

USO DE REDE NEURAL ARTIFICIAL APLICADA À CLASSIFICAÇÃO AUTOMÁTICA DE DESCONTINUIDADES EM CHAPAS DE COMPÓSITO LAMINADO DE ALUMÍNIO E EPÓXI REFORÇADO POR FIBRA DE VIDRO

Diego Bastos Pinheiro Lopes, diegobastos@ifba.edu.br¹

Eduardo Furtado Simas Filho, esimas@ifba.edu.br¹

Cláudia Teresa Teles Farias, cfarias@ifba.edu.br¹

João Carlos Barbosa, jkbarbosa@yahoo.com.br¹

Moisés Araujo Oliveira, moises@ifba.edu.br¹

Igor Souza Ribeiro, igorsr@ifba.edu.br¹

Juliana Lima da Silva Lopes, j.lopes@ifba.edu.br¹

Ygor Tadeu Bispo dos Santos, ygortadeu@ifba.edu.br¹

¹Instituto Federal da Bahia - IFBA, Rua Emídio dos Santos, s/n.

Resumo: *Compósitos metálicos laminados com matriz polimérica reforçada por fibras (LFM) têm sido largamente empregados na indústria aeronáutica, encontrando ainda aplicações na engenharia civil e mecânica. Estes materiais apresentam grandes vantagens como elevada rigidez associada a uma baixa massa específica, longo tempo de vida e diversidade de aplicações devido à flexibilidade quanto ao formato do laminado. Entretanto, este material sofre com mecanismos de degradação de difícil detecção nos estágios iniciais. Este trabalho visa contribuir no desenvolvimento de novas metodologias de avaliação estrutural de equipamentos que utilizem LFM. Para tal, foi realizada varredura ultrassônica na configuração pulso eco por imersão em corpos de prova de compósito laminado de alumínio e epóxi reforçado por fibra de vidro com três configurações distintas: sem defeito, com delaminação e com fratura de fibra. Devido à dificuldade de análise e interpretação de sinais provenientes de inspeção pulso eco em materiais compósitos, técnicas de Inteligência Artificial (IA) foram utilizadas como ferramenta auxiliar na classificação. Após passarem por uma etapa de pré-processamento, envolvendo a transformada de Fourier, os sinais adquiridos alimentaram uma rede neural tipo Perceptron de Múltiplas Camadas, com fins de classificá-los quanto à presença e tipo de descontinuidade.*

Palavras-chave: *compósito laminado fibra metal, ensaio não destrutivo, inteligência artificial.*

1. INTRODUÇÃO

Avançados materiais poliméricos reforçados com fibra são utilizados extensivamente, sobretudo na indústria aeroespacial e aplicações de engenharia civil e mecânica. Os compósitos laminados de fibra metal (LFM) apresentam vantagem sobre as ligas metálicas por serem mais resistentes a impactos, além de serem menos densos e mais resistentes a corrosão. Entretanto, sob determinadas condições esses materiais apresentam falhas estruturais como delaminação e fratura, que são de difícil detecção quando em seus estágios iniciais.

O ensaio por ultrassom é empregado nestes casos por se tratar de uma inspeção não invasiva e não destrutiva, de fácil aplicação, e pelo elevado número de informações possíveis de obtenção através dos resultados. Porém, devido à estrutura em multicamadas finas do material, os sinais ultrassônicos obtidos na inspeção são de difícil interpretação.

O escopo deste trabalho é a aplicação de redes neurais artificiais para a identificação e classificação de falhas em compósitos laminados de alumínio e epóxi reforçados por fibra de vidro com uso de ensaio não destrutivo ultrassônico obtidos pelo método pulso-eco por imersão, submetidos a uma etapa de pré-processamento, onde foi aplicada a Transformada de Fourier.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. Compósitos Laminados Fibra Metal

Os compósitos são formados a partir da união de dois ou mais materiais que combinados resultam em um material propriedades mecânicas superiores. Os componentes do compósito podem ser rotulados como aglomerante ou matriz e

reforço ou fibra. A constituição de um material compósito constam da utilização de fibras imersas na matriz em várias camadas dispostas empilhadas e coladas, podendo haver fibras em orientações distintas. Assim, as propriedades mecânicas específicas dos materiais compósitos dependem das propriedades da fibra e da matriz (Romariz, 2008).

