



**UNIVERSIDADE ESTADUAL PAULISTA**  
**“JÚLIO DE MESQUITA FILHO”**  
Campus de Ilha Solteira

**DANIELA CABRAL DE OLIVEIRA**

**LOCALIZAÇÃO DE DANOS EM ESTRUTURAS ISOTRÓPICAS COM A  
UTILIZAÇÃO DE APRENDIZADO DE MÁQUINA**

Ilha Solteira

2017



UNIVERSIDADE ESTADUAL PAULISTA  
“JÚLIO DE MESQUITA FILHO”  
Campus de Ilha Solteira

**DANIELA CABRAL DE OLIVEIRA**

**LOCALIZAÇÃO DE DANOS EM ESTRUTURAS ISOTRÓPICAS COM A  
UTILIZAÇÃO DE APRENDIZADO DE MÁQUINA**

Dissertação apresentada à Faculdade de Engenharia  
de Ilha Solteira – UNESP, para obtenção do título de  
mestre em Engenharia Mecânica.

Área de conhecimento: Mecânica dos Sólidos

Prof. Dr. Vicente Lopes Junior  
**Orientador**

Márcia Aparecida Fernandes  
**Co-orientadora**

Ilha Solteira

2017

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

O482l Oliveira, Daniela Cabral de.  
Localização de danos em estruturas isotrópicas com a utilização de  
aprendizado de máquina / Daniela Cabral de Oliveira. -- Ilha Solteira: [s.n.],  
2017  
123 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de  
Engenharia de Ilha Solteira. Área de conhecimento: Mecânica dos Sólidos, 2017

Orientador: Vicente Lopes Junior  
Co-orientador: Márcia Aparecida Fernandes  
Inclui bibliografia

1. SHM. 2. Aprendizado de máquina não-supervisionado. 3. Algoritmo K-  
Means. 4. Algoritmo propagação de afinidade.



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Ilha Solteira

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: LOCALIZAÇÃO DE DANOS EM ESTRUTURAS ISOTRÓPICAS COM A UTILIZAÇÃO DE APRENDIZADO DE MÁQUINA.

AUTORA: DANIELA CABRAL DE OLIVEIRA

ORIENTADOR: VICENTE LOPES JUNIOR

COORIENTADORA: MÁRCIA APARECIDA FERNANDES

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



Prof. Dr. VICENTE LOPES JUNIOR  
Departamento de Engenharia Mecânica / Faculdade de Engenharia de Ilha Solteira



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



Prof. Dr. MARCUS VINICIUS MONTEIRO VARANIS  
Faculdade de Engenharia / Universidade Federal da Grande Dourados

Ilha Solteira, 28 de junho de 2017

## **AGRADECIMENTOS**

Primeiramente, a Deus, por ter me dado essa oportunidade.

A meu orientador Dr. Vicente Lopes Júnior, que acreditou que eu era capaz de realizar este trabalho e muito me auxiliou para torná-lo realidade. Agradeço ainda pelas sugestões, críticas e opiniões que muito contribuiu para meu aprendizado.

A professora Dr<sup>a</sup>. Márcia Aparecida Fernandes por me ajudar nas implementações dos algoritmos e conhecimentos sobre aprendizado de máquina.

A professora Dr<sup>a</sup>. Mara Lúcia Lopes pela paciência e dedicação em me auxiliar na análise estatística dos dados.

Aos meus amigos Marcelo Rozan pelo auxílio e paciência na colaboração nos gráficos.

## RESUMO

Este trabalho introduz uma nova metodologia de Monitoramento da Integridade de Estruturas (SHM, do inglês Structural Health Monitoring) utilizando algoritmos de aprendizado de máquina não-supervisionado para localização e detecção de dano. A abordagem foi testada em material isotrópico (placa de alumínio). Os dados experimentais foram cedidos por Rosa (2016). O banco de dados disponibilizado é abrangente e inclui medidas em diversas situações. Os transdutores piezelétricos foram colados na placa de alumínio com dimensões de 500 x 500 x 2mm, que atuam como sensores e atuadores ao mesmo tempo. Para manipulação dos dados foram analisados os sinais definindo o primeiro pacote do sinal (first packet), considerando apenas o intervalo de tempo igual ao tempo da força de excitação. Neste caso, na há interferência dos sinais refletidos nas bordas da estrutura. Os sinais são obtidos na situação sem dano (*baseline*) e, posteriormente nas diversas situações de dano. Como método de avaliação do quanto o dano interfere em cada caminho, foram implementadas as seguintes métricas: pico máximo, valor médio quadrático (RMSD), correlação entre os sinais, normas  $H_2$  e  $H_\infty$  entre os sinais baseline e sinais com dano. Logo após o cálculo das métricas para as diversas situações de dano, foi implementado o algoritmo de aprendizado de máquina não-supervisionado K-Means no matlab e também testado no toolbox Weka. No algoritmo K-Means há a necessidade da pré-determinação do número de clusters e isto pode dificultar sua utilização nas situações reais. Então, fez se necessário a implementação de um algoritmo de aprendizado de máquina não-supervisionado que utiliza propagação de afinidades, onde a determinação do número de clusters é definida pela matriz de similaridades. O algoritmo de propagação de afinidades foi desenvolvido para todas as métricas separadamente para cada dano.

