

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE ENGENHARIA
CAMPUS DE ILHA SOLTEIRA**

FRANCISCO DIEGO GARRIDO DA SILVA

**MONITORAMENTO E ANÁLISE DA INTEGRIDADE DE UM TRATOR
UTILIZANDO REDES NEURAIS ARTMAP-*FUZZY***

Ilha Solteira
2016

FRANCISCO DIEGO GARRIDO DA SILVA

**MONITORAMENTO E ANÁLISE DA INTEGRIDADE DE UM TRATOR
UTILIZANDO REDES NEURAIS ARTMAP-FUZZY**

Dissertação apresentada à Faculdade de Engenharia de Ilha Solteira – UNESP como parte dos requisitos para obtenção do título de Mestre em Engenharia Mecânica.

Área de Conhecimento: Mecânica dos Sólidos.

FÁBIO ROBERTO CHAVARETTE
Orientador

MARA LÚCIA MARTINS LOPES
Coorientadora

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

S586m Silva, Francisco Diego Garrido da .
Monitoramento e análise da integridade de um trator utilizando redes neurais artmap-fuzzy / Francisco Diego Garrido da Silva. -- Ilha Solteira: [s.n.], 2016
70 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Mecânica Dos Sólidos., 2016

Orientador: Fábio Roberto Chavarette
Co-orientador: Mara Lúcia Martins Lopes
Inclui bibliografia

1. Redes neurais artificiais. 2. Artmap-fuzzy. 3. Monitoramento de integridade estrutural. 4. Detecção de falhas.

CERTIFICADO DE APROVAÇÃO

**TÍTULO DA DISSERTAÇÃO: MONITORAMENTO E ANÁLISE DA INTEGRIDADE DE UM TRATOR
UTILIZANDO REDES NEURAIS ARTMAP-FUZZY**

AUTOR: FRANCISCO DIEGO GARRIDO DA SILVA


ORIENTADOR: FABIO ROBERTO CHAVARETTE

CO-ORIENTADORA: MARA LUCIA MARTINS LOPES

Aprovado como parte das exigências para obtenção do Título de Mestre em ENGENHARIA
MECÂNICA, área: MECANICA DOS SÓLIDOS, pela Comissão Examinadora:


Prof. Dr. FABIO ROBERTO CHAVARETTE
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira


Prof. Dr. DOUGLAS DOMINGUES BUENO
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira


Prof. Dr. ALFREDO BONINI NETO
Departamento de Engenharia de Biosistemas / Faculdade de Ciências e Engenharia

Ilha Solteira, 13 de junho de 2016

Dedico este trabalho aos meus pais Francisco e Hilda, e a minha irmã Chris, pelo amor familiar e incentivo.

À minha esposa Alessandra pelo amor, compreensão, incentivo, apoio e motivação. E aos meus filhos Benício e Laura que são minhas razões de viver.

AGRADECIMENTOS

Primeiramente eu agradeço a Deus, pois sem Ele nada disso seria possível em minha vida. Pois o Senhor sempre me ajudou nos momentos de dificuldades, permitindo assim que este sonho se concretizasse.

Segundo ao meus pais, Francisco e Hilda que desde a minha meninice, estiveram presentes em minha vida como verdadeiros pais, mostrando-me as opções dos diversos caminhos que temos para trilhar, mas constantemente alertando-me quais eram os que me conduziriam para uma vida de cheia de amor e paz.

Quanto a minha esposa, não poderia ter uma pessoa melhor para estar ao meu lado durante este mestrado, pois sem a sua compreensão durante meus momentos de estudo, nada disso teria sido possível. E ela ainda me deu o maior presente que um homem pode receber de uma mulher, dois filhos maravilhosos. Benício e Laura, donos absolutos de um amor que brota da minha alma.

Não poderia esquecer da minha querida irmã, Chris, que sempre esteve ao meu lado nos momentos difíceis que enfrentei pela vida.

Agradeço uma pessoa especial que não está mais entre nós, meu caro amigo Adriano, pois foi quem me motivou enormemente a iniciar o mestrado na mecânica. E também pelo apoio dos amigos James, Parra, Outa, Aurélio, Paulo e Roni, pessoas muito queridas e que merecem minha admiração.

E claro, um agradecimento sincero ao meu orientador, Prof. Fábio Chavarette, e coorientadora Profa. Mara Lopes, que me acolheram de forma fraterna, e estiveram sempre prontos para ajudar. Meu muito obrigado pela paciência que tiveram comigo.

Finalizando, agradeço ao Departamento de Mecânica pela oportunidade dada e a possibilidade de ter vivenciado uma experiência ímpar, convivendo com profissionais excelentes como Prof. Douglas Bueno, Prof. Aparecido Gonçalves, Prof. Gilberto Peixoto, Prof. João Antônio, Prof. Gasche, Prof. Vicente Lopes, Prof. Campos e Prof. JBA.

“A melhor maneira de realizar seus sonhos é acordar”.

Paul Valéry.

RESUMO

Diante da constante necessidade de avanço tecnológico na agricultura para promover o aumento da produtividade e seguranças aos indivíduos envolvidos no processo, esta pesquisa apresenta o desenvolvimento de um sistema inteligente, utilizando redes neurais artificiais, aplicado ao monitoramento e análise de falhas estruturais em um trator. Simulou-se o trator por meio de um modelo numérico, representado através de equações diferenciais, o qual gera sinais conforme se alteram os parâmetros de velocidade do trator e a distância entre as saliências no solo. Para a análise, identificação e classificação dos dados simulados computacionalmente, foi utilizada uma rede neural do tipo *ARTMAP-Fuzzy*, que utiliza conceitos da Teoria da Ressonância Adaptativa, cujo algoritmo foi desenvolvido utilizando o programa Matlab. A principal aplicação deste sistema é inspecionar a estrutura do trator objetivando sua melhor conservação, indicando se o mesmo encontra-se em condições normais ou em caso de falha estrutural. Caso uma falha seja detectada, é possível classificar seu tipo. Os resultados evidenciados foram obtidos por meio de média simples entre as execuções do sistema, em virtude de se elevar a veracidade das informações demonstradas. Os resultados obtidos na aplicação da rede neural ao problema especificado mostraram-se ser satisfatórios.

Palavras-chaves: Redes neurais artificiais. *ARTMAP-Fuzzy*. Monitoramento de integridade estrutural. Detecção de falhas.

ABSTRACT

Faced with the constant need for technological advancement in agriculture to promote increased productivity and security to individuals involved in the process, this research presents the development of an intelligent system using artificial neural networks applied to the structural health monitoring and analysis of failure on a tractor. The tractor was simulated by means of a numerical model built by differential equations, which generates signals according to the parameters of tractor's speed and the distance between consecutive protrusions on the ground. For the analysis, identification and classification of computationally simulated data, a artificial neural network known as ARTMAP-fuzzy was used, which uses concepts of Adaptive Resonance Theory, whose algorithm was developed using Matlab. The main application of this system is to inspect the tractor structure aiming its better conservation, indicating whether it is in normal conditions or in case of structural failure. If the fault was detected, it is possible to classify the type of failure identified. The disclosed results were obtained by simple average between the executions of the system, because to increase the accuracy of the information shown. The results obtained in the application of artificial neural network to the specified problem proved to be satisfactory.

Keywords: Artificial neural networks. Fuzzy ARTMAP. Structural health monitoring. Failure Detection.

LISTA DE FIGURAS

Figura 1	- Acidente com trator em Descalvado – SP.....	23
Figura 2	- Acidente com trator em Portugal.....	23
Figura 3	- Neurônio biológico.....	27
Figura 4	- Componentes de um neurônio artificial.....	28
Figura 5	- Modelo não linear de um neurônio.....	29
Figura 6	- Funções de ativação: (a) Função de limiar. (b) Função linear por partes. (c) Função sigmóide para parâmetro de inclinação α variável.....	31
Figura 7	- Disposição de uma rede neural artificial.....	32
Figura 8	- Rede Neural Artificial ARTMAP- <i>Fuzzy</i>	40
Figura 9	- Fluxograma da rede neural ARTMAP- <i>Fuzzy</i>	44
Figura 10	- Modelo do trator.....	48
Figura 11	- Comportamento das rodas de um trator no campo: a) estado normal; b) o trator empina a frente; c) o trator empina a traseira; d) o trator salta.....	49
Figura 12	- Modelo do sistema dinâmico do trator.....	50
Figura 13	- Sinal nas condições normais.....	52
Figura 14	- Sinal de falha em que o trator empina a dianteira.....	52
Figura 15	- Sinal de falha em que o trator empina a traseira.....	53
Figura 16	- Sinal de falha em que o trator salta.....	53
Figura 17	- Lógica estrutural do sistema de SHM utilizando a rede ARTMAP- <i>Fuzzy</i>	54
Figura 18	- Combinações adotadas entre L e v	55
Figura 19	- Fluxograma do programa.....	61

LISTA DE TABELAS

Tabela 1	- Sinais presentes na base de dados.....	56
Tabela 2	- Quantidade de amostras utilizadas no treinamento e diagnóstico.....	57
Tabela 3	- Valores dos parâmetros utilizados pela rede ARTMAP- <i>Fuzzy</i>	59
Tabela 4	- Resultados obtidos aplicando rede ARTMAP- <i>Fuzzy</i>	61

LISTA DE SIGLAS E ABREVIATURAS

ART	<i>Adaptive Resonance Theory</i>
BAM	<i>Bidirectional Associative Memory</i>
CI	Computação Inteligente
CNM	<i>Combinatorial Neural Model</i>
CPN	<i>Counterpropagation Network</i>
FFT	<i>Fast Fourier Transform</i>
IA	Inteligência Artificial
NDE	<i>Nondestructive Evaluation</i>
PRS	Processar Resultados Salvos
RBFN	<i>Radial Basis Function Network</i>
RNA	Rede Neural Artificial
SHM	<i>Structural Health Monitoring</i>
SOM	<i>Self-Organizing Map</i>
SVM	<i>Support Vector Machines</i>

SUMÁRIO

1	INTRODUÇÃO.....	13
1.1	OBJETIVO DO TRABALHO.....	14
1.2	ORGANIZAÇÃO DO TEXTO.....	15
2	ATUALIZAÇÃO BIBLIOGRÁFICA.....	17
2.1	MONITORAMENTO DA INTEGRIDADE ESTRUTURAL.....	17
2.2	REDES NEURAIS ARTIFICIAIS.....	17
2.3	SISTEMAS INTELIGENTES APLICADOS EM SHM.....	18
3	MONITORAMENTO DA INTEGRIDADE DO TRATOR.....	21
3.1	INTRODUÇÃO.....	21
3.2	FALHA ESTRUTURAL.....	21
4	REDES NEURAIS ARTIFICIAIS.....	24
4.1	RESUMO HISTÓRICO.....	24
4.2	NEURÔNIO BIOLÓGICO.....	26
4.3	NEURÔNIO ARTIFICIAL.....	28
4.3.1	Funções de ativação.....	30
4.4	ARQUITETURA DAS REDES NEURAIS ARTIFICIAIS.....	31
4.5	TREINAMENTO DA REDE NEURAL.....	33
4.6	TIPOS DE REDES NEURAIS ARTIFICIAIS.....	34
4.7	BENEFÍCIOS DAS REDES NEURAIS ARTIFICIAIS.....	36
4.8	APLICAÇÕES DAS REDES NEURAIS ARTIFICIAIS.....	37
5	TEORIA DA RESSONÂNCIA ADAPTATIVA.....	38
5.1	REDE NEURAL ART.....	38
5.1.1	Rede neural ARTMAP-Fuzzy.....	39
5.1.2	Algoritmo ARTMAP-Fuzzy.....	41
5.2	PRINCIPAIS CONCEITOS DA LÓGICA NEBULOSA.....	45
5.2.1	Breve histórico.....	45
5.2.2	Fusão com redes neurais.....	47
6	DESENVOLVIMENTO E SIMULAÇÃO COMPUTACIONAL.....	48
6.1	MODELO NUMÉRICO.....	48
7	METODOLOGIA PROPOSTA.....	54
7.1	SISTEMA DE MONITORAMENTO E DIAGNÓSTICO DE FALHAS ESTRUTURAIS.....	54
7.1.1	Geração de amostras.....	55
7.1.2	Aleatoriedade.....	56
7.1.3	Treinamento do sistema.....	57
7.1.4	Classificação do sistema.....	58
8	APLICAÇÕES E RESULTADOS.....	59
8.1	PARÂMETROS UTILIZADOS.....	59
8.2	DETALHAMENTO DO PROGRAMA.....	60
8.3	RESULTADOS.....	61

8.4	DISCUSSÃO E ANÁLISE DO RESULTADO.....	62
8.4.1	Sugestões para tomadas de decisões.....	63
9	CONCLUSÃO.....	64
9.1	SUGESTÕES PARA TRABALHOS FUTUROS.....	64
	REFERÊNCIAS.....	66

1 INTRODUÇÃO

A agricultura é uma das principais atividades econômicas da sociedade moderna e, como em todas as áreas, a informatização tem sido incorporada nos processos produtivos ao longo dos anos. A incorporação das tecnologias possibilitou principalmente a expansão da área cultivada e o aumento da produtividade (PERUZZI; CHAVARETTE; GUILHERME, 2010).

