

DETECÇÃO EXPERIMENTAL DE DANOS EM UMA PLACA DE ALUMÍNIO USANDO O MÉTODO DISTÂNCIA DE MAHALANOBIS

Resumo

Nas últimas décadas tem crescido o interesse no desenvolvimento e na aplicação de técnicas de Monitoramento das Condições Estruturais (SHM) devido à grande necessidade de segurança e confiabilidade em determinados tipos estruturas, pois a falha destas podem ocasionar grandes catástrofes, como no caso de uma aeronave. Existem diversos métodos para realizar o monitoramento de uma determinada estrutura, sendo que para estruturas delgadas como fuselagem um meio é as Ondas de Lamb. Juntamente com estas técnicas de monitoramento, podem ser usadas técnicas computacionais de classificação de padrões, para detectar e localizar danos. Para comprovar, foi realizado experimento empregando piezelétricos (PZTs) como atuadores e sensores. Os sinais de propagação de ondas de Lamb captados foram pré-processados por métricas e o resultado serve para treinar um algoritmo de Aprendizado de Máquina baseado na distância de Mahalanobis para classificação de padrões.

Palavras-Chave: Aprendizado de Máquina, Ondas de Lamb, Monitoramento das Condições Estruturais

Abstract

In the last decades have been increased the development and implementation of Structural Health Monitoring (SHM) techniques due to the growing demand for safe and reliable structures. SHM techniques are widely used for damage detection in aircraft aimed to prevent significant failures which can lead to signals. There are several methods of perform the monitoring of a given structure, and for thin structure like fuselage a technique is the Lamb Waves. Along with these monitoring technique, can be used computational techniques of standards classifications, to detect and locate damages. To prove was performed he experiments have been done employing PZTs as actuators and sensors. The generated signals of Lamb Waves have been pre-processed by damage-sensitive features and then an outlier analysis has been done using a Machine Learning Algorithm based on the Mahalanobis distance. It is shown that analyzing the outliers of Mahalanobis distances for classification.

Keywords: Machine Learning, Lamb Waves, Structural Health Monitoring

1 INTRODUÇÃO

Grandes centros de pesquisa e desenvolvimento no mundo se empenham para criar e aprimorar técnicas capazes de monitorar a integridade estrutural de veículos, máquinas e estruturas. Esta preocupação é dada principalmente as estruturas cuja ruptura ou destruição possa provocar grandes prejuízos financeiros e grandes catástrofes, como no caso dos aviões. A possibilidade de monitorar a integridade estrutural é denominada *Structural Health Monitoring* – SHM (Mo-

onitoramento das Condições Estruturais). Existem diversas técnicas de SHM e a escolha para o monitoramento de uma determinada estrutura depende do ambiente de experimentação, do tipo de estrutura, da configuração construtiva e do procedimento da técnica de SHM, que pode ou não ser uma Avaliação Não Destrutiva (*Nondestructive Evaluation* – NDE). É importante ressaltar que um dos interesses em técnicas de análise não destrutivas para detecção e localização de danos estruturais em aeronaves é otimizar o tempo de manutenção realizando mais rapidamente as inspeções e indicando com precisão os possíveis danos (FARRAR; LIEVEN; BEMENT, 2005).

Uma das técnicas que podem ser usadas para o monitoramento de estruturas é a técnica das Ondas de Lamb (*Lamb Waves*). Esta técnica trata de ondas guiadas com alta sensibilidade a danos. Estas ondas se propagam nas superfícies superior e inferior de estruturas delgadas como placas. Por causa disto, qualquer mudança física entre as superfícies pode causar uma atenuação ou dispersão na onda propagada, sendo que, se existir estes fenômenos na onda propagada, pode ser um sinal da existência de um dano. Uma das vantagens desta técnica é que um pequeno conjunto de sensores e atuadores podem ser usados para monitorar uma grande área (SU; YE, 2009).