As principais funções da matriz envolvem a manutenção das fibras juntas e coesas, protegendo-as dos danos superficiais de abrasão mecânica ou reações químicas do meio, e receber a carga aplicada externamente, transmitindo-as para as fibras por meio da interface. As fibras de reforço são os elementos que suportarão a carga exercida sobre o compósito. Tal transferência de carga é efetuada pela interface no material compósito (Montes, 1998).

Os LFM consistem de camadas alternadas de finas ligas de alumínio e de pré-impregnados com resina epóxi (prepreg). De tal modo, estes materiais apresentam alta resistência à propagação de danos por fadiga, maior resistência à corrosão como também uma densidade menor (Farias, 2006).

O desenvolvimento tecnológico de materiais compósitos reforçados de fibra de vidro encontra-se relacionado à utilização e confiabilidade de estruturas na indústria aeronáutica e aeroespacial, onde a segurança é um fator crítico. A aeronave comercial A380 da Airbus© possui 25% do peso estrutural com a aplicação do laminado de fibra metal utilizado nas asas, seções da fuselagem, empenagens e portas, contribuindo para baixos custos de manutenção e redução do consumo de combustível (Farias, 2006; Romariz, 2008).

A presença das fibras de vidro adicionadas às resinas plásticas como reforço em materiais compósitos apresentam grande importância prática, pois constituem materiais leves, com um comportamento homogêneo quando sujeitos às deformações originadas por carregamentos externos. Os tipos de fibra de vidro comumente usados como reforço, o tipo “E” e o tipo “S”, conjugam resistência ao impacto, módulo de elasticidade e limite de resistência à tração promovendo as diversas aplicações nas áreas automobilística, aeronáutica e militar. Entretanto, é sabido que a fração volumétrica de fibras e a sua orientação contribuem diretamente nas propriedades dos materiais compósitos (Montes, 1998).

A Tab. (1) expõe algumas características das fibras de reforço largamente usados em materiais compósitos laminados. As fibras de aramida são comercializadas com o nome de Kevlar®.

Tabela 1. Propriedades mecânicas típicas das fibras de aramida, carbono e vidro (Zweben, 1989).

Propriedade	E (GPa)	σ_r (GPa)	Elongação na fratura (%)	Densidade (g/cm ³)
Fibra de Vidro Tipo E	72	3,0	4,0	2,6
Fibra de Vidro Tipo S	87	3,50	4,0	2,5
Kevlar 29	60	2,65	4,0	1,44
Kevlar 49	128	2,65	2,4	1,45
Kevlar 149	180	3,45	1,9	1,47
Fibra de Carbono Alta Resistência	250	2,80	1,2	1,8
Fibra de Carbono Alto Módulo	370	1,70	0,5	1,9
Fibra de Carbono Alto Desempenho	230	4,50	2,0	1,8

Outro dado importante é o comportamento dos materiais compósitos sob carga de impacto. Uma propriedade referente à resistência a cargas de impacto de um laminado é a energia relativa à iniciação de danos. Os laminados de resina epóxi reforçado por fibra de vidro tipo S são até sete vezes mais resistentes do que os laminados de fibra de carbono de alta resistência e 35 vezes mais resistente que os laminados reforçados com fibras de carbono de alta rigidez em ensaios Charpy (Romariz, 2008).

2.1.1. Mecanismos de Falha

Uma característica fundamental das estruturas de material compósito é que normalmente a falha não é um único evento, mas uma sequência gradual de micro trincas, delaminações e falha de fibras levando ao colapso da estrutura. O trincamento da matriz é um dos modos de dano inicial por conta da resistência das fibras ser geralmente superior à da matriz. O crescimento da trinca pode ocasionar a quebra de fibras, resultando em descolamento e separação das fibras e matriz ou a trinca se propaga deixando a fibra intacta, fenômeno chamado de “crack bridging” (Montes, 1998).

A delaminação, que ocorre entre duas camadas adjacentes do compósito, é um dos principais mecanismos de fratura. Ele consiste no trincamento procedente de flambagem localizada e altas tensões interlaminares normais e cisalhantes nos extremos da região afetada, exibido pela Fig. (1). O processo conduz à fratura completa ou até delaminações parciais responsáveis pela perda de integridade estrutural (Romariz, 2008).




Figura 1. Delaminações causadas por tensões interlaminares e normais.