Um crescimento ainda maior da produção agrícola depende, entre outros fatores, do nível de tecnologia em tratores usados na agricultura. Os tratores, para atenderem as exigências de custos e de produtividade, devem permitir a seus operadores a condição de exigir destas máquinas o máximo desempenho nas tarefas do campo, com incremento satisfatório de ergonomia e segurança de seus operadores. Sob certas condições do traçado e velocidade, o trator pode apresentar instabilidade direcional e níveis de vibrações que são prejudiciais à sua estrutura ou, em casos mais extremos, até mesmo tombamento (KHOURY et al., 2004). Quanto maior a velocidade, mais excessivamente é percebido a ação dos processos dinâmicos, que podem interferir na dirigibilidade do veículo (PERUZZI; CHAVARETTE; GUILHERME, 2010).

Os resultados de diversas pesquisas científicas atestam que o trator é a máquina móvel responsável pela maioria dos acidentes no campo e, dentre estes, o tombamento é o principal causador das fatalidades. O tombamento se deve a perda da estabilidade, tendo como causa prevaiente as saliências do terreno associado com a velocidade do veículo, além de seu centro de gravidade elevado (MONTEMOR; VELOSO; AREOSA, 2015).

Desta forma é necessário desenvolver maneiras eficientes de monitorar a estrutura, visando detectar falhas em estados iniciais, intervir na sua propagação e, consequentemente, impedir o seu desgaste ou até mesmo um acidente com vítimas fatais. Esta atual e importante linha de pesquisa é denominada Monitoramento da Integridade de Estruturas, do inglês *Structural Health Monitoring* (SHM).

Conforme destacado por Hall (1999), um SHM deve satisfazer os seguintes requisitos:

- Aquisição e processamento de dados;
- Validação e análise de sinais;
- Identificação e caracterização de falhas;

- Interpretação de mudanças adversas em uma estrutura;
- Auxiliar a tomada de decisões.

Em geral, as estruturas passam por avaliações de integridade estrutural. Nestes casos, são realizadas avaliações não destrutivas, do inglês *Nondestructive Evaluation* (NDE), visando estimar seu grau de segurança e confiabilidade.

Nos últimos anos, os sistemas de monitoramento de integridade estrutural vêm sofrendo uma evolução significativa, principalmente devido ao avanço das tecnologias de sensores, atuadores, materiais inteligentes, técnicas eficientes de processamento de dados e sinais, e principalmente a crescente demanda de se empregar tais ferramentas em tempo real.

Neste contexto, uma possível solução para se desenvolver um SHM moderno e eficiente é a utilização de sensores inteligentes e/ou técnicas de computação inteligentes (redes neurais artificiais, sistemas imunológicos, algoritmos genéticos, lógica *fuzzy*, e outros mais), que viabilizam habilidades como a extração de conhecimentos e informações de processos complexos, facilitando a análise de sinais e proporcionando a automatização da tomada de decisões.

Neste estudo, apresenta-se a proposta de uma metodologia para o desenvolvimento de um sistema de SHM, baseado em técnicas de computação inteligente (CI). Neste sentido, emprega-se uma rede neural artificial (RNA) do tipo *ARTMAP-Fuzzy* (CARPENTER et al., 1992) para realizar a análise e monitoramento da integridade de um trator, devido as suas características de aprendizagem e reconhecimento de padrões e, também por apresentarem bom desempenho em outros tipos de problemas de reconhecimento de padrões e diagnóstico, conforme destacado pelos autores em (TAN; LIM, 2010; LIMA et al., 2013; TONELLI NETO, 2012; LIMA et al., 2014a).

1.1 OBJETIVO DO TRABALHO

Este trabalho tem por objetivo aplicar um método de redes neurais artificiais, mais especificamente uma rede do tipo *ARTMAP-Fuzzy*, que utiliza a teoria da ressonância adaptativa, do inglês *Adaptive Resonance Theory* (ART), no monitoramento da dinâmica de um trator. Considerando o sistema trator-campo como um sistema vibratório não-linear com excitação periódica externa. O intuito deste sistema inteligente é oferecer informações suficiente para que sejam tomadas

decisões ótimas, evitando assim danos à estrutura do trator, como vibrações mecânicas, saltos, empinamento dianteiro e traseiro, e precipuamente evitando acidentes com vítimas.

1.2 ORGANIZAÇÃO DO TEXTO

A dissertação está estruturada em 9 capítulos mais as referências bibliográficas. A seguir apresenta-se um breve resumo dos tópicos.

- Capítulo 1 – Introdução
 - o Neste capítulo apresenta-se a introdução, objetivo e estrutura da dissertação.
- Capítulo 2 – Atualização Bibliográfica
 - o O capítulo 2 apresenta o levantamento bibliográfica utilizado para embasar teoricamente os assuntos abordados pelo trabalho, como: monitoramento da integridade estrutural, redes neurais artificiais e o uso de métodos inteligentes em SHM.
- Capítulo 3 – Monitoramento da Integridade Estrutural
 - o Neste capítulo apresenta-se basicamente o conceito de dano, falha estrutural e SHM.
- Capítulo 4 – Redes Neurais Artificiais
 - o O capítulo 4 apresenta a história e principais conceitos de uma RNA. Também é visto sua arquitetura, formas de aquisição do conhecimento, alguns tipos de redes existentes, seus benefícios e aplicações.
- Capítulo 5 – Teoria da Ressonância Adaptativa
 - o Neste capítulo são apresentados os conceitos básicos de métodos da família ART, em especial a ARTMAP-*Fuzzy*. Assim como uma apresentação sucinta de lógica nebulosa.
- Capítulo 6 – Desenvolvimento e Simulação Computacional
 - o No capítulo 6 consta o modelo numérico e a explicação de como foram geradas as amostras utilizadas pelo sistema.
- Capítulo 7 – Metodologia Proposta

- o É descrito no capítulo 7 o funcionamento do sistema SHM desenvolvido e seus módulos de treinamento e classificação.
- Capítulo 8 – Aplicações e Resultados
 - o Neste capítulo é detalhado a configuração do sistema e do programa, desenvolvido para automatizar as execuções. Também são mostrados os resultados obtidos e uma discussão sobre os mesmos.
- Capítulo 9 – Conclusão.
 - o No capítulo 9 apresenta-se uma síntese conclusiva de todo o trabalho e uma proposta para sua possível continuidade.

2 ATUALIZAÇÃO BIBLIOGRÁFICA

Para realização desta pesquisa, foram utilizadas referências com objetivo de introduzir conceitos básicos teóricos sobre os assuntos pesquisados. Assim, os próximos tópicos apresentam as referências utilizadas em cada área compreendida no trabalho.

2.1 MONITORAMENTO DA INTEGRIDADE ESTRUTURAL

Para o entendimento sobre monitoramento de estruturas, destacam-se os trabalhos especificados a seguir.

Sohn et al. (2004) apresenta um relatório contendo revisões sobre diversos trabalhos na área de SHM, além de sites, conferências e jornais técnicos. Os autores concluem o trabalho resumindo o estado da arte e comentando futuras áreas de pesquisa com objetivo de avançar os conhecimentos neste campo.

Devido ao aumento de pesquisas sobre SHM, Farrar e Worden (2006) foram motivados a publicar trabalho que aborda um breve histórico do tema e conceitua o processo de SHM em quatro passos do reconhecimento de padrões estatísticos, sendo estes: avaliação operacional; aquisição dos dados, normalização e limpeza; seleção das características e sintetização da informação; desenvolvimento do modelo estatístico e determinação das características.

Em Maio (2011) aborda-se SHM utilizando o método dos Elementos Finitos para uma análise de diferentes técnicas para detecção da posição e tamanho da delaminação em estruturas compósitas utilizando pastilhas piezoelétricas.

2.2 REDES NEURAIS ARTIFICIAIS

Como referencial na área de RNA Haykin (2001) apresenta em sua obra uma abordagem profunda dos principais conceitos sobre o tema. Silva, Spatti e Flauzino (2010) apresentam RNA de forma mais prática, com exemplos de implementações. E Yegnanarayana (2005) apresenta RNA utilizada no reconhecimento de padrões e processamento de sinais de forma introdutória.

Lopes (2005) utiliza redes neurais artificiais para resolver o problema de previsão de cargas elétricas. A autora propõe a introdução de melhorias na rede

neural *feedforward* com treinamento realizado utilizando o algoritmo de retropropagação. E para reduzir as imprecisões dos resultados de previsão é utilizada a rede neural ART&ARTMAP nebulosa.

No trabalho de Biondi et al. (2006), os autores focam na lógica *fuzzy*, também conhecida como nebulosa ou difusa, e suas aplicações, definições e terminologia. Uma rede neural do tipo *Perceptron* multicamadas, com modificações na função de ativação, foi utilizada para previsão multimodal de cargas no trabalho de (ALTRAN, 2010). Em Tonelli Neto (2012) é utilizado uma arquitetura da família ART, a rede neural ARTMAP-*Fuzzy*, conjuntamente com o emprego da transformada *wavelet* no desenvolvimento de um sistema inteligente que realiza o controle preventivo em sistemas de distribuição de energia elétrica.

2.3 SISTEMAS INTELIGENTES APLICADOS EM SHM

Na literatura especializada são encontrados trabalhos que aplicam métodos de computação inteligente no monitoramento da integridade estrutural, seja em aviões, construção civil ou estruturas mecânicas. Em Pandey e Barai (1995) é apresentado uma aplicação da rede neural *Perceptron* multicamadas na detecção de falhas em uma ponte com estruturas de aço. Furtado e Lopes (2002) combinam o método da impedância elétrica e de redes neurais para serem aplicados em sistemas de monitoramento das condições de máquina.

Em Tebaldi (2004) é proposta uma metodologia utilizando dados no domínio da frequência. Tendo como primeiro passo a utilização do método da impedância elétrica com objetivo de se determinar a localização das falhas e como segundo passo é realizada a quantificação da intensidade das falhas usando algoritmos genéticos.

O trabalho de Tebaldi, Coelho e Lopes (2006) propõem uma metodologia híbrida, sendo impedância elétrica para identificar a região do dano e posteriormente método de otimização para quantificar a severidade da falha.

Lee e Kim (2007) apresentam um algoritmo de dois níveis para detecção de danos, o qual recebe como entrada para RNA as respostas dinâmicas da estrutura. Neste caso a rede atua como um classificador de padrões. Para treinar a rede são utilizados sinais simulados numericamente e, por outro lado, os sinais adquiridos experimentalmente são usados para testar a RNA.

Silva, Dias e Lopes Júnior. (2008) apresentam a aplicação de SHM baseado em medidas da impedância elétrica obtidas por piezocerâmicas (PZT) acoplado em estruturas leves, neste caso uma viga. Xiang-jun et al. (2010) adotam técnicas *wavelet* para processar os sinais de vibração do monitoramento da estrutura de pontes. Em Shen et al. (2011), usando o método de Elementos Finitos, simula quinze padrões de falhas em uma asa de avião e, para o reconhecimento, utiliza uma rede neural probabilística.

Gonzalez (2012) aplica a técnica da impedância eletromecânica em sistemas SHM através de duas metodologias: uma utiliza a técnica de agrupamento *Fuzzy c-means*; e a outra utiliza análise da variância objetivando incorporar variações arbitrárias nos sistemas de medição e aquisição de dados.

Por meio de simulação de uma viga de alumínio, Lima et al. (2013) geram dados que são analisados por RNA do tipo *ARTMAP-Fuzzy* com objetivo de diagnosticar possíveis falhas na estrutura. Também, Wang et al. (2013) realizam uma comparação entre algoritmo genético multicamada e algoritmo genético convencional, aplicando-os em análise dos dados gerados a partir de uma ponte treliça de aço, discretizada por Elementos Finitos.

Souza et al. (2013) utilizam uma rede neural *ARTMAP-Fuzzy* para identificar e caracterizar as falhas estruturais de um edifício.

No trabalho de Lima (2014), são apresentadas duas metodologias para o desenvolvimento de sistemas SHM. O autor utiliza redes neurais artificiais e sistemas imunológicos artificiais sendo, mais especificamente, uma rede do tipo *ARTMAP-Fuzzy* e o Algoritmo de Seleção Negativa. Os dados para análise foram gerados a partir de um experimento em laboratório com uma viga de alumínio.

Lima et al. (2014b) utilizam um método inteligente baseado nos sistemas imunológicos artificiais para monitoramento da integridade de estruturas aeronáuticas. Os autores identificam e caracterizam amostras de falhas estruturais geradas a partir de um modelo genérico utilizando uma viga de alumínio por meio do Algoritmo de Seleção Negativa.

Gonzalez et al. (2014) descrevem o procedimento de avaliação da integridade estrutural por meio de análise de variância em conjunto com o teste de comparação múltipla de Tukey para determinar se os resultados são estatisticamente significantes. Os dados analisados são medidos por impedância eletromecânica através de sensores/atuadores piezocerâmicos acoplados na estrutura.

França (2014) propõe um método baseado em ondas de Lamb para detecção e localização de danos em compósitos que compõem a estrutura de uma fuselagem de avião. Para detecção e localização automática dos danos na estrutura, o autor utiliza RNA do tipo Levenberg-Marquardt *backpropagation*.

A detecção e quantificação de trincas transversais proposta por Khan e Parhi (2015) utilizam uma RNA de função de base radial, validada por meio de investigação experimental.

