

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
CÂMPUS DE ILHA SOLTEIRA
DEPARTAMENTO DE ENGENHARIA MECÂNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

JACQUELINE SANTOS CHAVES

MONITORAMENTO E CLASSIFICAÇÃO DE FALHAS EM ESTRUTURAS
UTILIZANDO REDES NEURAIS ARTIFICIAIS

Ilha Solteira
2016

JACQUELINE SANTOS CHAVES

**MONITORAMENTO E CLASSIFICAÇÃO DE FALHAS EM ESTRUTURAS
UTILIZANDO REDES NEURAS ARTIFICIAIS**

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

Área de Conhecimento: Mecânica dos Sólidos

Prof. Dr. FÁBIO ROBERTO CHAVARETTE

Orientador

Prof^a. Dr^a MARA LÚCIA MARTINS LOPES

Coorientadora

Ilha Solteira

2016

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

Chaves, Jacqueline Santos.

C512m Monitoramento e classificação de falhas em estruturas utilizando redes neurais artificiais / Jacqueline Santos Chaves. -- Ilha Solteira: [s.n.], 2016
71 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. Falhas estruturais. 2. Monitoramento da integridade estrutural.
3. Redes neurais artificiais.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: MONITORAMENTO E CLASSIFICAÇÃO DE FALHAS EM ESTRUTURAS UTILIZANDO REDES NEURAIS ARTIFICIAIS

AUTORA: JACQUELINE SANTOS CHAVES

ORIENTADOR: FABIO ROBERTO CHAVARETTE

CO-ORIENTADORA: MARA LUCIA MARTINS LOPES

Aprovada como parte das exigências para obtenção do Título de Mestra 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



Profa. Dra. RENATA DE FREITAS GÓIS COMPARONI
Faculdade de Tecnologia de São Paulo - FATEC

Ilha Solteira, 29 de julho de 2016

DEDICO

Aos meus pais Gilberto Theodoro Chaves e Sandra Regina Santos Chaves, pela motivação, pelo amor e total apoio.

AGRADECIMENTOS

Agradeço a Deus, primeiramente, pela sabedoria, cuidado, sustento e abundante misericórdia para comigo.

Agradeço ao meu orientador Prof. Dr. Fábio Roberto Chavarette, pela orientação, disponibilidade de tempo, confiança e dedicação para que esta dissertação fosse realizada. Ainda agradeço pelo apoio, compreensão, motivação e direcionamento no decorrer destes dois anos de mestrado, me conduzindo nos trabalhos a serem realizados.

Agradeço a minha coorientadora Prof^ª. Dra. Mara Lúcia Martins Lopes pela motivação, companheirismo, disponibilidade, recursos, pelo apoio em geral e orientações dadas para a conclusão deste mestrado.

Aos meus pais Gilberto e Sandra, que sempre me apoiaram e dedicaram tempo e esforços para que eu concluísse o curso de mestrado.

Aos professores do PPGEM da UNESP de Ilha Solteira por transmitirem seus conhecimentos e sabedoria no decorrer deste curso. Em especial, pelos professores Gustavo Luiz Chagas Manhães de Abreu, Aparecido Carlos Gonçalves, José Luiz Gasche e Antônio Eduardo Turra pela motivação que proporcionaram.

Aos meus colegas de disciplinas pelo companheirismo.

A CAPES pelo auxílio financeiro, através de bolsa de estudo de Mestrado, permitindo minha estadia, estudo, e dedicação a este projeto.

“Ninguém ignora tudo. Ninguém sabe tudo. Todos nós sabemos alguma coisa. Todos nós ignoramos alguma coisa. Por isso aprendemos sempre.” Paulo Freire.

RESUMO

As técnicas para o monitoramento de falhas em estruturas têm se tornado cada vez mais importantes principalmente por seus benefícios quanto à maior segurança de vida e por auxiliarem as empresas responsáveis em construir edifícios, pontes e estruturas em geral a diminuir seus custos com a manutenção das mesmas. Deste modo, a fim de desenvolver uma forma eficiente para a identificação e caracterização de falhas estruturais, esta dissertação tem por objetivo demonstrar uma aplicação de Redes Neurais Artificiais (RNAs) como uma técnica de monitoramento da integridade estrutural (SHM) para tal problema. Através de um modelo matemático de equações diferenciais ordinárias para a representação de uma estrutura predial, será desenvolvida uma RNA ARTMAP *Fuzzy* por ser uma rede flexível e estável em relação à sua habilidade em se adaptar às mudanças imprevistas do ambiente externo, para identificar tais falhas.

Palavras-Chaves – Monitoramento de falhas. Redes neurais artificiais. ARTMAP *Fuzzy*.

ABSTRACT

The techniques for failures monitoring in mechanical engineering structures have become increasingly important especially for its benefits as the largest life-security and assist the responsible companies for build buildings, bridges and structures in general to lower their costs to maintenance of them. Thus, in order to develop an efficient way for the identification and characterization of structural failures, this work aims to demonstrate an application of Artificial Neural Networks (ANN) as a monitoring technique of structural health monitoring (SHM) for this problem. Through a dynamic model for the representation of a building structure, Fuzzy ARTMAP ANN will be developed to be a flexible and stable network with respect to its ability to adapt to unexpected changes in the external environment to identify such failures.

Keywords – Damage monitoring. Artificial neural network. *Fuzzy ARTMAP*.

LISTA DE FIGURAS

Figura 1 - Edifícios: a) Guangzhou - China, b) International Commerce Centre - Hong Kong, c) Willis Tower – EUA.	11
Figura 2 - Colapso da ponte de Injaka, 1998.	12
Figura 3 - Trinca em uma parede.	18
Figura 4 - Trinca em um prédio.	18
Figura 5 - Exemplo da utilização de sensores em uma ponte.	21
Figura 6 - Implementação de um sistema de SHM.	22
Figura 7 - Fluxograma de um Algoritmo Genético.	25
Figura 8 - Modelo de neurônio artificial.	26
Figura 9 - Arquitetura simples de uma RNA.	27
Figura 10 - Estrutura de uma rede ART.	32
Figura 11 - Aprendizado supervisionado.	36
Figura 12 - Rede neural ARTMAP <i>Fuzzy</i> .	39
Figura 13 - Modelo dinâmico.	40
Figura 14 - Coordenadas generalizadas no modelo dinâmico do edifício.	41
Figura 15 - Diagnóstico da rede neural ARTMAP.	45
Figura 16 - Sinal de condição normal.	46
Figura 17 - Sinal de condição de falha no 1º andar.	47
Figura 18 - Sinal de condição de falha no 2º andar.	47
Figura 19 - Fluxograma da rede neural ARTMAP <i>Fuzzy</i>	50
Figura 20 - Graus de pertinência de um conjunto clássico.	71
Figura 21 - Grau de pertinência de um conjunto nebuloso referente a temperatura.	71
Figura 22 - Exemplo de variáveis linguísticas.	72

LISTA DE TABELAS

Tabela 1 - Parâmetros do modelo matemático.	44
Tabela 2 - Parâmetros de treinamento do teste de validação da RNA - Banco A.	51
Tabela 3 - Parâmetros do treinamento da rede ARTMAP <i>Fuzzy</i> - Banco A.	52
Tabela 4 - Parâmetros da ARTMAP <i>Fuzzy</i> para o melhor resultado - Banco A.	53
Tabela 5 - Sequência dos padrões de entrada e saída na fase de diagnóstico.	53
Tabela 6 - Parâmetros de treinamento e diagnóstico para classificação dos sinais - Banco A.	54
Tabela 7 - Primeiro teste cruzado – Banco A.	55
Tabela 8 - Segundo teste cruzado – Banco A.	55
Tabela 9 - Terceiro teste cruzado – Banco A.	56
Tabela 10 - Parâmetros de treinamento do teste de validação da RNA - Banco B.	56
Tabela 11 - Parâmetros da ARTMAP <i>Fuzzy</i> para o melhor resultado - Banco B.	57
Tabela 12 - Parâmetros de treinamento e diagnóstico para classificação dos sinais - Banco B.	58
Tabela 13 - Primeiro teste cruzado – Banco B.	58
Tabela 14 - Segundo teste cruzado – Banco B.	59
Tabela 15 - Terceiro teste cruzado – Banco B.	59
Tabela 16 - Parâmetros de treinamento do teste de validação da RNA - Banco C.	60
Tabela 17 - Parâmetros da ARTMAP <i>Fuzzy</i> para o melhor resultado - Banco C.	60
Tabela 18 - Parâmetros de treinamento e diagnóstico para classificação dos sinais - Banco C.	61
Tabela 19 – Primeiro teste cruzado – Banco C.	62
Tabela 20 - Segundo teste cruzado – Banco C.	62
Tabela 21 - Terceiro teste cruzado – Banco C.	62

LISTA DE SÍMBOLOS

m_1, m_2	-	Massa da Estrutura
k_1, k_2	-	Coefficiente de Rigidez Elástica da Estrutura
c_1, c_2	-	Coefficiente de Amortecimento viscoso da Estrutura
q_1, q_2	-	Coordenadas Generalizadas
$\dot{x}_1, \dot{x}_3$	-	Velocidade
$\ddot{x}_2, \ddot{x}_4$	-	Aceleração
S	-	Excitação Externa
$\dot{S}$	-	Velocidade da ação do sismo
$\ddot{S}$	-	Acelerograma da ação do sismo
ω_1, ω_2	-	Frequência Natural
f	-	Frequência
τ	-	Amplitude da Excitação Externa

SUMÁRIO

1	INTRODUÇÃO	11
1.1	JUSTIFICATIVA.....	14
1.2	OBJETIVO	14
1.3	ORGANIZAÇÃO DA DISSERTAÇÃO.....	15
2	FALHAS ESTRUTURAIS E O MONITORAMENTO DA INTEGRIDADE	
	ESTRUTURAL	17
2.1	DEFINIÇÕES	17
2.1.1	Falhas estruturais	17
2.1.2	Monitoramento da integridade estrutural.....	19
2.1.3	Motivação para o uso de um sistema de SHM.....	19
2.2	PROCESSO E IMPLEMENTAÇÃO DE UM SISTEMA DE SHM.....	20
2.3	TÉCNICAS COMUNS	22
2.4	NOVAS ABORDAGENS	23
2.4.1	Algoritmos genéticos	24
2.4.2	Redes neurais artificiais	25
2.5	REVISÃO BIBLIOGRÁFICA DE SHM.....	27
3	REDES NEURAIS ARTIFICIAIS BASEADAS NA TEORIA DA	
	RESSONÂNCIA ADAPTATIVA	30
3.1	REDES NEURAIS ART	30
3.2	REDE NEURAL ART 1.....	31
3.2.1	Treinamento da rede ART 1	32
3.3	REDE NEURAL ART <i>FUZZY</i>	34
3.3.1	Treinamento da rede neural ART <i>Fuzzy</i>	34
3.4	Rede neural ARTMAP	36
3.5	REDE NEURAL ARTMAP <i>FUZZY</i>	37
3.5.1	Treinamento da rede neural ARTMAP <i>Fuzzy</i>	37

4	MONITORAMENTO E CLASSIFICAÇÃO DE FALHAS UTILIZANDO REDES NEURAIS ARTIFICIAIS	40
4.1	SIMULAÇÃO COMPUTACIONAL PARA OBTENÇÃO DOS DADOS	40
4.2	TREINAMENTO DA REDE NEURAL ARTMAP <i>FUZZY</i>	44
4.3	DIAGNÓSTICO DA REDE NEURAL ARTMAP <i>FUZZY</i>	45
5	SIMULAÇÃO E RESULTADOS	46
5.1	DESENVOLVIMENTO COMPUTACIONAL	46
5.2	TESTES E RESULTADOS - BANCO A	51
5.2.1	Caso 1: validação da rede neural	51
5.2.2	Caso 2: reconhecimento de sinais normais ou sinais com falha	52
5.2.3	Caso 3: reconhecimento e classificação dos sinais	54
5.2.4	Caso 4: teste cruzado	55
5.3	TESTE E RESULTADOS – BANCO B	56
5.3.1	Caso 1: Validação da rede neural	56
5.3.2	Caso 2: reconhecimento de sinais normais ou sinais com falha	57
5.3.3	Caso 3: reconhecimento e classificação dos sinais	57
5.3.4	Caso 4: teste cruzado	58
5.4	TESTE E RESULTADOS – BANCO C	59
5.4.1	Caso 1: validação da rede neural	59
5.4.2	Caso 2: reconhecimento de sinais normais ou sinais com falha	60
5.4.3	Caso 3: reconhecimento e classificação dos sinais	61
5.4.4	Caso 4: teste cruzado	61
5.5	CONSIDERAÇÕES	63
6	CONSIDERAÇÕES FINAIS	64
6.1	PROPOSTAS FUTURAS DE TRABALHO	65
	REFERÊNCIAS	66
	APÊNDICE A – LÓGICA <i>FUZZY</i>	70

1 INTRODUÇÃO

Com o avanço da sociedade em relação a novas tecnologias, materiais e sistemas, dificilmente encontra-se uma cidade que não tenha um edifício, um prédio ou uma ponte. Conforme os anos se passaram as cidades foram crescendo numerosamente. Muitos edifícios como o Guangzhou na China, o Willis Tower nos EUA e o International Commerce Centre em Hong Kong foram construídos para serem ocupados por milhares de pessoas, como pode ser visto na Figura 1.

Figura 1 - Edifícios: a) Guangzhou - China, b) International Commerce Centre - Hong Kong, c) Willis Tower – EUA.¹



Além de edifícios, pontes e passarelas, como a Passarela Joaquim Falcão Macedo em Rio Branco/AC que conta com a passagem em média de 20 mil pessoas por dia, a Passarela Verde/SP e a Passarela Miguel Reale/SP, onde 5 mil pessoas passam diariamente, são

¹ Fonte: <http://super.abril.com.br/conheca-os-10-predios-mais-altos-do-mundo>

utilizadas por um grande número de pessoas (ASSOCIAÇÃO BRASILEIRA DA CONSTRUÇÃO METÁLICA - ABCEM, 2009).

De acordo com Inman et al. (2005), sistemas estruturais e mecânicos como, edifícios, prédios, pontes, etc., estão sujeitos à falhas em seu material ou em suas propriedades geométricas que afetam negativamente seus desempenhos. As consequências destas falhas podem ser imediatas ou demorar algum tempo para se manifestarem, gerando insegurança para as pessoas que ali vivem ou trabalham. Estas falhas também geram muitos custos com manutenção e, em alguns casos, elas podem gerar eventos catastróficos.