**Palavras-chave:** SHM. Aprendizado de máquina não-supervisionado. Algoritmo K-Means. Algoritmo propagação de afinidade.

## ABSTRACT

This paper introduces a new Structural Health Monitoring (SHM) methodology using unsupervised machine learning algorithms for locating and detecting damage. The approach was tested with isotropic material in an aluminum plate. Experimental data were provided by Rosa (2016). This provided database is open and includes measures in a variety of situations. The piezoelectric transducers were bonded to the aluminum plate with dimensions 500 x 500 x 2mm, and act as sensors and actuators simultaneously. In order to manipulate the data, signals defining the first packet were analyzed. It considers strictly the time interval equal to excitation force length. In this case, there is no interference of reflected signals in the structure boundaries. Signals are gathered at undamaged situation (baseline) and at several damage situations. As an evaluating method of how damage interferes in each path, it was implemented the following metrics: maximum peak, root-mean-square deviation (RMSD), correlation between signals,  $H_2$  and  $H_\infty$  norms regarding baseline and damaged signals. The metrics were computed for numerous damage situations. The data were evaluated in an unsupervised K-Means machine learning algorithm implemented in matlab and also tested in Weka toolbox. However, the K-Means algorithm requires the specification of the number of clusters and it is a problem for practical applications. Therefore, an implementation of an unsupervised machine learning algorithm, which uses affinity propagation was made. In this case, the determination of the number of clusters is defined by the data similarity matrix. The affinity propagation algorithm was developed for all metrics separately for each damage.

**Keywords:** SHM. Unsupervised machine learning. K-Means algorithm. Affinity propagation algorithm.

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>7</b>
1.1	OBJETIVO .....	9
<b>2</b>	<b>PRINCIPAIS CONCEITOS UTILIZADOS NA METODOLOGIA</b> .....	<b>12</b>
2.1	INTELIGÊNCIA ARTIFICIAL.....	12
2.1.1	Aprendizado de máquina .....	14
2.1.2	Aprendizado de máquina supervisionado.....	16
2.1.3	Aprendizado de máquina não-supervisionado .....	18
2.1.4	Algoritmo de aprendizado de máquina não-supervisionado com propagação de afinidades.....	22
2.2	MATERIAIS INTELIGENTES.....	24
2.2.1	Conceitos básicos sobre materiais piezelétricos .....	26
2.2.2	Conceitos básicos sobre ondas de lamb .....	27
2.2.3	Conceitos básicos sobre material isotrópico .....	28
<b>3</b>	<b>METODOLOGIA</b> .....	<b>30</b>
<b>4</b>	<b>RESULTADOS EXPERIMENTAIS</b> .....	<b>42</b>
<b>5</b>	<b>CONCLUSÕES E ETAPAS FUTURAS</b> .....	<b>119</b>
5.1	ETAPAS FUTURAS.....	120
	<b>REFERÊNCIAS</b> .....	<b>121</b>



## 1 INTRODUÇÃO

Atualmente pesquisas tem focado em desenvolver técnicas que monitoram a integridade estrutural de sistemas mecânico, civil e aeroespacial com intuito de diminuir custos operacionais da manutenção e aumentar a segurança.

Monitoramento da integridade de estruturas (do inglês Structural Health Monitoring, SHM) é um processo em desenvolvimento, que na fase atual busca sair de testes controlados em laboratórios para aplicações práticas. SHM envolve a observação do sistema usando amostras periódicas de tempo medidas por uma rede de sensores, a extração de características causadas por danos nas medidas e a análise estatística destas características que determinam o estado atual do sistema. SHM tenta fornecer um prognóstico do sistema quando existe dano na estrutura. Prognóstico nada mais é que a estimativa da vida útil restante do sistema ou equipamento com dano. Esta estimativa é baseada em vários fatores como: resultados de modelos preditivos, condições experimentais e operacionais, entre outros. Um comportamento indesejado de um equipamento ou sistema inviabiliza sua utilização e ameaça à integridade e confiabilidade de sua operação (FARRAR et al., 2005).

A presença de um tipo de avaria (ou dano), é a alteração na propriedade do material ou geometria do sistema, intencional ou não, que afeta negativamente o desempenho atual ou futuro, colocando em risco a segurança dos sistemas. Quando estas avarias não são detectadas e corrigidas, as falhas nestes tipos de estruturas podem levar a um grande prejuízo financeiro e também a perda de vidas. A preocupação com a integridade de estruturas se dá principalmente em sistemas de segurança crítica, como em aeronaves, onde a presença de danos na estrutura pode levar a perda irreparáveis e acidentes catastróficos. (ZHONGQING SU et al., 2009).