Utilizando um modelo numérico de um trator, Souza, Lima e Chavarette (2015) realizam um estudo comparando três técnicas de agrupamento não-supervisionado de dados, sendo elas K-Means, *Fuzzy C-Means* e a RNA Kohonen. Também o artigo de Xu et al. (2016) apresenta um método inteligente de diagnóstico de falha baseado em extração de características em conjunto seletivo com classificadores ARTMAP-*Fuzzy* múltiplos. Este método é aplicado ao diagnóstico de falhas de mancais de rolamentos.

Diante dos trabalhos apresentados neste subtópico, conclui-se que na última década tem aumentado significativamente o uso de métodos de computação inteligente para o monitoramento de estruturas, com a finalidade de não somente detectar, mas também classificar e quantificar a falha encontrada. As aplicações destes métodos têm sido feitas em diversos sistemas, como aeronaves, estruturas marítimas, mecânicas e civis. Porém, durante a revisão bibliográfica, foi encontrado, em particular, apenas o trabalho de Souza, Lima e Chavarette (2015) descrevendo o uso de métodos inteligentes aplicados em monitoramento de tratores. Assim, esta verificação evidencia a relevância do tema e a potencialidade de contribuição deste estudo.

3 MONITORAMENTO DA INTEGRIDADE DO TRATOR

3.1 INTRODUÇÃO

Para melhor compreensão do processo de monitoramento da integridade estrutural, precisa-se definir o que é dano. De acordo com os termos mais encontrados, pode-se definir danos como sendo alterações introduzidas em um sistema que afetam negativamente seu desempenho tanto no presente como no futuro (FARRAR; WORDEN, 2006). Como exemplos, cortes, afrouxamento de parafuso, trincas, incrustações, corrosões, desgaste de componentes, entre outros, podem ser considerados como danos à estrutura. A concentração ou evolução de danos podem ocasionar falhas e comprometer o funcionamento do sistema (GONSALEZ, 2012). Em outras palavras, um dano em uma estrutura mecânica não implica necessariamente na perda total da funcionalidade do sistema, mas sim que o sistema não está operando de maneira ótima. Conforme ocorre o aumento do dano, o funcionamento do sistema fica cada vez mais comprometido, até que atinja um estágio o qual não é mais aceitável pelo usuário. Então este estágio é chamado de falha (FARRAR; WORDEN, 2006).

Com base nas definições apresentadas, para a análise do problema de tombamento e empinamento do trator, neste trabalho define-se como falha o evento de tombamento e como dano algumas possíveis situações de perdas de contato dos pneus dianteiros ou traseiros com o solo. Com estas definições pretende-se generalizar o conceito de monitoramento da integridade do sistema dinâmico definido pelo trator em movimento no solo irregular. Assim, ao invés de apresentar as análises no contexto de dinâmica veicular, propõe-se discutir o problema como SHM para, inclusive, ao final, apresentar modelos conceituais de sistemas de atuação que possam garantir a operação de tratores em segurança.

3.2 FALHA ESTRUTURAL

O processo de implementação de uma estratégia de detecção de falhas em estruturas mecânicas é chamado de monitoramento da integridade estrutural. Em geral o monitoramento objetiva medir as entradas e saídas de um sistema antes de sofrer um dano. A análise destes dados, juntamente com as mesmas informações

obtidas em uma condição e análise desconhecida visa identificar uma possível condição de falha e, conseqüentemente, conhecer o nível de deterioração da estrutura observada. O prognóstico pode ser realizado por meio de informações das condições ambientais e operacionais atuais e, em alguns casos, análise numérica para estimar a vida útil remanescente do sistema (SOHN et al., 2004).

Lima (2014) considera que a identificação do tipo de alteração em uma estrutura analisada é o principal desafio em se projetar um SHM e, independentemente da origem ou intensidade, o acúmulo de um ou mais tipos de danos na estrutura pode desencadear uma falha e comprometer o funcionamento do sistema. De acordo com Lima et al. (2014b), a falha estrutural acarreta alteração dos parâmetros espaciais da estrutura, como: sensível redução da massa, alteração do amortecimento e diminuição da rigidez estrutural, ocasionando, por conseguinte, uma alteração no comportamento dinâmico da estrutura, de modo que estas alterações afetam os parâmetros como: frequências naturais, resposta, modos de vibração e fatores de amortecimento.

Em algumas aplicações a estrutura é submetida a uma avaliação não-destrutiva de sua integridade. Em geral, utiliza-se técnicas como: testes de emissão acústica, radiografia-X, líquido penetrante, inspeção ultrassônica, entre outros, objetivando estimar o grau de segurança e confiabilidade da estrutura. Todavia, estas técnicas não são efetivamente úteis quando há necessidade de avaliar uma estrutura em uso (LIMA et al., 2014), justificando assim o emprego de um sistema de monitoramento da integridade estrutural. Também a evolução dos sensores, o surgimento de materiais inteligentes (por apresentar características de um sistema biológico), miniaturização de componentes eletrônicos e aumento da capacidade de processamento de dados e sinais, tornam-se cada vez mais viável a utilização de sistema de SHM em estruturas que necessitam monitoramento em tempo real. Em particular, destaca-se o sistema para monitorar a integridade estrutural de um trator executando suas atividades no campo, sujeito à alterações abruptas do solo, colocando em risco não somente a integridade do trator mas também a vida do condutor, conforme ocorrências ilustradas nas figuras 1 e 2.

Figura 1 – Acidente com trator em Descalvado - SP.



Fonte: Trabalhador (2012).

Figura 2 – Acidente com trator em Portugal.



Fonte: Acidente (2015).

Contudo, destaca-se como um dos principais benefícios em se utilizar um sistema de SHM a possibilidade de identificar situações adversas, permitindo avisos ao usuário do sistema monitorado ou mesmo ativando mecanismos para corrigir o problema identificado (MAIO, 2011).

4 REDES NEURAIS ARTIFICIAIS

Neste capítulo apresenta-se uma revisão sobre redes neurais artificiais, abordando um resumo histórico, as principais características, o neurônio biológico, o neurônio artificial, sua estrutura, componentes e funcionamento.

4.1 RESUMO HISTÓRICO

Desde o início do século XX, o homem tem buscado compreender o funcionamento do cérebro. A partir desta busca, muitos pesquisadores têm se dedicado nesta área de estudo. Historicamente, a primeira publicação relacionada à neurocomputação é de 1943, e neste artigo os autores McCulloch e Pitts realizaram o primeiro modelamento matemático inspirado em um neurônio biológico, resultando-se na primeira concepção de um neurônio artificial (MCCULLOCH; PITTS, 1943).

McCulloch e Pitts (1943) descreveram um cálculo lógico das redes neurais que unificava os estudos de neurofisiologia e da lógica matemática. Eles definiram que o seu modelo formal de um neurônio seguia o propósito “tudo ou nada”. Com um número suficiente dessas unidades simples e com conexões sinápticas ajustadas e sincronicamente operando, McCulloch e Pitts mostraram que uma rede construída dessa forma realizaria o cálculo de qualquer função computável. Por este resultado, muitos pesquisadores aceitam este acontecimento como o nascimento das disciplinas de redes neurais e inteligência artificial (IA).

O próximo desenvolvimento significativo das redes neurais ocorreu no fim da década de 40 com a publicação do livro de Hebb “*The Organization of Behavior*”, o qual apresentou de forma inédita uma formulação explícita de uma regra de aprendizagem filosófica para a modificação sináptica, conhecida como aprendizagem Hebbiana. Resumidamente, Hebb propôs que a conectividade do cérebro é continuamente modificada conforme um organismo que vai aprendendo tarefas funcionais diferentes e essas modificações criam agrupamentos neurais. Publicado em 1949, o livro de Hebb foi imensamente influente entre os psicólogos mas teve pouco ou nenhum impacto sobre a comunidade de engenharia (HEBB, 1949).

Segundo Silva, Spatti e Flauzino (2010), diversos outros pesquisadores continuaram o trabalho de desenvolvimento de modelos matemáticos com base no neurônio biológico, gerando uma série de estruturas e de algoritmos de aprendizado. Entre os trabalhos publicados, destaca-se o de Frank Rosenblatt que desenvolveu o primeiro neurocomputador, denominado *Mark I – Perceptron*, idealizando o modelo básico da rede neural *Perceptron* (ROSENBLATT, 1958).

Na década de 60, especificamente em 1962, Rosenblatt publicou o livro “*Principles of Neurodynamics*” (ROSENBLATT, 1962). Este livro introduziu as redes denominadas *perceptrons* e, segundo Lopes (2005), mais tarde, em 1969, esta obra se tornou objeto de estudo dos pesquisadores Minsky e Papert, pois estes descobririam que os *perceptrons*, apresentado por Rosenblatt, eram incapazes de aprender o relacionamento entre as entradas e as saídas de funções lógicas bem simples como o XOR (ou-exclusivo), demonstrando claramente a impossibilidade das redes realizarem a correta classificação de padrões para classes não linearmente separáveis (SILVA; SPATTI; FLAUZINO, 2010). Devido a este fato, houve uma diminuição do interesse em pesquisas nesta área.

Já no início dos anos 80, Haykin (2001) relata que foram feitas importantes contribuições quanto a teoria e ao projeto de redes neurais, conseqüentemente havendo o ressurgimento do interesse pelas redes neurais. Neste momento autores como: Grossberg, Kohonen e Hopfield, dentre outros, contribuíram significativamente para as principais evoluções nesta nova fase. Grossberg (1980) estabeleceu um novo princípio de auto-organização conhecido como teoria da ressonância adaptativa. De forma simplificada, a teoria envolve uma camada de reconhecimento de baixo para cima, e uma camada generativa de cima para baixo. Ainda na década de 80, Kohonen (1982) publica artigo sobre os mapas auto-organizáveis, e Hopfield (1982) propõe as redes recorrentes baseadas em funções de energia, sendo esta última uma das principais responsáveis pela retomada de destaque da área de redes neurais, o mesmo destaque que possuía antes de 1969.

Em 1986, ocorreu um dos marcos mais importantes, o desenvolvimento do algoritmo *backpropagation*. Com a publicação do livro intitulado “*Parallel distributed processing*”, os autores Rumelhart, Hinton e Williams (1986) desenvolveram um algoritmo que permitia ajustar os pesos em uma rede com mais de uma camada, resolvendo até o problema de aprendizado dos padrões da função XOR (ou-exclusivo). Este algoritmo se tornou o mais popular entre as redes neurais.

No final dos anos 1990 e início dos anos 2000, houveram inúmeras aplicações práticas em diferentes ramos do conhecimento na área de redes neurais. Dezenas de novas outras contribuições têm permitido um crescente desenvolvimento teórico. Em especial, pode-se destacar a proposição de algoritmos de aprendizado baseados no método de Levenberg-Marquardt, também as redes neurais artificiais baseadas em máquina de vetores de suporte (*SVM - support vector machines*), que podem ser utilizados em classificação de padrões e regressão linear, e outra interessante contribuição é a implementação de circuitos integrados neurais com diversas configurações de tipologia (SILVA; SPATTI; FLAUZINO, 2010).

É possível encontrar mais detalhes sobre diversos outros fatos históricos das redes neurais na obra de (HAYKIN, 2001).

4.2 NEURÔNIO BIOLÓGICO


Algumas das características mais interessantes da rede neural biológica, que a torna superior ao mais sofisticado sistema de computação de IA, no que diz respeito a reconhecimento de padrões, segundo Yegnanarayana (2005), são:

- Robustez e tolerância a falhas: o envelhecimento das células nervosas parece não comprometer significativamente o desempenho;
- Flexibilidade: a rede automaticamente se ajusta ao novo ambiente sem utilizar instruções pré-programadas;
- Capacidade para lidar com uma enorme variedade de dados: a rede pode lidar com informações com ruído, probabilísticas, distorcidas e inconsistente;
- Computação coletiva: a rede tem capacidade de realizar operações em paralelo e, também, uma determinada tarefa de forma distribuída.

As características de uma rede neural biológica são atribuídas a sua estrutura e função. A unidade fundamental da rede é chamada de neurônio ou célula nervosa. O cérebro humano apresenta algo em torno de 100 bilhões de neurônios, destes, 10 bilhões somente no córtex, e 60 trilhões de sinapses ou conexões (HAYKIN, 2001; LOPES, 2005; SILVA, SPATTI; FLAUZINO, 2010).

Silva, Spatti e Flauzino (2010) afirmam que o principal papel do neurônio é conduzir impulsos que, na realidade, são estímulos elétricos advindos de reações

físico-químicas. Também, apresenta que o neurônio pode ser dividido em três partes principais: dendritos, corpo celular e axônio, conforme exibido na figura 3.



Fonte: Silva, Spatti e Flauzino (2010).

O núcleo está localizado no corpo celular (soma). Os dendritos têm como principal função captar, de forma contínua, sinais de outros neurônios e podem ser entendidos como terminais de entrada (LOPES, 2005). Já o axônio, estende-se desde o corpo celular através de um único filamento, cujas terminações são constituídas por ramificações denominadas terminações sinápticas, ou sinapses e podem ser entendidos como terminais de saída (SILVA; SPATTI; FLAUZINO, 2010).


