



## **Deteção e classificação de defeitos em chapas de aço carbono utilizando ondas ultrassônicas guiadas de Lamb e redes neurais artificiais**

**Matheus Souza Sales Araújo<sup>1</sup>, Cláudia Teresa Teles Farias<sup>2</sup>, Alexandre Smith Aquer de Oliveira<sup>3</sup>**

<sup>1</sup>Graduando em Engenharia Mecânica – IFBA/GPEND/LEUS. E-mail: [matheusaraujo@ifba.edu.br](mailto:matheusaraujo@ifba.edu.br)

<sup>2</sup>Doutora em Engenharia Metalúrgica e de Materiais – IFBA/GPEND/LEUS. E-mail: [cfarias@ifba.edu.br](mailto:cfarias@ifba.edu.br)

<sup>3</sup>Graduando em Engenharia Elétrica – IFBA/GPEND/LEUS. E-mail: [alexandresmith@ifba.edu.br](mailto:alexandresmith@ifba.edu.br)

**Resumo:** A técnica de inspeção por ondas guiadas consiste na utilização de ondas ultrassônicas na avaliação de materiais com a vantagem de se propagarem por longas distâncias. É característica do ensaio ultrassônico a alta sensibilidade na deteção de falhas ou variações microestruturais como amplamente conhecido na literatura. A perda de espessura é um tipo de falha comum em materiais de aço carbono que pode ser detectada por meio das ondas de Lamb. Contudo, a observação de pequenas perdas de espessura tanto no domínio do tempo ou mesmo da frequência pode não ser tão evidente, assim diferentes processamentos digital de sinais e/ou inteligência artificial são propostos com o intuito de otimizar o monitoramento da integridade estrutural. Neste trabalho é proposta a inspeção, por ondas guiadas de Lamb, de chapas de aço carbono com defeitos tipo entalhes com diferentes profundidades na configuração transmissão-recepção por imersão. Objetivou-se a deteção e a classificação de tais falhas através de processamentos digital de sinais e de redes neurais artificiais. Os resultados alcançados pelo classificador neural mostrou excelente caracterização de defeitos com 30% e 60% de perda de espessura, contudo as falhas com perda de 10% não tiveram um aproveitamento satisfatório em relação às outras categorias. Como avaliação geral, foi conceituado como positivo os resultados obtidos.

**Palavras-chave:** ensaios não destrutivos, integridade estrutural, ondas guiadas, redes neurais artificiais, transformada rápida de Fourier

### **1. INTRODUÇÃO**

Os ensaios não destrutivos (END) são uma realidade no monitoramento de integridade estrutural tornando-se assim fator indispensável para o setor industrial moderno. Os END são capazes de identificar descontinuidades, prever a vida útil de equipamentos, maquinários etc. consequentemente oferece a possibilidade de um planejamento mais acurado dos períodos de manutenção, poupando custos e evitando acidentes.

Dentre os diversos tipos de END, destaca-se neste artigo a técnica utilizando ondas guiadas de Lamb, que é uma variação do ensaio ultrassônico convencional, porém as ondas de Lamb divergem em alguns aspectos a exemplo de se propagar por longas distâncias, ter caráter multimodal e ser gerada obedecendo a determinados parâmetros. Os ensaios utilizando ondas guiadas têm alta sensibilidade para deteção de falhas com diferentes dimensões, perda de espessura ou mesmo variações microestruturais.

Estudos têm sido feitos da interação destas ondas com descontinuidades de diversos tipos, em chapas metálicas e em compósitos (ARAÚJO, 2011; FARIAS, 2012). O uso de processamento de sinais é de bastante valia para os casos onde não é possível a identificação de descontinuidades de maneira simples, apresentando resultados satisfatórios.

