figura 3 – Fase monitoramento do ASN.



Fonte: Adaptado de De Castro (2001).

As cadeias no ASN são agrupadas em dois tipos: antígenos (Ag) e linfócitos (Ab). O Ag são os dados a serem analisados ou desconhecido pelo ASN, que são representados pelas equações 4 e 5, conforme definidas por De Castro e Timmis (2003) e Lima et al. (2013).

$$Ag = Ag_1, Ag_2, Ag_3, Ag_4, \dots, Ag_L \quad (4)$$

$$Ab = Ab_1, Ab_2, Ab_3, Ab_4, \dots, Ab_L \quad (5)$$

A variável L corresponde a dimensão do espaço dos linfócitos e dos antígenos.

Para aumentar o desempenho da prognose e detecção foi proposto um desvio padrão de 3% vinculado ao detector padrão, conforme apresentado na equação 6. Este desvio atua em cada posição i do vetor, permitindo verificar o casamento em cada posição.

$$\underline{Ab}_i \leq Ag_i \leq \overline{Ab}_i \quad (6)$$

Sendo:

Ag_i : valor do padrão em análise;

\underline{Ab}_i : valor padrão detector;

\overline{Ab}_i : valor padrão detector mais desvio adotado.

Para determinar a afinidade entre os padrões é analisado posição por posição. A expressão pela equação 7 representa a afinidade total entre os dois padrões em análise (Bradley & Tyrrell, 2002):

$$Af_T = \frac{\sum_{i=1}^L P_c}{L} * 100 \quad (7)$$

Sendo:

Af_T : % de afinidade entre os padrões;

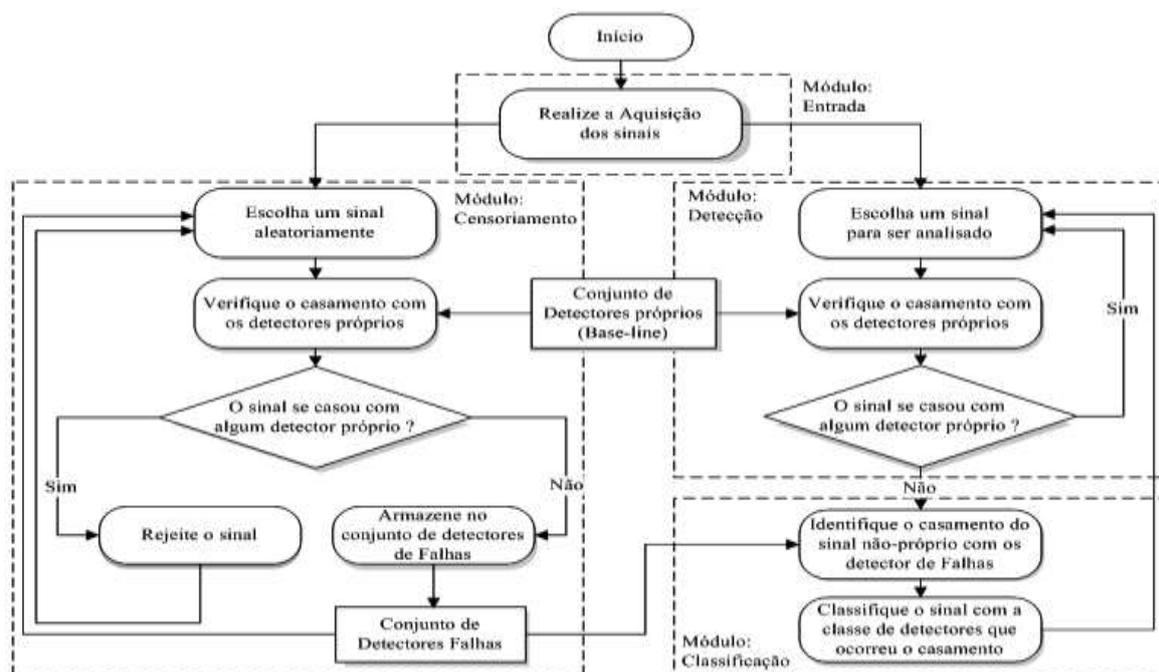
L : quantidade total de posições;

P_c : posição casada;

$\sum_{i=1}^L P_c$: somatório das posições casadas.