“As sinapses são unidades estruturais e funcionais elementares que medeiam as interações entre os neurônios”, define (HAYKIN, 2001). Lopes (2005) ressalta que as sinapses ocorrem na região em que o axônio de um neurônio se conecta a um dendrito de outro neurônio, lembrando que inexistente contato físico nesta junção. E quando um neurônio é ativado transmitindo-se um sinal eletroquímico através do axônio que, por meio das terminações sinápticas, é enviado para outros neurônios. Se este sinal eletroquímico alcança um limiar (*threshold*) e, então, uma atividade elétrica na forma de pulsos curtos é gerada. Segundo Yegnanarayana (2005), geralmente esta atividade elétrica permanece no interior do neurônio, enquanto que mecanismos químicos ocorrem nas sinapses. Lopes (2005) conclui que por meio desta conectividade à sinapse é atribuída a inteligência.

4.3 NEURÔNIO ARTIFICIAL

A estrutura de uma RNA é baseada a partir de modelos conhecidos de sistemas nervosos biológicos e do próprio cérebro humano (SILVA; SPATTI; FLAUZINO, 2010). E a partir dos neurônios biológicos houve a inspiração para se criar, de forma mais simplificada, unidades processadoras, ou seja, os neurônios artificiais. Segundo Lopes (2005), estes neurônios artificiais possuem a capacidade de armazenar conhecimento, e a rede neural artificial forma um processador paralelo composto por neurônios ou nodos.


McCulloch e Pitts (1943) propuseram um modelo de neurônio mais simples, porém não descartando as principais características de uma rede neural biológica, ou seja, o paralelismo e a alta conectividade. E este vem sendo o modelo mais utilizado nas diversas arquiteturas de redes neurais artificiais. Este modelo pode ser observado através da figura 4.

Figura 4 – Componentes de um neurônio artificial.



Fonte: Lopes (2005).

O modelo básico de neurônio, que forma a base para o projeto de RNA, é apresentado na figura 5. O neurônio artificial possui m entradas (x_m), e uma função não linear de ativação na saída $[\varphi(\cdot)]$.

Figura 5 – Modelo não linear de um neurônio.

Fonte: Haykin (2001).

Assim, considerando a figura 5, verifica-se que o processo de treinamento do neurônio artificial se dá da seguinte forma (HAYKIN, 2001; SILVA; SPATTI; FLAUZINO, 2010):

- a) Sinais de entrada $x = \{x_1, x_2, \dots, x_m\}$: neste caso tem-se um neurônio de m entradas, onde um sinal x_j , vindo do meio externo, conecta-se a sinapse j . Estes sinais podem ser considerados como os valores assumidos pelas variáveis de uma aplicação específica.
- b) Pesos sinápticos $w = \{w_{k1}, w_{k2}, \dots, w_{km}\}$: são escritos w_{kj} , onde k se refere ao neurônio em questão e j se refere ao terminal de entrada da sinapse a qual o peso está ligado. É importante salientar que pesos sinápticos podem assumir valores positivos ou negativos, e são utilizados para ponderar cada uma das variáveis de entrada da rede.
- c) Combinador linear Σ : é um somador dos sinais de entrada, ponderados pelos respectivos pesos sinápticos.
- d) Bias b_k : possui o efeito de aumentar ou diminuir a entrada da função de ativação, podendo ser positivo ou negativo, respectivamente.
- e) Potencial de ativação v_k : é o resultado da diferença entre o combinador linear e o limiar de ativação. Se tal valor é positivo, com $u_k > b_k$, então possui potencial excitatório, caso contrário, o potencial será inibitório.

- f) Função de ativação $\varphi(\cdot)$: seu objetivo é restringir a amplitude da saída do neurônio para um valor finito. Tipicamente normaliza a saída obtendo valores como $[0, 1]$ ou $[-1, 1]$.
- g) Sinal de saída y_k : é o sinal que poderá ser utilizado por outros neurônios. Consiste no valor final produzido pelo neurônio artificial conforme conjunto de sinais de entrada.

Em termos matemáticos, as expressões (1) e (2) sintetizam o resultado produzido pelo neurônio artificial proposto por McCulloch e Pitts, ou seja:

$$u_k = \sum_{j=1}^m w_{kj} \cdot x_j \quad (1)$$

e

$$y_k = \varphi(u_k + b_k) \quad (2)$$


Haykin (2001) resume o funcionamento de um neurônio artificial de seguinte forma:

- Recebe-se de um conjunto de valores a serem adotados como as variáveis de entrada;
- Multiplica-se cada valor de entrada por seu respectivo peso sináptico;
- Obtém-se o potencial de ativação;
- Aplica-se uma função de ativação apropriada na soma do potencial de ativação mais o limiar de ativação;
- Compila-se a saída a partir da função de ativação;

4.3.1 Funções de ativação

A função de ativação $\varphi(v)$ define a saída de um neurônio em termos do potencial de ativação v . A figura 6 identifica três tipos básicos de funções de ativação: função de limiar; função linear por partes; e função sigmóide.

Figura 6 – Funções de ativação: (a) Função de limiar. (b) Função linear por partes. (c) Função sigmóide para parâmetro de inclinação a variável.



De acordo com Lopes (2005) e Altran (2010), a função de limiar, também conhecida como degrau, são apropriadas para sistemas binários discretos, enquanto que as funções sigmoidais podem ser utilizadas tanto em sistemas binários quanto contínuos. Ambos os autores concordam que a função sigmóide é a mais utilizada pelo fato de ser contínua e apresentar derivada simples.


4.4 ARQUITETURA DAS REDES NEURAIS ARTIFICIAIS próxima folha

A arquitetura de uma RNA define como estão arranjos ou dispostos os seus neurônios, uns com relação aos outros. A essência desses arranjos está no direcionamento das conexões sinápticas (SILVA; SPATTI; FLAUZINO, 2010).

Altran (2010) destaca que uma rede neural artificial consiste de neurônios (elementos de processamento) e sinapses (suas conexões), e dentro deste esquema há uma camada de entrada e uma camada de saída. Porém, entre estas camadas podem haver um número variável de camadas intermediárias (escondida, oculta ou invisível).

Assim, uma RNA pode ter suas saídas servindo como entradas a outros neurônios, ou ter suas entradas precedentes das saídas de outros neurônios. E neste cenário, há um peso para cada conexão de entrada de um neurônio. Altran (2010) também afirma que o nome de arquitetura da rede neural está diretamente ligado à disposição das camadas e o número de neurônio por camadas, exemplificado pela figura 7.

Figura 7 – Disposição de uma rede neural artificial.



Fonte: Lopes (2005).

Podem haver três classificações com relação à propagação dos dados dentro da estrutura de uma RNA, que são:

- Redes *Feedforward* (não recorrentes): o fluxo de informações segue sempre uma única direção (unidirecional), fluem sempre a partir da camada de entrada, em direção à camada de saída. O processamento das informações pode se estender por uma ou mais camadas, mas sem haver realimentação (KROSE; SMAGT, 1996). Como exemplo de camada simples, pode-se citar a rede *Perceptron* e a *Adaline*; e de camadas múltiplas, o *Perceptron* Multicamadas sem realimentação.
- Redes *Feedback* (recorrentes): contêm laço de realimentação, ou seja, a saída de um neurônio é utilizada para realimentar o mesmo neurônio,

ou neurônios das camadas anteriores. No início do processo de realimentação, há um período em que as unidades se submetem a um processo de adaptação tal que a rede passa para um estado estável, no qual a realimentação não mais pode variar a saída, desenvolvendo assim uma memória a longo prazo nos neurônios internos (KROSE; SMAGT, 1996; LOPES, 2005). Como exemplo pode-se citar a rede de Hopfield.

- Redes reticuladas: possuem como principais características a consideração da disposição espacial dos neurônios objetivando propósitos de extração de características. Neste contexto, a localização espacial dos neurônios está diretamente relacionada com o processo de ajuste de seus pesos e limiares (SILVA; SPATTI; FLAUZINO, 2010). Como exemplo pode-se citar a rede de Kohonen.

4.5 TREINAMENTO DA REDE NEURAL

A propriedade que é de importância primordial presente em uma RNA, é sua habilidade de aprender, pois com esta aprendizagem é possível melhorar seu desempenho. A aprendizagem acerca de seu ambiente se dá através de um processo iterativo de ajustes aplicados aos pesos sinápticos. A evolução da aprendizagem acontece a cada iteração (HAYKIN, 2001).

Haykin (2001) faz uma definição de forma precisa de aprendizagem, ele a define como sendo “[...] um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente na qual está inserida [...]”. E o objetivo da aprendizagem, ou treinamento, é permitir que um conjunto de valores de entrada (vetores), produza um conjunto de saídas esperadas ou desejadas (ALTRAN, 2010; LOPES, 2005).

Quanto aos tipos de treinamento, podem ser classificados em quatro, como se segue abaixo.

- Treinamento supervisionado ou treinamento associativo: a rede é treinada a partir de padrões de entradas e saídas. Na fase de aprendizado, o treinamento acontece por um agente externo (professor) que informa à rede a resposta desejada para o padrão de entrada especificado. O professor adquire conhecimento da rede, na

forma de mapeamento de entrada-saída. Dentre algumas redes que possuem este tipo de treinamento, pode-se citar a rede Madaline, que utiliza o algoritmo de aprendizagem *backpropagation*, a rede Groosberg, a rede ARTMAP, a rede ARTMAP-Fuzzy, entre outras (ALTRAN, 2010; KROSE; SMAGT, 1996; LOPES, 2005).

- Treinamento não-supervisionado ou *Self-organization*: exclusivamente, o treinamento depende de vetores de entradas. Este treinamento não possui um agente externo informando à rede a resposta desejada para o padrão de entrada apresentado. A partir desta ideia a rede projetada deve ser capaz de efetuar seu aprendizado através de um processamento estatístico dos padrões de entrada juntos de seus respectivos resultados na saída. Podem-se citar, como exemplos, as redes: Hopfield, Kohonen e ART (convencional e nebulosa) (KROSE; SMAGT, 1996; LOPES, 2005).
- Treinamento competitivo: este treinamento possui uma saída desejada. Verifica-se que as redes que fazem uso deste tipo de treinamento, possuem vários neurônios na camada de saída, e estes competem entre si para oferecer a saída desejada quando um padrão de entrada é aplicado à rede. Pode-se citar a *counterpropagation* como exemplo de uma rede neural que utiliza este tipo de treinamento (LOPES, 2005).
- Treinamento híbrido: faz uso alternadamente dos treinamentos supervisionado e não-supervisionado.

Dentre os diversos algoritmos existentes para treinar uma RNA, pode-se destacar: a regra de Hebb; a regra delta de Widrow e Hoff; a regra delta generalizada e o algoritmo de aprendizagem *backpropagation* (KROSE; SMAGT, 1996).

4.6 TIPOS DE REDES NEURAIIS ARTIFICIAIS

Há diversos modelos de RNA sendo utilizadas nas mais variadas aplicações em inúmeras áreas do conhecimento. Dentre os modelos de RNA mais conhecidos, destacam-se (LOPES, 2005):

- Rede neural de McCulloch-Pitts: por meio do ajuste adequado dos pesos, o neurônio tem capacidade de executar operações lógicas básicas. Foi desenvolvido em 1943 (MCCULLOCH; PITTS, 1943).
- *Perceptron* de camada simples: utilizada para resolução de problemas lógicos envolvendo os operadores AND e OR, e também no reconhecimento e classificação de padrões. Foi proposta por Rosenblatt em 1958 (ROSENBLATT, 1958).
- *Perceptron* de múltiplas camadas: capacidade para realizar operações lógicas complexas (LOPES, 2005).
- *Adaline*: após devidamente treinada, é utilizada para reconhecimento e classificação de padrões (WIDROW; HOFF, 1960).
- *Madaline*: rede neural multicamada que apresenta alto grau de tolerância a falhas (WIDROW; HOFF, 1960).
- Rede neural *feedforward*: rede neural multicamada utilizada para classificação e controle de robôs. Foi proposta em 1969 (MINSKY; PAPERT, 1969).
- SOM (*Self Organizing Map*) de Kohonen: elaborada em 1972, é uma rede competitiva utilizada para fazer mapeamento entre dados de entrada e saída (KOHONEN, 1972).
- Rede neural *backpropagation*: Werbos (1974) foi quem apresentou a primeira concepção de algoritmo *backpropagation*. Porém, Rumelhart, Hinton e Williams (1986), sabendo sobre o trabalho de Werbos, descobriram como ajustar os pesos de uma RNA das unidades de entrada para a unidade de saída e propagar o erro da saída em direção da camada de entrada. Rede com aplicabilidade em operações lógicas complexas e classificação de padrões.
- Rede ART (*Adaptive Resonance Theory*): elaborada por Grossberg (1976) em 1975, esta rede possui por base características da ressonância adaptativa. Utilizada para reconhecimento de sinais e processamento de imagens.
- Rede de Hopfield: rede aplicada em reconhecimento de imagens (HOPFIELD, 1982).