Contudo, ainda há situações que não é trivial a avaliação correta da inspeção direto da tela do aparelho de ultrassom. Para tal, faz-se necessário o uso de processamento digital de sinais que são técnicas computacionais com o intuito de reduzir o ruído presente no sinal adquirido ou até mesmo extrair melhores características. Dentre os diversos tipos de processamentos são destacáveis: filtros, projetados para amenizar o ruído e o algoritmo da transformada de Fourier, responsável pela mudança do domínio temporal para o domínio da frequência. A avaliação no domínio da frequência é bastante útil, pois a análise espectral oferece uma visualização mais simples devida também ao menor nível de ruídos.

Além dos processamentos digitais de sinais citados, técnicas de inteligência artificial (AI) ganham cada vez mais espaço. Conforme informa a literatura, as redes neurais artificiais (RNA) são ferramentas de excelente suporte na avaliação de materiais. De acordo com Santos *et al* (2012), as RNA conseguem facilmente extrair do meio os parâmetros mais relevantes para a classificação desejada.

Atualmente, a utilização de redes neurais artificiais vem crescendo para o uso com processamentos tipo transformada de Fourier ou transformada discreta do Cosseno (SANTOS, 2012), pois possuem uma melhor avaliação dos resultados, apresentando respostas plausíveis das discontinuidades existentes em chapas.

O objetivo deste trabalho é caracterizar defeitos tipo entalhes com perdas de 10%, 30% e 60% da espessura nominal de uma chapa de aço de 1,5 mm de espessura por meio de ondas ultrassônica guiadas de Lamb na técnica de imersão e método de transmissão-recepção utilizando o modo de propagação  $S_0$  e processamento de sinais via FFT e classificador utilizando redes neurais artificiais.

## 2. MATERIAL E MÉTODOS

### 2.1. Ondas guiadas de Lamb

Lamb (1917) provou teoricamente que sob determinadas condições um número finito de modos vibracionais de ondas podem se propagar de forma independente em uma placa. As ondas de Lamb, também conhecidas como ondas planas ou ondas guiadas, representam vibrações em duas dimensões em chapas (ALLEYNE, 1992). As características das ondas de Lamb dependem da densidade, propriedades elásticas e da espessura do material, além da frequência (SIQUEIRA, 2002).

Os modos são denominados em função do movimento característico de suas partículas como ilustrado na Figura 1, podendo ser simétricos ou antissimétricos.




Figura 1- Modos de propagação das ondas de Lamb (FARIAS, 2011)

### 2.2. Corpos de prova

Neste trabalho, foi utilizada uma chapa de aço carbono SAE 1020 com composição vista na Tabela 1, dimensionada em 300x300x1,5 mm. O posicionamento dos entalhes foi projetado conforme a Fig. 2 a seguir.

Tabela 1- Composição química do corpo de prova utilizado, SAE 1020 (GERDAU, 2003)

Composição	Porcentagem
C	0,18% - 0,23%
Mn	0,30%-0,60%
Cu	0,20%
S	0,05%
P	0,03%
B	0,0005 - 0,003%




Figura 2- Dimensões (mm) e posições dos entalhes no corpo de prova: (a) 60%, (b) 10% e (c) 30% da espessura da chapa de aço carbono.

### 2.3. Curvas de dispersão

Depois de selecionado o corpo de prova, faz-se necessário estudo dos parâmetros intrínsecos ao material, neste caso o aço carbono. Foram simuladas curvas de dispersão através do software Disperse<sup>®</sup> para aquisição de tais dados. A Figura 3(a) mostra os valores da velocidade de fase, indicando que o modo  $S_0$  é o menos dispersivo para a zona de frequência-espessura de interesse; a Figura 3(b) indica a velocidade de grupo; a Figura 3(c) o ângulo de incidência que a onda deverá incidir de modo a gerar apenas o modo  $S_0$ , encontra-se  $16,2^\circ$ ; a Figura 3(d) mostra que o modo  $S_0$  é menos atenuante do que o modo  $A_0$  no intervalo de interesse, o que torna o modo  $S_0$  mais atraente para esta inspeção.