O piezelétrico-PZT é um dispositivo sensorial que pode ser acoplado em estruturas para a propagação das Ondas de Lamb. Tal importância é dada ao PZT por ele ser versátil, agindo tanto como sensor quanto atuador, facilitando a montagem de arranjos para o sensoriamento da estrutura (GIURGIUTIU, 2007).

Neste trabalho, uma placa de alumínio em condição de contorno livre-livre em temperatura controlada é a estrutura utilizada no estudo de detecção e localização de danos utilizando as Ondas de Lamb. Para auxiliar no processamento dos dados é utilizando um das técnicas de *Outlier Analysis* (análise de pontos divergentes ou discrepantes) e o método Distância de Mahalanobis, que será melhor explicadas na próxima seção.

Abordagens semelhantes estão publicadas em: Worden e Manson (2000), que publicaram um artigo que explana a utilização da *outlier analysis* em detecção de danos e para demonstrar propôs quatro abordagens, sendo: uma simulando um sistema massa-mola, duas pseudo-experimental e uma experimental.

2 OUTLIER ANALYSIS

Outlier analysis é uma área de probabilidade e estatística, onde há diversas técnicas para determinar se algum ponto em análise é ou não um *outlier* (dado divergente). Primeiramente, *outlier* é definido por Barnett e Lewis (1984), como “uma observação (ou um subconjunto de observações) que parece ser inconsistente comparado ao restante do conjunto de dados”. Em um contexto de média e mediana, dado divergente em um conjunto de dados é uma observação que é diferente do resto do conjunto de dados.

Outlier analysis podem ser usadas como técnicas de reconhecimento de padrão, sendo um processo estatístico de determinação de classes de um conjunto de dados. Esta é uma abordagem que se aplica as ferramentas de detecção de mudanças, que em SHM pode dividir os dados em duas classes: estrutura danificada (*damaged*) ou não danificada (*undamaged*). As informações fornecidas para a criação de uma técnica de classificação de padrões configura a criação de um treinamento supervisionado que necessita para tal, apenas dados de padrão de conformidade. Em SHM tais dados são provenientes da estrutura sem danos, não necessitando de dados de todas as possíveis ou prováveis condições da estrutura com danos.

Esta análise podem ser classificada entre métodos com uma única variável e métodos com multivariáveis, dependendo da disponibilidade de informações vindas do sistema em análise.

Em um cenário onde o conjunto de dados é univariável, a identificação de anomalias pode ser facilmente realizada através da distância Euclidiana do i -ésimo elemento da amostra pela média do conjunto de dados (GIROLDO; BARROSO, 2008). Essa distância é dada pela equação 1.

$$ED_i = \sqrt{(x_i - \bar{x})^2} \quad (1)$$

onde x_i é o provável *outlier* e \bar{x} é a média. Esta equação possui algumas limitações que foram estudadas por Mahalanobis, que introduziu o cálculo do desvio padrão na distância euclidiana, termo que leva em consideração a distribuição das amostras (Equação 2),

$$UMD_i = \sqrt{\frac{(x_i - \bar{x})^2}{\sigma_x}} \quad (2)$$

onde x_i é provável *outlier* e \bar{x} e σ_x representam a média e do desvio padrão das amostras de dados respectivamente. Os últimos dois valores podem ser calculados com alguns potenciais *outlier*, para o caso de detecção de ruídos entre os dados utilizados como base, como no exemplo de detecção de danos, buscar ruídos (*outliers*) entre dados classificados como *undamaged* (não danificado) e incluí-los ou não dos cálculos de média e desvio padrão.