Assim sendo, a aplicação de técnicas de monitoramento da integridade de estruturas em geral torna-se uma questão muito importante para a segurança da população, pois através destas técnicas, falhas podem ser detectadas em seu estágio inicial, auxiliando e promovendo a melhor forma de manutenção destas estruturas, garantindo que as mesmas continuem em pleno funcionamento. Na Figura 2 tem-se o exemplo da Ponte Injaka em Mpumalanga, África do Sul, que entrou em colapso durante sua própria construção em julho de 1998.

Figura 2 - Colapso da ponte de Injaka, 1998.



Fonte: Balageas, Fritzen e Güemes (2006).

A prevenção de falhas em componentes mecânicos surgiu desde as primeiras construções das estruturas de engenharia. Inicialmente, esta prevenção era feita de forma empírica e a solução para tais casos era devido à escolha certa do material e da forma do elemento estrutural (PASTOUKHOV; VOORWALD, 1995). Portanto, a necessidade de desenvolver métodos eficazes para a detecção de falhas cresceu no decorrer dos anos.

Segundo Sasmal e Ramanjaneyulu (2009), os métodos para a detecção de falhas baseiam-se no fato de que os parâmetros modais (frequências, amortecimento e formas modais) representam funções das propriedades físicas da estrutura (massa, amortecimento e

rigidez). Portanto, quando estas propriedades físicas sofrem alguma alteração, por exemplo, a redução de rigidez, as propriedades modais apresentarão alterações detectáveis.

Farrar e Worden (2006) citam que o processo de implementação de estratégias na identificação de danos, seja na engenharia mecânica, civil ou no ambiente aeroespacial, é conhecido como Monitoramento da Integridade Estrutural (SHM). Uma característica importante das técnicas de SHM é a capacidade de fornecer informações sobre a expectativa de vida das estruturas, além de detectar e localizar danos. Wenzel (2009) complementa que a identificação de danos, geralmente, é estruturada em quatro níveis:

- a. detecção: onde se verifica se a estrutura apresenta algum tipo de dano;
- b. localização: onde se encontra o dano detectado;
- c. tipificação: qual o tipo de dano;
- d. extensão do dano: avalia-se a gravidade do dano.

Os principais benefícios que os sistemas de SHM apresentam são: a diminuição dos custos com manutenção e a maior confiabilidade das estruturas projetadas, gerando uma maior segurança de vida. (BALAGEAS; FRITZEN; GÜEMES, 2006). Ao aplicar uma técnica de SHM em tempo real, aumenta-se a segurança proporcionada pela estrutura, uma vez que as falhas sendo precocemente detectadas, não evoluem para níveis perigosos (RAMOS, 2006).

As técnicas convencionais de SHM, conhecidas também como técnicas de ensaio não destrutivas (NDEs) são: emissão acústica, raios X, correntes de Eddy, métodos de campo magnético, inspeção visual, líquido penetrante, entre outros (CARRILLO, 2007; BITENCOURT; STEFFEN JÚNIOR, 2009).

Além das técnicas mencionadas, existem outras técnicas que aproveitam os benefícios dos sistemas inteligentes. Estes são caracterizados por manipularem conhecimentos especializados com benefícios qualitativos e quantitativos através das tecnologias de informação pertencentes à área de inteligência artificial que tem como objetivo o desenvolvimento de sistemas que apresentam as mesmas funcionalidades da natureza ou do cérebro humano. Esses sistemas também abrangem um maior número de pessoas no que se refere ao acesso ao conhecimento a partir de sua sistematização, aquisição, processamento e representação (REZENDE, 2005). Alguns exemplos são: os sistemas especialistas, algoritmos genéticos, redes neurais artificiais, lógica *fuzzy*, etc.

1.1 JUSTIFICATIVA

A identificação de falhas em estruturas pode ser considerada, para alguns casos, como um problema de otimização e, então, permite que algumas abordagens de otimização sejam adotadas para quantificar estas falhas. Tendo em vista a melhoria das estruturas mecânicas, técnicas de otimização foram desenvolvidas e amplamente utilizadas, desde o início dos anos 1960. Desde então, várias técnicas aplicadas para solução deste problema foram desenvolvidas e, entre elas, algoritmos genéticos e redes neurais artificiais são consideradas novas abordagens, pois ainda há muita pesquisa a ser feita sobre os conceitos básicos e a forma de processamento delas (INMAN et al., 2005).

Tendo em vista os conceitos apresentados e a necessidade de desenvolver técnicas mais eficientes para o problema proposto, esta dissertação tem por objetivo pesquisar, analisar e aplicar redes neurais artificiais como uma técnica de SHM na identificação de falhas.

Resumidamente, as Redes Neurais Artificiais (RNAs) são algoritmos computacionais utilizados na resolução de problemas complexos. Seu processamento baseia-se no funcionamento do sistema nervoso biológico. Segundo Haykin (2001) as RNAs possuem uma habilidade natural em armazenar conhecimento experimental e disponibilizá-lo para uso posteriormente. Seu conhecimento é obtido através de métodos de aprendizado, podendo estes ser divididos em duas categorias: aprendizado supervisionado e não-supervisionado.

De acordo com Braga, Carvalho e Ludermitz (2012), por meio de muitos estudos já realizados na área de redes neurais artificiais, elas vêm demonstrando um grande desempenho em funções específicas como o diagnóstico de falhas, reconhecimento e classificação de padrões, otimização de sistemas, entre outros. As RNAs obtiveram um grande sucesso em problemas associados a não-linearidade desde que tais problemas sejam bem representados pelos padrões de entrada da rede.

1.2 OBJETIVO

O objetivo geral desta dissertação é apresentar um sistema de SHM baseada na técnica de redes neurais artificiais, aplicando-a na identificação de falhas estruturais em um edifício de dois andares.

Como objetivos específicos desta dissertação, temos:

- a. Gerar os dados representando a condição normal e a condição de falha de uma estrutura a partir de um modelo matemático dinâmico representando um edifício de dois andares;
- b. Estudar e implementar uma RNA do tipo ARTMAP *Fuzzy*, pois esta rede tem como base a teoria da ressonância adaptativa que, segundo Carpenter et al. (1991b) e Carpenter e Grossberg (1992) apresenta características fundamentais e diferenciais em relação às demais redes neurais: a elasticidade e plasticidade, que proporcionam a rede neural uma aprendizagem estável e convergência rápida, além de ser feita em tempo real.
- c. Aplicar a rede neural implementada para o problema de identificação de falhas estruturais;
- d. Analisar os resultados obtidos e verificar se a utilização de redes neurais atende as necessidades do problema proposto.

1.3 ORGANIZAÇÃO DA DISSERTAÇÃO

Para melhor compreensão desta dissertação, a mesma está organizada da seguinte forma:

O primeiro capítulo apresentou uma introdução em relação aos principais conceitos que serão abordados mais profundamente no decorrer da dissertação, a justificativa e o objetivo da mesma.

O segundo capítulo apresenta os conceitos de falhas estruturais e do monitoramento da integridade estrutural (SHM) bem como o seu processo e forma de implementação além das técnicas mais comuns e novas técnicas em estudo.

No terceiro capítulo, são abordadas as principais redes neurais baseadas na teoria da ressonância adaptativa (ART) que vêm se destacando na literatura por preservarem duas características fundamentais para o processamento da rede: a estabilidade e a plasticidade que proporcionam à rede uma aprendizagem estável e convergência rápida (CARPENTER et al., 1991b; CARPENTER; GROSSBERG, 1992).

No capítulo quatro, é descrito a metodologia desta dissertação, que assumiu três etapas: a aquisição dos dados representando a condição normal e a condição com falhas por meio do modelo matemático, o desenvolvimento da rede neural ARTMAP *Fuzzy* onde seu processamento é dividido em fase de treinamento da rede e fase de diagnóstico.

No quinto capítulo apresenta-se a aplicação em geral: como os dados foram gerados, qual o valor dos parâmetros utilizados, como a rede neural adquiriu seu conhecimento, como funcionou o método de aprendizagem utilizado, quais foram às saídas apresentadas no diagnóstico da rede neural, os testes realizados e os resultados obtidos.

No capítulo seis, encontram-se as considerações finais da dissertação em geral e sugestões para trabalhos futuros.

Por fim, no Apêndice A, tem-se uma breve descrição dos conceitos de Lógica *Fuzzy*.

2 FALHAS ESTRUTURAIS E O MONITORAMENTO DA INTEGRIDADE ESTRUTURAL

2.1 DEFINIÇÕES

2.1.1 Falhas estruturais

De acordo com Chen e Nagarajaiah (2008) as falhas estruturais são danos na estrutura que implicam em mudanças nas suas propriedades físicas, e consequentemente nas características dinâmicas. Essas estruturas podem ser prédios, pontes, plataformas, etc., em que tais falhas podem influenciar no desempenho geral da estrutura, bem como causar consequências desastrosas. Silva et al. (2014) explica que uma edificação é a interligação lógica entre diversos materiais e componentes que possuem um tempo de vida útil, ou seja, não duram eternamente. Estes materiais e componentes podem apresentar trincas ou romper-se perante a ação de um determinado nível de carregamento por exemplo.

Doebbling et al. (1996) explica que os efeitos destas falhas sobre a estrutura são classificados em lineares e não-lineares. Uma situação de efeito linear ocorre quando, mesmo após o dano, uma estrutura linear-elástica mantém sua linearidade, ou seja, a resposta apresentada pelos parâmetros modais da estrutura ainda pode ser modelada por uma equação de movimento linear. Já uma situação de efeito não linear, quando uma determinada estrutura linear-elástica sofre um dano, seu comportamento torna-se não linear. Exemplos desta situação é a formação de trincas por fadiga, conexões soltas que fazem barulho e o comportamento não-linear do material. Thomaz (1989) destaca três aspectos fundamentais para que o problema das trincas em estruturas possua uma maior importância: primeiramente por elas serem um aviso sobre um eventual estado perigoso para a estrutura, segundo por afetarem o comprometimento do desempenho da obra em serviço e terceiro pelo constrangimento psicológico causado pela fissuração do edifício sobre os usuários do mesmo. As Figuras 3 e 4 mostram alguns tipos de trinca.

Figura 3 - Trinca em uma parede.²



Figura 4 - Trinca em um prédio.³



Além destas falhas, Silva et al. (2014) cita outras falhas que podem ocorrer em estruturas em geral, como: fissuras nas paredes, abaulamento do piso, corrosão de armadura, rachaduras que facilitam infiltrações, etc. Estas falhas podem ser originadas por diversos fatores. Em Silva et al. (2014) são apresentadas as seguintes causas:

- a. Erros de planejamento e projeto;
- b. Infiltração de água ou outros elementos;
- c. Recalque: excesso de peso, fraqueza do material;
- d. Trepidações: vibrações causadas por elevadores, compressores, veículos;
- e. Em estruturas metálicas, pode haver corrosão na base dos pilares e ligações entre elementos;
- f. Em estruturas de madeira podem ocorrer infiltrações, apodrecimento, ataque de fungos e insetos que causam a perda de resistência;

² Fonte: <http://lorenaarquiteta.blogspot.com.br/2011/10/e-fissuras-ocupam-o-segundo-lugar-entre.html>

³ Fonte: <http://blogdopetcivil.com/category/catastrofes/>

2.1.2 Monitoramento da integridade estrutural

O monitoramento da integridade estrutural, o qual será mencionado nesta dissertação por SHM (referente ao termo em inglês *Structural Health Monitoring*) é descrito por Farrar e Worden (2006) como o processo de implementação de estratégias na identificação de falhas estruturais, seja na engenharia mecânica, civil ou no ambiente aeroespacial. Segundo Balageas, Fritzen e Güemes (2006), um sistema de SHM tem por objetivo apresentar um diagnóstico da integridade estrutural de uma estrutura como um todo, das partes separadas e dos materiais que a constituem em qualquer momento da vida útil da mesma.

De acordo com Louzada (2013) existem alguns princípios fundamentais sobre os sistemas de SHM:

1. Falhas e defeitos inerentes estão presentes em todo tipo de material;
2. Para a avaliação de um determinado dano estrutural é necessário a comparação entre dois estados da estrutura;
3. A identificação da existência e a localização de um dano podem ser realizadas por meio de aprendizado não supervisionado, entretanto para identificar o tipo e o grau do dano geralmente requer um aprendizado supervisionado;
4. É necessário extrair e processar os dados coletados para a conversão dos mesmos em informações relevantes;
5. Através de mudanças na dinâmica do sistema é possível determinar a dimensão do dano e este é inversamente proporcional à faixa de frequência de excitação.

2.1.3 Motivação para o uso de um sistema de SHM

Cada vez mais, empresas públicas e privadas vêm aplicando técnicas de detecção de falhas o quanto antes possível. Estas empresas vêm aplicando técnicas de SHM mais frequentemente, movidas pela maior segurança de vida e o impacto econômico que elas causam. Farrar e Worden (2006) citam alguns exemplos da aplicação destas técnicas:

- a. Indústrias que fabricam semicondutores que adotam as técnicas de SHM para solucionar o problema de redundância de máquinas, necessária para evitar o tempo de inatividade por conta da manutenção das mesmas;

- b. Empresas que mudaram sua forma de negócio, alugando equipamentos ao invés de vendê-los, pois a responsabilidade de manutenção dos mesmos cabe a estas empresas. Portanto, a fim de estender os ciclos de manutenção, elas se utilizam destas técnicas de SHM;
- c. Na recuperação rápida de edifícios, em especial, aqueles ligados a fabricação de algum produto, reduzindo significativamente os custos causados por eventos sísmicos;
- d. Estruturas que ainda estão ocupadas e em funcionamento, mesmo após o seu tempo de vida útil, apesar de seu envelhecimento e acumulação de danos.

2.2 PROCESSO E IMPLEMENTAÇÃO DE UM SISTEMA DE SHM

Farrar e Worden (2006) especificam que o processo de um sistema de SHM envolve três etapas:


- a. A observação da estrutura ao longo do tempo através de medições periódicas;
- b. A extração de características sensíveis ao dano por meio das medições realizadas;
- c. E por fim, a análise estatística destas características para que se possa determinar o estado atual da estrutura analisada.

Em um sistema de SHM em longo prazo, a saída deste processo é atualizada periodicamente com informações sobre a capacidade da estrutura a fim de que o sistema continue a exercer sua função de forma satisfatória, considerando o desgaste normal da estrutura por tempo de uso e os danos inevitáveis resultantes do ambiente operacional.