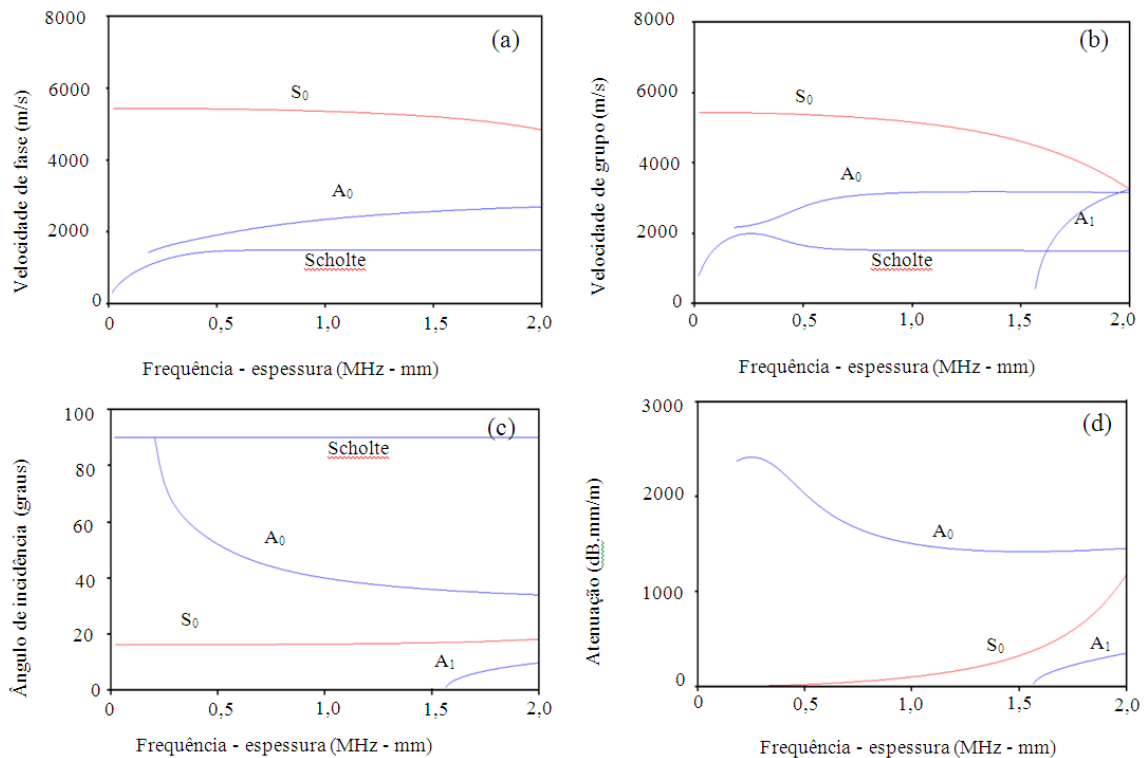


Figura 3 - Curvas de dispersão simuladas para chapa de aço carbono com 1,5 mm de espessura em ensaio por imersão: (a) velocidade de fase; (b) velocidade de grupo; (c) ângulo de incidência; (d) atenuação.

## 2.4. Configuração experimental

Para as inspeções ultrassônicas do corpo de prova foram empregados os seguintes equipamentos: Gerador de pulso Olympus®, modelo 5077PR; transdutores Olympus Panametrics®, modelo V-303-SU, diâmetro 12,7 mm e frequência central de 0,88 MHz imersos e largura de banda 0,52 MHz; e osciloscópio digital Tektronix®, modelo TDS 2024B, com frequência de amostragem de 250 MHz com ligação para um microcomputador para armazenamento dos sinais. A configuração foi estabelecida conforme Figura 4.