- Rede CNM (*Combinatorial Neural Model*): é uma rede neural com características que permitem sua aplicação em processamento de reconhecimento, análise e classificação de dados (MACHADO; ROCHA, 1989).
- Rede CPN (*Counterpropagation Network*): é uma rede neural competitiva elaborada para trabalhar como uma tabela de consulta autoprogramável com habilidade de interpolar dados de entrada, segundo (HECHT-NIELSEN, 1987).
- Rede BAM (*Bidirectional Associative Memory*): possui memória associativa bidirecional. Quando os dados fornecidos possuem um padrão corrompido, ela permite uma certa tolerância a erros (KOSKO, 1988).
- Rede *Neocognitron*: rede neural multicamada desenvolvida para reconhecer caracteres alfabéticos escritos à mão. Possui interligações parciais entre as unidades das várias camadas. Possui uma boa tolerância a erros, pois identifica os caracteres mesmo com certa inclinação na escrita ou pequena distorção na imagem (FUKUSHIMA, 1980).
- Rede RBFN (*Radial Basis Function Network*): possui arquitetura *feedforward* de camadas múltiplas. Uma das particularidades desta rede é a utilização de uma função de ativação de base radial, como as gaussianas, nos neurônios de camada intermediária (SILVA; SPATTI; FLAUZINO, 2010).

4.7 BENEFÍCIOS DAS REDES NEURAIIS ARTIFICIAIS

De acordo com Lopes (2005), a RNA possui como base uma arquitetura de implementação paralelamente distribuída com capacidade de generalização, ou seja, a RNA responde adequadamente a novas situações (diagnóstico) com base no aprendizado adquirido em experiências passadas (treinamento). Estas duas características são primordiais, porquanto possibilitam a resolução de problemas da vida real que possuem solução complexa.

As redes neurais apresentam particularidades únicas que somente são encontradas em suas estruturas. Seu uso oferece as seguintes propriedades úteis e capacidades (HAYKIN, 2001; LOPES, 2005):

- **Não linearidade:** a não linearidade é de um tipo próprio, por toda a rede, porém, um neurônio artificial pode ou não ser linear. Essa possibilidade de obter um sinal de entrada gerado a partir de um mecanismo físico inerentemente não linear faz da não linearidade algo muito importante.
- **Aprendizado e generalização:** possui a capacidade de adquirir resultados significativos por meio da aprendizagem e do acúmulo de conhecimento.
- **Processamento paralelo:** maior rapidez na execução de tarefas mais difíceis.
- **Robustez:** a rede possui capacidade de processar dados mesmo com ruídos ou incompletos.
- **Flexibilidade:** é possível aplicar as redes neurais em diversas áreas do conhecimento.

4.8 APLICAÇÕES DAS REDES NEURAIS ARTIFICIAIS

A capacidade de aprendizado e generalização das RNAs proporciona um alto grau de aplicabilidade em inúmeras questões da vida real. Na atualidade, pesquisadores tem inovado a área de arquitetura de redes neurais e técnicas de treinamento, adequando-as a aplicações específicas. Dessa forma, o interesse de utilização das RNAs vem aumentando de forma significativa. Dentre as principais aplicações destacam-se: diagnóstico; processamento de imagens diversas; reconhecimento de padrões; classificação de padrões; controle; regressão e previsão; otimização; e filtragem de dados (LOPES, 2005; SILVA; SPATTI; FLAUZINO, 2010).

5 TEORIA DA RESSONÂNCIA ADAPTATIVA

5.1 REDE NEURAL ART

A Teoria da Ressonância Adaptativa, do inglês *Adaptive Resonance Theory* (ART), é uma estrutura de rede neural estabelecida, desenvolvida no Centro de Sistemas Adaptativos da Universidade de Boston (SERRANO-GOTARREDONA; LINARES-BARRANCO; ANDREOU, 1998). É baseada em muitos anos de sólidos estudos de modelos matemáticos o que tornou possível a criação de uma série de arquiteturas ART (GROSSBERG, 1976; GROSSBERG, 1980; CARPENTER; GROSSBERG, 1991).

Em 1976 Grossberg introduziu a rede ART sendo um sistema que utiliza a aprendizagem não supervisionada como uma teoria do processo de informação cognitiva humana (GROSSBERG, 1976). Este tipo de rede apresenta uma topologia em que a dinâmica possui como base a teoria da ressonância adaptativa, permitindo assim que este tipo de rede seja de suma importância, pois baseia-se na resolução do dilema da plasticidade e da estabilidade, produzido por meio do teste de vigilância, dando origem a uma rede mais rápida e precisa (LOPES, 2005).

O dilema “Estabilidade-Plasticidade”, em resumo, apresenta uma rede que seja flexível o suficiente para absorver mudanças nos padrões de entradas da rede, ou seja, mudanças no comportamento da classe de entrada, e seja capaz de se adaptar a este novo tipo de padrão e ao mesmo tempo seja estável o suficiente para garantir o agrupamento de todos os elementos sem perder o que já foi aprendido, ou seja, toda a aprendizagem já absorvida nos processos anteriores (MARTINS, 2010).

Martins (2010) salienta que redes do tipo ART foram criadas para serem utilizadas em ambientes que seja necessário trabalhar durante longos períodos, em cenários que há possibilidades de aparecimento de novos padrões, e que atualize seus pesos de forma contínua e incremental. Lopes (2005) define as redes ART como desenvolvidas para codificar reconhecimentos estáveis, em tempo real, através da auto-organização, em detrimento a sequências arbitrárias de padrões de entrada.

Segundo Silva, Spatti e Flauzino (2010), as topologias baseadas na arquitetura ART podem ser divididas nos grupos citados a seguir, que são

classificados de acordo com o tipo de suas entradas e seus processos de treinamento, conforme segue:

- **ART-1:** padrões com entradas binárias e treinamento não supervisionado (CARPENTER; GROSSBERG, 1987a).
- **ART-2:** padrões com entradas binárias ou analógicas (contínuas) e treinamento não supervisionado (CARPENTER; GROSSBERG, 1987b).
- **ART-3:** treinamento não supervisionado e entradas binárias ou analógicas. Usa-se aqui topologia multinível e transmissores para controle do processo de busca pela melhor solução (CARPENTER; GROSSBERG, 1990).
- **ARTMAP:** treinamento supervisionado em tempo real e padrões de entradas binárias ou analógicas. Utiliza em sua estrutura duas redes ART (CARPENTER; GROSSBERG; REYNOLDS, 1991a).
- **Fuzzy ART:** treinamento não supervisionado e engloba em sua arquitetura cálculos baseados em lógica nebulosa (CARPENTER; GROSSBERG; ROSEN, 1991b).
- **ARTMAP-Fuzzy:** treinamento supervisionado com todos os cálculos fundamentados na lógica nebulosa (CARPENTER et al., 1992).

Quando o objetivo é reconhecer e classificar padrões a Teoria da Ressonância Adaptativa é de grande utilidade. Suas particularidades e capacidade de auto organizar padrões de entrada em categorias de reconhecimento a faz alcançar equilíbrio na questão plasticidade e estabilidade (MARTINS, 2010).

5.1.1 Rede neural ARTMAP-Fuzzy

A rede neural artificial ARTMAP-Fuzzy possui uma arquitetura estável e plástica, que garante uma vantagem com relação a outros tipos de redes neurais artificiais. Este tipo de rede permite a inclusão de um módulo de treinamento continuado, o qual habilita a extração de conhecimento sem a necessidade de reiniciar o processo de treinamento quando novos padrões são apresentados, ao contrário do que acontece com a maioria das redes neurais. Esta característica torna possível um uso reduzido de padrões de entrada na fase de treinamento, durante a

- **Taxa de treinamento β ($\beta \in [0\ 1]$):** controla a velocidade de adaptação da rede;
- **Parâmetro de vigilância (ρ_a, ρ_b e $\rho_{ab} \in [0\ 1]$):** controla a ressonância da rede, nomeando os parâmetros responsáveis pelo número de categorias criadas, também aceitando a categoria proposta, ou rejeitando de forma a se buscar a escolha de uma nova categoria.

Aumentando o valor de ρ , a rede neural se torna mais seletiva, reduzindo sua capacidade de generalização. Diminuindo o valor de ρ , é reduzido o número de categorias criadas, maximizando a capacidade de generalização da rede ARTMAP-Fuzzy.

5.1.2 Algoritmo ARTMAP-Fuzzy

Com relação a codificação, a seguir é apresentado as etapas de como o algoritmo é executado durante a fase de treinamento, tendo em vista a figura 8.

Etapa 1: obtém-se os dados de entrada para o módulo ART_a e ART_b.

Etapa 2: efetua-se a normalização dos vetores a e b , respectivamente. Na equação (3) é possível observar a normalização do vetor de entrada do módulo ART_a.

$$\bar{a} = \frac{a}{|a|} \quad 3)$$

Etapa 3: inicialmente todos os pesos da rede neural possuem o valor igual a 1, indicando que não existe categoria ativa, conforme apresenta a equação (4).

$$W_j^a = W_k^b = W_j^{ab} = 1 \quad 4)$$

Etapa 4: faz-se a leitura dos parâmetros $\alpha, \beta, \rho_a, \rho_b, \rho_{ab}, \varepsilon$.

Etapa 5: efetua-se a codificação do complemento, preservando a amplitude da informação.

$$\overline{a}_i^c = 1 - \bar{a}_i$$

5)

Etapa 6: então o vetor de entrada no campo F_0 será um vetor 2M-dimensional, conforme se segue:

$$I = [\bar{a} \quad \bar{a}^c] = [\bar{a}_1 \quad \dots \quad \bar{a}_M \quad \bar{a}_1^c \quad \dots \quad \bar{a}_M^c] \quad (6)$$

Etapa 7: obtém-se valores os quais podem ser escolhidos como categoria.

$$T_j = \frac{|I \wedge W_j|}{\alpha + |W_j|} \quad (7)$$

Etapa 8: escolhe-se a categoria do módulo ART_b , através da expressão:

$$T_k^b = \max \{T_k^b : k = 1, \dots, N_b\} \quad (8)$$

Etapa 9: neste momento ocorre o teste de viglância. Se houver ressonância, parte-se para a etapa 11, caso contrário, etapa 10.

$$\frac{|I_s \wedge W_k^b|}{I_s} \geq \rho_b \quad (9)$$

Etapa 10: *reset*. Após aplicar o *reset*, volta-se para a etapa 8.

$$T_k^b = 0 \quad (10)$$

Etapa 11: adapta-se os pesos do módulo ART_b .

$$W_k^{novo} = \beta(I_s \wedge W_k^{velho}) + (1 - \beta)W_k^{velho} \quad (11)$$

Etapa 12: atualiza-se o vetor atividade Y_b .

Etapa 13: escolhe-se a categoria do módulo ART_a .

$$T_j^a = \max \{T_j^a : j = 1, \dots, N_a\} \quad (12)$$

Etapa 14: faz-se o teste de vigilância. Se houver ressonância, parte-se para a etapa 16, caso contrário, etapa 15.

$$\frac{|I_e \wedge W_j^a|}{I_e} \geq \rho_a \quad (13)$$

Etapa 15: *reset*. Após aplicar o *reset*, volta-se para a etapa 13.

$$T_j^a = 0 \quad (14)$$

Etapa 16: realiza-se o *match tracking*. Se houver ressonância, parte-se para a etapa 19, caso contrário, etapa 17.

$$\frac{|Y^b \wedge W_j^{ab}|}{Y^b} \geq \rho_{ab} \quad (15)$$

Etapa 17: *reset*.

$$T_j^a = 0 \quad (16)$$

Etapa 18: acresce-se o parâmetro de vigilância, e volta-se para a etapa 13.

$$\rho_a = \frac{|I_e \wedge W_j^a|}{I_e} + \varepsilon \quad (17)$$

Etapa 19: atualiza-se o vetor atividade de F_2 .


Etapa 20: adapta-se os pesos do módulo ART_a.

$$W_j^{novo} = \beta(I_e \wedge W_j^{velho}) + (1 - \beta)W_j^{velho} \quad (18)$$

Etapa 21: adapta-se os pesos Inter-ART. Treinamento concluído.

Com o objetivo de facilitar a compreensão do funcionamento da rede neural ARTMAP-Fuzzy foi desenvolvido um fluxograma apresentando cada etapa da realização do treinamento, que pode ser visualizado na figura 9.

Figura 9 – Fluxograma da rede neural ARTMAP-Fuzzy.



Fonte: elaborado pelo autor.

5.2 PRINCIPAIS CONCEITOS DA LÓGICA NEBULOSA

Zadeh (1965), da Universidade da Califórnia em Berkeley, ainda na década de 60, estruturou a lógica nebulosa para tratar e representar incertezas. A importância condicionada à ela é pelo motivo do mundo não ser constituído apenas de fatos absolutamente verdadeiros ou falsos, pois permite representar valores intermediários, que estão entre os valores verdadeiros e falsos da conhecida lógica clássica. A lógica clássica atribui o valor 1 (um) para aquilo que se considera completamente verdadeiro, e 0 (zero) para aquilo que se considera completamente falso. Porém, a lógica nebulosa, também conhecida como difusa ou *fuzzy*, possui a vantagem de poder ser atribuída às informações que não são completamente verdadeiras ou falsas, podendo ter seu valor variando entre 0 e 1. A lógica nebulosa permite que se possa atribuir valores intermediários entre avaliações convencionais (sim/não, verdadeiro/falso), são as chamadas variáveis linguísticas, objetos ou palavras, que possuem um entendimento mais adequado que os números. As variáveis nebulosas permitem que noções como copo meio cheio ou copo meio vazio sejam formuladas matematicamente e processadas pelo computador (LOPES, 2005).