Os sistemas de monitoramento são divididos em várias etapas, que podem incluir a detecção do dano, a localização do dano na estrutura, a identificação do tipo de dano, a avaliação da extensão do dano e a identificação do tempo de vida útil restante da estrutura. A habilidade de monitorar a integridade estrutural tem sido amplamente estudadas para aumentar a segurança e reduzir custos de manutenção. Os sistemas de SHM são projetados para monitorar e testar de maneira confiável a integridade e o desempenho de estruturas (FARRAR et al., 2005).

A escolha da técnica para o monitoramento de uma estrutura depende da configuração construtiva, do ambiente de experimentação e do tipo de estrutura, que pode se basear em diversas técnicas não-destrutivas, denominadas NDE (*Nondestructive Evaluation*). Dentre elas, estão: inspeção por partículas magnéticas, correntes de Eddy, análise de deformações, técnicas utilizando fibras ópticas, emissões acústicas, vácuo comparativo, raios-x, líquidos penetrantes, propagação de ondas (ondas Lamb) e impedância eletromecânica (GONSALES, 2012).

As ondas de Lamb são ondas de deformação plana que ocorrem em uma placa nas superfícies (inferior e superior) livre. Uma das várias vantagens do uso das ondas Lamb no monitoramento da condição estrutural é que um conjunto de atuador e sensor é capaz de abranger uma grande área, sendo possível monitorar grandes estruturas com poucos atuadores e sensores em um arranjo bem projetado. O Titanato de Zircônio de Chumbo-PZT compõe o dispositivo mais utilizado a ser acoplado em estruturas para a propagação das ondas de Lamb por ser versátil, agindo tanto como sensor quanto atuador, facilitando a construção de arranjos para o sensoriamento da estrutura. O PZT possui alto desempenho em aplicações em altas frequências, como no caso das ondas Lamb e Impedância Eletromecânica (MARQUI, 2007).

Em aplicações do *'pitch-catch'*, com PZT sensor, alocado a uma distância adequada do PZT atuador, pode-se obter uma grande área de cobertura. Nesta área é possível determinar alterações químicas ou físicas na estrutura através da atenuação e dispersão da onda. Com essas características do sinal captado é possível utilizar sistemas de inteligência artificial para o processamento de sinais, que a partir das informações geradas pelos desvios dos sinais podem determinar a existência ou não de danos, localização e a gravidade (FRANCO, 2009).

A inteligência artificial é atualmente bastante utilizada em vários campos de aplicações, auxiliando a capacidade humana em projetos de desenvolvimento de novos sistemas e produtos e, ainda, substituindo muitas atividades repetitivas e enfadonhas de operadores humanos em diversas funções produtivas. Isto se tornou possível graças ao desenvolvimento dos sistemas especialistas: como Lógica Fuzzy, Redes Neurais Artificiais, Algoritmos Evolucionários e outros (LOPES et al., 2014).

Perante, os conceitos apresentados e a necessidade de desenvolver técnicas eficientes de SHM na identificação e localização de falhas foi necessário aprofundar estudos sobre uma das subáreas da Inteligência Artificial, que é o aprendizado de

máquina, capaz de verificar qualquer informação e produzir possibilidades a partir de resultados obtidos.

O aprendizado de máquina pode ser classificado em supervisionado e não-supervisionado. No supervisionado é apresentado um conjunto de pares entradas-saídas, sendo as entradas formadas por características relativas aos objetos que se deseja descobrir algum padrão ou tendência, e as saídas correspondem ao agrupamentos de objetos com as mesma estrutura de dados desejados. No aprendizado não-supervisionado, apenas as entradas são fornecidas, sendo que, neste caso, o padrão de saída deve ser deduzido pelo próprio sistema de aprendizado (ARTERO, 2009).

Os dados utilizados para monitoramento de integridade estrutural são obtidos através de testes experimentais ou modelos computacionais, porém, os testes experimentais são caros e difíceis de serem realizados, pois devem incluir todos os danos esperados. De outro lado, a construção de modelos envolve técnicas complexas, pois é necessário a inclusão da modelagem das falhas. Sendo assim, o aprendizado de máquina supervisionado, apresenta uma dificuldade para as aplicações práticas, que é simular todos os possíveis dados da estrutura com todos tipos de danos que se deseja monitorar, já o aprendizado de máquina não-supervisionado não tem essa necessidade.

Figueiredo et al. (2010) apresentou metodologia de algoritmos de aprendizado de máquina não supervisionado para detecção de danos com abordagem na modelagem estatística e manipulação dos dados baseados em rede neural auto associativa, análise fatorial, distância Mahalanobis e decomposição de valores singulares para classificação do grupo, análise de regressão e detecção de outlier.