A Figura 4 ilustra o fluxo das atividades do algoritmo de seleção negativa no sistema inteligente. Neste artigo foram definidos detectores próprios e detectores de falhas com cinco situações de falhas. A fase de sensoriamento é realizada de modo *off-line*, já a fase de monitoramento do ASN é realizada no modo *on-line* De Castro & Timmis, 2003.

Figura 4 – Fluxo do algoritmo ASN no SHM.

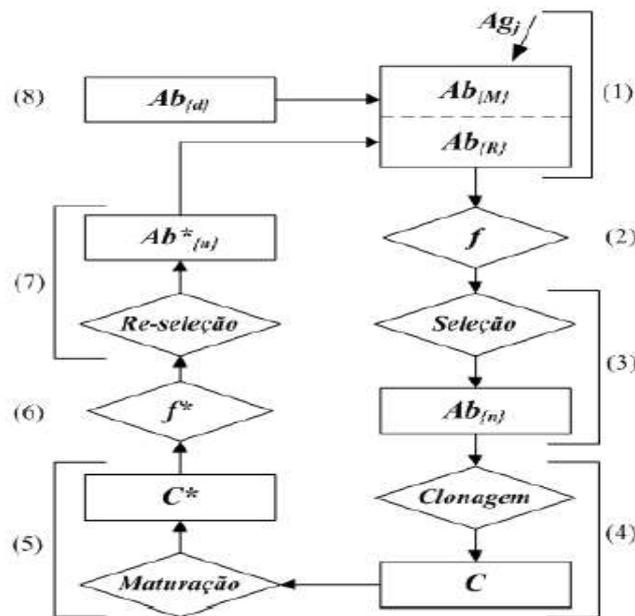


Fonte: Adaptado de De Castro (2001)

Neste artigo, na fase de sensoriamento foi gerado um conjunto de detectores próprios e cinco conjuntos de detectores de falhas utilizados na fase de monitoramento. O conjunto de detectores próprios possuem características normais da estrutura. Já os cinco conjuntos de detectores de falhas possuem características de falhas da estrutura. Os conjuntos detectores próprios e de falhas foram utilizados na fase de monitoramento do ASN.

Já o algoritmo de aprendizado continuado, também chamado de CLONALG é constituído das seguintes fases apresentados por De Castro (2001) & De Castro & Timmis (2002): fase de inicialização da população, fase de avaliação da afinidade de cada antígeno, fase de seleção dos linfócitos com maior afinidade, fase de clonagem dos linfócitos selecionados, fase de hipermutação, ou seja, processo de maturação da nova população, fase de avaliação da afinidade, fase de resseleção da população madura, fase de metadinâmica, ou seja, substituição dos anticorpos com menores afinidades por anticorpos com maiores afinidades e fase de critério de parada. A Figura 5 ilustra o fluxo do algoritmo CLONALG.

Figura 5 – Fluxo de funcionamento do algoritmo CLONALG.



Fonte: Adaptado de De Castro (2001)

Na fase de clonagem a quantidade N_c de clones é dada pela equação 8 De Castro (2001):

$$N_{ic} = \text{round}\left(\frac{\beta N}{i}\right) \quad (8)$$

Sendo:

- β : multiplicador entre [0,1];
- N : quantidade total da população;
- round* : operador de arredondamento;

Na fase de hipermutação a taxa de mutação (α) de cada clone é definida pela equação 9 (De Castro, 2001):

$$a = \exp(-pfn) \quad (9)$$

Sendo:

- p : controle de amortecimento da função exponencial;
- fn : valor da afinidade f ;