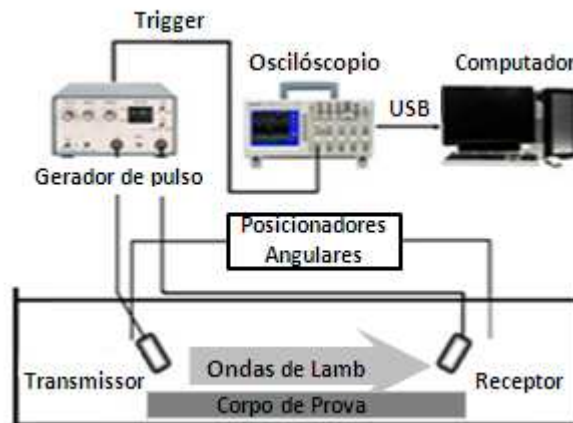


Figura 4 - Esquema experimental da geração das ondas de Lamb usando a configuração transmissão-recepção

## 2.5. Transformada de Fourier

A transformada de Fourier é normalmente implementada a partir do algoritmo da transformada rápida de Fourier (*fast Fourier transform* – FFT) e tem como alguma de suas funções: extrair a distribuição energética do sinal características da fase, frequência central do transdutor e a largura de banda utilizando não mais o domínio temporal, mas o domínio da frequência (RIBEIRO, 2010).

A FFT é definida pelas equações:

$$X(k) = \sum_{j=1}^N x(j) \omega_N^{(j-1)(k-1)} \quad (1)$$

$$x(j) = (1/N) \sum_{k=1}^N X(k) \omega_N^{-(j-1)(k-1)} \quad (2)$$

$$\omega_N = e^{(-2\pi i)/N} \quad (3)$$

Onde o sinal ultrassônico é representado pelo vetor  $x$  de tamanho  $N$  (THE MATH WORKS, 2008).

A partir da FFT é possível identificar, através de variações sensíveis dos espectros de frequência, defeitos circulares de diferentes diâmetros em alumínio (ARAÚJO, 2011) e defeitos como

fratura e delaminação em chapas de compósito (FARIAS, 2012). Mostrando-se assim como excelente técnica de processamento digital de sinais aplicado aos ensaios ultrassônicos.

## 2.6. Redes Neurais Artificiais

As RNA, de forma elementar, são formadas de pequenos nós de processamento, denominados “Neurônios Artificiais”, que são interligados de forma complexa, de forma análoga à estrutura do cérebro humano (SOUZA, 2011) . A Figura 5 ilustra um neurônio artificial.

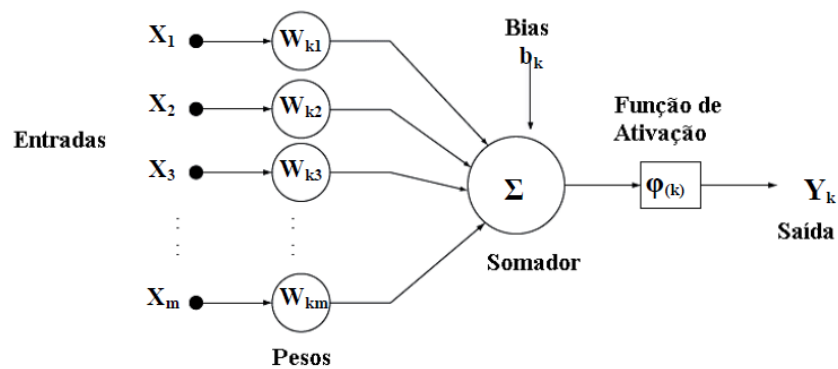


Figura 5 - Neurônio Artificial de McCulloch-Pitts (SOUZA, 2011).

A junção de vários neurônios artificiais em camadas interligadas constitui uma Rede Neural Artificial. Um tipo de rede muito utilizado é a *Multi-Layer Perceptron* (MLP, Perceptron de Múltiplas Camadas), uma modificação da *Single-Layer Perceptron* (BRAGA, 2000). Uma rede MLP contém várias camadas “alimentada a diante” (*feedforward*). A Figura 6 ilustra uma rede do tipo.