## 1.1 OBJETIVO

O trabalho tem como objetivo introduzir uma nova metodologia de detecção e localização de danos estruturais em aeronave utilizando o aprendizado de máquina não-supervisionado. Os testes serão realizados em uma placa de material isotrópico com dimensões de 500 x 500 x 2mm. A excitação será realizada através de sinais de ondas guiadas, conhecidas como ondas de Lamb, que são transmitidas e captadas através de transdutores piezelétricos. Os dados serão analisados através de

similaridades para geração dos clusters que representam as situações com dano e sem dano.

## 1.2 MONITORAMENTO DE INTEGRIDADE ESTRUTURAL (SHM)

Veículos terrestres, aéreos, marítimos e espaciais, grandes estruturas, grandes máquinas estão em todos os lugares. A presença de danos nestes sistemas pode pôr em risco a segurança, podendo inviabilizar suas operações. Danos estruturais tem o potencial de causar um grande prejuízo financeiro e da pior das situações também afetar vidas. Entre 1990 e 2007 houve 1502 comunicados de acidentes de avião no transporte regional no espaço aéreo norte americano, no qual 386 deles (26%) foram fatais, resultando em 1104 mortes. Muitas destas falhas foram resultados da presença de danos estruturais ou acúmulo progressivo de defeitos destes danos no material, chegando a um nível crítico, causando então o colapso. O envelhecimento das aeronaves ou submissão à carga de fadiga e exposição a ambientes corrosivos comprometem a integridade estrutural ocasionado danos e subseqüentemente a falha (ZHONGQING SU et al., 2009).

Um sistema de SHM pode ser classificado em níveis que se baseiam na capacidade de abrangência, conforme Doebiling et al. (1998):

- Nível 1 – Detecta a existência do dano;
- Nível 2 – Detecta e localiza o dano;
- Nível 3 – Detecta, localiza e quantifica o dano;
- Nível 4 – Detecta, localiza e quantifica o dano e então estima a vida útil do restante do equipamento;

Inman (2001) acrescentou mais três níveis, englobando a utilização de materiais inteligentes, que:

- Nível 5 – Combina o nível 4 com estruturas inteligentes para autodiagnóstico do dano estrutural;
- Nível 6 – Combina o nível 4 com as estruturas inteligentes e controle para formar um sistema de auto reparo estrutural;

- Nível 7 – Combina o nível 1 com controle ativo e estruturas inteligentes para obtenção de um sistema simultâneo de controle e monitoramento.

Louzada (2013) complementa que há quatro fases para a implementação de um sistema 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 coletado.
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 reproduzir 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, que podem ser NDEs, sistemas inteligentes, entre outros, para gerar a saída final do sistema.

## 2 PRINCIPAIS CONCEITOS UTILIZADOS NA METODOLOGIA

Este capítulo traz os principais conceitos de inteligência artificial que darão suporte ao trabalho.

### 2.1 INTELIGÊNCIA ARTIFICIAL

Segundo Artero (2009) as principais áreas de atuação da inteligência artificial são:

- Robótica: dispositivos robóticos têm se tornado muito comum na indústria, sendo capazes de realizar tarefas que exigem grande força e também precisão;
- Visão por computador: esta área tem como objetivo desenvolver a capacidade de extrair informações do ambiente a partir de imagens obtidas;
- Processamento de linguagem natural: a capacidade de aprender línguas é uma das habilidades mais importantes das pessoas e dotar as máquinas desta aptidão é uma ambição bastante antiga, o que tornaria possível a tradução online de conversas entre pessoas de diferentes etnias;
- Sistemas especialistas: são sistemas que, a partir do processamento de uma base de conhecimento, conseguem fornecer respostas, sobre um determinado domínio, a um usuário;
- Reconhecimento de padrões: esta área envolve uma grande quantidade de tarefas, como reconhecer faces, gestos, palavras escritas e faladas e o próprio ambiente;
- Base de dados inteligentes: consiste em adicionar às bases de conhecimento a habilidade de raciocinar, de modo que seja possível gerar resultados novos e;
- Prova de teoremas: estratégias usadas para que as demonstrações possam ser empregadas na solução de problemas em diversas áreas, em se definir sequências lógicas de ações que levam de uma situação inicial (hipótese) até o objetivo final (tese).

A Inteligência Artificial é um campo de estudos da computação que se dedica ao estudo e desenvolvimento de sistemas que possam reproduzir comportamentos

inteligentes e cumprir tarefas complicadas com um grau de confiabilidade que é equivalente ou superior ao de um humano (RUSSELL; NORVING, 2013).

Em Lopes et al. (2000) as redes neurais artificiais (ANN) surgiram como ferramenta promissora para monitoramento e classificação de máquinas e equipamentos. Resolve problemas no contexto do monitoramento e detecção de falhas devido ao reconhecimento de padrões e capacidades de interpolação.

Morales (2009) aplica três tipos de algoritmo genético com o propósito de verificar a aplicabilidade na detecção de danos e a partir de 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.

Lima (2014) utiliza as metodologias, Sistemas Imunológicos Artificiais (AIS) 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.