Desta forma, cada clone sofre um processo de mutação representada pela equação 10 descrita por De Castro (2001):

$$m = \text{round}(\alpha * N(0,1)) \quad (10)$$

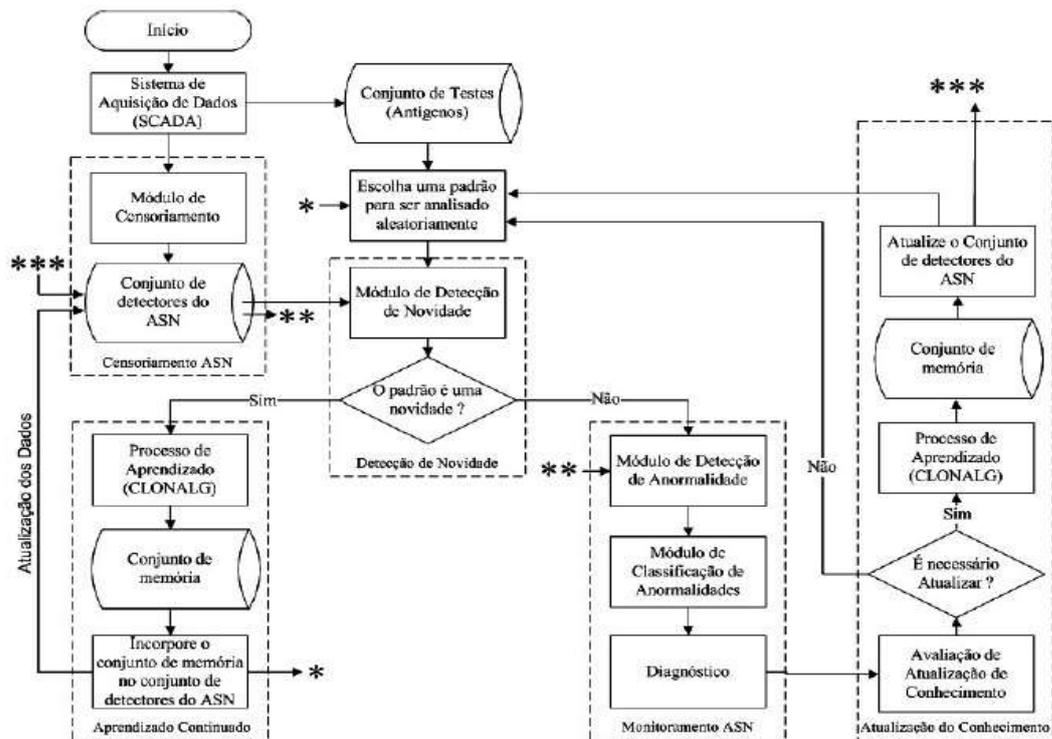
Sendo:

- m : quantidade de mutações;
- round* : operador de arredondamento para o inteiro mais próximo;
- α : taxa de mutação;
- N : variável randômica gaussiana de média zero e desvio padrão = 1.

A prognose e detecção das falhas estruturais em trator agrícola foi composto por seis fases: simulação numérica, fase censoriamento, fase de detecção de novidade, fase de aprendizado continuado, fase de monitoramento do ASN e fase de atualização do conhecimento. A Figura 5 ilustra o fluxo do ASN para o processo de prognose e detecção das falhas e o CLONALG para a estratégia de aprendizado continuado.

Simulação numérica: Os dados foram obtidos através de simulações realizadas no modelo numérico, sendo representado através de equações diferenciais. Os dados foram utilizados nas fases de: censoriamento do ASN, detecção de novidade, aprendizado continuado, monitoramento do ASN e atualização do conhecimento.

Figura 5 – Fluxo de funcionamento do algoritmo com aprendizado continuado.



Fonte: Adaptado de De Castro (2001)

Fase de sensoriamento do ASN: foram definidos os detectores próprios e detectores com falhas, formando o conjunto de detectores do ASN. O conjunto de detectores próprios foi constituídos de 257 pontos dos dados, sendo 3 pontos para cada dados normais. Já os detectores com falhas foram constituídos por 9 pontos para cada dados com falhas resultando em 45 pontos de dados com falhas.