Para realizar o diagnóstico da integridade estrutural, os sistemas de SHM podem utilizar a integração de sensores, materiais inteligentes, transmissão de dados, poder computacional (software e hardware) e o processamento de sinais. Sobre os materiais inteligentes, segundo Ramos (2006) estes são caracterizados por atuarem autonomamente em função das ações exteriores a que possam estar sujeitas. Quando utilizados em técnicas de SHM, espera-se que eles tenham a capacidade de auxiliarem na transmissão de um histórico sobre o desempenho ou localização de uma falha na estrutura a ser analisada. Como os sistemas inteligentes, os materiais inteligentes são inspirados nos mecanismos da natureza, cujo comportamento se assemelha muito com os comportamentos humanos.

Ramos (2006), por meio da Figura 5, demonstra um exemplo da aplicação de sensores em uma ponte. A aquisição das informações sobre o dano através das medições realizadas e da análise estatística é utilizada para determinar a integridade da estrutura. Através desta aquisição, é possível efetuar planos de manutenção de acordo com o dano encontrado, podendo prolongar o tempo de vida útil da ponte.

Figura 5 - Exemplo da utilização de sensores em uma ponte.



Fonte: Ramos (2006).


Louzada (2013) complementa que há quatro fases para a implementação de um sistema de SHM.

1. Na primeira fase ocorre a aquisição dos dados ou sinais transmitidos pela estrutura a ser monitorada. Nesta fase, pode haver a integração de sensores, atuadores, tipos de malhas, etc. Segundo Farrar e Worden (2006) nesta fase é preciso estar atento aos intervalos em que os dados serão medidos e a forma em que eles serão coletados.
2. Já na segunda fase é necessário trabalhar com os dados obtidos que estão em sua forma bruta. A análise dos mesmos através de filtros a fim de reduzir qualquer tipo de ruído e técnicas de normalização para se obter uma melhor interpretação dos mesmos são alguns métodos utilizados. A normalização dos dados também é considerada como o processo que irá identificar quais alterações resultantes de danos daquelas causadas pela variação das condições ambientais ou operacionais (FARRAR; WORDEN, 2006). Vale destacar que o pré-processamento dos

dados é de suma importância para o aumento da eficiência do sistema de SHM como um todo.

3. Após o pré-processamento dos dados, na terceira fase é feita a transmissão dos mesmos para o sistema proposto que realizará sua interpretação. No caso de um sistema para o diagnóstico de falhas, ele analisará os dados e trará como resposta se a estrutura monitorada possui alguma falha ou não.
4. Na última fase, são empregadas as técnicas de SHM em si, citadas anteriormente, que podem ser técnicas NDEs, sistemas inteligentes, entre outros, para gerar a saída final do sistema. Estas técnicas são mais bem exemplificadas nos tópicos 2.3 e 2.4. A Figura 6 demonstra todo este processo.

Figura 6 - Implementação de um sistema de SHM.



Fonte: Louzada (2013).

2.3 TÉCNICAS COMUNS

Em Silva Junior e Marques (2006) encontram-se algumas técnicas de SHM mais utilizadas:

- a. Ensaio radiográfico: consiste em utilizar feixes de radiação X através do elemento a ser analisado e registrar as características da radiação emergente,

utilizando um meio adequado, como um filme radiográfico, ou dispositivos eletrônicos de detecção de imagem radiográfica.

- b. Ultrassom: é feito ao introduzir um feixe sonoro de alta frequência no material ou componente de interesse, com o objetivo de detectar, localizar e dimensionar discontinuidades internas ou superficiais.
- c. Líquido penetrante: é utilizado para revelar discontinuidades superficiais. Aplica-se o líquido com características especiais sobre a superfície ou peça, de forma que, após um determinado tempo, o mesmo penetre em falhas presentes no material e que sejam abertas à superfície. Após este tempo, utiliza-se um material chamado revelador que age de forma a retirar o líquido penetrante, formando uma imagem da falha encontrada.
- d. Partículas magnéticas: utilizada a fim de encontrar discontinuidades superficiais e sub-superficiais. É uma técnica rápida e relativamente fácil de ser aplicada, pois é feita por meio de campos magnéticos aplicados ao material e o uso de pequenas partículas magnéticas. Estas se acumulam em regiões da superfície do material onde ocorre uma saída de fluxo magnético ocasionada pela presença de uma discontinuidade.

Em Inman et al. (2005) ainda tem-se:

- e. Impedância: foram desenvolvidas utilizando a característica de acoplamento eletromecânico dos materiais piezoelétricos. O conceito básico desta técnica é monitorar as variações na impedância mecânica da estrutura causada pela presença de danos.
- f. Ondas de Lamb: é considerado um método confiável em relação à estimativa de informações sobre danos em uma determinada estrutura em termos de localização, gravidade e tipo de dano. Normalmente, integra-se a esta técnica, sensores e rede de atuadores durante a operação.

2.4 NOVAS ABORDAGENS

Os sistemas inteligentes possuem a característica de manipularem conhecimentos especializados através das tecnologias de informação pertencentes à área de inteligência artificial.

Esta, por sua vez, busca capacitar o computador através do desenvolvimento de algoritmos que irão executar funções desempenhadas pelo ser humano usando o conhecimento e o raciocínio.

Os sistemas inteligentes podem ser desenvolvidos utilizando-se de várias técnicas, as quais podem ser aplicadas isoladamente ou em conjunto para auxiliar o processo de decisão. Um exemplo disso é a combinação de redes neurais artificiais e lógica *fuzzy* (REZENDE, 2005).

As principais técnicas usadas pelos sistemas inteligentes como sistemas de SHM são os algoritmos genéticos, redes neurais artificiais e lógica *fuzzy*. Esta última é descrita no Apêndice A desta dissertação.


2.4.1 Algoritmos genéticos

Além das técnicas NDEs mais comuns citadas no tópico anterior, existem duas técnicas consideradas novas abordagens por Inman et al. (2005), que são: algoritmos genéticos e redes neurais artificiais.

Os algoritmos genéticos são algoritmos computacionais baseados na teoria de Darwin sobre a sobrevivência dos mais aptos. Eles têm sido usados para resolver uma variedade de problemas de otimização discreta e buscam uma melhor solução através da evolução de populações de soluções codificadas através de cromossomas artificiais. Um cromossoma artificial é uma estrutura de dados que representa uma das possíveis soluções do espaço de busca do problema (PACHECO, 1999).

Uma característica básica dos algoritmos genéticos é que a “população inicial” evolui ao longo de gerações para produzir novas gerações melhores que as anteriores. Os elementos da população inicial são gerados aleatoriamente ou heurísticamente.


O processamento de um algoritmo genético envolve quatro etapas: avaliação, seleção, recombinação (*crossover*) e mutação. A Figura 7 apresenta o fluxograma de um algoritmo genético.

Figura 7 - Fluxograma de um Algoritmo Genético.

Fonte: Adaptado de Vieira Souza e Reis Neto (2010).

2.4.2 Redes neurais artificiais

Haykin (2001) afirma que o conceito de redes neurais artificiais surgiu primeiramente nos trabalhos de Warren McCulloch e Walter Pitts em 1943 onde eles descreviam um cálculo lógico das redes neurais que agregava conceitos de neurofisiologia e lógica matemática. Através de suas pesquisas surgiu o primeiro neurônio artificial conforme mostrado na Figura 8. A saída (y_k) gerada por esse neurônio artificial é dada da seguinte forma: multiplica-se cada sinal de entrada ($x_1...x_m$) representando informações advindas do meio externo pelo seu respectivo peso sináptico ($w_{k1},...w_{km}$) resultando no combinador linear $\sum$. Em seguida, obtém-se o potencial de ativação (v_k) através da subtração do combinador linear pelo limiar de ativação (b_k), este último indica qual o patamar adequado para que o combinador linear gere um valor de disparo para a saída do neurônio. Por fim, aplica-se a função de ativação ($\phi(.)$) em relação ao seu potencial de ativação.

Figura 8 - Modelo de neurônio artificial.

Fonte: Haykin (2001).

As RNAs possuem a capacidade de aprender através de exemplos (padrões) e, a partir do ajuste das intensidades das conexões entre os neurônios artificiais, é que elas adquirem seu conhecimento. O processo de aprendizado de uma RNA busca a melhoria de seu desempenho de acordo com um critério preestabelecido.


Em resumo, o funcionamento de uma RNA segue duas etapas: fase de treinamento e fase de diagnóstico. A fase de treinamento tem um destaque maior, pois, é nesta etapa que a rede neural irá adquirir seu conhecimento através do ajuste dos pesos das conexões entre os neurônios artificiais seguindo um método de aprendizado específico. Portanto, quanto maior for o conhecimento adquirido, melhor será a capacidade de generalização da rede neural na fase de diagnóstico. Na fase de diagnóstico a rede será avaliada, tendo como entrada, novos dados, a fim de verificar se seu comportamento está de acordo com o desejado.

De acordo com Haykin (2001), existem duas categorias de aprendizado: o treinamento supervisionado e o não-supervisionado. O autor também destaca alguns aspectos importantes sobre as RNAs:

- a. Não linearidade;
- b. Mapeamento de entrada-saída;
- c. Adaptabilidade;
- d. Tolerância a falhas.

A Figura 9 ilustra a arquitetura de uma rede neural artificial multicamadas (camadas de entrada, intermediária e de saída), sendo que a camada de entrada contém quatro neurônios, a camada intermediária três e a camada de saída apenas um neurônio.

Figura 9 - Arquitetura simples de uma RNA.



Fonte: Haykin (2001).

2.5 REVISÃO BIBLIOGRÁFICA DE SHM

Nesta revisão são apresentadas pesquisas da área de SHM, destacando aquelas que abordaram a utilização de redes neurais como técnica de monitoramento da integridade estrutural.

Santos, Almeida e Tu (1999) aplicaram uma RNA do tipo *Multilayer Perceptron* com algoritmo *backpropagation* para a detecção de danos em ferramentas de corte, comprovando a capacidade da rede neural de apresentar resultados confiáveis, obtendo índices de acerto entre 95% e 100% para uma ampla faixa de parâmetros de usinagem. Demarchi, Pereira e Lopes Junior (1999) também demonstram uma aplicação de Redes Neurais com método de aprendizado *backpropagation* para classificar sistemas com diferentes razões de rigidez, representando diferentes tipos de falhas simulados numericamente, sendo que a rede neural pôde quantificar as falhas em todos os testes realizados.

Furtado (2004) apresenta uma metodologia robusta para a identificação de falhas estruturais utilizando conceitos de impedância elétrica através de atuador e sensor piezocerâmico e redes neurais artificiais com método de aprendizado supervisionado *backpropagation*, apresentando resultados bons e satisfatórios. Tsuruta (2008) também avalia o conceito de impedância eletromecânica como uma técnica de SHM para a detecção e quantificação de danos causados por impactos de baixa energia em placas de material

composto. A metodologia utilizada mostrou-se eficiente e bem adaptada às necessidades apresentadas pela indústria aeronáutica, sendo esta a motivação de pesquisa do autor.

Leucas (2009) apresenta duas técnicas de SHM aplicadas na detecção de danos em estruturas metálicas rebitadas, a saber, vigas e painéis aeronáuticos. A primeira técnica foi baseada na impedância eletromecânica e a segunda, como uma alternativa da primeira, baseada em redes neurais artificiais a fim de detectar os diferentes estágios do dano de um painel aeronáutico. Os resultados apresentados confirmaram a eficiência das técnicas aplicadas e de sua boa adaptação em relação às necessidades de segurança e manutenção apresentadas pela indústria aeronáutica. De forma complementar, Bitencourt e Steffen Júnior (2009) expõem dois experimentos para exemplificar uma aplicação da técnica de impedância na detecção de danos comuns em estruturas aeronáuticas. No entanto, apesar da técnica de impedância mostrar-se eficiente tanto na detecção quanto na indicação da severidade dos danos, a desvantagem apresentada pelos autores foi em relação ao hardware e software utilizados para adquirir e processar os sinais, pois os mesmos se mostraram pesados e volumosos.

Morales (2009) aplica três tipos de algoritmo genético com o propósito de verificar sua aplicabilidade na detecção de danos a partir das mudanças ocorridas em estruturas do tipo viga, treliça e pórtico sob diferentes cenários de dano. A metodologia aplicada apresentou um bom comportamento na detecção de danos em diversos casos, porém quando as medições eram completas e livres de ruído. Para medições incompletas o autor propõe que se utilize uma técnica de expansão. Por fim, para exemplos de treliça, a metodologia não atingiu um bom desempenho.

Maio (2011) desenvolve uma análise de diferentes técnicas para detecção da posição e tamanho da delaminação em estruturas compósitas utilizando pastilhas piezoelétricas, no entanto, mesmo apresentando algumas dificuldades, as técnicas foram consideradas válidas para alguns casos.

Suetake (2012) implementa sistemas inteligentes para o monitoramento e diagnóstico de falhas ocorrentes em motores de indução trifásicos. Os resultados mostraram robustez principalmente em carregamentos das máquinas entre 50% e 100% do torque nominal. O autor destaca que a aplicabilidade da técnica é melhor quando os níveis de carregamento estão próximos ao nominal.

Em Louzada (2013) encontra-se uma proposta de desenvolvimento de uma técnica de monitoramento empregando redes de Bragg para a identificação dos danos e redes neurais

artificiais para a caracterização dos mesmos, sendo que as redes neurais apresentaram resultados excelentes. No primeiro caso analisado, a porcentagem de erro foi inferior a 5%.

O método de detecção e localização de danos em compósitos que compõe a estrutura de uma fuselagem de avião proposto por França (2014) utiliza-se de uma RNA com o objetivo de isolar o efeito da temperatura na análise através de sua capacidade de generalização. A RNA utilizada reconheceu todos os padrões apresentando uma generalização satisfatória.

Em Santos (2014) são apresentadas duas aplicações de software de tempo real com o objetivo de gerenciar os dados de uma técnica de SHM baseada em redes de sensores ópticos FBG. Ambas as aplicações identificaram completamente as anomalias inseridas artificialmente nos sinais de dados dos sensores, demonstrando eficiência, robustez e flexibilidade das mesmas.

Por fim, Lima (2014) utiliza duas metodologias, sistemas imunológicos artificiais e redes neurais artificiais para o desenvolvimento de sistemas de monitoramento da integridade de estruturas mecânicas, apresentando resultados satisfatórios e demonstrando a eficiência das técnicas utilizadas.

3 REDES NEURAIS ARTIFICIAIS BASEADAS NA TEORIA DA RESSONÂNCIA ADAPTATIVA

3.1 REDES NEURAIS ART

As redes neurais artificiais são algoritmos computacionais baseadas no funcionamento do cérebro humano. É uma das principais funcionalidades que o nosso cérebro é capaz de realizar, é aprender novas coisas sem necessariamente esquecer, a princípio, do conhecimento previamente adquirido.