Anaya et al. (2015) apresentou uma metodologia de detecção de danos baseada em Sistemas Imunológicos Artificiais como técnica de reconhecimento de padrões e parcelas de afinidade para discriminar diferentes estados estruturais. O algoritmo AIS é uma estratégia bioinspirada baseada em uma abordagem estatística onde a fusão dos dados de sensores, a extração dos recursos e reconhecimento de padrões são avaliados, dispensando um modelo matemático.

Simone et al. (2015) apresentou um comparativo de três algoritmos de aprendizado de máquina não supervisionado utilizado para monitorar a integridade estrutural de um trator agrícola. As técnicas estudadas foram: K-Means, Fuzzy C-Means e rede neural artificial Kohonen. Essas técnicas são ferramentas de aprendizado de máquina não supervisionado que fornecem classificações das informações com base nas similaridades dos clusters. Para avaliar os algoritmos, a modelagem e os sinais de simulação foram realizados a partir de um modelo numérico de um trator agrícola.

### 2.1.1 Aprendizado de máquina

De acordo com o aprendizado de máquina os autores Smola e Vishwanathan (2008) explicam que “com as crescentes quantidades de dados gerados há boas razões para acreditar que a análise inteligente de dados se tornará ainda mais difundida como um ingrediente necessário para o processo tecnológico”.

Com o aumento de dados gerados diariamente, a linha de pesquisa de aprendizado de máquina vem ganhando destaque. Esta linha de pesquisa objetiva estudar técnicas e algoritmos para que as máquinas com base em exemplos ou experiências passadas, sejam capazes de melhorar sua performance em determinados processos ou solucionar problemas de forma autônoma (BARBOSA, 2009).

Por exemplo, podemos ter um modelo definido com alguns parâmetros e o objetivo da máquina é otimizar esses parâmetros usando dados do treinamento ou experiências passadas. O modelo pode ser preditivo para fazer previsões, ou descritivo para adquirir conhecimento através dos dados, ou ambos. A utilização de métodos de aprendizado de máquina em bases de dados é chamado de mineração de dados. A analogia é que um grande volume de terra e matéria-prima é extraído de uma mina, no qual quando processado conduz a uma pequena quantidade de material precioso. Da mesma forma, na mineração de dados, um grande volume de dados é processado para construir um modelo simples, com utilização valiosa, por exemplo, ter alta precisão preditiva (ALPAYDIN, 2010).

A figura 1 retrata que o aprendizado de máquina pode ser utilizado em diversas áreas, como por exemplo nas lojas de vendas de livros como a Amazon, ou serviços de TV por internet como o Netflix fazem uso extensivo de aplicações de aprendizado de máquina para motivar usuários a comprar outros produtos ou indicar um novo filme, com base nos hábitos do usuário (ALPAYDIN, 2010; DOMINGOS, 2012; SMOLA; VISHWANATHAN, 2008).



Figura 1 - Sugestões do Netflix com base nos hábitos do usuário



Fonte: Netflix (2015).

A figura 2 mostra o aprendizado de máquina, onde uma imagem de uma pessoa é dada, e o sistema deve reconhecer quem é esta pessoa classificando o rosto em uma das muitas categorias ou classificá-lo como desconhecido. O sistema aprende quais características são relevantes para a identificação de uma pessoa, lidando assim com diferentes condições de iluminação, expressões faciais, penteado e etc.

Figura 2 - Diversas expressões faciais



Fonte Artero (2009).

O aprendizado de máquina se divide em: aprendizado de máquina supervisionado e não-supervisionado.

### 2.1.2 Aprendizado de máquina supervisionado

Em aprendizado supervisionado há um conjunto de exemplos (treinamento) para os quais as características do objeto associado é definido. Então o intuito é executar previsões com base no treinamento. O termo supervisionado indica que há um supervisor, especificando a saída para cada entrada. A saída também é chamada de rótulo, particularmente quando o objetivo é a classificação (BARBER, 2012).

Considerando um banco de imagens de rostos, os registros são representados por um vetor  $x$ . Cada imagem  $x$  tem uma classe  $y \in \{\text{masculino, feminino}\}$  equivalente, que define se a imagem é um rosto masculino ou feminino. Um banco com 10000 registros é disponível por  $D = \{(x_n, y_n), n = 1, \dots, 10000\}$ . A tarefa é fazer um preditor  $y(x^*)$  do sexo de uma nova imagem  $x^*$ . Este é o exemplo de uma aplicação que é difícil de programar de um modo tradicional para especificar uma regra que diferencia rostos do sexo masculino e feminino. Uma alternativa seria apresentar exemplos de rostos com os gêneros definidos e deixar a máquina aprender a regra automaticamente (BARBER, 2012, p. 295).

O treinamento do aprendizado supervisionado consiste em pares ordenados  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ , onde cada  $x_i$  é uma medição ou conjunto de medições de um único dado e  $y_i$  é a saída ou rótulo. No aprendizado supervisionado, o conjunto de dados é dividido em treinamento, teste e validação.