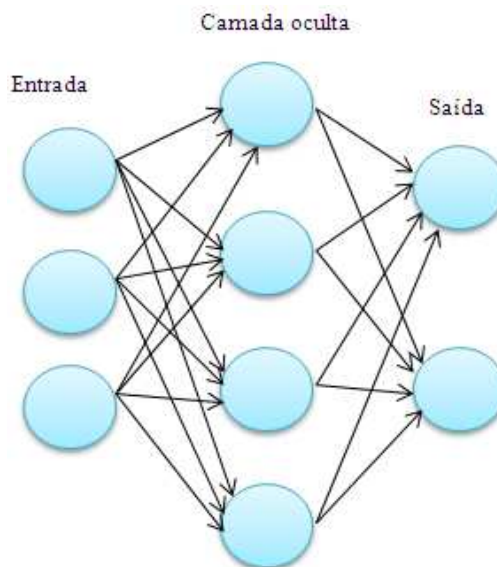


Figura 6 - Diagrama de uma rede neural tipo *Multi-Layer Perceptron*

O treinamento de uma MLP *feedforward* dá-se pelo emprego do algoritmo *backpropagation*. Este algoritmo é responsável por ajustes dos pesos sinápticos, a fim de adequar a saída de cada neurônio; e por conseqüência, a saída da RNA, ao conjunto alvo fornecido através do cálculo e retropropagação (*backpropagation*) do erro de saída (ZHANG, 2003).

O classificador neural utilizado foi uma MLP, conforme metodologia utilizada por Santos *et al* (2012) que avaliou com este tipo de redes variações microestruturais no aço ferrítico 430 devido a diferentes tratamentos térmicos. O número de neurônios ocultos para a rede neural utilizada neste trabalho foi vinte.

### 3. RESULTADOS E DISCUSSÃO

#### 3.1. Análise espectral

Os sinais coletados através do osciloscópio e armazenados no computador foram convertidos para o domínio da frequência através da transformada de Fourier feita na plataforma computacional MATLAB<sup>®</sup>. Observou-se modificações no comportamento espectral como era esperado, de acordo com Oliveira *et al* (2012), devido aos defeitos encontrados no corpo de prova. A Figura 7(a) mostra um dos sinais no domínio do tempo. O mesmo sinal está representado depois de aplicada a FFT, Figura 7(b), modo como os dados alimentaram posteriormente a rede neural artificial.

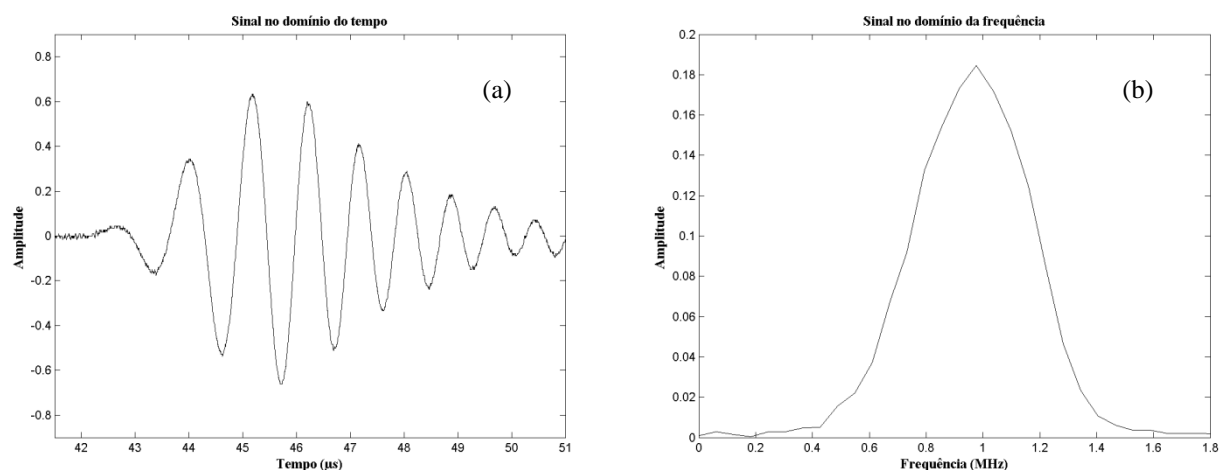


Figura 7 – Representação de um sinal no domínio do tempo (a); e o mesmo após a FFT (b), ou seja, no domínio da frequência.