Expandindo a equação 2 para o caso multivariante obtém-se a equação 3, onde \mathbf{x} é o vetor do potencial *outlier*, $\bar{\mathbf{x}}$ é o vetor de média das amostras e S é a matriz de variância e covariância. Assim como no caso univariante, os ruídos considerados como *outliers* nos dados de base podem ser incluído ou excluído em testes de avaliação.

$$MMD_i = \sqrt{(\{\mathbf{x}\}_i - \{\bar{\mathbf{x}}\})^T S^{-1} (\{\mathbf{x}\}_i - \{\bar{\mathbf{x}}\})} \quad (3)$$

Em ambas as formas, para a classificação de *inliers* e *outliers* (convergente e divergente) é necessário estabelecer um *threshold value* (valor limite) que serve como fronteira de decisão. Uma maneira muito utilizada para a determinação do *threshold value* é o método de Monte Carlo (WORDEN; MANSON, 2007).

3 APARATO EXPERIMENTAL

O corpo de prova utilizado no experimento foi uma placa de alumínio de 450x450x2mm de dimensão. Nesta estrutura foram colados 9 PZTs na superfície e devidamente enumerados como demonstrado na figura 1(a). A placa foi subdividida em 100 partes iguais de 45x45mm, fazendo com que os PZTs tenham distâncias padronizadas, sendo as menores de 180mm e as maiores de 509,1mm.




Figura 1(a) – Imagem focando o corpo de prova juntamente com os sensores/atuadores, o suporte e a dano. **(b)** Ilustração de todo o aparato experimental.

Para sustentação da placa, proporcionando a condição de contorno livre-livre, foram utilizados suportes elásticos de látex tubular com alta elasticidade, demonstrado na figura 1(a) e na ilustração da figura 1(b). O suporte elástico tem suas extremidades externas fixadas apenas nos ganchos na câmara climática, sendo que a placa apenas repousa sobre este suporte.

Para a representação de dano, foi utilizado Massa Adesiva. Na figura 1(a) é demonstrada a utilização e localização da deposição da massa adesiva. Na figura 1(b) é ilustrado os dispositivos utilizados para condicionar e ambientar adequadamente o corpo de prova e os equipamentos utilizados na aquisição dos sinais de propagação.

4 METODOLOGIA

Para organizar as informações geradas no experimento, os PZTs foram enumerados e colados nas posições demonstradas na figura 1(a), configuração que permite mapear regiões da placa, afim de localizar possíveis danos, dividindo a em quadrantes, como ilustrado na figura 2, onde é ilustrado o arranjo de sensores/atuadores. Através de tal disposição é possível monitorar a superfícies usando um dos PZTs como atuador e os oito PZTs restantes como sensores. Se variada esta situação entre os nove PZTs será possível analisar a estrutura em setenta e dois caminhos de propagação. Na figura 3(a) é ilustrado os primeiros caminhos de propagação e na figura 3(b) ilustrado os últimos caminhos de propagação. Os PZTs utilizados como sensores são representados como circunferências brancas, e os PZTs utilizados com atuadores são representados pela circunferência preta nos instantes de teste. É importante ressaltar que as medidas são realizadas uma de cada vez.




Figura 2 – Divisões da placa em áreas de supervisão.

Primeiramente os testes foram feitos na estrutura sem a presença do dano e em temperatura controlada, construindo assim o banco de dados para criar as matrizes de variância e os vetores de média. Esta matriz oriunda do banco de dados foi utilizada como comparação afim de ressaltar variações.

Foram coletados 26 amostras para o treinamento (26 vezes 72). Depois deste procedimento, os dados de treinamento foram armazenados para servir como base de comparação com os dados da estrutura em condições desconhecidas para o sistema de classificação de padrão.




Figura 3(a) – Primeiros caminhos de propagação. (b) Últimos caminho de propagação.

Para simular o efeito do dano, foram realizados dois danos em tempos distintos, primeiro de 1 cm com 1 g de massa plástica adesiva denominado como DANO 1, e o segundo dano, denominado DANO 2, também com deposição de massa plástica adesiva porém sendo 4 g em uma área de 4 cm, ambas deposições aconteceram no mesmo local, na intersecção entre os caminhos 1-5 e 2-4. Os testes foram realizados com a temperatura controlada de 25°C pela câmara climática.