Fase de detecção de novidade: foi escolhido aleatoriamente um dado para ser analisado e assim a fase de aprendizado continuado foi acionada com intuito de aprender sobre o novo dado.

Fase de Aprendizado Continuado: o algoritmo CLONALG gerou um conjunto de conhecimento a partir da falha desconhecida. Uma população de linfócitos foi definida aleatoriamente e calculada a afinidade entre os linfócitos da população e o antígeno. Em seguida, foi selecionado N melhores linfócitos com maiores valores de afinidade em relação ao antígeno para o processo de clonagem e hipermutação. Os linfócitos selecionados substituíram os piores linfócitos da população e separados para o conjunto de conhecimento. O processo foi repetido até o determinado número de iterações.

Após obter o conjunto de conhecimento do antígeno desconhecido, no caso da pesquisa a falha 5, o mesmo foi incorporado ao conjunto de detectores do ASN, fornecendo

conhecimento ao sistema, para que numa próxima análise do mesmo tipo de antígeno o sistema seja capaz de efetuar o reconhecimento e detecção da falha.

Fase de monitoramento do ASN: nesta fase ocorre a classificação das cinco situações de falhas.

A pesquisa se enquadra como metodologia quantitativa. De acordo com Pereira et al., (2018, p.67) “os métodos qualitativos são aqueles nos quais é importante a interpretação por parte do pesquisador com opiniões sobre o fenômeno em estudo”.

3. Resultados e Discussões

A implementação da simulação numérica e dos algoritmos de seleção negativa e seleção clonal foram desenvolvidos no software Octave. Para resolução da equação diferencial foi utilizado integrador numérico Runge Kutta de quarta ordem, com os seguintes parâmetros, conforme ilustra a Tabela 1.

Para simular as excitações na estrutura do trator, por meio das equações 2 e 3, foram usados como parâmetros de controle a distância entre as saliências consecutivas ($L=0,6m$ à $L=0,1m$) e a velocidade ($v=1m/s$ à $10m/s$) para cada L . Sabe-se que o trator funciona em condições normais com $L=0,6m$ e a variação de $v=1m/s$ a $3m/s$, e sendo as outras consideradas anormais, com $L=0,15m$ e velocidade acima $v=6m/s$ que, sob certas condições do traçado e velocidade, o trator apresenta instabilidade nas vibrações prejudicando o controle por parte do operador. Para cada L e v fixado, foi obtida uma resposta em frequência utilizando-se a transformada rápida de Fourier, também conhecida como Fast Fourier Transform (FFT), na resposta temporal obtida pela integração numérica do deslocamento do trator, conforme ilustra a Figura 6. As unidades dos eixos do gráfico são: eixo X metros e eixo Y segundos.

Tabela 1 – Parâmetros.

| Parâmetros | Runge Kutta Quarta Ordem |
|------------|-----------------------------|
| k1 | 200.000 |
| k2 | 260.000 |
| l1 | 0.7 |
| l2 | 0.64 |
| c1 | 5.500 |
| c2 | 6.690 |
| g | 9.81 |
| J | 600 |
| m | 888 |
| a0 | 0.025 |
| a1 | $a_0 \log(v)/L$ |
| a2 | $a_0 \log(3v^2)/L$ |
| a3 | $a_0 \log(v)/3$ |
| a4 | $a_0 \log(3v^2)/3$ |

Fonte: Autores.

Figura 6 – Deslocamento do trator.



Fonte: Autores.

Para implementação dos algoritmos ASN e CLONALG foi utilizado o banco de dados para cinco situações distintas de falhas e uma situação normal (baseline) que corresponderam a 257 pontos dos dados, sendo que 3 pontos para cada dados próprios (dados normais - baseline) e 9 pontos para cada dados não-próprios (dados com falhas) resultando em 45 pontos de dados com falhas. Para o bom funcionamento dos algoritmos de seleção negativa (ASN) e seleção clonal (CLONALG), foram necessários alguns parâmetros conforme apresentados na Tabela 2.