Segundo Lopes, Minussi e Lotufo (2005), a Teoria da Ressonância Adaptativa (ART) foi desenvolvida por Carpenter e Grossberg a fim de solucionar o dilema de plasticidade e estabilidade que as outras redes neurais artificiais não atendiam. Ou seja, a rede neural ART deveria ser flexível para incorporar novas classes de entrada (novos conhecimentos) referentes às mudanças ocorridas no ambiente externo e ao mesmo tempo estável a fim de que, ao realizar um novo treinamento da rede neural, ela não perdesse o conhecimento já adquirido em processos de treinamento anteriores. Portanto, as redes neurais ART são redes que se auto-organizam com o propósito de realizar o reconhecimento de categorias para as sequências arbitrárias dos padrões de entrada que são apresentadas a rede.

Cada rede neural ART busca formar categorias de reconhecimento estáveis em resposta às sequências de entrada arbitrárias, seja com regimes de aprendizagem rápidos ou lentos. Ferreira (2003) afirma que o processamento da rede neural ART é descobrir categorias de forma independente e criar novas caso seja necessário. Em relação ao reconhecimento de padrões, por exemplo, quando uma nova entrada é apresentada a rede, ela verificará se esta se encaixa em alguma categoria já existente. Se não houver, uma nova categoria é criada. Este processo não é possível em outras redes neurais, pois ao realizar um novo treinamento, elas perdem o conhecimento já adquirido. Isto só é possível nas redes ART por conta do mecanismo de vigilância que elas possuem, o qual é responsável por administrar a entrada de novos padrões em cada categoria existente ou não.

Assim, uma série de redes neurais baseadas nesta teoria foi criada (CARPENTER, 2000; CARPENTER; GROSSBERG; ROSEN, 1991):

- O primeiro modelo, ART 1 fazia o reconhecimento de categorias para padrões de entrada binários sendo treinada por um método de aprendizado não-supervisionado.
- O modelo ART 2 e ART *Fuzzy* abrangeram não só as características do ART 1 mas também categorizaram padrões de entrada analógicos.
- As redes neurais do tipo ART 3 foram baseadas no modelo ART 2, mas incluem um modelo da sinapse que resolve o problema de pesquisa de memória encontrado nas arquiteturas da família ART.
- A rede ARTMAP foi desenvolvida a partir da conexão de duas redes ARTs para realizar o reconhecimento de categorias através de um método de aprendizado supervisionado.
- Por fim a rede ARTMAP *Fuzzy* que manteve as características da rede ARTMAP, alterando apenas a utilização de redes ART por ART *Fuzzy*, a fim de aceitar padrões de entrada binários e analógicos, ao utilizar os conjuntos nebulosos.

3.2 REDE NEURAL ART 1

O primeiro modelo ART, chamado de ART 1, foi uma rede neural que utilizou-se de um tipo de aprendizado não supervisionado, chamado de treinamento competitivo, para categorizar padrões de entrada binários.

No aprendizado não-supervisionado, a própria rede se auto-organiza para relacionar as características entre os elementos do conjunto de entrada identificando possíveis subconjuntos que contenham semelhanças. A regularidade e a redundância nas entradas da rede são fundamentais para que haja este tipo de aprendizado, pois, durante o processo, os padrões de entrada são mostrados de forma contínua à rede e a regularidade nesses dados torna o aprendizado possível.

Haykin (2001) afirma que no treinamento competitivo ou aprendizagem competitiva, por pertencer à categoria de aprendizado não-supervisionado, os neurônios da camada de saída competem entre si para serem ativados. Portanto, diferentemente de outras formas de aprendizagem, onde vários neurônios da camada de saída podem estar ativos simultaneamente, na aprendizagem competitiva, apenas um único neurônio é ativado em um determinado instante.


Para Haykin (2001) existem três elementos fundamentais sobre este tipo de treinamento:

- Um conjunto de neurônios onde todos são iguais entre si, exceto por alguns pesos sinápticos que estão distribuídos aleatoriamente, e que por isso respondem diferentemente a um dado conjunto de padrões de entrada;
- Há um limite imposto sobre a “força” de cada neurônio;
- Um mecanismo que permite cada neurônio competir pelo direito de responder a certo conjunto de padrões de entrada, de forma que apenas um neurônio de saída ou um neurônio do grupo esteja ativo em um determinado instante. O neurônio que vence esta “competição” é denominado *winner-take-all* (o vencedor leva tudo).

3.2.1 Treinamento da rede ART 1

Braga, Carvalho e Ludermir (2012) explicam que o treinamento de uma rede neural ART envolve três fases: o reconhecimento, a comparação e a busca. Portanto, a Figura 10 demonstra a estrutura de uma rede ART1, enfatizando os processos realizados durante o treinamento da mesma.

Figura 10 - Estrutura de uma rede ART.



Fonte: Lopes, Minussi e Lotufo (2004).

Na fase de reconhecimento, cada neurônio pertencente à camada de entrada (F_0) pode receber três sinais: o sinal do vetor de entrada, o sinal de *feedback* da camada de saída e o sinal da unidade de controle. Para que o neurônio da camada de entrada seja ativado, é necessário, portanto, receber pelo menos, dois sinais excitatórios. Esta regra é chamada de regra dos dois terços. Uma vez que um dos neurônios foi ativado, o valor do sinal da unidade de controle passa a ser 0 e a regra dos dois terços é aplicada novamente em cada um dos neurônios da camada de entrada, resultando na ativação ou não deles. Segue-se a fase de comparação.

Como o sinal da unidade de controle é 0, ocorre uma operação *AND* entre o vetor de *feedback* da camada de saída e o vetor de entrada, produzindo um novo vetor, chamado de vetor de comparação, $\mathbf{z}$. Esse vetor ($\mathbf{z}$) é enviado para o processo de *reset* juntamente com o vetor de entrada. O *reset*, portanto, será responsável por fazer o teste de similaridade entre esses dois vetores. Este teste é feito através do cálculo da razão P , dado pela equação (1), entre o número de valores iguais a 1 de ambos os vetores e comparando o resultado dessa razão com o parâmetro de vigilância ρ .

$$P = \frac{\|\sum x_i z_{ij}\|}{\|\sum x_i\|} \quad (1)$$

sendo:

$\mathbf{x}$: vetor de entrada;

$\mathbf{z}$: vetor de comparação.

Se $P > \rho$ o padrão de entrada é incluído no grupo de neurônio da camada de saída ativado (F_2). Se não, outro neurônio da camada de saída deverá ser encontrado para armazenar o vetor de entrada atual, e a rede neural inicia a fase de busca.

Na fase de busca o neurônio da camada de saída rejeitado na fase de comparação, assume um valor igual a 0 e não participa desta seleção. Portanto, o vetor de entrada é reapresentado e a rede executa novamente o processo de comparação terminando com o processo de *reset*. Este ciclo é repetido até que a rede neural encontre um neurônio de saída que melhor se assemelhe ao vetor de entrada corrente, dentro dos limites de ρ . No entanto, se nenhum neurônio for encontrado, o vetor de entrada é considerado de uma classe desconhecida, sendo considerado um neurônio de saída “livre”, ou seja, ele não é associado ainda, a nenhum grupo para representa-lo.

3.3 REDE NEURAL ART FUZZY

A rede neural ART *Fuzzy* abordou as características da rede ART1 juntamente com os conceitos da teoria dos conjuntos nebulosos (ver Apêndice A – Lógica *Fuzzy*) permitindo a inserção de padrões de entrada do tipo analógico e binário, utilizando-se também de um aprendizado não-supervisionado.

3.3.1 Treinamento da rede neural ART *Fuzzy*

Carpenter et al. (1992) afirmam que o aprendizado de uma rede neural ART *Fuzzy* sempre converge, pois todos os seus pesos adaptativos não são incrementados. No entanto, por não ter um processamento adicional a esses pesos, surge um problema de proliferação de categorias. Para resolver tal questão, um pré-processamento no vetor de entrada, chamado decodificação de complemento, é aplicado. Esta codificação de complemento irá normalizar o vetor de entrada, permitindo que o vetor seja inserido na rede neural.

Portanto, antes de começar o treinamento da rede ART *Fuzzy* os dados de entrada passam por um pré-processamento a fim de normalizá-los, evitando a proliferação de categorias conforme descrito na equação (2).

$$\bar{a} = \frac{a}{|a|} \quad (2)$$

sendo $\bar{a}$ = vetor de entrada normalizado

$$|a| = \sum_i |a_i| \quad (3)$$

É aplicada a codificação de complemento, preservando a amplitude da informação segundo a equação (4).

$$\bar{a}_i^c = 1 - \bar{a}_i \quad (4)$$

sendo, $\bar{a}^c$ é o vetor complementar de entrada normalizado. Sendo assim, a entrada da rede será:

$$I_a = [\bar{a} \ \bar{a}^c] \quad (5)$$

Após a normalização do vetor de entrada, inicia-se o treinamento da rede neural que começa com a etapa de escolha de categoria, dada pela equação (6).

$$T_j = \frac{|I \wedge w_j|}{\alpha + |w_j|} \quad (6)$$

$\wedge$ = operador lógico AND nebuloso, o qual é definido por:

$$(I \wedge w)_i = \min(I_i, w_i) \quad (7)$$

A categoria escolhida será o valor encontrado em J , que representa que ela está ativa. No entanto, se J possuir mais de um valor, a categoria escolhida será a de menor índice.

$$J = \operatorname{argmax} T_j \quad j = 1, \dots, N \quad (8)$$

Após a escolha da categoria, faz-se o teste de vigilância representado pela equação (9), a fim de verificar a ressonância da rede ART *Fuzzy*.

$$\frac{|I_a \wedge w_J|}{|I_a|} \geq \rho \quad (9)$$

Se a equação (9) não for verdadeira, ocorre o *reset*. Isto quer dizer que será necessário ativar outra categoria. Neste caso, T_j mostrado na equação (8) passa a valer 0 e uma nova categoria é selecionada através de (8), isto é, um novo valor de J é selecionado. Este processo de *reset* é realizado até que uma categoria satisfaça a equação (9).

Lopes, Minussi e Lotufo (2005) destacam três parâmetros fundamentais para o processamento e treinamento da rede ART *Fuzzy*:

- Parâmetro de escolha: utilizado na seleção de categorias ($\alpha > 0$).
- Taxa de Treinamento: que controla a velocidade da adaptação da rede ($\beta \in [0,1]$). Quando $\beta = 1$, o treinamento é rápido, pois os pesos das conexões são valores ótimos e há poucos ciclos de aprendizagem. Normalmente, é utilizado quando não há muitas entradas novas na rede, mas que exige uma resposta imediata da mesma.

Se $\beta < 1$, o treinamento é considerado lento e os pesos das conexões são forçados a se adaptarem lentamente.

- Parâmetro de vigilância ($\rho \in [0,1]$): responsável por controlar a ressonância da rede.

Se houver a ressonância da rede, o vetor de pesos é atualizado conforme a equação (10)


$$w_j^{novo} = \beta (I \wedge w_j^{velho}) + (1 - \beta) w_j^{velho} \quad (10)$$

3.4 REDE NEURAL ARTMAP

De acordo com Carpenter et al. (1992) a rede neural ARTMAP é uma rede que se utiliza de um aprendizado supervisionado incremental para o reconhecimento de categorias e mapas multidimensionais em resposta aos vetores de entrada apresentados de forma arbitrária.

O treinamento supervisionado de uma rede neural implica na existência de um “professor”, o qual tem conhecimento da saída que ele espera que a rede apresente, ou seja, o “professor” é capaz de fornecer uma saída desejada para que ao obter a saída da rede neural, ele possa comparar as duas saídas e ajustar os parâmetros da rede, a fim de aproximar ou igualar a saída real que a rede neural apresenta com a saída desejada (HAYKIN, 2001). A Figura 11 mostra esta forma de aprendizado.

Figura 11 - Aprendizado supervisionado.



Fonte: Haykin (2010).

A rede ARTMAP foi projetada para que ao mesmo tempo ela maximizasse a generalização e minimizasse o erro de previsão em condição de aprendizagem rápida e em tempo real. Ela tem por objetivo aprender a fazer previsões precisas de forma flexível a fim de que seu aprendizado seja contínuo sem prejudicar o conhecimento prévio (CARPENTER; GROSSBERG; REYNOLDS, 1991).

Sua arquitetura é formada por dois módulos ART que são capazes de se auto-organizar em realizando o reconhecimento de categorias estáveis em resposta a uma sequência arbitrária dos padrões de entrada. Por ser uma rede neural que se utiliza de um aprendizado supervisionado, a saída gerada pelo primeiro módulo ART representará a entrada da rede ARTMAP e a saída do segundo módulo, a saída desejada. Portanto, estes dois módulos estão conectados a um terceiro módulo INTER-ART, o qual avaliará a ressonância entre eles, ou seja, se as duas saídas se “casam”.

3.5 REDE NEURAL ARTMAP *FUZZY*

Segundo Carpenter et al. (1992) a rede ARTMAP, inicialmente, foi aplicada para classificar apenas vetores de entrada binária. Buscando uma rede mais geral que atendesse entradas de dados binários e analógicos, foi desenvolvida a rede ARTMAP *Fuzzy*. Isso foi possível através da substituição dos módulos ART por módulos ART *Fuzzy*, pois a dinâmica destes é descrita em termos de operações dos conjuntos nebulosos (ver Apêndice A – Lógica *Fuzzy*).

3.5.1 Treinamento da rede neural ARTMAP *Fuzzy*

A rede neural ARTMAP *Fuzzy* é uma rede de fácil manuseio, já que possui poucos parâmetros e não requer qualquer elaboração específica do problema a ser solucionado além de não precisar de valores de peso inicial.

A arquitetura é composta por um par de redes ART *Fuzzy*, também chamadas de módulo ARTa e ARTb. Durante o treinamento, o módulo ARTa recebe padrões de entrada ($a^{(p)}$) e ARTb, padrões de entrada ($b^{(p)}$), onde $b^{(p)}$ é a previsão correta dada aos padrões de entrada $a^{(p)}$. Os módulos ARTa e ARTb estão ligados por um terceiro módulo denominado INTER-ART (ou *map field*, termo em inglês), que corresponde ao módulo de memória associativa.

Todos os pesos relacionados ao ARTa , ARTb e ao INTER-ART inicialmente possuem valor “1” indicando que as categorias não estão ativas, ou seja, inicialmente nenhuma categoria foi selecionada. Após a seleção das categorias elas tornam-se ativas (CARPENTER; GROSSBERG; REYNOLDS, 1991).