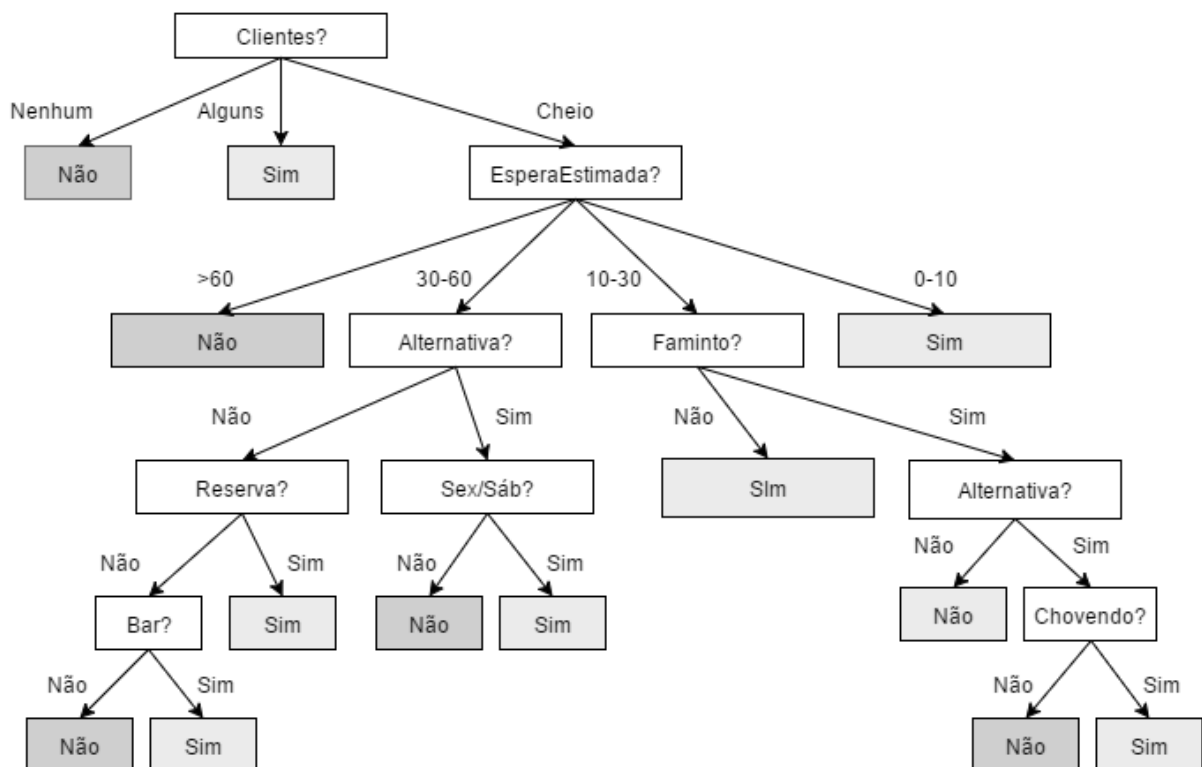
Algoritmos de aprendizado de máquina supervisionados têm como objetivo identificar padrões de relações entre exemplos e suas classes. Um conjunto de exemplos para os quais a classe (ou rótulo) é conhecida é fornecido ao algoritmo de aprendizado supervisionado. O objetivo do algoritmo é construir um modelo que possa determinar automaticamente e corretamente a classe de novos exemplos. Quando a classe dos exemplos assume valores discretos esse problema é chamado de classificação (ALPAYDIN, 2010; MICHELL, 1997; FLACH, 2012).

O algoritmo de árvore de decisão é um algoritmo de aprendizado de máquina supervisionado que alcança a classificação ao executar uma sequência de testes. Cada nó na árvore corresponde a um teste do valor de um atributo de entrada e as ramificações dos nós são classificadas com os valores possíveis do atributo. Cada

nó de folha na árvore especifica o valor a ser retornado pela função (RUSSELL; NORVIG, 2013).

A figura 3 mostra uma árvore de decisão para decidir a espera ou não de uma mesa em um restaurante. As entradas são: 1 – Alternativa: se há um restaurante alternativo apropriado por perto; 2 – Bar: se o restaurante tem um espaço de bar; 3 – Sex/Sáb: verdadeiro às sextas e sábado; 4 – Faminto: se estamos com fome; 5 – Clientes: quantas pessoas estão no restaurante; 6 – Preço: a faixa de preço do restaurante; 7 – Chovendo: se está chovendo do lado de fora; 8 – Reserva: se fizemos uma reserva; 9 – Tipo: tipo de restaurante; 10 – Espera Estimada: a espera estimada pelo gerente.

Figura 3 - Exemplo de árvore de decisão.



Fonte: Próprio autor.