Para a detecção e localização dos danos, 72 *outliers analysis* foram criadas, sendo uma para cada caminho de propagação de onda.

Para ilustrar o efeito do DANO 1 na propagação de onda, estão demonstradas nas figuras 4, 5 e 6 os sinais de propagação entre os PZTs: 1 e 5; 2 e 4; 1 e 9, respectivamente. Observe que os sinais são redundantes, pois em um momento o um PZT é atuador e o outro sensor, depois esta condição se inverte.

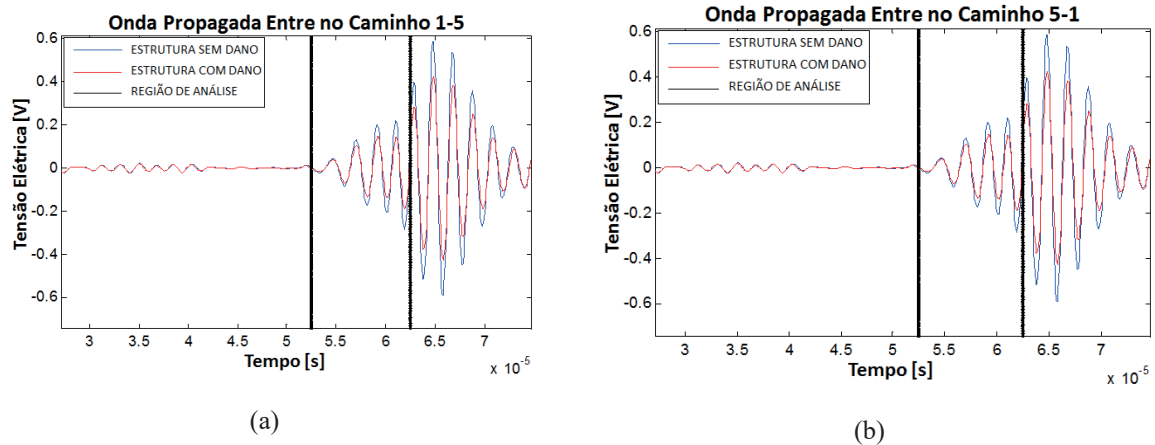


Figura 4(a) - Sinais da estrutura nas condições não danificada e danifica entre o atuador 1 e o sensor 5. **(b)** Sinais da estrutura nas condições não danificada e danifica entre o atuador 5 e o sensor 1.