A partir das saídas geradas por ARTa e ARTb, o módulo INTER-ART verificará se há ressonância entre elas, segundo a equação (11).

$$|x^{ab}|_i = \frac{|y_i \wedge w^{ab}_j|}{|y_i|} \quad (11)$$

Se a equação (11) não for satisfeita, uma nova categoria em ARTa é selecionada até que haja a ressonância, ou seja, se as duas entradas não combinam, um sinal de *reset* é gerado e o processo *match tracking* ativará uma nova busca na qual escolherá uma nova categoria no módulo ARTa, cujo prognóstico será combinado novamente com a categoria atual de ARTb.

No entanto, se a etapa de ressonância for concluída, passa-se para a atualização dos pesos. Os pesos dos módulos ARTa e ARTb, w_a e w_b , são atualizados conforme a equação (10) e os pesos do módulo INTER-ART, w_{ab} , são atualizados através da equação (12), sendo J referente a categoria ativa no módulo ARTa e K representa a categoria ativa no módulo ARTb.


$$\begin{aligned} w_{JK}^{ab \text{ novo}} &= 1 \\ w_{jk}^{ab \text{ novo}} &= 0, \text{ para } j \neq J \text{ e } k \neq K \end{aligned} \quad (12)$$

sendo:

- J : categoria ativa referente à ARTa;
- K : categoria ativa referente à ARTb;
- w_J^{novo} : vetor de peso atualizado;
- w_J^{velho} : vetor de peso anterior;

A estrutura do treinamento da rede neural ARTMAP Fuzzy é mostrada na Figura 12.

Figura 12 - Rede neural ARTMAP Fuzzy.



Fonte: Carpenter et al. (1992).

Após a conclusão do treinamento da rede neural, ela estará apta para realizar o reconhecimento de novos padrões. Assim, é feito o diagnóstico da rede, onde novos padrões de entrada serão apresentados e a mesma deverá reconhecê-los, através do conhecimento já adquirido pela atualização do vetor de pesos. Portanto, para isto, executa-se apenas o código referente ao módulo ART_a que representa a entrada da rede e em seguida, a ressonância é verificada pelo módulo INTER-ART.

4 MONITORAMENTO E CLASSIFICAÇÃO DE FALHAS UTILIZANDO REDES NEURAIS ARTIFICIAIS

A metodologia proposta para esta dissertação seguiu três etapas:


1. Simulação computacional para obtenção dos dados;
2. Treinamento da rede ARTMAP *Fuzzy*;
3. Diagnóstico da rede ARTMAP *Fuzzy*.

Para a execução do algoritmo da rede ARTMAP *Fuzzy*, tanto para o treinamento quanto para o diagnóstico, utilizou-se o software livre OCTAVE, por ser de fácil manuseio e específico na resolução de problemas matemáticos.

4.1 SIMULAÇÃO COMPUTACIONAL PARA OBTENÇÃO DOS DADOS

A obtenção dos dados foi feita por meio de um modelo matemático formado por um sistema de equações diferenciais ordinárias modelando uma estrutura predial, sendo utilizado o integrador numérico *Runge Kutta* de quarta ordem. Para realizar as simulações das condições normais (*base-line*) e anormais (falha estrutural) do edifício, alteraram-se as massas (m_1 e m_2) dos andares na estrutura.

Figura 13 - Modelo dinâmico.



Fonte: Pegaiane (2014).

Conforme Pegaiane (2014) a Figura 13 ilustra o modelo que representa o comportamento dinâmico de um edifício, onde se derivam as equações do movimento para um pórtico plano simples, levando em consideração o encurtamento das barras devido à deflexão das mesmas, sob excitação na direção vertical, provocando uma não linearidade geométrica.


Segundo Aguiar (2010), aplica-se uma formulação alternativa em que os efeitos das forças atuantes sobre o sistema são levados em conta por meio de variações de energia cinética e potencial, conhecida como princípio de Hamilton.

Para descrever as equações de movimento que representam o sistema que se move sob a ação de uma força conservativa, utiliza-se a função Lagrangeana (MONTEIRO, 2002):

$$L = T - V \quad (13)$$

em que T representa a energia cinética e V a energia potencial do sistema. Ao adotarmos as coordenadas q_1 e q_2 , o princípio de Hamilton garante que possamos aplicar a função Lagrangeana em qualquer sistema de coordenadas, conforme mostra a Figura 14.

Figura 14 - Coordenadas generalizadas no modelo dinâmico do edifício.



Fonte: Pegaiane (2014).

em que:

$$x_1 = a + S + q_1,$$

$$x_2 = b + S + q_2$$

$$S = A \cos(\lambda t)$$

A energia cinética total (T) do sistema é:

$$T = \frac{1}{2} [m_1 (\dot{S} + \dot{q}_1)^2 + m_2 (\dot{S} + \dot{q}_2)^2] \quad (14)$$

A energia potencial total (V) do sistema é:

$$V = \frac{1}{2} [k_1 q_1^2 + k_2 (q_2 - q_1)^2] \quad (15)$$

O Lagrangeano ($L = T - V$) é:

$$L = \frac{1}{2} [m_1 (\dot{S} + \dot{q}_1)^2 + m_2 (\dot{S} + \dot{q}_2)^2 - k_1 q_1^2 - k_2 (q_2 - q_1)^2] \quad (16)$$

A equação de Lagrange para a coordenada generalizada q_1 é:

$$m_1 (\ddot{q}_1 + \ddot{S}) + k_1 q_1 - k_2 (q_2 - q_1) = -c_1 \dot{q}_1 \quad (17)$$

A equação de Lagrange para a coordenada generalizada q_2 é:

$$m_2 (\ddot{q}_2 + \ddot{S}) + k_2 (q_2 - q_1) = -c_2 (\dot{q}_2 - \dot{q}_1) \quad (18)$$

Assim, o sistema pode ser modelado pelo sistema de equações:

$$m_1 \ddot{q}_1 + k_1 q_1 - k_2 (q_2 - q_1) + c_1 \dot{q}_1 = -m_1 \ddot{S} \quad (19)$$

$$m_2 \ddot{q}_2 + k_2 (q_2 - q_1) + c_2 (\dot{q}_2 - \dot{q}_1) = -m_2 \ddot{S}$$

ou

$$\ddot{q}_1 + \frac{k_1}{m_1} q_1 - \frac{k_2}{m_1} (q_2 - q_1) + \frac{c_1}{m_1} \dot{q}_1 = -\ddot{S} \quad (20)$$

$$\ddot{q}_2 + \frac{k_2}{m_2} (q_2 - q_1) + \frac{c_2}{m_2} (\dot{q}_2 - \dot{q}_1) = -\ddot{S}$$

Tomando

$$\omega_1^2 = \frac{k_1 + k_2}{m_1}$$

$$\omega_2^2 = \frac{k_2}{m_2} \quad (21)$$

Tem-se

$$\ddot{q}_1 + \omega_1^2 q_1 - \frac{k_2}{m_1} q_2 + \frac{c_1}{m_1} \dot{q}_1 = -S \quad (22)$$

$$\ddot{q}_2 + \omega_2^2 (q_2 - q_1) + \frac{c_2}{m_2} (\dot{q}_2 - \dot{q}_1) = -S$$

A fim de transformar o sistema em um sistema na forma de estado, faz-se as seguintes considerações:

$$x_1 = q_1$$

$$x_2 = \dot{q}_1$$

$$x_3 = q_2$$

$$x_4 = \dot{q}_2$$

Tem-se o sistema de equações descrito pela Equação (23).

$$\dot{x}_1 = x_2 \quad (23)$$

$$\dot{x}_2 = -\omega_1^2 x_1 + \frac{k_2}{m_1} x_3 - \frac{c_1}{m_1} x_2 - S$$

$$\dot{x}_3 = x_4$$

$$\dot{x}_4 = \omega_2^2 (x_1 - x_3) + \frac{c_2}{m_2} (x_2 - x_4) - S$$

sendo S uma excitação periódica.

Os valores dos parâmetros iniciais utilizados no modelo matemático estão descritos na Tabela 1, sendo aplicado o integrador *Runge Kutta* de quarta ordem na equação (23) e para as condições iniciais $x_1=0$; $x_2=0$; $x_3=0$ e $x_4=0$ no tempo considerando amostras de 0 a 200s, sendo que m_1 e m_2 representam a massas do primeiro e segundo andar, respectivamente; c_1 e c_2 os amortecimentos; x_1 e x_2 representam deslocamento e velocidade do primeiro andar; x_3 e x_4 representam deslocamento e velocidade do segundo andar; ω_1 e ω_2 as frequências; k_1 e k_2 são as rigidez; S é a excitação; A é uma constante e τ é a frequência de excitação.

Tabela 1 - Parâmetros do modelo matemático.

Parâmetros	Valores
m_1	7 kg
m_2	7 kg
c_1	0,6 N.s/m
c_2	0,7 N.s/m
x_1	0,01 m
x_2	0,01 m
x_3	0,01 m
x_4	0,01 m
ω_1	1 rad/s
ω_2	2 rad/s
K_2	0,8 N/m
S	$A \cos(\tau t)$
A	10^{-5}
τ	1

Fonte: Pegaiane (2014).

4.2 TREINAMENTO DA REDE NEURAL ARTMAP FUZZY

O treinamento de uma rede neural artificial é feito através do ajuste ou adaptação dos pesos sinápticos. Como descrito no capítulo 3, a rede ARTMAP *Fuzzy* é formada por dois módulos ART *Fuzzy* e adquire seu conhecimento através do aprendizado supervisionado, descrito no tópico 3.3. O módulo ARTa é responsável por receber o vetor de entrada da rede neural em geral, o qual é formado por sinais normais e sinais com falha aleatoriamente e o módulo ARTb por receber o vetor de saída desejada da rede, isto é, para os sinais normais foram atribuídos valor igual a 0 e para os sinais com falha, valor igual a 1. Os dois módulos ART estão interligados por um terceiro módulo, INTER-ART.

Após o treinamento destes dois módulos (tópico 3.2.1), ocorre o processo chamado *match tracking* que verificará a ressonância entre a saída gerada pelo módulo ARTa e a saída gerada por ARTb, ou seja, se há o “casamento” entre eles (equação 11).

Os padrões de entrada da rede neural são representados pelos deslocamentos, x_i , avaliado no tempo, t , e os padrões de saída da rede neural são representados pelo estado do sistema, ou seja, sistema normal ou sistema com falha. Matematicamente, tem-se:

$$X(h) = [x_i]$$

$$Y(h) = \begin{cases} 0 & \text{sistema normal} \\ 1 & \text{sistema com falha} \end{cases}$$

sendo:

$X(h)$: entrada da rede ARTMAP Fuzzy;

$Y(h)$: saída da rede ARTMAP Fuzzy;

x_1 : deslocamento da estrutura;

h : quantidade de padrões.


4.3 DIAGNÓSTICO DA REDE NEURAL ARTMAP FUZZY

Para realizar o diagnóstico da rede, foi apresentado um novo conjunto de sinais aleatórios contendo sinais normais e com falha, diferente do conjunto utilizado no treinamento, pois, uma vez treinada, a rede neural ARTMAP Fuzzy deve ser capaz de através do reconhecimento de uma categoria, classificar os dados não treinados, identificando assim, um sinal de condição normal ou um sinal com falha.

Durante o diagnóstico é realizado apenas o processo do módulo ARTa conforme descrito no tópico 3.2.1. A saída gerada por este módulo é então, comparada com o conhecimento adquirido durante o treinamento, ou seja, é executado o processo de *match tracking* verificando a ressonância da rede.

A Figura 15 demonstra o processo de diagnóstico da rede.

Figura 15 - Diagnóstico da rede neural ARTMAP.



Fonte: Carpenter et al. (1992).


5 SIMULAÇÃO E RESULTADOS

5.1 DESENVOLVIMENTO COMPUTACIONAL

Primeiramente, foram gerados os dados para a simulação, conforme descrito no Capítulo 4, formando assim o banco de dados de sinais com e sem falha. Os sinais com falha foram gerados ao alterar os valores da massa (m_1 e m_2).


As Figuras 16, 17 e 18 ilustram uma representação dos sinais em sua condição normal, condição de falha no 1º andar e condição de falha no 2º andar, respectivamente.

Figura 16 - Sinal de condição normal.




Fonte: Elaboração do próprio autor.

Figura 17 - Sinal de condição de falha no 1º andar.



Fonte: Elaboração do próprio autor.

Figura 18 - Sinal de condição de falha no 2º andar.



Fonte: Elaboração do próprio autor.

Nesta dissertação foram gerados três bancos de sinais, denominados como bancos A, B e C. O banco A é composto por um conjunto de 221 sinais, sendo que, 9 sinais representam a condição normal e os outros 212 sinais representam a condição de falha (170 sinais representando falha no 1º andar e 42 representando falha no 2º andar). A quantidade de sinais gerada foi obtida ao alterar a massa da estrutura m_1 de 8 até 9 com variação de 0,5 e a m_2 de 1 a 7 com variação de 0,5.

Após realizar os testes com o primeiro banco de sinais gerado e ao observar os resultados obtidos, propôs-se gerar um segundo banco com uma quantidade maior de sinais, já que, quanto maior a quantidade de padrões de entrada em uma rede neural, melhor será o seu aprendizado e, conseqüentemente, melhor será o resultado apresentado por ela.

Portanto, um novo banco de sinais foi obtido ao alterar a massa de m_1 de 8 até 9 com variação 0,1 e a m_2 de 1 até 7 com variação 0,1, aumentando a quantidade de sinais para 4941 sinais dos quais 121 representavam a condição normal, 4050 a condição de falha no 1º andar e 770 a condição de falha no 2º andar.

No entanto, pela quantidade muito elevada de sinais gerados com a variação de 0,1, optou-se por gerar um banco intermediário, o qual foi obtido ao alterar a massa m_1 de 8 até 9 com variação 0,3 e a m_2 de 1 até 7 com variação 0,3, contendo 567 sinais no total, sendo 12 sinais de condição normal e 555 de condição de falha. Dentre os sinais do Banco B, 459 sinais representam falha no 1º andar e 96 sinais representam falha no 2º andar.

Para uma maior praticidade, o banco intermediário será chamado de Banco B e o Banco maior de banco C. Portanto, tem-se a análise de três bancos de dados gerados a partir das variações das massas dos andares do edifício, no qual:


- Banco A: 221 sinais - condição normal (9 sinais); falha no 1º andar (170 sinais) e falha no 2º andar (42 sinais);
- Banco B: 567 sinais - condição normal (12 sinais); falha no 1º andar (459 sinais) e falha no 2º andar (96 sinais);
- Banco C: 4941 sinais - condição normal (121 sinais); falha no 1º andar (4050 sinais) e falha no 2º andar (770 sinais).

Portanto, através de um modelo matemático de um edifício de dois andares foram gerados três conjuntos de dados que serão utilizados na análise do Monitoramento da Integridade Estrutural do Edifício.