### 2.1.3 Aprendizado de máquina não-supervisionado

Em aprendizado não supervisionado, não há um supervisor, o algoritmo só recebe os dados e o objetivo é encontrar padrões nos dados. O algoritmo agrupa (formação de clusters) os dados com base em atributos semelhantes. Após o agrupamento, geralmente, é necessária uma avaliação para definir o que cada agrupamento significa no âmbito do problema (MONARD; BARANAUSKAS, 2003).

Clusterização é o agrupamento dos dados de entrada. Por exemplo, de uma empresa com dados de antigos clientes, os dados do cliente contêm o histórico das transações com a empresa e, a empresa talvez queira ver a distribuição dos perfis de clientes para analisar qual tipo de cliente compra com mais frequência. Neste caso, a clusterização aloca os clientes com atributos semelhantes no mesmo grupo, fornecendo à empresa um agrupamento natural dos clientes. Uma vez que os grupos foram definidos, a empresa pode definir estratégias, produtos ou serviços para diferentes seguimentos de clientes (ALPAYDIN, 2010).

O cluster é uma técnica de agrupamentos a partir dos padrões de entrada, isto é, não precisa de exemplos pré-classificados para formação dos clusters. Um agrupamento é composto de um número não fixo de objetos (exemplos) similares conforme uma medida de similaridade.

A figura 4 demonstra que similar é diferente de igual, pois é medida de semelhança.

Figura 4 - Definição de Similaridade



Fonte: Artero (2009).

Similaridade é uma medida de distância que existe em diversas metodologias, tais como: minkowski, euclidiana, manhatan, chebyshey, mahalanobis, cosseno, etc.


O algoritmo tradicional do aprendizado de máquina não- supervisionado é o K-Means, que é um algoritmo que utiliza a distância euclidiana, ou seja, é calculado a raiz quadrada da soma dos quadrados da diferença entre os pontos para a criação dos clusters. Um cluster é representado pelo centroide, ou seja, o centro da média aritmética das entradas do cluster.

O algoritmo K-Means busca particionar N observações e K clusters, cada observação pertence ao cluster com a menor distância. Para o funcionamento do algoritmo são necessárias três etapas:

1. Escolher aleatoriamente um número de centros para iniciar os clusters.
2. Cada objeto é atribuído ao cluster cujo centro é o mais próximo, através da medida de distância;
3. Mover cada centro para a média (centroide) dos objetos do cluster;
4. Repetir as etapas dois e três até algum critério de convergência.

As figuras 5, 6, 7, 8 e 9 demonstram o passo-a-passo do algoritmo. A figura 5 corresponde ao primeiro passo onde se escolhe os k centros iniciais.


Figura 5 - Passo 1 do algoritmo K-Means



Fonte: Artero (2009).

A figura 6 corresponde à segunda etapa onde atribui cada objeto ao cluster de centros mais próximos.


Figura 6 - Passo 2 do algoritmo K-Means



Fonte: Artero (2009).

A figura 7 move cada centro para o vetor médio do cluster (centroide).


Figura 7 -Passo 3 do algoritmo K-Means



Fonte: Artero (2009).


A figura 8 reavalia os objetos aos clusters de centroides mais próximos, enquanto a figura 9 recalcula os valores médios dos centroides.

Figura 8 - Retorno ao passo 2 do algoritmo K-Means



Fonte: Artero (2009).

Figura 9 - Retorno ao passo 3 do algoritmo K-Means



Fonte: Artero (2009).

A vantagem do algoritmo K-Means é a menor sensibilidade a outliers e a desvantagem é a maior complexidade computacional (RUSSELL; NORVIG, 2013).

### 2.1.4 Algoritmo de aprendizado de máquina não-supervisionado com propagação de afinidades

Propagação de Afinidades é um algoritmo de clusterização, que tem como entrada um conjunto de pontos (dados) e a partir deles é obtido um conjunto de medidas de similaridades. Na matriz de similaridades é determinado o parâmetro de clusterização por tentativa e erro ou realizada por procedimentos metaheurísticos.

O algoritmo troca mensagens entre os pontos até que uma condição de parada seja satisfeita. No presente trabalho o critério de convergência utilizado foi o número de iterações, sendo visto graficamente com retorno de confirmação de convergência e número de iterações.

Há dois tipos de mensagens que podem ser trocada entre os pontos. A responsabilidade  $r(i,k)$  no ponto  $y^i$  envia mensagem para candidato exemplar  $y^k$ , que reflete a evidência acumulada para quão bem adaptado o ponto  $y^k$  deve servir como exemplar para o ponto  $y^i$ , tendo em conta outros exemplares potenciais para o ponto  $y^i$ . A disponibilidade  $a(i,k)$  para o candidato exemplar ponto  $y^k$  envia mensagem para o ponto  $y^i$ , que reflete a evidência acumulada para quão apropriado seria para o ponto  $y^i$  escolher o ponto  $y^k$  como um exemplar, tendo em conta o apoio de outros pontos que o ponto  $y^k$  deve ser um exemplar (SANTANA et al., 2010). A matriz de responsabilidade indica quantos pontos podem ser exemplares, podendo ser um ou vários exemplares. Já a matriz de disponibilidade confirma o bom candidato a ser considerado como o exemplar definido pela matriz de responsabilidade.