#### 3.2. Classificador Neural

Após aplicação da metodologia descrita anteriormente, o classificador neural foi treinado com um primeiro grupo de sinais (341 sinais) e alcançou performance de  $3,55 \times 10^{-5}$ . A matriz confusão, Tabela 2, mostra os resultados obtidos dos testes de classificação com o segundo grupo (126 sinais), o qual foi armazenado em uma inspeção diferente do primeiro grupo para tornar a situação mais próxima da prática.

Os resultados mostram excelente classificação dos sinais com perda de 30% de espessura, bem como os de 60%, o que era esperado devido à variação sensível observada nos espectros de frequência de ambos, conseguindo um aproveitamento superior a 94%. Os sinais sem defeito (SD) também foram bem classificados, contudo o aproveitamento para os sinais com perda de 10% foi mediano. Os espectros de frequência não sofrem tanta variação em relação aos sinais sem defeitos visualmente como mostra Oliveira *et al* (2012). Ainda assim, a RNA conseguiu identificar acima da metade os sinais correspondentes a 10%. Como avaliação geral, a rede obteve 85,7% de acerto o que caracteriza a rede com um conceito positivo e como uma ferramenta promissora para atividades industriais práticas.



Tabela 2 – Matriz confusão indicando os respectivos acertos alcançados pelo classificador neural por categoria

Categorias	SD	10%	30%	60%
SD	84,1%	42,1%	0,0%	0,0%
10%	15,9%	57,9%	0,0%	0,0%
30%	0,0%	0,0%	100%	5,3%
60%	0,0%	0,0%	0,0%	94,7%

SD = Sinal sem defeito; Perdas de espessura: 10%; 30%; 60%.

#### 4. CONCLUSÕES

Neste trabalho foi realizada a inspeção de chapas de aço carbono utilizando as ondas ultrassônicas de Lamb para detecção de defeitos do tipo fenda e também foram usadas redes neurais artificiais para classificação dos sinais de acordo com as variações dos espectros de frequência dos sinais.

Os resultados obtidos pelo classificador neural foram bastante animadores, pois o índice de acerto se manteve elevado mesmo com um número limitado de amostras para treinamento. Os resultados obtidos por Oliveira *et al* (2012) para um corpo de prova de mesma configuração apenas foi possível visualizar descontinuidades com perdas de 30% e 60% da espessura nominal. Com a rede neural foi possível identificar com altos índices tais defeitos e ainda uma boa percentagem dos sinais da zona sem defeito e de 10% de perda de espessura.

As técnicas de inteligência artificial como as redes neurais são de grande valia para situações práticas de avaliação onde é necessário o monitoramento da integridade estrutural, tais como áreas onde a corrosão atua de maneira acentuada, para visualizar a perda gradativa de espessura do material e evitar acidentes e gastos desnecessários.

#### AGRADECIMENTOS

Ao Laboratório de Ensaios Ultrassônicos – LEUS do Instituto Federal de Educação, Ciência e Tecnologia da Bahia – IFBA, pela utilização da infraestrutura. Ao Grupo de Pesquisas em Ensaios Não Destrutivos – GPEND, pelo apoio técnico. Ao IFBA e FAPESB, pelo apoio financeiro.

#### REFERÊNCIAS

ALLEYNE D. N.; CAWLEY P. **Optimization of Lamb Wave Inspection Techniques**. NDT & E International. Vol. 25 n1, pp. 11-22, 1992.

ARAÚJO, M. S. S.; FARIAS, C.T.T.; SANTOS, E.T.F.; MENEZES, I.J.; SANTOS, Y.T.B.; OLIVEIRA, M.A.; **Análise do espectro de frequência do modo S0 das ondas de Lamb em chapas de alumínio com furos circulares de diferentes diâmetros**. 5TH PAN AMERICAN CONFERENCE FOR NDT, COPAEND, Cancun, México, outubro 2011.

BRAGA, A.P.; CARVALHO, A.P.L.F.; LUDERMIR, T.B., **Redes Neurais Artificiais: Teoria e Aplicações**, Rio de Janeiro, LTC, 2000.