A presença da delaminação afeta principalmente o comportamento de compressão em relação à tração. Os carregamentos de tração podem induzir a ruptura de fibras a depender do grau de adesão entre a fibra e a matriz, enquanto que os carregamentos de compressão ocorrem por meio de microflambagem ou mesmo o cisalhamento das mesmas, de acordo com a Fig. (2).




Figura 2. Mecanismos de falha a compressão: (a) microflambagem (b) cisalhamento (Romariz, 2008).

2.2. Ensaios Ultrassônicos em Materiais Compósitos

A aplicabilidade de compósitos em sistemas em que a segurança é fator crítico, tais como aeronaves, requer uma capacidade adequada de avaliação não destrutiva. Dentre as técnicas de investigação a materiais compósitos, os ensaios ultrassônicos (US) são aplicados em virtude da relativa facilidade em empregá-lo e a quantidade de informações que podem ser obtidas através destes (Lee, 2009).

Por conta da estrutura em multicamadas finas dos laminados de fibra metal que dificulta a análise dos sinais, os métodos ultrassônicos aplicáveis a materiais metálicos não são extensivamente apropriados (Farias, 2006). A necessidade de empregar metodologia de inspeção para detectar, localizar e dimensionar o máximo de danos comuns aos materiais compósitos, viabilizando o custo total da manutenção é a motivação de muitos trabalhos de pesquisa.

A seleção de transdutor de baixa frequência limita o tamanho e a profundidade dos danos observados enquanto que cabeçotes com frequência elevada permitem identificar descontinuidades menores embora sinais refletidos das interfaces entre as camadas e dos contornos livres interfiram na avaliação do sinal no domínio do tempo. Assim, a possibilidade de efetuar a avaliação no domínio da frequência através de técnicas de processamento digital de sinais e o uso de redes neurais artificiais para classificação dos danos em materiais compósitos contribui na aplicação de ensaios ultrassônicos.

2.3. Processamento Digital de Sinais Ultrassônicos

Os métodos de ensaios não destrutivos por ultrassom têm-se desenvolvido nos últimos anos pelo fato de que o sinal refletido de um defeito contém uma soma de informações não observadas pelas técnicas tradicionais. A heterogeneidade da estrutura combinada com a relação sinal/ruído, atenuação acústica e dispersão do feixe ultrassônico cria uma dificuldade na detecção de falhas. A aquisição de informações que podem caracterizar melhor os tipos de defeito, aumentando a visibilidade do eco, das descontinuidades e na orientação ao desenvolvimento de novas técnicas está relacionado com o processamento digital de sinais (PDS) (Drai, 2006).

A análise do sinal no domínio da frequência com o uso da Transformada Discreta de Fourier é uma ferramenta largamente usada no processamento de sinais ultrassônicos para identificar e distinguir os diferentes componentes de frequência dos sinais coletados (Farias, 2006).

A equação (1) apresenta matematicamente a descrição do algoritmo da Transformada Discreta de Fourier implementado para a extração dos componentes de frequência dos sinais utilizados na avaliação, onde N é o comprimento do vetor de entrada.

$$X(k+1) = \sum_{n=0}^{N-1} x(n+1) e^{-j\left(\frac{2\pi}{N}\right).k.n} \quad (1)$$

2.4. Redes Neurais Artificiais

As Redes Neurais Artificiais consistem de técnicas de Inteligência Artificial (IA), capazes de modelar matematicamente problemas complexos com características não-lineares. Para tal, as redes buscam solucionar problemas através de métodos computacionais que simulem o comportamento do cérebro humano, apresentando uma organização estrutural semelhante à de organismos inteligentes. Isto garante uma característica fundamental das redes: a capacidade de “aprender” por meio da experiência.

As RNA's são compostas de unidades básicas de processamento chamadas neurônios artificiais distribuídos paralelamente, garantindo dessa forma a principal vantagem na utilização de redes neurais: a sua habilidade de adaptação e aprendizagem, isto é, modelos de redes neurais podem lidar com dados imprecisos e situações não totalmente definidas. Uma rede satisfatoriamente treinada pode adquirir capacidade de generalizar, quando é apresentada às entradas, dados diferentes aos utilizados durante o seu treinamento (Haykin, 1999).

A Fig. (3) ilustra o modelo não linear de um neurônio artificial proposto por McCulloch (1943), identificando seus principais componentes. As entradas, representadas por x_i ponderadas por um peso sináptico w_{ki} são somadas em um combinador linear. Uma função de ativação restringe a saída da rede reduzindo-a a valores finitos. Matematicamente, pode ser descrito pela equação (2).