Tabela 2 – Parâmetros.

| Parâmetros | ASN sem Aprendizado Continuado | ASN com Aprendizado Continuado |
|------------|--------------------------------|--------------------------------|
| N | - | 20 |
| n | - | 4 |
| β | - | 0.3 |
| d | - | 0 |
| desvio | 0.3 | 0.3 |
| afinidade | 70% | 70% |
| roh | - | 3 |

Fonte: Autores.

Os parâmetros apresentados na Tabela 2 foram obtidos por meio de testes empíricos. O valor da taxa de afinidade TA_f foi definido em 70%.

Nas fases de sensoriamento foram realizados testes SEM e COM o aprendizado continuado excluindo a falha 5, com intuito de medir o desempenho das fases de detecção de novidade, aprendizado continuado e atualização do conhecimento no sistema de prognose e detecção de falhas em trator agrícola.

O ASN não conseguiu identificar a falha excluída na fase de sensoriamento, ou seja, sem conhecimento prévio da falha o algoritmo não reconheceu os padrões da falha 5, havendo 0% de acerto.

Tabela 3 – Resultados do algoritmo convencional – 4 situações de falhas e 1 sem falha.

| Padrões | Padrões Testados | Padrões Acertados | Acertos (%) |
|----------|------------------|-------------------|-------------|
| Baseline | 3 | 3 | 100,00 |
| Falha 1 | 9 | 9 | 100,00 |
| Falha 2 | 9 | 9 | 100,00 |
| Falha 3 | 9 | 9 | 100,00 |
| Falha 4 | 9 | 9 | 100,00 |
| Falha 5 | 0 | 0 | 0 |
| Total | 39 | 39 | 100,00 |

Fonte: Autores.

O sistema inteligente de SHM realizada no trator agrícola apresentou um índice de acerto igual a 100,00% em todas as configurações, menos na falha 5 já que mesmo foi excluído no processo do algoritmo de ASN.

O ASN apresentou um bom desempenho para as situações de falhas 1 a 4, sendo possível afirmar que as quantidades de detectores influenciaram diretamente no reconhecimento de padrões das situações sem falha e com falhas.

Só que diante da situação exposta, fez se necessário aplicar o algoritmo CLONALG para a mesma situação anterior, onde foi excluído a falha 5 e submetido ao aprendizado continuado. O algoritmo CLONAL apresentou bom desempenho apresentando 100% de acerto para as cinco situações de falhas e a situação sem falha. A Tabela 4, apresenta os resultados obtidos pelo algoritmo de aprendizado continuado na mesma condição da Tabela 3.

Tabela 4 – Resultados do algoritmo com aprendizado continuado – 4 situações de falhas e 1 sem falha

| Padrões | Padrões Testados | Padrões Acertados | Acertos (%) |
|----------|------------------|-------------------|-------------|
| Baseline | 3 | 3 | 100,00 |
| Falha 1 | 9 | 9 | 100,00 |
| Falha 2 | 9 | 9 | 100,00 |
| Falha 3 | 9 | 9 | 100,00 |
| Falha 4 | 9 | 9 | 100,00 |
| Falha 5 | 9 | 9 | 100,00 |
| Total | 48 | 48 | 100,00 |

Fonte: Autores.

Verificando as Tabelas 3 e 4, foi possível observar que o algoritmo ASN sem o aprendizado continuado não reconheceu a falha 5, que foi excluído do processo de sensoriamento, apresentado 0% de acerto. Posteriormente, o algoritmo CLONALG com aprendizado continuado reconheceu a falha 5 tendo um índice de acerto de 100,00% para as cinco situações de falhas e a situação sem falha.

4. Considerações Finais

Neste trabalho, foi desenvolvido um sistema de monitoramento de integridade estrutural capaz de diagnosticar falhas em tratores agrícolas através de sistemas imunológicos artificiais com o algoritmo de seleção negativa e seleção clonal.