FARIAS, C.T.T.; FILHO, E.F.S.; SANTOS, Y.T.B.; ARAÚJO, M.S.S.; RIBEIRO, I.S., **Spectral Analysis of the propagation of Lamb Waves on Fibre-Metal Laminated Plates to detect and evaluate different defects**, WORLD CONFERENCE OF NONDESTRUCTIVE TESTING, WCNDT, Durban, África do Sul, abril 2012.

FARIAS, C.T.T.; PARANHOS, R.S.; SILVA, I.C.; SIMAS FILHO, E.F.; MENEZES, I.J.; DIAS, J.C. **Estudo da propagação das ondas de Lamb em chapas de alumínio com furos de diferentes profundidades**. 5TH PAN AMERICAN CONFERENCE FOR NDT, COPAEND, Cancun, México, outubro 2011.



GERDAU, **Manual de Aços**, pg. 33, 2003.

LAMB, H., **On waves in an elastic plate**, Royal Society of London, 1917.

OLIVEIRA, A. S. A.; DIAS, J. C.; FARIAS, C.T.T.; SEIXAS, P. L.; SANTOS, Y. T. B., TEIXEIRA, C. A.; CARDOSO, L. B., **Avaliação não destrutiva ultrassônica de chapas de alumínio com diferentes descontinuidades utilizando ondas de Lamb**, In: XXX CONGRESSO NACIONAL DE ENSAIOS NÃO DESTRUTIVOS E INSPEÇÃO E 16º *CONFERENCIA INTERNACIONAL SOBRE EVALUACIÓN DE INTEGRIDAD Y EXTENSIÓN DE VIDA DE EQUIPOS INDUSTRIALES*, CONAEND & IEV, São Paulo, julho 2012.

RIBEIRO, I.S.; FARIAS, C.T.T.; SIMAS FILHO, E.; SOUZA, Y.; BORGES JR., E.; LOPES, D. **Processamento digital de sinais e inteligência computacional aplicado aos ensaios ultrassônicos**. V CONNEPI, 2010.

SANTOS, Y.T.B.; ARAÚJO, M.S.S.; FARIAS, C. T.T.; FILHO, E.F.S.; SOBRAL, M.D.C.; LEITE, V.L.C. **Classificação de danos térmicos em chapas de aço inoxidável ferrítico AISI 430 utilizando transformada discreta do Cosseno e redes neurais artificiais para as ondas ultrassônicas de Lamb**. In: XXX CONGRESSO NACIONAL DE ENSAIOS NÃO DESTRUTIVOS E INSPEÇÃO E 16º *CONFERENCIA INTERNACIONAL SOBRE EVALUACIÓN DE INTEGRIDAD Y EXTENSIÓN DE VIDA DE EQUIPOS INDUSTRIALES*, CONAEND & IEV, São Paulo, julho 2012.

SIQUEIRA, M.H.S. **Inspeção em grandes distâncias utilizando ondas ultra-sônicas e inteligência artificial**. Tese de doutorado em Engenharia Metalúrgica e de Materiais, COPPE/UFRJ, Rio de Janeiro, 2002;

SOUZA, Y.N.; SIMAS FILHO E.F.; FARIAS C.T.T.; LEITE V.L.C.; SOUZA I.S.; LOPES J.L.S.; ARAUJO P.R.A. **Avaliação Não Destrutiva da Integridade Estrutural de Compósitos de Alumínio e Epoxi Utilizando Processamento Estatístico e Redes Neurais Artificiais como Ferramenta de Auxílio**. In: CONFERÊNCIA SOBRE TECNOLOGIA DE EQUIPAMENTOS. 11º COTEQ, Ipojuca/PE, 2011.

THE MATH WORKS, **Signal Processing Toolbox for Use with MATLAB®**. Versão 5, EUA, 1-45 a 1-48, 2008.

ZHANG, Z.; FRIEDRICH, K., **Artificial neural networks to polymer composites: a review**, Composites Science and Technology, 2003.