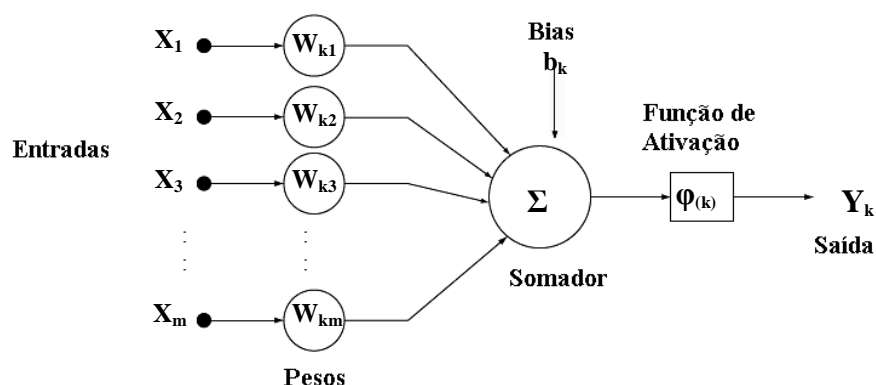


Figura 3. Modelo Não-Linear de Neurônio Artificial.

$$y = h \left(\sum_{i=1}^n w_i x_i + b_i \right) \quad (2)$$

Dois principais paradigmas de aprendizagem dividem as redes neurais: o aprendizado supervisionado e o não supervisionado. No primeiro, durante o treinamento é apresentada à rede um par entrada-alvo que representa a ação ótima da rede na tarefa de classificação. No segundo, o vetor alvo não é apresentado e a própria rede extrai características, realizando um mapeamento das entradas e conseqüentemente classificando-as.

2.4.1. Redes Backpropagation – Algoritmo Levenberg Marquardt

Dentre as variadas arquiteturas e configurações de rede, o quanto a rede pode aprender, é o parâmetro que define o potencial da rede (Haykin, 2001). As primeiras redes de camada única, denominadas perceptrons, mostraram-se limitadas quanto à capacidade de representação de conhecimento. O aprendizado consiste na capacidade de representar informação extraída de dados reais do ambiente (experiência) e, a partir dessa informação, fornecer modelos capazes de interpretar novas situações que sejam apresentadas. O algoritmo backpropagation é um método de treinamento de redes com múltiplas camadas (MLP, multi layer perceptron), responsável pela considerável expansão do campo de aplicações de RNA's.

O treinamento das RNAs por backpropagation envolve a retroalimentação do padrão do vetor entrada de treinamento, o cálculo e a retropropagação do erro associado e o ajuste dos pesos sinápticos, admitindo o uso com uma quantidade diferente de estratégias de otimização (Zhang, 2003).

Uma rede neural artificial backpropagation foi utilizada por Thavasimuthu (1996) para classificar sinais ultrassônicos no aço inoxidável AISI 304, obtidos pela técnica pulso eco, de baixa amplitude, melhorando a sensibilidade de detecção. Zhang (2003) desenvolveu técnicas de predição do comportamento de materiais compósitos poliméricos através de redes neural artificial. Bezerra (2007) implementou uma rede neural artificial treinada com algoritmo Levenberg-Marquardt capaz de prever o comportamento tensão-deformação de laminados metálicos reforçados por fibra de carbono e vidro. Veiga (2003) utilizou redes neurais artificiais com a finalidade de automatizar a análise do ensaio ultrassônico pulso eco realizado em chapas de aço carbono avaliando as condições de juntas soldadas.

3. MATERIAIS E MÉTODOS

3.1. Confeção dos Corpos de Prova

O ensaio utilizou 03 corpos de prova de compósitos laminados de alumínio e epóxi reforçado por fibra de vidro. Apresentando dimensões de (100 x 100 x 1,34) mm, e duas lâminas de pré-impregnados de fibra de vidro, a classificação dos CPs é feita conforme os diferentes tipos de defeito, apresentada na Tab. (2):

Tabela 2. Configuração dos corpos de prova.