Biondi et al. (2006) define lógica nebulosa como uma lógica multivalorada capaz de processar informações vagas, geralmente apresentadas em uma linguagem natural, convertendo-as para um formato numérico. Ainda, acrescenta que entre a certeza do ser e do não ser da lógica binária, há infinitos graus de incerteza.

A lógica *Fuzzy* tem como propósito central fazer com que as decisões tomadas a partir de sistemas computadorizados cheguem cada vez mais próximas das decisões humanas. Antes da chegada da lógica *Fuzzy*, não havia como processar computacionalmente informações vagas, imprecisas ou incertas (BIONDI et al., 2006).

5.2.1 Breve histórico

Em 1965, Lotfi Askar-Zadeh, professor de Departamento de Engenharia Elétrica e Ciências da Computação da Universidade da Califórnia, apresentou a teoria de conjuntos *Fuzzy*, exatamente quando trabalhava com classificação de

conjuntos, os quais não apresentavam limites bem definidos devido ser suave e não abrupta a transição entre eles. Em diversos momentos, devido a relação de pertinência não ser bem definida, tornava-se complicado afirmar que um elemento pertencia ou não a um determinado conjunto. A ideia de Zadeh foi flexibilizar essa relação, e então elaborar um grau de pertinência. Dessa forma um determinado elemento poderia pertencer parcialmente a um determinado conjunto (RIBEIRO; MELO, 2013). Este artigo é um marco da teoria dos conjuntos *Fuzzy*, e foi publicado em 1965 (ZADEH, 1965).

Segundo Ribeiro e Melo (2013), logo que publicada, a teoria da lógica *Fuzzy* recebeu fortes críticas da comunidade científica, principalmente por parte dos estatísticos norte-americanos. Apesar disso, outros pesquisadores compreendiam a potencialidade desta teoria, e trabalhos foram surgindo em diversos países, principalmente no Japão. Um caso prático é do professor Toshiro Terano da Universidade de Hosei, que em 1972, introduziu a ideia na comunidade de pesquisas japonesas, e logo começaram a aplicar a teoria em larga escala no processo eletromecânico de elevadores e metrô.

Ribeiro e Melo (2013) ainda pontuam os seguintes tópicos ao longo da história:

- 1974 – Aplicação *Fuzzy* de locomotiva a vapor;
- 1976 – Controlador *Fuzzy* aplicado aos fornos das fábricas;
- 1985 – Produção do primeiro chip *Fuzzy* no laboratório Bell;
- 1987 – Fabricação de um helicóptero não-tripulado controlado por um controlador *Fuzzy*.
- 1988 – Primeiro sistema *Fuzzy* de comércio financeiro;
- 1989 – Pesquisas japonesas aplicando *Fuzzy* em sistemas de suporte a decisões e inteligência de robôs;
- 1990 – Primeira máquina de lavar roupas *Fuzzy*;

Com este breve histórico é possível perceber quão rápido foi sua evolução e que há uma área enorme para suas aplicações.

5.2.2 Fusão com redes neurais

Para Lee (2005) as redes neurais artificiais e a lógica *Fuzzy* são duas tecnologias que se completam. Redes podem aprender a partir de dados, porém o conhecimento representado pela RNA é de difícil compreensão. Ao contrário, sistemas *Fuzzy* são fáceis de compreender pois eles utilizam termos linguísticos e não é necessário aprender algoritmos. Então, diversas pesquisas foram elaboradas com intuito de uni-las, e estas podem ser classificadas da seguinte maneira:

- Sistemas *Fuzzy* modificados com treinamento supervisionado de RNA;
- Criação de redes neurais usando sistemas *Fuzzy*;
- Desenvolvendo funções de pertinência com redes neurais;
- Concatenação de redes neurais e sistemas *Fuzzy*.


6 DESENVOLVIMENTO E SIMULAÇÃO COMPUTACIONAL

Neste capítulo apresenta-se o modelo numérico utilizado para gerar os dados usados pelo sistema inteligente, tanto para o treinamento da rede quanto para a classificação dos eventos de danos ou falhas.

6.1 MODELO NUMÉRICO

O principal objetivo deste estudo consiste no desenvolvimento de um sistema inteligente para o monitoramento de falhas do trator. Os dados são obtidos através de simulações realizadas em um modelo numérico, representado através de equações diferenciais. A ilustração esquemática do trator é apresentada na figura 10.

Figura 10 – Modelo do trator.




Fonte: Sakai (2006).

Durante o trabalho no campo as rodas traseiras e dianteiras de um trator podem perder o contato com o chão. Este fenômeno pode ocorrer de 3 modos principais, conforme figura 11, 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 contato com o chão (o trator empina a traseira);
- as rodas traseiras e dianteiras perdem contato com o chão ao mesmo tempo (o trator dá um salto).


Conforme descrito na seção 3.1, cada um dos eventos mencionados acima, neste trabalho, é entendido como um dano no sistema. Obviamente não tratam-se de alterações nos parâmetros estruturais do trator como massa, amortecimento ou rigidez, porém são situações que precede o evento de tombamento que, para este contexto, define uma falha de operação do sistema.

Figura 11 – Comportamento das rodas de um trator no campo: a) estado normal; b) o trator empina a frente; c) o trator empina a traseira; d) o trator salta.



Fonte: Peruzzi, Chavarette e Guilherme (2010).

Para se obter respostas do sistema nas condições especificadas anteriormente adota-se o sistema dinâmico ilustrado na figura 12, na qual apresenta M como sendo a massa total do trator. Os pneus são modelados por molas lineares e por amortecimento viscoso colocados em paralelo. Então, k_1 e k_2 são rigidezes das molas; c_1 e c_2 são os coeficientes de amortecimento viscoso; y é o deslocamento vertical do centro de gravidade do trator; θ é o deslocamento angular do centro de gravidade do trator em relação ao eixo lateral; a é a distância entre o centro de gravidade e rodas frontais e b é a distância entre o centro de gravidade e rodas traseiras; F_1 e F_2 são excitações devido desníveis do solo.

Figura 12 – Modelo do sistema dinâmico do trator.

Fonte: Sakai (2006).

Para o referido modelo, Sakai (2006) afirma que a força de equilíbrio na direção vertical e do momento do salto é equacionada por (19):

$$\begin{cases} m\ddot{y} - F_1(y, \dot{y}, \theta, \dot{\theta}) - F_2(y, \dot{y}, \theta, \dot{\theta}) + mg = 0 \\ J\ddot{\theta} - aF_1(y, \dot{y}, \theta, \dot{\theta}) + bF_2(y, \dot{y}, \theta, \dot{\theta}) = 0 \end{cases} \quad (19)$$

onde, J é o momento angular de inércia do centro de massa; $F_1(\cdot)$ e $F_2(\cdot)$ são cargas dinâmicas nos pneus, respectivamente, dianteiro e traseiro do trator, dadas pelas equações (20) e (21):

$$F_1(y, \dot{y}, \theta, \dot{\theta}) = -k_1(y + a\theta - h_1(t)) - c_1(\dot{y} + a\dot{\theta} - \dot{h}_1(t)) \quad (20)$$

$$F_2(y, \dot{y}, \theta, \dot{\theta}) = -k_2(y - b\theta - h_2(t)) - c_2(\dot{y} - b\dot{\theta} - \dot{h}_2(t)) \quad (21)$$

Nas equações (20) e (21) $h_1(t)$ e $h_2(t)$ são excitações periódicas que simulam os desníveis da superfície:

$$h_1 = a_0 + a_1 \cos(\omega t) + a_2 \cos(2\omega t) + a_3 \sin(\omega t) + a_4 \sin(2\omega t) \quad (22)$$

$$h_2 = a_0 + a_1 \cos(\omega t - \phi) + a_2 \cos(2\omega t - \phi) + a_3 \sin(\omega t - \phi) + a_4 \sin(2\omega t - \phi) \quad (23)$$

onde, $\omega = \frac{2\pi v}{L}$ e $\phi = \frac{2\pi W_B}{L}$.


Observe que quando o trator:

- Empina a frente $F_1(\cdot) = 0$;
- Empina a traseira $F_2(\cdot) = 0$;
- Dá um salto $F_1(\cdot) = F_2(\cdot) = 0$.


A implementação do modelo numérico foi codificada em Matlab®. Para resolução da equação diferencial (19) foi utilizado integrador numérico Runge Kutta de quarta ordem, com os seguintes parâmetros: $k_1=200.000$; $k_2=260.000$; $l_1=0.7$; $l_2=0.64$; $c_1=5.500$; $c_2=6.690$; $g=9,81$; $J=600$; $m=888$; $a_0=0,025$; $a_1=a_0\log(v)/L$; $a_2=a_0\log(3v^2)/L$; $a_3=a_0\log(v)/3$ e $a_4=a_0\log(3v^2)/3$;

Para simular as excitações na estrutura do trator, por meio das equações (22) e (23), 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, é obtida uma resposta em frequência utilizando-se a transformada rápida de Fourier (FFT do inglês *Fast Fourier Transform*) na resposta temporal obtida pela integração numérica da velocidade de deslocamento da estrutura do trator. Cada sinal gerado é composto por 512 pontos. Nas figuras 13, 14, 15 e 16 pode-se observar quatro exemplos de sinais, escolhidos aleatoriamente, obtidos através da simulação. A figura 13 exhibe um sinal nas condições normais, a figura 14 exhibe um sinal que apresenta dano no sistema, especificamente a situação em que o trator empina a dianteira. A figura 15 exhibe um sinal de dano em que o trator empina a traseira e, finalmente, a figura 16 exhibe o sinal de falha obtido do evento em que o trator salta, ou seja, perde o contato com o solo das rodas dianteiras e traseiras.


Figura 13 – Sinal nas condições normais.

Fonte: elaborado pelo autor.

Figura 14 – Sinal de dano em que o trator empina a dianteira.


Fonte: elaborado pelo autor.

Figura 15 – Sinal de dano em que o trator empina a traseira.



Fonte: elaborado pelo autor.

Figura 16 – Sinal de falha em que o trator salta.



Fonte: elaborado pelo autor.

7 METODOLOGIA PROPOSTA


Este capítulo apresenta um detalhamento do sistema inteligente proposto neste trabalho. Será possível observar o funcionamento de cada etapa do processo de monitoramento da operação do trator.

7.1 SISTEMA DE MONITORAMENTO E DIAGNÓSTICO DE FALHAS ESTRUTURAIS

O sistema de monitoramento e diagnóstico proposto neste trabalho é composto por quatro fases fundamentais: geração das amostras de resposta do sistema, no domínio da frequência, para cada um dos eventos descritos anteriormente; a divisão aleatória das amostras; treinamento e classificação do evento identificado.

Para melhor entendimento das fases, foi elaborado um fluxograma do funcionamento do sistema de monitoramento e diagnóstico utilizando uma rede ARTMAP-Fuzzy, o qual pode ser observado através da figura 17. Ainda, a seguir, cada fase é sucintamente descrita

Figura 17 – Lógica estrutural do sistema de SHM utilizando a rede ARTMAP-Fuzzy.



Fonte: elaborado pelo autor.

7.1.1 Geração de amostras

Este conjunto de entrada da rede ARTMAP-Fuzzy, originado pelo modelo numérico, é composto por quatro vetores multidimensionais, sendo um para cada condição analisada, sendo elas: condição normal, trator empina a dianteira, trator empina a traseira e trator salta.

O modelo numérico proposto gera as amostras são sinais de resposta em frequência com 512 pontos para cada L e v atribuído. Entende-se que L é a distância entre as saliências consecutivas na superfície do campo, e v é a velocidade do trator no plano horizontal. Assim, é possível variar a distância entre as saliências consecutivas e, para cada uma, alterar o valor da velocidade. Com esta estratégia é possível representar cada um dos eventos de interesse.

Para realizar as simulações das condições normais e anormais (falha ou dano), efetuou-se as seguintes variações.

- Distância entre as saliências consecutivas no traçado L
 - o Foi alterada de 0,6m até 0,1m, com intervalos de 0,02m.
- Velocidade do trator v
 - o Para cada L utilizado, variou-se a velocidade em 0,5m/s iniciando em 1,0m/s até 10,0m/s.

Para elucidar as combinações adotadas no processo de geração das amostras, foi elaborado a figura 18.

Figura 18 – Combinações adotadas entre L e v .

	1,0 (m/s)	1,5 (m/s)	2,0 (m/s)	3,0 (m/s)	...	8,0 (m/s)	8,5 (m/s)	9,0 (m/s)	9,5 (m/s)	10 (m/s)
L=0,60m	X	X	X	X	...	X	X	X	X	X
L=0,58m	X	X	X	X	...	X	X	X	X	X
...	...	...	...	...	...	...	...	...	...	...
L=0,12m	X	X	X	X	...	X	X	X	X	X
L=0,10m	X	X	X	X	...	X	X	X	X	X

Fonte: elaborado pelo autor.

Dessa forma, constituiu-se uma base de dados de 494 amostras distintas, das quais 34 em condições normais e 460 nas demais condições. O grupo de amostras em condição de falha ou danos, é subdividido quantitativamente em: 194 do trator

em dano empinando a dianteira, 143 em dano empinando a traseira e 123 em falha saltando. Estas quantidades são representadas na tabela 1.

Tabela 1 – Sinais presentes na base de dados.