A análise da SHM será realizada através de uma rede neural artificial ARTMAP *Fuzzy* que irá atuar como um sistema de detecção de falhas estruturais, sendo que os sinais com e sem falha serão utilizados na fase de treinamento e diagnóstico da rede neural.

O fluxograma do algoritmo da rede neural ARTMAP *Fuzzy* é ilustrado na Figura 19. Através do fluxograma é possível verificar os passos a serem executados para o funcionamento da rede.

Figura 19 - Fluxograma da rede neural ARTMAP Fuzzy



Os tópicos 5.2, 5.3 e 5.4 apresentarão os testes realizados com os três bancos de sinais Bancos A, B e C, assim como os resultados obtidos em cada teste.

Para cada banco de dados (A, B e C) serão feitas as seguintes análises:

1. **Análise de Validação da Rede Neural:** Este processo é importante, pois é através dele que é feita a verificação da eficiência e validação da rede neural artificial;
2. **Identificação dos Sinais Normais e Sinais com Falha:** A primeira análise da rede neural consistia em identificar dentre os sinais a serem apresentados os sinais que eram normais e os sinais que apresentavam falha;
3. **Reconhecimento e Classificação dos Sinais:** Uma segunda análise é realizada partindo do reconhecimento da falha, ou seja, uma vez identificada a falha a rede neural tem por objetivo classificar se a falha ocorreu no primeiro ou segundo andar.

5.2 TESTES E RESULTADOS - BANCO A

5.2.1 Caso 1: validação da rede neural

O primeiro teste realizado foi o de validação da rede neural, a fim de verificar se a mesma estava funcionando de forma correta. A validação da rede é feita a partir da utilização de todos os sinais, com falha e sem falha que foram utilizados na fase de treinamento, na fase de diagnóstico, sendo que a rede neural deverá apresentar um reconhecimento dos sinais de 100% de acerto.

Tabela 2 - Parâmetros de treinamento do teste de validação da RNA - Banco A.

Treinamento da RNA				
Parâmetro de Escolha	Taxa de Treinamento	P. V. ⁴ ARTa	P. V. ARTb	P. V. Inter-ART
0,1	1,0	0,7	1,0	1,0
Diagnóstico da RNA				
P. V. ARTa	Acerto - Sinal Normal	Acerto - Sinal com Falha	Acerto (%)	
0,7	9	212	100	

⁴ Parâmetro de Vigilância

Portanto, a Tabela 2 apresenta os parâmetros utilizados no treinamento e no diagnóstico da rede neural para o teste de validação, assim como os resultados obtidos pela rede neural.

A partir do resultado mostrado pela rede, de 100% de acerto, concluiu-se que a rede está validada e pronta para ser implementada no reconhecimento e classificação de sinais.

5.2.2 Caso 2: reconhecimento de sinais normais ou sinais com falha

Neste segundo caso, foi realizado o teste em que a rede neural deveria reconhecer os sinais e classificá-los em sinal de condição normal ou sinal de condição de falha.

Este teste se baseava apenas na identificação do sinal normal e do sinal com falha. Portanto, não houve a divisão entre sinais com falha no 1º andar e sinais com falha no 2º andar.

A representação de identificação dos sinais utilizados pela rede neural foi definida da seguinte forma:

- Os sinais que representavam a condição normal do edifício (*base-line*) tiveram uma saída desejada com valor igual a 0;
- Os sinais que representavam a condição de falha, tiveram uma saída desejada com valor igual a 1.

O conjunto de dados utilizados na fase de treinamento foi composto por 80% dos sinais normais e 80% dos sinais com falha selecionados aleatoriamente, totalizando 177 sinais. Os valores dos parâmetros da rede ARTMAP Fuzzy utilizados na fase de treinamento são mostrados na Tabela 3. Estes valores foram estipulados visando um melhor reconhecimento da rede neural em relação aos padrões com falha e sem falha.

Tabela 3 - Parâmetros do treinamento da rede ARTMAP Fuzzy - Banco A.

Parâmetro de Escolha	Taxa de Treinamento	P. V. ARTa	P. V. ARTb	P. V. Inter-ART
0,1	1,0	0,7	1,0	1,0

Assim sendo, o conjunto de dados para o diagnóstico foi composto por 20% dos sinais normais e 20% dos sinais com falha selecionados aleatoriamente, ressaltando que estes sinais não foram utilizados na fase de treinamento, totalizando 44 sinais. Os parâmetros iniciais

utilizados na fase de treinamento e diagnóstico da rede ARTMAP *Fuzzy* que geraram o melhor resultado assim como o resultado final, são mostrados na Tabela 4.

Tabela 4 - Parâmetros da ARTMAP *Fuzzy* para o melhor resultado - Banco A.

Treinamento da RNA				
Parâmetro de Escolha	Taxa de Treinamento	P. V. ARTa	P. V. ARTb	P. V. Inter-ART
0,1	1,0	0,7	1,0	1,0
Diagnóstico da RNA				
P. V. ARTa	Acerto - Sinal Normal	Acerto - Sinal com Falha	Acerto (%)	
0,7	2	42	100	

Para a verificação real do resultado apresentado pela rede neural, a sequência de padrões de entrada aleatória na fase de diagnóstico, foi armazenada em uma variável, a fim de compará-la com a saída final da rede neural. Lembrando que os sinais com valor igual a 0 representam o sinal normal, e os sinais com valor igual a 1, os sinais com falha. A Tabela 5 apresenta a sequência de entrada e a sequência de saída obtida pela rede ARTMAP *Fuzzy*.

Tabela 5 - Sequência dos padrões de entrada e saída na fase de diagnóstico.

Posição	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22
Entrada	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	1	0	1	1	1	1
Saída	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	1	0	1	1	1	1
Posição	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	41	42	43	44
Entrada	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
Saída	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1

Nota-se que todas as saídas geradas pela rede estão de acordo com os padrões de entrada, o que significa que a rede reconheceu corretamente todos os sinais, distinguindo os sinais normais dos sinais que representavam a falha.

5.2.3 Caso 3: reconhecimento e classificação dos sinais

Além do reconhecimento dos sinais (tópico 5.2.2), foi realizado um teste de classificação dos mesmos a fim de que a rede identificasse em que andar a falha se encontrava, ou seja, no 1º andar ou 2º andar.

Para realizar a identificação da falha, ou seja, se a falha se encontra no primeiro ou segundo andar, adotou-se a seguinte estratégia:

- Os sinais que representavam a condição normal do edifício (*base-line*) tiveram uma saída desejada com uma representação binária composta por dois “*bits*”, ou seja, 0 0;
- Para os sinais que representam a condição de falha no 1º andar, a saída desejada é representada pelos “*bits*”, 0 1;
- Para os sinais que representam a condição de falha no 2º andar, a saída desejada é representada pelos “*bits*”, 1 0;

Os parâmetros utilizados nas fases de treinamento e diagnóstico da rede neural ARTMAP Fuzzy, assim como os resultados obtidos na fase de diagnóstico da rede neural, são apresentados na Tabela 6.

É importante observar que a rede neural ARTMAP Fuzzy foi capaz de reconhecer todos os sinais (normais e com falha) e identificou com uma precisão 100% de acerto, em quais andares ocorreram as falhas.

Tabela 6 - Parâmetros de treinamento e diagnóstico para classificação dos sinais - Banco A.

Treinamento da RNA				
Parâmetro de Escolha	Taxa de Treinamento	P. V. ARTa	P. V. ARTb	P. V. Inter-ART
0,1	1,0	0,7	1,0	1,0
Diagnóstico da RNA				
P. V. ARTa	Acerto - Sinal Normal	Acerto - Sinal com Falha 1º andar	Acerto - Sinal com Falha 2º andar	Acerto (%)
0,7	2	34	8	100

5.2.4 Caso 4: teste cruzado

Por fim, a partir do teste mostrado no tópico 5.2.3, foi realizado um teste cruzado, no qual a rede neural é submetida a várias execuções utilizando-se dos mesmos valores para os parâmetros da rede, mas os padrões de entrada são aleatórios e diferentes. Este teste é executado com a finalidade de verificar a confiabilidade da rede neural perante a um conjunto de dados quaisquer.

Foram feitos três testes cruzados, sendo que em cada teste o parâmetro de vigilância de ARTa teve um determinado valor e a rede neural foi executada 100 vezes. Para cada teste também foi calculada uma média simples da porcentagem de acerto.

A Tabela 7 apresenta os parâmetros utilizados nas fases de treinamento e diagnóstico da rede e a média da porcentagem de acerto, sendo o valor do parâmetro de vigilância de ARTa igual a 0,7.

Tabela 7 - Primeiro teste cruzado – Banco A.

Treinamento da RNA				
Parâmetro de Escolha	Taxa de Treinamento	P. V. ARTa	P. V. ARTb	P. V. Inter-ART
0,1	1,0	0,7	1,0	1,0
Diagnóstico				
P.V. ARTa		Média da Porcentagem de Acerto (%)		
0,7		91,09		

A Tabela 8 apresenta os parâmetros utilizados no treinamento e diagnóstico da rede e a média da porcentagem de acerto, sendo o valor do parâmetro de vigilância de ARTa igual a 0,8.

Tabela 8 - Segundo teste cruzado – Banco A.

Treinamento da RNA				
Parâmetro de Escolha	Taxa de Treinamento	P. V. ARTa	P. V. ARTb	P. V. Inter-ART
0,1	1,0	0,8	1,0	1,0
Diagnóstico				
P.V. ARTa		Média da Porcentagem de Acerto (%)		
0,8		92,61		

A Tabela 9 apresenta os parâmetros utilizados no treinamento e diagnóstico da rede e a média da porcentagem de acerto, sendo o valor do parâmetro de vigilância de ARTa igual a 0,9.

Tabela 9 - Terceiro teste cruzado – Banco A.

Treinamento da RNA				
Parâmetro de Escolha	Taxa de Treinamento	P. V. ARTa	P. V. ARTb	P. V. Inter-ART
0,1	1,0	0,9	1,0	1,0
Diagnóstico				
P.V. ARTa		Média da Porcentagem de Acerto (%)		
0,9		93,89		

Observou-se que, mesmo aumentando o valor do parâmetro de vigilância de ARTa referente ao terceiro teste cruzado, a melhor porcentagem de acerto continuou sendo de 93,89%.

5.3 TESTE E RESULTADOS – BANCO B

5.3.1 Caso 1: Validação da rede neural

Assim como no banco A, foi feito um teste de validação da rede neural para o banco B. Portanto, a Tabela 10 apresenta os parâmetros utilizados no treinamento e no diagnóstico da rede neural, bem como o resultado obtido pela rede neural.

Tabela 10 - Parâmetros de treinamento do teste de validação da RNA - Banco B.

Treinamento da RNA				
Parâmetro de Escolha	Taxa de Treinamento	P. V. ARTa	P. V. ARTb	P. V. Inter-ART
0,1	1,0	0,7	1,0	1,0
Diagnóstico da RNA				
P. V. ARTa	Acerto - Sinal Normal	Acerto - Sinal com Falha	Acerto (%)	
0,7	12	555	100	

Com o resultado de 100% de acerto apresentado pela rede, a mesma está validada e pronta para os próximos testes.

5.3.2 Caso 2: reconhecimento de sinais normais ou sinais com falha

Seguindo a mesma estratégia apresentada no tópico 5.2.2, realizou-se o teste na rede neural de reconhecimento dos sinais em sinal de condição normal ou sinal de condição de falha.

O conjunto de padrões utilizados no treinamento possui 454 sinais e o conjunto de padrões para o diagnóstico 113 sinais. A Tabela 11 apresenta os parâmetros utilizados no treinamento e diagnóstico da rede neural que geraram o melhor resultado.

Tabela 11 - Parâmetros da ARTMAP *Fuzzy* para o melhor resultado - Banco B.

Treinamento da RNA				
Parâmetro de Escolha	Taxa de Treinamento	P. V. ARTa	P. V. ARTb	P. V. Inter-ART
0,1	1,0	0,7	1,0	1,0
Diagnóstico da RNA				
P. V. ARTa	Acerto - Sinal Normal	Acerto - Sinal com Falha	Acerto (%)	
0,7	1	111	100	

5.3.3 Caso 3: reconhecimento e classificação dos sinais

Conforme a estratégia utilizada no tópico 5.2.3 foi realizado o teste de reconhecimento e classificação dos sinais em sinal normal, sinal de falha no 1º andar ou sinal de falha no 2º andar.

Os parâmetros da fase de treinamento e diagnóstico, assim como o melhor resultado gerado pela rede, são apresentados na Tabela 12.

Tabela 12 - Parâmetros de treinamento e diagnóstico para classificação dos sinais - Banco B.

Treinamento da RNA				
Parâmetro de Escolha	Taxa de Treinamento	P. V. ARTa	P. V. ARTb	P. V. Inter-ART
0,1	1,0	0,7	1,0	1,0
Diagnóstico da RNA				
P. V. ARTa	Acerto - Sinal Normal	Acerto - Sinal com Falha 1º andar	Acerto - Sinal com Falha 2º andar	Acerto (%)
0,7	2	92	19	100

5.3.4 Caso 4: teste cruzado

A partir do teste apresentado no tópico 5.3.3, realizou-se o teste cruzado da rede neural, semelhantemente ao teste cruzado realizado com o banco A.

A Tabela 13 apresenta os parâmetros utilizados no treinamento e diagnóstico da rede e a média da porcentagem de acerto, sendo o valor do parâmetro de vigilância de ARTa igual a 0,7.

Tabela 13 - Primeiro teste cruzado – Banco B.

Treinamento da RNA				
Parâmetro de Escolha	Taxa de Treinamento	P. V. ARTa	P. V. ARTb	P. V. Inter-ART
0,1	1,0	0,7	1,0	1,0
Diagnóstico				
P.V. ARTa		Média da Porcentagem de Acerto (%)		
0,7		95,81		

A Tabela 14 apresenta os parâmetros utilizados no treinamento e diagnóstico da rede e a média da porcentagem de acerto, sendo o valor do parâmetro de vigilância de ARTa igual a 0,8.

Tabela 14 - Segundo teste cruzado – Banco B.

Treinamento da RNA				
Parâmetro de Escolha	Taxa de Treinamento	P. V. ART_a	P. V. ART_b	P. V. Inter-ART
0,1	1,0	0,8	1,0	1,0
Diagnóstico				
P.V. ART_a		Média da Porcentagem de Acerto (%)		
0,8		96,14		

A Tabela 15 apresenta os parâmetros utilizados no treinamento e diagnóstico da rede e a média da porcentagem de acerto, sendo o valor do parâmetro de vigilância de ART_a igual a 0,9.

Tabela 15 - Terceiro teste cruzado – Banco B.