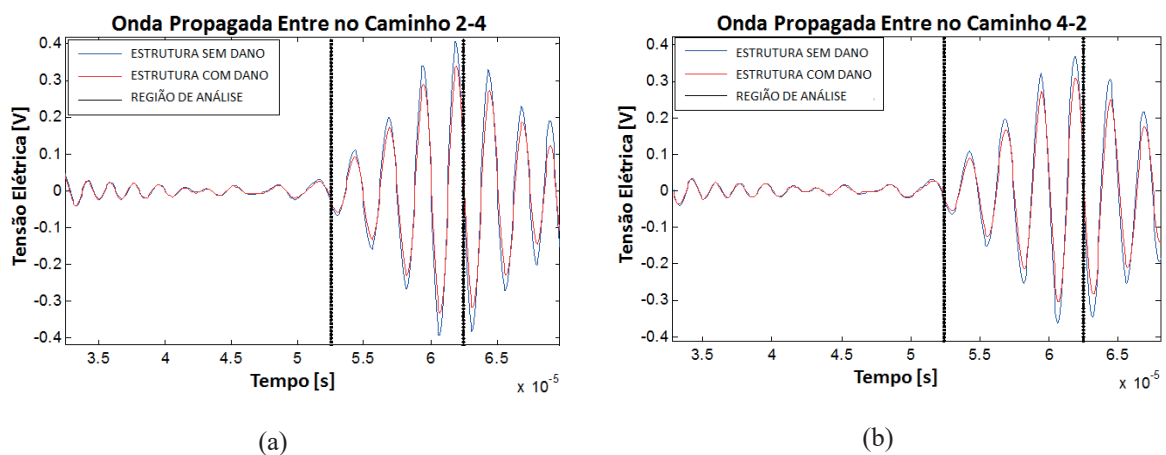


Figura 5(a) – Sinais da estrutura nas condições não danificada e danifica entre o atuador 2 e o sensor 4. **(b)** Sinais da estrutura nas condições não danificada e danifica entre o atuador 4 e o sensor 2.

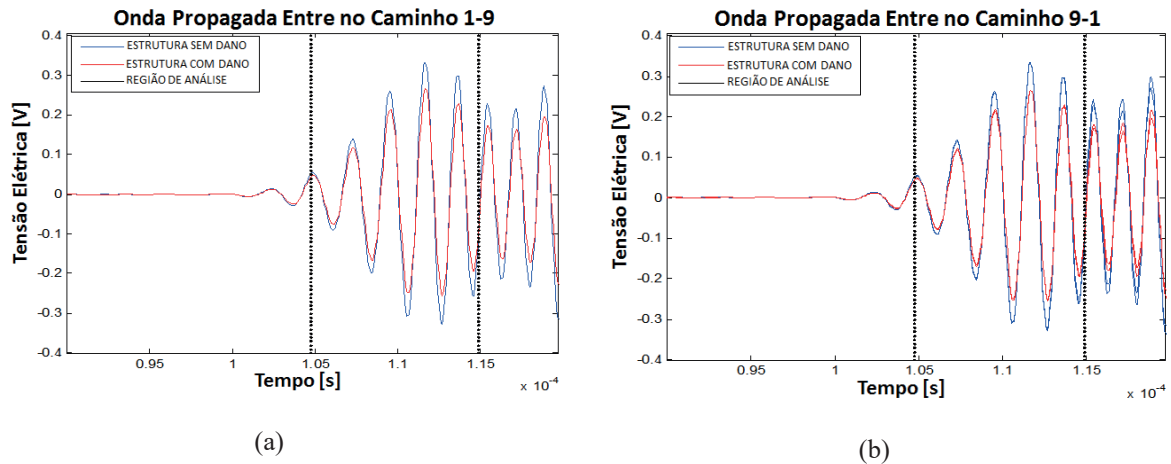


Figura 6(a) - Sinais da estrutura nas condições não danificada e danificada entre o atuador 1e o sensor 9. **(b)** Sinais de undamaged and damaged condition entre o atuador 9 e o sensor 1.

Dos sinais gerados, apenas um pequeno pedaço é avaliado. São demonstrados nas figuras 4(a) e (b), 5(a) e (b) e 6(a) e (b), duas linhas verticais cada cruzando os sinais, onde a linha à esquerda representa o ponto inicial da avaliação e a linha à direita representa o ponto final da avaliação para aquele determinado caminho. Estes pontos são programados levando em conta a distância entre o atuador e o sensor e a velocidade de fase da propagação do modo simétrico da onda, que para o alumínio é de aproximadamente 5400 m/s, para uma frequência de excitação de 500 kHz. Todos os sinais gerados foram pré-processados pelas métricas H_2 e H_∞ . As duas são representadas nas equações 4 e 6. Estas métricas são frequentemente usadas para este tipo de análise porque o efeito da variação de temperatura no dano afeta a amplitude e o tempo de propagação da onda.