Tipo de Amostra	Quantidade
Condições normais	34
Trator empina a frente (dano)	194
Trator empina a traseira (dano)	143
Trator salta (falha)	123
Total	494

Fonte: elaborado pelo autor.

O modelo numérico do trator foi codificado para armazenar individualmente cada tipo de amostra apresentada na tabela 1 em vetores multidimensionais, resultando em quatro vetores singulares, uma para cada condição de evento.

7.1.2 Aleatoriedade

Os quatros vetores multidimensionais são submetidos à função *randperm* (permutação aleatória) do Matlab que aleatoriamente os divide na proporção de 75% das amostras para o módulo de treinamento e os 25% restantes para o módulo de classificação. A aleatoriedade na separação dos dados que são quais dados serão utilizados no treinamento e na classificação elimina qualquer tentativa empreendida na manipulação dos resultados.

A tabela 2 contém o detalhamento do quantitativo dos dados utilizados por cada módulo.

Tabela 2 – Quantidade de amostras utilizadas no treinamento e diagnóstico.

Tipo de Amostra	Qtde. Treinamento	Qtde. Diagnóstico
Condições normais	26	8
Trator empina a dianteira (dano)	146	48
Trator empina a traseira (dano)	108	35
Trator salta (falha)	93	30
Total	373	121

Fonte: elaborado pelo autor.

7.1.3 Treinamento do sistema

A fase de treinamento da rede neural ARTMAP-Fuzzy é responsável por adquirir o conhecimento que será aplicado no módulo de classificação. Pode ser realizada de forma *offline* (sem que o sistema esteja efetivamente em produção) e é importante para ajustar os pesos e criar as categorias que são utilizadas no módulo de diagnóstico dos dados. Nesta fase a rede é treinada com um conjunto de amostras, gerando uma quantidade de categorias igual ao número de sinais de entrada.

Conforme especificado anteriormente, o treinamento da rede ARTMAP-Fuzzy é do tipo supervisionado, ou seja, para cada amostra de entrada também é fornecido a saída desejada, dessa forma cria-se um conhecimento sobre as amostras do sistema.

Para ocorrer a ressonância entre as informações de entrada e saída codificadas no módulo ART_a e ART_b, é realizado o mapeamento $b = f(a)$, a (entrada) $\in \mathbb{R}^n$ e b (saída) $\in \mathbb{R}^m$, sendo f uma função desconhecida (linear ou não-linear) multidimensional. Assim, o mecanismo inter-ART exerce a função de realizar o treinamento supervisionado.

Após a normalização dos vetores multidimensionais de entrada, os valores são compostos por números entre 0 e 1. Quanto à saída, foi adotada uma representação binária de três dígitos. Cada combinação entre os dígitos de saída indica uma classificação quanto ao tipo da amostra analisada. Esta combinação se dá conforme segue:

- 000 – trator em condições normais;

- 101 – dano: trator empina a dianteira;
- 110 – dano: trator empina a traseira;
- 111 – falha: trator salta.

7.1.4 Classificação do sistema

A fase de diagnóstico da rede neural ARTMAP-*Fuzzy* é realizada de forma *online* (com o sistema em produção) e tem como objetivo validar a utilização da estratégia proposta. Nesta fase um novo conjunto de amostras, diferente do conjunto de amostras utilizadas na fase de treinamento, deve ser apresentado à rede e cada amostra analisada individualmente. Todas as amostras são comparadas com o conhecimento (categorias criadas na fase de treinamento) obtido pela rede neural ARTMAP-*Fuzzy* e, assim, quando há ressonância entre os padrões, classifica-se em categoria a amostra apresentada à rede. Obtida a categoria correspondente a um determinado padrão é, finalmente, identificado a intensidade (porcentagem de falha) e a classificação do evento.

8 APLICAÇÕES E RESULTADOS

Neste capítulo são apresentados os resultados obtidos com a aplicação do método proposto na base de amostras simuladas.

8.1 PARÂMETROS UTILIZADOS

O algoritmo foi desenvolvido em ambiente MATLAB®, utilizando-se a versão 8.1, e os testes realizados em um computador com processador Intel I7-5500U 2.4GHz, com 8GB de memória RAM e sistema operacional Windows 10 Education 64 bits. Para avaliar a metodologia proposta foram adotados como indicadores de eficiência a precisão e o custo computacional, assumido proporcional ao tempo de processamento.

Na tabela 3 apresenta-se os valores dos parâmetros utilizados no processo de treinamento e diagnóstico do sistema de SHM. Deve-se destacar que os parâmetros foram escolhidos depois de exaustivos testes para se obter uma configuração ótima. Salienta-se que os testes foram realizados de forma qualitativa, mediante alteração dos valores dos parâmetros e observação dos resultados obtidos na fase de classificação. O critério utilizado foi proposto por Sakai (2006), sendo v acima de 6,0 m/s e L abaixo de 0,15 m como falha ou dano.

Tabela 3 – Valores dos parâmetros utilizados pela rede ARTMAP-Fuzzy.

Parâmetros	Valores
α	0,1
β	1
ρ_a	0,9
ρ_b	1
ρ_{ab}	0,95
ξ	0,0001

Fonte: elaborado pelo autor.

Observa-se que o valor do parâmetro de vigilância (ρ_a) é de 0,9. Este valor alto é utilizado devido os sinais apresentarem uma distinção significativa, permitindo assim se obter um sistema mais “exigente” quanto a ressonância. Neste trabalho, ρ_a


com valores menores que 0,5 reduz significativamente o índice de acerto do sistema.

8.2 DETALHAMENTO DO PROGRAMA

Tendo como objetivo maximizar a veracidade dos resultados obtidos, foi desenvolvido um programa computacional, também codificado em Matlab, com a finalidade de separar aleatoriamente as amostras e automatizar a execução do sistema de SHM. Para isto, no programa foi definido a variável *ite* (de iteração). Salienta-se que em cada execução, os resultados da classificação são salvos para análise posterior. Neste trabalho foi utilizado $ite = 1.000$.

A função aleatoriedade, conforme o nome sugere, é utilizada para selecionar aleatoriamente quais amostras são utilizadas para treinamento ou para classificação do sistema de SHM. Dessa forma, elimina-se procedimentos eventualmente tendenciosos, como selecionar quais amostras devam ser utilizadas para treinamento tal que permitam um melhor índice de acerto durante a classificação. Este sistema possui imparcialidade na escolha das amostras utilizadas em cada módulo do sistema de SHM.

Completado o número especificado de execuções, a função processar resultados salvos (PRS) apresenta um resumo do processo. Por exemplo, cada execução do sistema gera resultados como tempo necessário para o treinamento e classificação, quantidade de amostras utilizadas para treinamento e classificação e quantidade de erros e acertos do módulo de classificação. Logo, depois de *ite* execuções, a função PRS calcula a tabela de referência cruzada para cada grupo de resultados salvos. A figura 19 apresenta o fluxograma do programa para clareza de entendimento.

Figura 19 – Fluxograma do programa.

Fonte: elaborado pelo autor.

8.3 RESULTADOS

Na tabela 4 apresenta-se os resultados obtidos pelo sistema de SHM ao processar as amostras geradas a partir do modelo numérico do trator. Observa-se que o sistema foi executado 1.000 vezes ($ite = 1.000$) e, em cada execução, foi gerado um registro das informações obtidas para a partir dela calcular a média simples dos valores.

Tabela 4 – Resultados obtidos aplicando rede ARTMAP-Fuzzy.

	Treinamento	Classificação			Porcentagem (%)		Tempo de Processamento (ms)	
		Qtde. de Amostras	Errada	Correta	Erro	Acerto	Treina.	Classif.
Execuções 1.000								
Média Simples	373	121	4	117	3,31	96,69	1.668,8	466,8

Fonte: elaborado pelo autor.

Para maior entendimento do comportamento do sistema em relação à média simples apresentada, é possível efetuar o cálculo do desvio padrão das porcentagens de acerto das mil execuções do programa por meio da equação (24).

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (x - \bar{x})^2}{n}} \quad 24)$$

onde:

σ = desvio padrão;

n = número de amostras;

x = porcentagem de acerto;

$\bar{x}$ = média da porcentagem de acerto.

Realizado o cálculo do desvio padrão, a porcentagem de acerto do sistema de SHM é de $96,69 \pm 1,59\%$, ou seja, há 68% de probabilidade do sistema obter um acerto na classificação entre 95,10% e 98,28%. Considerando o valor de duas vezes o desvio padrão, a probabilidade aumenta para 95% de chance de as classificações corretas ficarem entre 93,51% e 99,87%. Ainda, quanto ao tempo de processamento, para o módulo de treinamento seu valor é de $1.668,8 \pm 46,7\text{ms}$ e, para o módulo de classificação, é de $466,8 \pm 37,2\text{ms}$.

8.4 DISCUSSÃO E ANÁLISE DO RESULTADO

De acordo com a tabela 4, as mil execuções do programa tiveram em média um índice de 96,69% de classificação correta das amostras analisadas. Os resultados obtidos pelos testes com o sistema de SHM utilizando RNA do tipo ARTMAP-Fuzzy, demonstraram um índice de acerto acima de 93,51%, cumprindo satisfatoriamente o objetivo proposto neste trabalho, comprovando sua eficiência quando aplicado ao monitoramento da integridade de estruturas mecânicas.

Finalmente, com relação ao tempo de processamento do módulo de classificação, obteve-se o valor de 466,8ms, em média, para analisar 121 amostras, o que resulta em um tempo de aproximadamente 3,86 milésimos de segundo por amostra, superficialmente atingindo uma autonomia de análise e classificação de 260 amostras por segundo. De acordo com tempo obtido, viabiliza-se a aplicação do

sistema de SHM para análise e classificação em tempo real, levando em consideração que as tomadas de decisões devem ocorrer rapidamente, prevenindo possíveis acidentes e danos à estrutura mecânica.

8.4.1 Sugestões para tomadas de decisões

Após detectado a presença de dano pelo sistema de SHM, o mesmo possui condições, por meio de codificação, de:

- Acionar um dispositivo sonoro ou visual para alertar o indivíduo que opera o trator;
- Disparar um sinal para o sistema de controle dos freios do veículo;
- Ou mesmo, acionar um circuito de atuadores para estabilização do trator.

9 CONCLUSÃO

Neste trabalho foi apresentada uma pesquisa sobre o uso de um método de computação inteligente, no caso redes neurais artificiais, aplicado ao monitoramento e diagnóstico de saltos e tombamento de um trator. Foi proposto interpretar os saltos como danos e o tombamento como falha do sistema definido pelo trator em movimento no solo irregular. Especificamente, foi possível identificar a existência de danos ou falha e, também, classificar o tipo do evento. Foram consideradas duas condições de danos: a de o trator empinar a dianteira ou a traseira; e a falha ao saltar perdendo totalmente o contato com o solo. Foi entendido salto como tombamento pois ele pode ser causado pelo mesmo.

Destaca-se que a configuração dos parâmetros do sistema de SHM, exigidos pela rede ARTMAP-*Fuzzy*, deve ser realizada de forma precisa e cautelosa, pois um ligeiro erro na configuração dos parâmetros de vigilância, da taxa de treinamento ou do parâmetro de escolha, compromete significativamente o desempenho do sistema.

O método de diagnóstico proposto alcançou um índice médio de acerto de 96,69% quando executado com a sua melhor configuração de parâmetros. A rede neural ARTMAP-*Fuzzy* mostrou-se apta para ser utilizada como um sistema de tempo real, pois a fase de treinamento, que é mais demorada, pode ser realizada de forma *offline*, enquanto que a fase de diagnóstico obteve um tempo de resposta de 3,86 milésimos de segundos por amostra classificada. Este tempo é considerado aceitável para um sistema de tomada de decisão em tempo real.

Portanto, conclui-se que o sistema para monitoramento de falhas em estruturas proposto a partir de uma rede neural artificial ARTMAP-*Fuzzy* é confiável e preciso quando utilizado com objetivo de manter a integridade do trator e, conseqüentemente, a segurança do seu condutor.

9.1 SUGESTÕES PARA TRABALHOS FUTUROS

Para dar continuidade a esta pesquisa sugere-se os seguintes itens:

- Aplicar o sistema de SHM ARTMAP-*Fuzzy* em outros problemas, como por exemplo: estruturas marítimas, espaciais, aeronaves, pontes e edifícios;

- Verificar a possibilidade de utilizar o sistema de SHM para prevenir a ocorrência de anormalidades, ou seja, antecipadamente à ocorrência de falhas estruturais.
- Incorporar o módulo de treinamento continuado nos sistemas que utilizam ARTMAP-*Fuzzy* como método de classificação, explorando mais amplamente a característica de estabilidade e plasticidade.
- Agregar outros métodos a rede ARTMAP-*Fuzzy*, como enxame de partículas, para auxiliar na seleção de conjunto de critérios; e coeficiente Kappa, para reduzir a quantidade de atributos.