Placa de LFM 2/1	Tipo de defeito	Configuração prepreg
CPI_D	Delaminação	0°/0°
CPI_F	Fratura de fibra	0°/0°
CPI_SD	Sem defeito	0°/0°

Para confeccionar os corpos de prova foram necessários:

- Lâminas de prepreg de fibra de vidro S₂ unidirecional (UD) em epóxi Hexply® com dimensões de (100 x 100 x 0,17) mm, fornecidas pela Hexcel Composites ©.
- Chapas de alumínio com dimensões de (100 x 100 x 0,5) mm,
- As propriedades do prepreg são visualizadas na Tab.(3) enquanto a composição química vê-se na Tab.(4);

Tabela 3. Propriedades do prepreg UD com fibra de vidro S₂/epóxi (De Vries, 2001).

Propriedades	PREPREG UD S ₂ (Vf = 60%)
Módulo de Young, E1 (GPa)	54
Módulo de Young, E3 (GPa)	9,4
Coefficiente de Poisson, ν_{12}	0,0575
Coefficiente de Poisson, ν_{23}	0,33
Módulo de Cisalhamento, G13 (GPa)	5,55
Densidade, ρ (g/cm ³)	1,98

Tabela 4. Composição química da chapa de alumínio comercial (Alcoa S/A).

Elemento	Al	Cu	Fe/Si	Mg	Mn	Zn	Outros
% peso	99,0	0,05	< 1,00	< 1,00	0,05	0,10	0,00 – 0,15

A fratura de fibras foi simulada pelo corte e a remoção do prepreg antes do empilhamento enquanto a delaminação foi inserida com a adição de fita de *teflon*, sendo retirada após a cura realizada em autoclave. A Fig. (4) exhibe as dimensões e o posicionamento dos defeitos implantados nos corpos de prova.




Figura 4. Localização e dimensões dos defeitos nos corpos de prova: (a) fratura de fibra; (b) delaminação.

3.2. Configuração dos Ensaio Ultrassônicos

Os ensaios não destrutivos por ultrassom foram executados com o método pulso-eco de incidência normal por imersão, com o emprego do aparelho de ultrassom Krautkrämer®, modelo USM 25, responsável por gerar e receber os pulsos ultrassônicos a um transdutor Olympus Panametrics, modelo NDT V-326, diâmetro de 9,525 mm e frequência

nominal de 5MHz. Ao conjunto foi adicionado um osciloscópio Tektronix, modelo TDS 2024B para a aquisição dos sinais digitalizados a uma taxa de amostragem de 500 MHz, permitindo uma melhor análise dos sinais ultrassônicos.

Dois suportes cilíndricos em *nylon* com dois ímãs permanentes terra-rara em cada um foram confeccionados para assegurar a concentricidade entre eles quando dispostos em lados opostos no corpo de prova, e também auxiliar a fixação e a estabilidade do transdutor em relação à distância ao corpo de prova.

A organização dos pontos para a coleta dos sinais ultrassônicos era distinta para o tipo, localização e tamanho da região do compósito em questão:

- Região com delaminação: malha retangular (8 x 10), espaçamento de 0,2 mm entre pontos, coletando 4 amostras por ponto, num total de 320;
- Região com fratura: malha retangular (5 x 10), espaçamento de 0,2 mm entre pontos, coletando 6 amostras por ponto, num total de 300;
- Região sem defeito: malha quadrada (10 x 10), espaçamento de 0,2 mm entre pontos, coletando 3 amostras por ponto, num total de 300.

3.3. Análise Espectral de Sinais Ultrassônicos

Os sinais ultrassônicos coletados de cada corpo de prova foram processados utilizando uma rotina no software MATLAB® para obtenção dos espectros de frequência via Transformada Rápida de Fourier, a fim de facilitar a análise e visualização das descontinuidades como também a influência da orientação das fibras de vidro nos sinais aquisitados

Cada amostra proveniente do osciloscópio apresenta 2500 pontos contendo uma taxa de amostragem de 500 MHz. Para cada condição de dano, os sinais passaram por uma etapa de normalização e posterior transformação de domínio tempo - frequência, armazenando separadamente todos os coeficientes referentes às características de delaminação, fratura de fibra e sem defeito dos LFM.

Por se tratar de uma etapa de pré-processamento do sistema de classificação automática usando uma rede neural artificial, em cada conjunto foi selecionada uma faixa de frequência abrangente à de operação do transdutor ultrassônico banda larga utilizado na avaliação não destrutiva, entre 0 e 10 MHz, com o intuito de qualificar os componentes relativos às diversas condições para então efetuar o processo de aprendizagem e teste do classificador neural.