Treinamento da RNA				
Parâmetro de Escolha	Taxa de Treinamento	P. V. ART_a	P. V. ART_b	P. V. Inter-ART
0,1	1,0	0,9	1,0	1,0
Diagnóstico				
P.V. ART_a		Média da Porcentagem de Acerto (%)		
0,9		96,18		

Observou-se que, com o aumento do valor do parâmetro de vigilância de ART_a, o terceiro teste cruzado, apresentou a melhor porcentagem de acerto que foi em torno de 96,18%.

5.4 TESTE E RESULTADOS – BANCO C

5.4.1 Caso 1: validação da rede neural

A Tabela 16 apresenta os parâmetros utilizados no treinamento e no diagnóstico da rede neural, assim como o resultado que a mesma apresentou para o teste de validação.

Tabela 16 - Parâmetros de treinamento do teste de validação da RNA - Banco C.

Treinamento da RNA				
Parâmetro de Escolha	Taxa de Treinamento	P. V. ART _a	P. V. ART _b	P. V. Inter-ART
0,1	1,0	0,7	1,0	1,0
Diagnóstico da RNA				
P. V. ART _a	Acerto - Sinal Normal	Acerto - Sinal com Falha	Acerto (%)	
0,7	121	4820	100	

Assim como os demais testes de validação realizados com os bancos A e B, a rede neural também apresentou um resultado de 100% de acerto para o teste de validação para o banco C.

5.4.2 Caso 2: reconhecimento de sinais normais ou sinais com falha

O conjunto de sinais para o treinamento teve 3953 sinais e o conjunto de sinais para o diagnóstico 988 sinais. Os parâmetros utilizados nas fases de treinamento e diagnóstico que geraram o melhor resultado são apresentados na Tabela 17.

Tabela 17 - Parâmetros da ARTMAP *Fuzzy* para o melhor resultado - Banco C.

Treinamento da RNA				
Parâmetro de Escolha	Taxa de Treinamento	P. V. ART _a	P. V. ART _b	P. V. Inter-ART
0,1	1,0	0,7	1,0	1,0
Diagnóstico da RNA				
P. V. ART _a	Acerto - Sinal Normal	Acerto - Sinal com Falha	Acerto (%)	
0,7	24	964	100	

5.4.3 Caso 3: reconhecimento e classificação dos sinais

Seguindo a mesma estratégia utilizada nos testes de reconhecimento e classificação de falhas para os bancos A e B, assim também foi feito para o banco C.

A Tabela 18 apresenta os parâmetros da fase de treinamento e diagnóstico, assim como o melhor resultado obtido.

Tabela 18 - Parâmetros de treinamento e diagnóstico para classificação dos sinais - Banco C.

Treinamento da RNA				
Parâmetro de Escolha	Taxa de Treinamento	P. V. ART _a	P. V. ART _b	P. V. Inter-ART
0,1	1,0	0,8	1,0	1,0
Diagnóstico da RNA				
P. V. ART _a	Acerto - Sinal Normal	Acerto - Sinal com Falha 1º andar	Acerto - Sinal com Falha 2º andar	Acerto (%)
0,8	24	810	154	100

5.4.4 Caso 4: teste cruzado

A partir do teste apresentado no tópico 5.4.3, realizou-se o teste cruzado da rede neural, semelhantemente ao teste cruzado realizado com os bancos A e B.

A Tabela 19 apresenta os parâmetros utilizados no treinamento e diagnóstico da rede e a média da porcentagem de acerto, sendo o valor do parâmetro de vigilância de ART_a igual a 0,7.

Tabela 19 – Primeiro teste cruzado – Banco C.

Treinamento da RNA				
Parâmetro de Escolha	Taxa de Treinamento	P. V. ARTa	P. V. ARTb	P. V. Inter-ART
0,1	1,0	0,7	1,0	1,0
Diagnóstico				
P.V. ARTa		Média da Porcentagem de Acerto (%)		
0,7		99,25		

A Tabela 20 apresenta os parâmetros utilizados no treinamento e diagnóstico da rede e a média da porcentagem de acerto, sendo o valor do parâmetro de vigilância de ARTa igual a 0,8.

Tabela 20 - Segundo teste cruzado – Banco C.

Treinamento da RNA				
Parâmetro de Escolha	Taxa de Treinamento	P. V. ARTa	P. V. ARTb	P. V. Inter-ART
0,1	1,0	0,8	1,0	1,0
Diagnóstico				
P.V. ARTa		Média da Porcentagem de Acerto (%)		
0,8		98,42		

A Tabela 21 apresenta os parâmetros utilizados no treinamento e diagnóstico da rede e a média da porcentagem de acerto, sendo o valor do parâmetro de vigilância de ARTa igual a 0,9.

Tabela 21 - Terceiro teste cruzado – Banco C.

Treinamento da RNA				
Parâmetro de Escolha	Taxa de Treinamento	P. V. ARTa	P. V. ARTb	P. V. Inter-ART
0,1	1,0	0,9	1,0	1,0
Diagnóstico				
P.V. ARTa		Média da Porcentagem de Acerto (%)		
0,9		98,26		

5.5 CONSIDERAÇÕES

Observou-se através dos testes realizados que a rede neural comportou-se de forma esperada, apresentando um resultado positivo em relação ao reconhecimento e classificação de sinais.

Nos testes em que o objetivo da rede era apenas classificar o sinal em sinal normal ou sinal de falha, a mesma apresentou um resultado de 100% para os testes com todos os bancos A, B e C.

Em relação aos testes em que a rede deveria classificar os sinais em sinal normal, sinal de falha no 1º andar e sinal de falha no 2º andar, a rede neural ARTMAP *Fuzzy* também demonstrou um ótimo desempenho ao obter 100% de acerto em relação a todos os bancos de sinais.

Outro ponto positivo observado foi o resultado dos testes cruzados. Ao utilizarmos o banco de sinais A, a maior média da porcentagem de acerto que a rede apresentou foi de 93,89% de acerto. Já os testes cruzados realizados com o banco de sinais B, apresentaram de início, uma média de porcentagem de acerto de 95,81%.

Por fim, a rede neural ARTMAP *Fuzzy* demonstrou um ótimo resultado no teste cruzado realizado com o Banco C, tendo como melhor resultado uma média da porcentagem de acerto de 99,25% em seu primeiro teste cruzado, comprovando que quanto maior a quantidade de padrões inseridos na rede neural, melhor será o resultado apresentado por ela.

6 CONSIDERAÇÕES FINAIS

Nesta dissertação verificou-se que edifícios e pontes são exemplos de estruturas que abrigam ou permitem a passagem de milhares de pessoas. Toda a estrutura é suscetível a falhas pequenas ou grandes que podem se manifestar a curto ou longo prazo, causando falta de segurança, custos maiores com manutenção ou ainda resultados catastróficos.

Apresentou-se o conceito de falhas estruturais, quais as possíveis falhas que podem ocorrer em prédios e pontes além das causas que as resultam.

Observou-se que técnicas eficientes de monitoramento da integridade destas estruturas precisam ser desenvolvidas. A implementação destas técnicas é conhecida como monitoramento da integridade estrutural, ou também como SHM.

Mostrou-se a importância da utilização destas técnicas no ambiente da engenharia mecânica e os benefícios que elas proporcionam como maior segurança de vida e menor custo com a manutenção de estruturas. Foi visto que as técnicas mais comuns são conhecidas como técnicas não destrutivas.

Apesar de já existirem estas técnicas de SHM, há também novas abordagens que se mostram promissoras na área de monitoramento, baseados nos sistemas inteligentes, como os algoritmos genéticos e as redes neurais artificiais. Para esta dissertação, optou-se pela segunda abordagem.

As RNAs são algoritmos computacionais que se baseiam no funcionamento do cérebro humano. Em relação a elas, seu processamento é desenvolvido em duas etapas: treinamento da rede e diagnóstico. A etapa de treinamento é a mais importante, pois é onde a rede neural irá adquirir seu conhecimento através do ajuste de pesos das conexões de neurônios artificiais, para poder realizar ações como o reconhecimento ou a classificação dos padrões de entrada.

Foram apresentadas as principais características das RNAs baseadas na Teoria da Ressonância Adaptativa, desenvolvida por Carpenter e Grossberg. Viu-se como são os métodos de treinamento delas e seu processamento em geral, a fim de utilizá-las como técnicas de SHM. Observou-se que elas possuem duas características diferenciais em relação às demais redes neurais já desenvolvidas: a estabilidade e plasticidade.

Portanto, a metodologia aplicada nesta dissertação buscou demonstrar uma técnica de SHM baseada em redes neurais artificiais, desenvolvendo e aplicando a rede neural ARTMAP Fuzzy que agrega o conceito da Teoria da Ressonância Adaptativa (ART) e da Lógica

Nebulosa ou Lógica *Fuzzy* preservando duas características fundamentais em relação às redes neurais: a estabilidade e a plasticidade, que proporcionam à rede uma aprendizagem estável e convergência rápida.

A metodologia utilizada nesta dissertação foi dividida em três etapas: aquisição dos dados, treinamento da RNA escolhida e o diagnóstico da mesma.

Na aquisição dos dados buscou-se criar um banco de dados que representasse um edifício de dois andares, tendo sinais normais e sinais com falhas. Já no treinamento e diagnóstico da rede, obtiveram-se parâmetros que gerassem o melhor resultado para sequências arbitrárias dos padrões de entrada.

A rede neural por sua vez, demonstrou precisão, robustez e um bom desempenho para o problema proposto, operando conforme as expectativas. O resultando gerado por ela foi de 100% de acerto para os testes de reconhecimento e classificação de sinais. Ao realizar também testes cruzados, a rede apresentou bons resultados, sendo que a média de porcentagem de acerto mínima foi de 91,09% e a máxima de 99,25%, demonstrando que por ser uma rede adaptativa, ela tende a obter um resultado máximo e não retrocede, comprovando a eficiência de seu treinamento.

6.1 PROPOSTAS FUTURAS DE TRABALHO

A princípio, a técnica de SHM desenvolvida nesta dissertação foi aplicada utilizando-se de dados numéricos simulados por um modelo matemático dinâmico. Deste modo, para trabalhos futuros, propõe-se que:

- a. Seja feita a aplicação desta técnica com dados experimentais a fim de confirmar seu desempenho e observar melhor seu funcionamento diante de uma situação em tempo real;
- b. Compara-la com outras técnicas que se utilizam de redes neurais artificiais, buscando a que melhor atende o problema em questão;
- c. Juntamente com esta técnica, utilizar materiais inteligentes para a aquisição de dados em um ensaio experimental;
- d. Desenvolver um sistema geral, com interface habilitada para usuários comuns, a fim de colocá-la em prática nas empresas atuais;

REFERÊNCIAS

- AGUADO, A. G.; CANTANHEDE, M. A. **Lógica fuzzy**. Limeira: UNICAMP, 2010. p. 12
- AGUIAR, M. A. M. **Tópicos de mecânica clássica**. Campinas: Livraria da Física, 2010. p. 250.
- BALAGEAS, D.; FRITZEN, C. P.; GÜEMES, A. **Structural health monitoring**. London: ISTE, 2006. p. 496.
- BILOBROVEC, M.; MARÇAL, R. F. M.; KOVALESKI, J. L. Implementação de um sistema de controle inteligente utilizando a lógica fuzzy. SIMPÓSIO DE ENGENHARIA DE PRODUÇÃO - SIMPEP, 11., 2004, Bauru, 2004. **Simpósio...** Bauru: [s.n.], 2004. p.7. ISSN 1809-7189
- BITENCOURT, T. F.; STEFFEN JÚNIOR, V. Monitoramento da integridade estrutural de aeronaves. **Horizonte Científico**, v. 3, n. 2, p.18, 2009. ISSN: 1808-3064
- BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2012. p. 226
- CARPENTER, G. A. et al. Fuzzy ARTMAP: An adaptive resonance architecture for incremental learning of analog maps. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS- IJCNN, 3., 1992, Baltimore. **Conference...** Baltimore: IEEE, 1992. p. 309-314.
- 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**, Holanda do Norte, v. 4, n 5, p. 565-588, 1991.
- CARPENTER, G. A.; GROSSBERG, S.; REYNOLDS, J. ARTMAP: a self-organizing neural network architecture for fast supervised learning and pattern recognition. In: SEATTLE INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS- IJCNN, 1., 1991, Seattle. **Conference...** Seattle: IEEE, 1991. p. 863-868.
- CARPENTER, G. A.; GROSSBERG, S.; ROSEN, D. B. Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance system. **Neural Network**, Holanda do Norte, v. 4, n. 6, p. 759-771, 1991b.
- CARPENTER, G. A.; GROSSBERG, S. A self-organizing neural network for supervised learning, recognition and prediction. **IEEE Communications Magazine**, Piscataway, v. 30, n. 9, p. 38-49, 1992.
- CARPENTER, G. A. **ART Neural networks: distributed coding and ARTMAP applications**. Boston: Boston University, Department of Cognitive and Neural Systems, 2000. p. 13.

CARPENTER, G. A.; GROSSBERG, S.; ROSEN, D. B. ART 2-A: an adaptive resonance algorithm category learning and recognition. **Neural Networks**, Kidlington., v. 4, n. 4, p. 493-504, 1991.

CARRILLO, O. J. B. **Algoritmo híbrido para avaliação da integridade estrutural: uma abordagem heurística**. 2007. 152 f. Tese (Doutor em Engenharia Civil)- Escola de Engenharia de São Carlos, Universidade de São Paulo- USP, São Carlos, 2007.

CHEN, B.; NAGARAJAIAH, S. Structural damage detection using decentralized controller design method. **Smart Structures and Systems**, Yuseong-gu, v. 4, n. 6, p. 779-794, 2008. ISSN 1738-1584.

DEMARCHI, D.; PEREIRA, J. A.; LOPES JUNIOR, V. Técnicas não destrutivas de monitoramento e detecção de falhas estruturais utilizando redes neurais. CONGRESSO BRASILEIRO DE ENGENHARIA MECÂNICA, 15., 1999, Águas de Lindóia. **Congresso...**, Águas de Lindóia: ABCM Journal, 1999. p. 10.

DOEBLING, S. W. et al. **Damage identification and health monitoring of structural and mechanical systems from changes in their vibration characteristics: a literature review**. Novo México: Los Alamos National Laboratory, 1996. (Report, LA-13070-MS).

FARRAR, C.; WORDEN, K. **An introduction to structural health monitoring: philosophical transactions of the royal society A**. [S.l.: s.n.], 2006. p. 303-315.

FERREIRA, W. P. **Análise dinâmica de contingências de sistemas de energia elétrica por redes neurais baseadas na teoria da ressonância adaptativa**. 2003. 130 f. Tese (Doutor em Engenharia Elétrica)- Faculdade de Engenharia, Universidade Estadual Paulista- UNESP, Ilha Solteira, 2003.