REFERÊNCIAS

- ACIDENTE faz vítima mortal em S. João da Pesqueira. **Correio do Amanhã**, 17 jun. 2015. Disponível em: <http://www.cmjornal.xl.pt/nacional/detalhe/morre_em_capotamento_de_trator.html>. Acesso em: 18 jan. 2016.
- ALTRAN, A. B. **Sistema inteligente para previsão de carga multinodal em sistemas elétricos de potência**. 2010. 86 f. Tese (Doutorado em Engenharia Elétrica) - Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2010.
- BIONDI, L. N. et al. Minicurso de sistema especialista nebuloso. In: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, 38., 2006, Goiânia. **Anais...** Rio de Janeiro: Sobrapo, 2006. p. 2508-2543.
- CARPENTER, G. A. et al. Fuzzy ARTMAP: a neural network architecture for incremental supervised learning of analog multidimensional maps. **IEEE Transactions on Neural Networks**, Piscataway, v. 3, n. 5, p. 698-713, set 1992.
- CARPENTER, G. A.; GROSSBERG, S. A massively parallel architecture for a self-organizing neural pattern recognition machine. **Computer Vision, Graphics, and Image Processing**, Maryland Heights, v. 37, n. 1, p. 54-115, 1987a.
- CARPENTER, G. A.; GROSSBERG, S. ART2: self-organization of stable category recognition codes for analog input patterns. **Applied Optics**, Washington, v. 26, n. 23, p. 4919-4930, 1987b.
- CARPENTER, G. A.; GROSSBERG, S. ART3: hierarchical search using chemical transmitters in self-organizing pattern recognition architectures. **Neural Networks**, Kidlington, v. 3, n. 2, p. 129-152, 1990.
- CARPENTER, G. A.; GROSSBERG, S. **Pattern recognition by self organizing**. Cambridge: MIT Press, 1991. 710 p.
- CARPENTER, G. A.; GROSSBERG, S.; REYNOLDS, J. H. ARTMAP: supervised real-time learning and classification of nonstationary data by a self-organizing neural network. **Neural Networks**, Kidlington, v. 4, n. 5, p. 565-588, 1991a.
- CARPENTER, G. A.; GROSSBERG, S.; ROSEN, D. B. Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance system. **Neural Networks**, Kidlington, v. 4, n. 6, p. 759-771, 1991b.
- FARRAR, C. R.; WORDEN, K. An introduction to structural health monitoring. **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering**, London, v. 365, n. 1851, december 2006. p. 303-315.
- FRANÇA, A. A. **Detecção e localização de danos em materiais compósitos aplicado em aeronaves utilizando redes neurais artificiais**. 2014. 109 f.

Dissertação (Mestrado em Engenharia Mecânica)- Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2014.

FUKUSHIMA, K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. **Biological Cybernetics**, New York, v. 36, p. 193-202, 1980.

FURTADO, R. M.; LOPES, V. J. Localização de falhas estruturais usando sensores e atuadores piezoelétricos e redes neurais artificiais. In: CONGRESSO NACIONAL DE ENGENHARIA MECÂNICA - CONEM, 2., 2002, João Pessoa. **Anais...** Rio de Janeiro: ABCM, 2002.

GONSALEZ, C. G. **Metodologias para Reconhecimento de Padrões em Sistemas SHM Utilizando a Técnica da Impedância Eletromecânica (E/M)**. 2012. 116 f. Dissertação (Mestrado em Engenharia Mecânica)- Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2012.

GONSALEZ, C. G. et al. Structural damage detection in an aeronautical panel using analysis of variance. **Mechanical System and Signal Processing**, London, v. 52-53, p. 206-216, 2014.

GROSSBERG, S. Adaptive pattern classification and universal recoding I: Parallel development and coding of neural feature detectors. **Biological Cybernetics**, New York, v. 23, n. 3, p. 121-134, 1976.

GROSSBERG, S. How does a brain build a cognitive code? **Psychological Review**, Washington, v. 87, p. 1-51, january 1980.

HALL, S. R. The effective management and use of structural health data. **Structural Health Monitoring 2000**, Palo Alto, v. 1, n. 1, p. 265-275, 1999.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001. 900 p.

HEBB, D. O. **The organization of Behavior: a neuropsychological theory**. New York: Wiley, 1949. 335 p.

HECHT-NIELSEN, R. Counterpropagation networks. **Applied Optics**, Washington, v. 26, n. 23, p. 4979-4984, dec. 1987.

HOPFIELD, J. J. Neural network and physical systems with emergent collective computational abilities. **National Academy of Sciences. Proceedings**, Washington, v. 79, n. 8, p. 2554-2558, 1982.

KHAN, I. A.; PARHI, D. R. Fault detection of composite beam by using the modal parameters and RBFNN technique. **Journal of Mechanical Science and Technology**, Heidelberg, v. 29, n. 4, p. 1637-1648, 2015.

KHOURY, J. K. J. et al. Modelagem da estabilidade de tratores agrícolas de pneus. **Pesq. Agropec. Bras.**, Brasília, v. 39, n. 5, p. 459-468, mai. 2004.

KOHONEN, T. Correlation Matrix Memories. **IEEE Transactions on Computers**, New York, v. c-21, n. 4, p. 353-359, apr 1972.

KOHONEN, T. Self-organized formation of topologically correct feature maps. **Biological Cybernetics**, Heidelberg, v. 43, n. 1, p. 59-69, 1982.

KOSKO, B. Bidirectional associative memories. **IEEE Transactions on Systems, Man and Cybernetics**, New York, v. 18, n. 1, p. 49-60, jan/feb 1988.

KROSE, B.; SMAGT, P. V. **An introduction to neural network**. Amsterdam: University of Amsterdam, 1996. 135 p.

LEE, J.; KIM, S. Structural damage detection in the frequency domain using neural networks. **Journal of Intelligent Material Systems and Structures**, London, v. 18, n. 1, p. 785-792, 2007.

LEE, K. H. **First course on fuzzy theory and applications**. Berlin: Springer-Verlag Berlin Heidelberg, 2005. 335 p.

LIMA, F. P. A. **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, 2014.

LIMA, F. P. A. et al. ARTMAP-Fuzzy artificial neural network applied to the monitoring and fault identification in structural. **Lecture Notes in Information Technology**, Korea, v. 39, n. 1, p. 3-9, 2013.

LIMA, F. P. A. et al. Diagnóstico de falhas em estruturas mecânicas utilizando rede neural artificial ARTMAP-Fuzzy. In: CONGRESSO DE MATEMÁTICA APLICADA E COMPUTACIONAL - CMAC, 1., 2014, Curitiba. **Congresso...** Curitiba: SBMAC, 2014a. p. 1-6.

LIMA, F. P. A. et al. Monitoramento da integridade de estruturas aeronáuticas utilizando um método inteligente baseado em sistemas imunológicos artificiais. In: SERIES OF THE BRAZILIAN SOCIETY OF APPLIED AND COMPUTATIONAL MATHEMATICS, 2., 2014, Curitiba. **Proceedings...** Curitiba: SBMAC, 2014b. p. 1-6

LOPES, M. L. M. **Desenvolvimento de redes neurais para previsão de cargas elétricas de sistemas de energia elétrica**. 2005. 149 f. Tese (Doutorado em Engenharia Elétrica)- Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2005.

MACHADO, R. J.; ROCHA, A. F. **Handling knowledge in high order neural networks: the combinatorial neural network**. Rio de Janeiro: IBM Rio Scientific Center, 1989. (Technical Report, CCR076).

MAIO, C. E. B. **Técnicas para monitoramento de integridade estrutural usando sensores e atuadores piezoelétricos**. 2011. 113 f. Dissertação (Mestrado em

Engenharia Mecânica)- Escola de Engenharia de São Carlos, Universidade de São Paulo - USP, São Carlos, 2011.

MARTINS, J. R. D. **Detecção e classificação de curtos-circuitos em sistemas de distribuição usando rede neural artificial ARTMAP nebulosa**. 2010. 84 f. Dissertação (Mestrado em Engenharia Elétrica)- Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2010.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin Mathematical Biophysics**, New York, v. 5, n. 1, p. 115-133, 1943.

MINSKY, M. L.; PAPERT, S. A. **Perceptrons**: an introduction to computational geometry. Cambridge: MIT Press, 1969. 308 p.

MONTEMOR, C.; VELOSO, L.; AREOSA, J. Acidentes com tratores agrícolas e florestais: aprender para prevenir. **Sociologia, Revista da Faculdade de Letras da Universidade do Porto**, Porto, v. 30, n. 1, p. 119-143, 2015.

PANDEY, P. C.; BARAI, S. V. Multilayer perceptron in damage detection of bridge structures. **Computers & Structures**, Kidlington, v. 54, n. 4, p. 597-608, 1995.

PERUZZI, N. J.; CHAVARETTE, F. R.; GUILHERME, I. R. Análise da dinâmica do modelo de um trator com excitação periódica vertical. In: CONFERÊNCIA BRASILEIRA DE DINÂMICA, CONTROLE E APLICAÇÕES - DINCON, 9., 2010, Serra Negra. **Conferencia...** Serra Negra: SBMAC, 2010. p. 552-557.

RIBEIRO, D. T. M.; MELO, D. T. **Sistemas especialistas e lógica fuzzy**: análise de risco cardíaco. Mococa: [s.n.], 2013. 92 p.

ROSENBLATT, F. The Perceptron: a probabilistic model for information storage and organization in the brain. **Psychological Review**, Washington, v. 65, n. 1, p. 386-408, 1958.

ROSENBLATT, F. **Principles of neurodynamics**. Washington: Spartan Books, 1962. 616 p.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, London, v. 323, n. 9, p. 533-536, oct 1986.

SAKAI, K. **Nonlinear dynamics and chaos in agricultural systems**. Amsterdam: Elsevier Science B.V., 2006. 220 p.

SERRANO-GOTARREDONA, T.; LINARES-BARRANCO, B.; ANDREOU, A. G. **Adaptive resonance theory microchips**: circuit design techniques. New York: Springer, 1998.

SHEN, T. et al. Damage location and identification of the wing structure with probabilistic neural networks. In: PROGNOSTICS & SYSTEM HEALTH MANAGEMENT CONFERENCE, 1., 2011, Shenzhen. **Conference...** Shenzhen: IEEE, 2011. p. 1-6.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010. 399 p.

SILVA, S.; DIAS, M. J.; LOPES, V. Jr. Structural health monitoring in smart structures through time series analysis. **Structural Health Monitoring**, London, v. 7, n. 3, p. 231-244, 2008.

SOHN, H. et al. **A review of structural health monitoring literature: 1996-2001**. [S.l.]: Los Alamos National Laboratory, 2004. p. 301.

SOUZA, A. S. et al. Analysis of structural integrity using an ARTMAP-Fuzzy artificial neural network. **Advanced Materials Research**, Hong Kong, v. 838-841, p. 3287-3290, 2013.

SOUZA, S. S. F.; LIMA, F. P. A.; CHAVARETTE, F. R. Monitoring of structural integrity using unsupervised data clustering techniques. **International Journal of Pure and Applied Mathematics**, Bulgaria, v. 104, n. 1, p. 119-133, 2015.

TAN, S. C.; LIM, C. P. Evolutionary Fuzzy ARTMAP neural networks and their applications to fault detection and diagnosis. **Neural Processing Letters**, New York, v. 31, n. 3, p. 219-242, may 2010.

TEBALDI, A. **Detecção de falhas estruturais usando sensores e atuadores piezelétricos e algoritmos genéticos**. 2004. 105 f. Dissertação (Mestrado em Engenharia Mecânica)- Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2004.

TEBALDI, A.; COELHO, L. S.; LOPES, V. J. Detecção de falhas em estruturas inteligentes usando otimização por nuvem de partículas: fundamentos e estudo de casos. **Revista Controle & Automação**, Campinas, v. 17, n. 3, p. 312-330, 2006.

TONELLI-NETO, M. S. **Formulação do controle preventivo em sistemas de distribuição de energia elétrica baseada na lógica fuzzy e redes neurais**. 2012. 137 f. Dissertação (Mestrado em Engenharia Elétrica)- Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2012.

TRABALHADOR morre em acidente com trator em Descalvado. **São Carlos Agora**, 23 nov. 2012. Disponível em: <<http://www.saocarlosagora.com.br/regiao/noticia/2012/11/23/36240/trabalhador-rural-morre-em-acidente-com-trator-em-descalvado/>>. Acesso em: 18 jan. 2016.

WANG, F. L. et al. Damage diagnosis for complex steel truss bridges using multi-layer genetic algorithm. **Journal of Civil Structural Health Monitoring**, England, v. 3, n. 2, p. 117-127, 2013.

WERBOS, P. J. **Beyond regression: new tools for prediction and analysis in the**. 1974. 906 f. Thesis (Doutorado)- Harvard University, Harvard, 1974.

WIDROW, B.; HOFF, M. E. **Adaptative switching circuits**. ire wescon convention record. California: Institute of Radio Engineers, 1960. p. 96-104.

XIANG-JUN, C. et al. Application of wavelet analysis in vibration signal processing of bridge structure. In: INTERNATIONAL CONFERENCE ON MEASURING TECHNOLOGY AND MECHATRONICS AUTOMATION, 2., 2010, Changsha City. **Conference...** Changsha City: IEEE, 2010. p. 671-674.

XU, Z. et al. A selective fuzzy ARTMAP ensemble and its application to the fault diagnosis of rolling element bearing. **Neurocomputing**, Amsterdam, v. 182, p. 25-35, 2016.

YEGNANARAYANA, B. **Artificial neural networks**. New Delhi: Prentice-Hall of India, 2005. 476 p.

ZADEH, L. A. Fuzzy sets. **Information and Control**, Maryland Heights, v. 8, p. 338-353, 1965.