3.4. Classificação por Redes Neurais

Para determinação da arquitetura mais eficiente foram criadas redes através do software MATLAB®. Primeiramente desenvolveu-se uma rede MLP composta por: 100 neurônios na camada de entrada, referente ao número de pontos selecionados do espectro de frequência; camada oculta variando de 5 a 10 neurônios artificiais, todos com função tangente sigmoïdal (tansig); a camada de saída com três neurônios de saída.

Visando facilitar o cálculo de desempenho de discriminação da rede, a camada de saída era composta por 3 neurônios, sendo que cada um era ativado para determinada classe, permanecendo os outros inativos.

Com o objetivo de explorar ao máximo o conjunto de sinais foram geradas aleatoriamente 10 matrizes de treinamento e teste para serem alimentadas à rede. Cada matriz de teste foi construída com 60 amostras de sinais: 20 sinais com delaminação, 20 com fratura e 20 sem defeito, respectivamente. Os sinais, uma vez utilizados na matriz de teste, eram retirados do conjunto de sinais, garantindo que não seriam usados na criação da matriz de treinamento. Esta, por sua vez era composta por 300 sinais, sendo 100 para cada condição.

A Fig. (5) ilustra um diagrama que exemplifica o procedimento utilizado para a categorização das descontinuidades em compósitos.




Figura 5. Diagrama de blocos da cadeia de classificação.

4. RESULTADOS E DISCUSSÕES

4.1. Inspeção Ultrassônica e Processamento de Sinais

A Fig. (6) apresenta os sinais aquisitados pelo ensaio ultrassônico e normalizados no domínio do tempo para as situações analisadas nos corpos de prova. CP1 D, CP1 F e CP1 SD, exibindo o primeiro eco refletido proveniente do compósito de fibra de vidro. Evidencia-se aqui a dificuldade preliminar em distinguir com precisão a existência e qual o tipo de dano ao qual o LFM foi submetido.




Figura 6. Sinais ultrassônicos no domínio do tempo: (a) sem defeito (b) delaminação e (c) fratura de fibra.

A Fig. (7) apresenta o espectro de frequência obtido através da Transformada Rápida de Fourier para os respectivos sinais no domínio do tempo. Durante a avaliação dos coeficientes entre uma faixa de 0 a 10 MHz observou-se uma significativa variação dos componentes para cada classificação de dano. Em seguida, estes sinais foram apresentados à rede neural artificial para a classificação automática.