A norma H_2 pode ser obtida por:

$$H_2 = \frac{\left(\|Z\|_2^{ref}\right)^2 - \left(\|Z\|_2^{unk}\right)^2}{\left(\|Z\|_2^{ref}\right)^2} \quad (4)$$

onde:

$$\|Z\|_2 = \left(\sum_{i=1}^n |Z_i|^2\right)^{\frac{1}{2}} \quad (5)$$

onde Z é o sinal onde será calculada a norma, $\|Z\|_2^{ref}$ é a norma do sinal referência (*baseline*) e $\|Z\|_2^{unk}$ é a norma do sinal de resposta da estrutura em condições desconhecidas.

$$H_{\infty} = \frac{\left(\|Z\|_2^{ref}\right)^2 - \left(\|Z\|_2^{unk}\right)^2}{\left(\|Z\|_2^{ref}\right)^2} \quad (6)$$

onde:

$$\|Z\|_{\infty} = \lim_{n \rightarrow \infty} \left(\sum_{i=1}^n |Z_i|^p \right)^{\frac{1}{p}} = \max_{i=1 \rightarrow n} (|Z_i|) \quad (7)$$

onde, Z é o vetor sinal para qual esta sendo calculado, $\|Z\|_{\infty}^{ref}$ é a norma do sinal referência (*baseline*) $\|Z\|_{\infty}^{unk}$ é a norma do sinal de resposta da estrutura em condições desconhecidas..

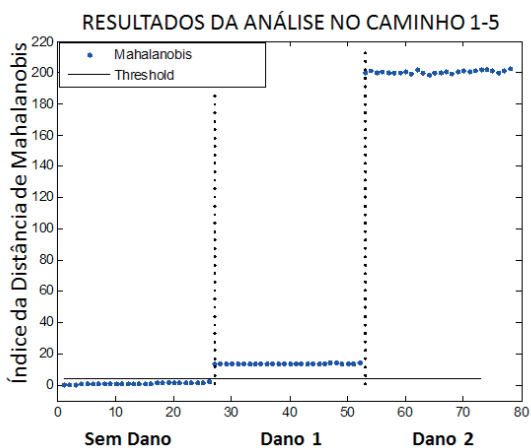
Como citado anteriormente, os experimentos foram realizados em temperatura controlada. É importante ressaltar que este controle é necessário, pois a variação de temperatura interfere na propagação de onda na estrutura, gerando falso positivo na detecção de danos. A temperatura causa modificações na amplitude e na velocidade de fase na onda propaganda, atenuando e atrasando a onda à medida que as temperaturas aumentam. A presença de danos pode causar também dispersão e atenuação, no entanto, considera-se que a temperatura afeta todos os caminhos de propagação. O dano afeta apenas os caminhos onde o dano está localizado.

Para tratar do efeito de temperatura, é necessário a utilização de um sistema de aprendizado de máquina preparado para tal tarefa. Em França (2014) é demonstrado um sistema composto de Redes Neurais para separar os efeitos da temperatura e do dano, afim de detectar e localizar danos em uma placa de fibra de carbono.


5 RESULTADOS OBTIDOS

Como dito na seção anterior, que para demonstrar a capacidade do método de *outlier analysis* programado para auxiliar na detecção e localização de danos, foram gerados 26 amostras para cada uma das três classes de dados, sendo que a primeira foi gerada sem o dano, a segunda com a deposição de 1 g massa adesiva para simular um dano pequeno, e a terceira com a deposição de 4 g de massa para simular um dano maior que o primeiro.

Cada caminho de propagação foi analisado individualmente, a fim de calcular os *threshold value* e determinar quais caminhos obteriam a interferência do dano, avaliando se dentre as amostras obtidas haveriam *outliers*. Considerando que o dano está no centro do quadrante I. Com este arranjo, espera-se que os sinais de propagação gerados: 1 - 5 e 5 - 1; 2 - 4 e 4 - 2; e 1 - 9 e 9 - 1 sejam alterados, como demonstrado nas figuras 4, 5 e 6. Estes sinais a serem pré-processados pelas métricas e em seguida organizados e processados pelo programa para *outlier analysis* utilizando a Distância de Mahalanobis. Os resultados obtidos para os caminhos de propagação descritos estão demonstrados na figura 7, 8 e 9.