FRANÇA, A. A. **Detecção e localização de danos em materiais compósitos aplicado em aeronaves utilizando redes neurais artificiais**. 2014. 109 f. Dissertação (Mestre em Engenharia Mecânica)- Faculdade de Engenharia, Universidade Estadual Paulista- UNESP, Ilha Solteira, 2014.

FURTADO, R. M. **Identificação de falhas estruturais usando sensores e atuadores piezelétricos e redes neurais artificiais**. 2004. 144 f. Dissertação (Mestre em Engenharia Mecânica)- Faculdade de Engenharia, Universidade Estadual Paulista- UNESP, Ilha Solteira, 2004.

GOMIDE, F. A.; GUDWIN, R. R.; TANSCHKEIT, R. Conceitos fundamentais da teoria de conjuntos fuzzy, lógica fuzzy e aplicações. In: IFSA CONGRESS-TUTORIALS, 6., 1995, São Paulo. **Congress...** São Paulo: IFSA'95, 1995. p. 1- 38.

HAYKIN, S. Introdução. In:_____. **Redes neurais: princípios e práticas**. Porto Alegre: Bookman, 2001. p. 908.

INMAN, D. J. et al. **Damage prognosis for aerospace, civil and mechanical systems**. Hoboken: John Wiley & Sons, 2005. p. 470.

LEUCAS, L. F. **Utilização das técnicas de impedância eletromecânica e ondas de Lamb para identificação de dano em estruturas com rebites.** 2009. 58 f. Dissertação (Mestre em Engenharia Mecânica)– Faculdade de Engenharia Mecânica, Universidade Federal de Uberlândia, Uberlândia, 2009.

LIMA, F. P. A. **Monitoramento e identificação de falhas em estruturas aeronáuticas e mecânicas utilizando técnicas de computação inteligente.** 2014. 72 f. Dissertação (Mestre em Engenharia Mecânica)- Faculdade de Engenharia, Universidade Estadual Paulista- UNESP, Ilha Solteira, 2014.

LIMA, I. R. **Sistemas inteligentes para auxiliar na tomada de decisões em mercado de capitais.** 2012. 192 f. Dissertação (Mestre em Engenharia de Sistemas) - Universidade Federal de Lavras, Lavras, 2012.

LOPES, M. L. M.; MINUSSI, C. R.; LOTUFO, A. D. P. Electric load forecasting using a fuzzy ART&ARTMAP neural network. **Applied Soft Computing**, Amsterdam, v. 5, n. 2, p. 235–244, 2005.

LOUZADA, D. R. **Detecção e caracterização de danos estruturais através de sensores a rede de Bragg e redes neurais artificiais.** 2013. 173 f. Tese (Doutor em Engenharia Mecânica)– Faculdade de Engenharia Mecânica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2013.

MAIO, C. E. B. **Técnicas para monitoramento de integridade estrutural usando sensores e atuadores piezoelétricos.** 2011. 113 f. Dissertação (Mestre em Engenharia Mecânica)- Escola de Engenharia de São Carlos, Universidade de São Paulo- USP, São Carlos, 2011.

MARRO, A. A. et al. **Lógica fuzzy: conceitos e aplicações.** Natal: Universidade Federal do Rio Grande do Norte, 2010. p. 23.

MONTEIRO, L. H. A. **Sistemas dinâmicos.** São Paulo: Livraria da Física, 2002. p. 527. ISBN: 8588325-08x

MORALES, J. D. V. **Detecção de dano em estruturas utilizando algoritmos genéticos e parâmetros dinâmicos.** 2009. 191 f. Dissertação (Mestre em Engenharia de Estruturas)- Escola de Engenharia de São Carlos, Universidade de São Paulo- USP, São Carlos, 2009.

PACHECO, M. A. C. **Algoritmos genéticos: princípios e aplicações.** Rio de Janeiro: Pontifícia Universidade Católica do Rio de Janeiro, 1999. p. 9.

PEGAIANE, M. G. R. dos R. **Minimizando vibrações de um sistema dinâmico através de controle híbrido.** 2014. 70 f. Dissertação (Mestrado em Engenharia Mecânica)- Faculdade de Engenharia, Universidade Estadual Paulista- UNESP, Ilha Solteira, 2014.

RAMOS, C. A. X. **Materiais compósitos inteligentes.** 2006. 324 f. Tese (Doutor em Ciências da Engenharia)- Faculdade de Engenharia, Universidade do Porto, Porto, 2006.

REZENDE, S. O. **Sistemas inteligentes: fundamentos e aplicações.** Barueri: Manole, 2005. p. 525

SANDRI, S; CORREA, C. Lógica nebulosa. In: ESCOLA DE REDES NEURAIAS, 5., 1999, São José dos Campos. **Escola...** São José dos Campos: ITA, 1999. p. c073-c090.

SANTOS, A. D. F. **Proposta de gerenciamento de dados para monitoramento de saúde estrutural utilizando redes de sensores ópticos FBG**. 2014. 104 f. Dissertação (Mestre em Engenharia Elétrica)– Instituto de Tecnologia, Universidade Federal do Pará, Pará, 2014.

SANTOS, M. T.; ALMEIDA, A. R; TU, C. C. C. Redes neurais artificiais aplicadas no monitoramento da condição de ferramentas de corte utilizando o algoritmo de extração das características SFS. In: CONGRESSO BRASILEIRO DE REDES NEURAIAS ARTIFICIAIS, 4., São José dos Campos. **Congresso...** São José dos Campos: ITA, 1999. p. 292-297.

SASMAL, S.; RAMANJANEYULU, K. Detection and quantification of structural damage of a beam-like structure using natural frequencies. **Engineering**, Don Mills, 2009, v. 1, n. 3, p. 167-176. doi:10.4236/eng.2009.13020.

SILVA JUNIOR, S. F.; MARQUES, P. V. **Ensaaios não destrutivos**. Belo Horizonte: Instituto Federal de Santa Catarina 2006. p. 96

SILVA, R. et al. Porque um edifício entra em colapso. **Revista Científica Integrada**, Ribeirão Preto, v. 1, n. 3, p.11, 2014. ISSN 2359-4632.

SUETAKE, M. **Sistemas inteligentes para monitoramento e diagnóstico de falhas em motores de indução trifásicos**. 2012. 126 f. Tese (Doutor em Ciências) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2012.

THOMAZ, E. **Trincas em edifícios**: causas, prevenção e recuperação. São Paulo: Pini, 1989.

TSURUTA, K. M. **Monitoramento de integridade estrutural de materiais compostos sujeitos a impactos empregando a técnica da impedância eletromecânica**. 2008. 114 f. Dissertação (Mestre em Engenharia Mecânica) – Faculdade de Engenharia Mecânica, Universidade Federal de Uberlândia, Uberlândia, 2008.

VIEIRA, D. A. H.; SOUZA, C. C.; REIS NETO, J. F. Algoritmos genéticos como ferramenta auxiliar na tomada de decisão em atividades de gestão agroindustrial. In: ENCONTRO DE INICIAÇÃO CIENTÍFICA- ETIC, 6., Presidente Prudente, 2010. **Encontro...** Presidente Prudente: [s.n.], 2010. p. 1-14. ISSN 21-76-8498.

WENZEL, H. **Health monitoring of bridges**. Singapura: John Wiley & Sons, 2009. p. 652. ISBN 9780470031735.

ZADEH, L. A. Fuzzy sets. **Information and Control**, Maryland Heights, v. 8, n. 3, p. 338-353, 1965.

APÊNDICE A – LÓGICA FUZZY

As classes de objetos estabelecidas no mundo real não possuem critérios de adesão definidos com precisão. Por exemplo, a temperatura que sentimos em um determinado dia (muito frio, frio, quente, muito quente). No entanto, por tais classes exercerem um papel muito importante no pensamento humano, especificamente no reconhecimento de padrões e na comunicação e abstração de informações, Zadeh (1965) desenvolveu a teoria dos conjuntos nebulosos. Sandri e Correa (1999) conceituam esta teoria como lógica nebulosa ou lógica *fuzzy*, quando utilizada no âmbito lógico, como o de sistemas baseados em conhecimento, por exemplo, as redes neurais artificiais.

Bilobrovec, Marçal e Kovaleski (2004), acrescentam que a lógica *fuzzy* possibilita o tratamento de informações lógicas seguindo as regras naturais de raciocínio do ser humano, dando como exemplo: SE tensão for muito baixa, ENTÃO desligue o motor. Ou seja, a lógica *fuzzy* permite a manipulação de valores não precisos, expressões verbais abstratas, e etc.

De acordo com Marro et al. (2010), o principal objetivo da lógica *fuzzy* é modelar em sistemas computacionais, o raciocínio humano, que muitas vezes é impreciso, ambíguo e vago. Ao contrário da lógica convencional, a lógica *fuzzy* utiliza a ideia de que todas as coisas seja temperatura, velocidade, altura e etc. admitem graus de pertinência também chamados de graus de adesão. De acordo com Gomide, Gudwin e Tanscheit (2002), o grau de adesão de uma proposição pode ser um subconjunto *fuzzy* de qualquer conjunto parcialmente ordenado, isto é, o grau de adesão pode assumir mais de um valor, diferentemente dos sistemas lógicos binários, onde o grau de adesão só pode assumir valor igual a 1 ou 0.

Portanto, Zadeh (1965), afirma que “um conjunto *fuzzy* é uma classe de objetos com uma série contínua de graus de adesão. Tal conjunto é caracterizado por uma função de pertinência (característica), que atribui a cada objeto um grau de adesão que varia entre zero e um.”.


A. Conjuntos Clássicos X Conjuntos Nebulosos

Na teoria dos Conjuntos Clássicos, tendo um universo U e um elemento particular x , onde $x \in U$, o grau de pertinência $\mu_A(x)$ em relação ao conjunto $A \subseteq U$ é dado por:

$$\mu_A(x) = \begin{cases} 1 & \text{se } x \in A \\ 0 & \text{se } x \notin A \end{cases} \quad (24)$$

Ou seja, nesta teoria o grau de pertinência assume apenas valores igual a 0 ou 1. Portanto, tendo um problema de manipulação de dados com erros limitados, todos os números dentro de um erro percentual terão um grau de pertinência 1 e os demais 0, como representado na Figura 17(a). Para um caso preciso, o grau de pertinência é somente 1 no número exato de x , tendo valor igual a 0 para todos os demais, visto na Figura 17(b).

Figura 20 - Graus de pertinência de um conjunto clássico.




Fonte: Gomide, Gudwin e Tanscheit (2002).

Segundo Gomide, Gudwin e Tanscheit (2002), a teoria dos Conjuntos Nebulosos se difere pelo fato de que o grau de pertinência é mais amplo, visto que alguns elementos pertencem mais a um determinado conjunto do que outros. Seguindo os conceitos desta teoria, Bilobrovec, Marçal e Kovaleski (2004) descrevem que o grau de pertinência pode assumir qualquer valor entre 0 e 1, onde:

$$\mu_A(x) = \begin{cases} 1, & \text{se } x \text{ está em total pertinência a } A \\ 0, & \text{se } x \text{ está em completa exclusão a } A \\ 0 < \mu(x) < 1, & \text{se } x \text{ está parcialmente pertinente a } A \end{cases} \quad (25)$$

Figura 21 - Grau de pertinência de um conjunto nebuloso referente a temperatura.



Fonte: Gomide, Gudwin e Tanscheit (2002).


Outro exemplo é: ao expressar a temperatura de um determinado lugar, onde seu valor se encontra por volta de 25°C, pode-se utilizar uma função de pertinência triangular, com o pico em 25, para sugerir que a ideia de que quanto mais perto o número de 25, mais ele se identifica com o conceito representado, como demonstrado na Figura 18.

B. Funções de Pertinência

De acordo com Aguado e Cantanhede (2010) as funções de pertinência são exemplificadas como um mapeamento matemático de cada valor numérico possível para as variáveis linguísticas. Estas variáveis são consideradas nomes de conjuntos *fuzzy*. Ou seja, as funções de pertinência caracterizam cada conjunto *fuzzy*, ao corresponderem a uma curva que define o grau de pertinência de cada entrada (LIMA, 2012).

Voltando ao exemplo da temperatura, a mesma pode ser considerada uma variável linguística ao assumir valores “baixa”, “média” e “alta” (GOMIDE; GUDWIN; TANSCHUIT, 2002), demonstrada na Figura 19 para melhor compreensão.

Figura 22 - Exemplo de variáveis linguísticas.



Fonte: Gomide, Gudwin e Tanscheit (2002).

Os termos utilizados na Lógica *Fuzzy* são diversos e, segundo Gomide, Gudwin, e Tanscheit (2002) eles podem ser divididos nas seguintes categorias:

- a. Termos primários: que são os termos especificados em um universo (alto, baixo, pequeno, grande, etc.);
- b. Conectivos lógicos: a negação Não, os conectivos E e OU, e conectivos mascarados como mas e porém.
- c. Modificadores: muito, pouco, levemente, extremamente, etc.;
- d. Delimitadores: uso de parênteses ().

Marro et al. (2010) explica que a escolha de uma função de pertinência depende muito do problema a ser modelado e da capacidade computacional disponível. Para problemas mais complexos, as funções não-lineares se mostram mais eficientes, no entanto, elas requerem uma capacidade computacional muito maior que as funções lineares.

Algumas funções de pertinência mais utilizadas são: triangular, trapezoidal, gaussiana e a exponencial.

C. Operadores lógicos

Assim como na teoria clássica, na teoria *fuzzy* são utilizados operadores lógicos como AND, OR e NOT para o cálculo de operações entre os conjuntos nebulosos. Porém, estes operadores são definidos de forma diferente em relação à lógica *fuzzy*.

De acordo com Marro et al. (2010), dado dois conjuntos A e B pertencentes a um determinado universo U, o operador AND que representa a interseção entre eles é definido pela equação (26), onde ele fornece o valor mínimo entre os dois conjuntos.

$$A \text{ AND } B = A \cap B = \min \{ \mu_A(x) \mu_B(x) \}, x \in U \quad (26)$$

Já o operador OR que representa a união destes conjuntos, fornece o valor máximo entre os dois conjuntos, é dado pela equação (27):

$$A \text{ OR } B = A \cup B = \max \{ \mu_A(x) \mu_B(x) \}, x \in U \quad (27)$$

Por fim, o operador NOT representa o complemento de um dos conjuntos, no caso o conjunto A por exemplo, e é definido por:

$$\text{NOT } A = \neg A = \mu_A(x) = 1 - \mu_A(x), x \in U \quad (28)$$