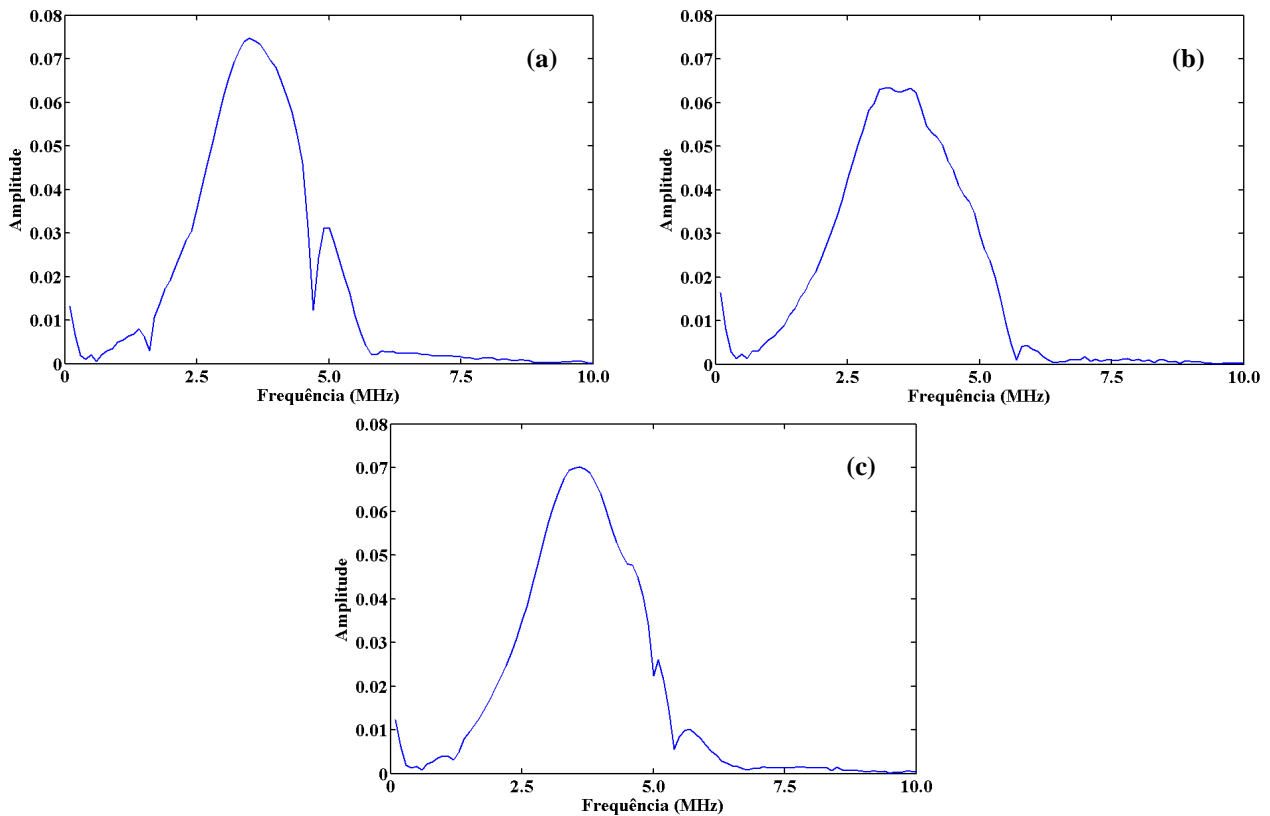


Figura 7. Espectro de frequência dos sinais US: (a) sem defeito, (b) com delaminação e (c) com fratura de fibra

4.2. Avaliação da RNA

A partir da análise dos testes realizados, pode-se determinar a rede neural artificial mais eficiente na tarefa de classificação dos sinais. Um classificador neural composto por 5 neurônios na camada oculta apresentou o melhor resultado quando apresentado aos conjuntos de teste disponíveis. A Tab. (5) ilustra os resultados obtidos por esta rede:

Tabela 5. Matriz de confusão do classificador neural

	DELAMINAÇÃO	FRATURA	SEM DEFEITO
DELAMINAÇÃO	91,5%	4,5%	4,0%
FRATURA	10,0%	90,0%	0,0%
SEM DEFEITO	25,5%	4,5%	70,0%

5. CONCLUSÕES

Os resultados apresentados pela rede neural artificial são satisfatórios, visto que o classificador foi capaz de detectar e qualificar os danos através de sinais ultrassônicos. A classe que apresentou o menor rendimento foi a classe sem defeito. Entretanto considerando-se um critério de segurança, o custo em classificar um LFM sem defeito como se apresentasse falha é muito menor que aceitar um material com falha como se estivesse em perfeitas condições. Como trabalhos futuros, outras técnicas de processamento digital de sinais poderão ser empregadas, dentre as quais, a Transformada Wavelet, com o intuito de melhorar o desempenho do sistema de classificação.

6. AGRADECIMENTOS

À FAPESB, pelo apoio financeiro; ao IFBA, pela infraestrutura; ao GPEND, pelo apoio técnico.