No ASN foi possível constatar que quanto maior é o conhecimento obtido no módulo de sensoriamento, maior é a eficiência no processo de reconhecimento e classificação do algoritmo no módulo de monitoramento. O CLONALG por meio do aprendizado continuado aprende a falha desconhecida e utiliza esta aprendizagem numa próxima análise melhorando os percentuais de acerto. O teste de referência cruzada proporciona confiabilidade e rapidez.

Desta forma, conclui-se que o algoritmo proposto neste trabalho baseado em técnicas de computação inteligentes foi eficiente, confiável, robusto e preciso para realização do monitoramento de integridade estrutural em tratores agrícolas.

Referências

- Bradley, D. W. & Tyrrell, A. M. (2002). Immunotronics: novel finite-state-machine architectures with built-in self-test using self-nonsel self differentiation, 6. *IEEE Transactions on Evolutionary Computation*, New York.
- Dasgupta, D. (1998). Artificial immune systems and their applications. New York: *Springer Verlag*.
- De Castro, L. N. (2001). Engenharia imunológica: desenvolvimento e aplicação de ferramentas computacionais inspiradas em sistemas imunológicos artificiais. 286 f. *Tese (Doutorado) - Faculdade de Engenharia Elétrica e de Computação*, Universidade Estadual de Campinas, Campinas.
- De Castro, L. N. & Timmis, J. (2002). Artificial immune systems: a new computational intelligence approach. New York: *Springer*.
- De Castro, L. N. & Timmis, J. (2003). Artificial Immune Systems as a Novel Soft Computing Paradigm. *Soft Computing Journal*, 7(8), 526-544, Heidelberg.
- De Castro, L. N. & Von Zuben, F. J. (2000). The clonal selection algorithm with engineering applications. In: *Workshop Proceedings of Gecco, Workshop on Artificial Immune Systems and Their Applications*, Las Vegas.
- Forrest, S. A., Perelson, A. L. & Cherukuri, R. (1994). Self-nonsel self discrimination in a computer. In: *Proceedings of the IEEE Symposium on Research in Security and Privacy*, Oakland. Proceedings [...].
- Franco, V. R., Bueno, D. D., Brennan, M. J., Cavalini, JR., A. A., Gonsalez, 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*. Anais Dincon. Bauru: SBMAC.
- Haykin, S. (2008). Neural networks and learning machines, 3. New York: Prentice-Hall.

Kartalopoulos, S. V. (1996). Understanding Neural Networks and Fuzzy Logic: Basic Concepts and Applications, *IEEE Press, Piscataway, NJ, USA*.

Khoury, J. K. JR., Dias, G. P., Cordeiro, R. R. & Souza, C. M. A. (2004). Modelagem da estabilidade de tratores agrícolas de pneus, 39(5), 459-468. *Pesquisa Agropecuária Brasileira, Brasília*.

Lima, F. P. A., Chavarette, F. R., Souza, A. S. E., Souza, S. S. F. & Lopes, M. L. M. (2013). Artificial immune systems with negative selection applied to health monitoring of aeronautical structures, 871, 283-289. *Advanced Materials Research, Hong King*.

Lima, F. P. A., Chavarette, F. R., Souza, A. S. E., Souza, S. S. F. & Lopes, M. L. M. (2014). Artificial immune systems applied to the analysis of structural integrity of a building. *Applied Mechanics and Materials, 472, 544-549, Yandong Wang*.

Sakai, K. (2006). Nonlinear dynamics and chaos in agricultural systems. Amsterdam: *Elsevier Science B.V.*

Zadeh, L. A. (1995). Fuzzy sets, *Information and Control, 8(3), New York*.

Porcentagem de contribuição de cada autor no manuscrito

Dionatan Pontes de Oliveira – 12,5%

Wayrone Klaiton Silva – 12,5%

Daniela Cabral de Oliveira – 12,5%

Fábio Roberto Chavarette – 12,5%

Daniel Emanuel Cabral de Oliveira – 12,5%

Luis Cláudio Villani Ortiz – 12,5%

Dorgival Fidellis de Souza – 12,5%

João Areis Ferreira Barbosa Júnior – 12,5%