(a)




(b)

Figura 7 – Análise entre os sinais dos caminhos (a) 1-5 e (b) 5-1




(a)




(b)

Figura 7 – Análise entre os sinais dos caminhos (a) 2 - 4 e (b) 4 - 2



(A)



(B)

Figura 9 – Análise entre os sinais dos caminhos (a) 1-9 e (b) 9-1

6 CONSIDERAÇÕES FINAIS

Os resultados obtidos neste trabalho mostraram que a distância de Mahalanobis pode ser usada para detectar e localizar os danos em uma placa de alumínio com PZTs, funcionando como sensores e atuadores em um ambiente de temperatura controlada. Com o uso deste método, foi possível não apenas detectar o dano, estabelecendo um valor limiar da distância de Mahalanobis, mas localizá-lo comparando os resultados de vários caminhos de propagação das ondas de Lamb. Embora este método não pudesse produzir uma avaliação quantitativa sobre a dimensão do dano, através da comparação de dois conjuntos de dados, foi possível estabelecer uma avaliação qualitativa da proporção, pois é claramente perceptível que as distâncias de Mahalanobis para o dano 2 são maiores que as distâncias para danos 1.

7 REFERÊNCIAS BIBLIOGRÁFICAS

BARNETT, V.; LEWIS, T. *Outliers in Statistical Data: Wiley Series in Probability and Mathematical Statistics*. Publisher: **John Wiley & Sons Inc**, 1994.

FARRAR, Charles R.; WORDEN, Keith. **Structural health monitoring: a machine learning perspective**. John Wiley & Sons, 2012.

FARRAR, Charles R.; LIEVEN, Nick AJ; BEMENT, Matthew T. An introduction to damage prognosis. **Damage Prognosis for Aerospace, Civil and Mechanical Systems**, p. 1-12, 2005.

FRANÇA, Altair de Araujo. Detecção e localização de danos em materiais compósitos aplicado em aeronaves utilizando redes neurais artificiais. 2014.

GIROLDO, Fabíola Rocha de Santana. **Alguns métodos robustos para detectar outliers multivariados**. 2008. Tese de Doutorado. Universidade de São Paulo.

GIURGIUTIU, Victor. Tuned Lamb wave excitation and detection with piezoelectric wafer active sensors for structural health monitoring. **Journal of intelligent material systems and structures**, v. 16, n. 4, p. 291-305, 2005.

LEO, Donald J. **Engineering analysis of smart material systems**. John Wiley & Sons, 2007.

PAVLOPOULOU, S.; SOUTIS, C.; MANSON, G. Non-destructive inspection of adhesively bonded patch repairs using Lamb waves. **Plastics, Rubber and Composites**, v. 41, n. 2, p. 61-68, 2012.

SU, Zhongqing; YE, Lin. **Identification of damage using Lamb waves: from fundamentals to applications**. Springer Science & Business Media, 2009.

WORDEN, Keith; MANSON, Graeme. The application of machine learning to structural health monitoring. **Philosophical Transactions of the Royal Society of London A: Mathematical, Physical and Engineering Sciences**, v. 365, n. 1851, p. 515-537, 2007.

WORDEN, Keith; MANSON, Graeme; FIELLER, Nick RJ. Damage detection using outlier analysis. **Journal of Sound and Vibration**, v. 229, n. 3, p. 647-667, 2000.

8 AGRADECIMENTOS

Os autores reconhecem o apoio financeiro fornecido pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES, Brasil) e Fundação de Amparo Pesquisa de Minas Gerais (FAPEMIG) para financiar parcialmente o presente trabalho de pesquisa através do Instituto Nacional de Ciência e Tecnologia em Estruturas Inteligentes em Engenharia (INCT-EIE). Agradecimentos também ao professor Dr. Vicente Lopes Junior pelo apoio e a Universidade Estadual Paulista (UNESP) campus Ilha Solteira onde foram feitos os ensaios.