7. REFERÊNCIAS

- Bezerra, E.M., Ancelotti, A.C., Pardini, L.C., Rocco, J.A.F.F., Iha, K., Ribeiro, C.H.C., 2007, "Artificial neural networks applied to epoxy composites reinforced with carbon and E-glass fibers: Analysis of the shear mechanical composites", Materials Science and Engineering.
- Bouquet, P., 2003, "Critical analysis of the long-term behaviour of polymer matrix composites under a complex mechanical loading history", Tese de Ph. D., Vrije Universiteit Brussel, Belgium;
- De Vries, T.J., 2001, "Blunt and Sharp Notch Behaviour of Glare Laminates", Tese de Ph.D., Delft University of Technology, Netherlands;
- Drai, R. and Benamar, A. 2006, "Ultrasonic Signal Processing in the Detection of Defect in Composite", European Conference of Non Destructive Testing, NDT, Berlin, Alemanha;
- Haykin, S., 2001, "Redes Neurais: princípios e prática", Ed.Bookman, Porto Alegre, Brasil, p 36;
- Farias, C.T.T., 2006, "Utilização das Ondas Ultra-sônicas de Lamb na Inspeção de Materiais Compósitos Laminados Fibra-Metal", Dissertação de Doutorado em Engenharia Metalúrgica e de Materiais, COPPE/UFRJ, Rio de Janeiro-RJ, Brasil;
- Lee, W.J., Chang, W.V., Yang, W. and Kim, B. 2009, "Defects Detection Using a Smart Ultrasound Pulse-Echo Technique", Polymer Composites;
- Manual Alcoa S/A;
- Mitrevski, T., Marshall, I.H., and Thomson, R., 2006, "The influence of impactor shape on the damage to composite laminates", Composite Structures, Volume 76, Number 1-2, pp116-122;
- McCulloch, W.S. and Pitts, W., 1943, "A logical calculus of the ideas immanent in nervous activity", Bulletin of Mathematical Biophysics, Volume 5, pp. 115-133;
- Montes, R.M., 1998, "Desenvolvimento de Compósitos Laminados da Liga de Alumínio ALCLAD 2024-T3 com Epóxi Reforçado por Fibras de Vidro e Aramida", Dissertação de Mestrado em Engenharia Metalúrgica e de Materiais, COPPE/UFRJ, Rio de Janeiro-RJ, Brasil;
- Romariz, L.A., 2008, "Dano em Placas Laminadas devido ao Impacto a Baixas Velocidades", Dissertação de Mestrado em Engenharia Mecânica, USP, São Paulo-SP, Brasil;
- Thavasimuthu, M., Rajagopalan, C., Kalyanasundaram, P. and Raj, B., 1997, "Improving the evaluation sensitivity of an ultrasonic pulse echo technique using a neural network classifier", NDT&E International, Volume 30, Number 5, p 323;
- Veiga, J.L.B.C., Carvalho, A.A., Silva, I.C., Rebello, J.M.A., 2003, "Automação da análise do ensaio ultra-sônico pulso-eco utilizando redes neurais artificiais" III Pan - American Conference for Nondestructive Testing, Rio de Janeiro-RJ, Brazil;
- Zhang, Z. and Friedrich, K., 2003, "Artificial neural networks to polymer composites: a review", Composites Science and Technology;

Zweiben, C., Hahn,H.T., Chou, T.W., 1989, “Mechanical Behavior and Properties of Composite Materials”, Lancaster
2nd Edition, Technomic Publishing Company.



VI CONGRESSO NACIONAL DE ENGENHARIA MECÂNICA
VI NATIONAL CONGRESS OF MECHANICAL ENGINEERING
18 a 21 de agosto de 2010 – Campina Grande – Paraíba - Brasil
August 18 – 21, 2010 – Campina Grande – Paraíba – Brazil

USE OF ARTIFICIAL NEURAL NETWORK APPLIED TO AUTOMATIC CLASSIFICATION OF DISCONTINUITY IN LAMINATED COMPOSITE PLATES ALUMINIUM EPOXY REFORCED BY FIBERGLASS

Diego Bastos Pinheiro Lopes, diegobastos@ifba.edu.br¹

Eduardo Furtado Simas Filho, esimas@ifba.edu.br¹

Cláudia Teresa Teles Farias, cfarias@ifba.edu.br¹

João Carlos Barbosa, jkbarbosa@yahoo.com.br¹

Moisés Araujo Oliveira, moises@ifba.edu.br¹

Igor Souza Ribeiro, igorsr@ifba.edu.br¹

Juliana Lima da Silva Lopes, j.lopes@ifba.edu.br¹

Ygor Tadeu Bispo dos Santos, ygortadeu@ifba.edu.br¹

¹Federal Institute of Bahia - IFBA, Emídio dos Santos Street.

Abstract. Composite laminates with metal matrix composites reinforced by fibers (LFM) have been widely used in the aerospace industry and finding applications in civil and mechanical engineering. These materials have great advantages such as high stiffness coupled with a low density, long life and diversity of applications due to flexibility in the format of the laminate. However, this material suffers degradation mechanisms are difficult to detect in its early stages. This paper aims to contribute to the development of new methods of structural evaluation of equipment using LFM. For this, a scanning ultrasonic pulse echo configuration immersion test specimens of composite laminate of aluminum and epoxy reinforced with glass fibers with three different types: flawless, with delamination and fiber fracture. Due to the difficulty of analysis and interpretation of signals from pulse echo inspection of composite materials, techniques of Artificial Intelligence (AI) were used as an auxiliary tool for classification. After passing through a stage of preprocessing, involving the Fourier transform, the signals acquisitive fed a neural network type Multilayer Perceptron, for the purpose of classifying them as to the presence and type of discontinuity.

Keywords: fiber-metal laminate composite, non-destructive testing, artificial intelligence.