A disponibilidade é inicializada com zero:  $a(i,k) = 0$ . Então, as responsabilidades são computados a partir da (Equação (1)):

$$r(i,k) \leftarrow s(y^i, y^k) - \max_{k' | k' \neq k} \{ a(i,k') + s(y^i, y^{k'}) \} \quad (1)$$

em que:

$k$ : corresponde ao exemplar analisado;

$k'$ : representa os demais exemplares, tal que,  $k' \neq k$ .

Cada candidato exemplar é considerado um exemplar obtido a partir da equação de disponibilidade (Equação (2)):

$$a(i,k) \leftarrow \min \{ 0, r(k, k) + \sum_{i' \in \{i, k\}} \max \{ 0, r(i', k) \} \} \quad (2)$$



É possível observar pela disponibilidade dada pela equação (2) que apenas as responsabilidades positivas são adicionadas.

A autodisponibilidade  $a(k, k)$  pode ser atualizada de forma diferente:

$$a(k, k) = \sum_{i|i' \neq k} \max \{0, r(i', k)\} \quad (3)$$

A matriz de disponibilidade pode ser definida tanto pelo valor mínimo ou máximo da diagonal. O valor máximo da diagonal define os melhores exemplares.

O algoritmo encontra uma solução aproximada, ou seja, um certo número de clusters, utilizando a matriz de similaridade e as duas medidas: responsabilidade (matriz R) e disponibilidade (matriz A), por meio das diagonais principais destas matrizes que contém informações relevantes para identificar se o ponto é ou não um representante do cluster.

De forma semelhante a outros métodos de propagação, existem oscilações numéricas que surgem em algumas circunstâncias e esta técnica consiste em definir uma variação entre  $(0 < \lambda < 1)$  para o valor de lambda.

As etapas do algoritmo de propagação de afinidade são descritas da seguinte maneira:

#### Propagação de afinidade

---

Inicializar disponibilidade  $a(i, k)$  para zerar todo  $i, k$

Faça{

Equação (1), todas responsabilidades dada as disponibilidades;

Equação (2), toda disponibilidade dada a responsabilidade;

Combinar disponibilidade e responsabilidade para obter decisões de exemplares;

} até critério de iterações.

---

Para melhorar o resultado da clusterização do algoritmo com propagação de afinidades é necessário utilizar o algoritmo melhorado. A representação esquemática do algoritmo melhorado é mostrada a seguir:

### Algoritmo Melhorado

---

```

Iter = 0;
Enquanto iter < maxiter
  Para cada ponto  $y^i$ 
    Para cada atual cluster  $j$ 
      Se  $j$  contém pelo menos dois pontos, encontrar média
      similaridade  $s^i_{y^i}$  de  $y^i$  para pontos em  $j$ .  $J$  são clusters representados por um ou mais
      pontos.
      Else  $s^i_{y^i} = -\infty$ 
      Encontrar cluster  $j_{\max}$  com média de similaridade positiva de  $y^i$  para
      os pontos em  $j_{\max}$ .
      Para cada ponto  $y^i$ .
      Atribuir  $y^i$  para cluster  $j_{\max}$ 
    Iter = iter + 1

```

---

Como exemplo ilustrativo pode-se representar a seguinte situação: o algoritmo melhorado pega cada ponto gerado pelo algoritmo anterior e para cada cluster (com mais de dois elementos) verifica em qual destes clusters o ponto se encaixa melhor. Para isso, calcula a similaridade média entre os pontos pertencentes a cada cluster, ou seja, no cluster 10 tem os elementos [3,10] onde o ponto pertencerá ao cluster onde está a maior média. Este procedimento é repetido até que haja convergência.

## 2.2 MATERIAIS INTELIGENTES

Devido algumas necessidades especiais de projeto em engenharia, aliadas ao desenvolvimento de novos materiais, foram criados dispositivos e materiais que vêm sendo utilizados com sucesso como sensores e/ou atuadores que são facilmente incorporados a estrutura de interesse. Estas novas estruturas, denominadas “estruturas inteligentes”, utilizando-se destes novos materiais, denominados “materiais inteligentes”, vêm ganhando reconhecidas aplicações na indústria.

Investigações científicas e tecnológicas realizadas em centros de pesquisa em todo o mundo vêm revolucionando o projeto de sistemas estruturais e prometendo novas aplicações em muitas áreas da engenharia (BANKS et al., 1996).

A comunidade de engenharia nomeou a expressão “Estruturas Inteligentes” ao longo das últimas décadas e, atualmente, esta denota a capacidade extraordinária de algumas estruturas ou componentes estruturais em modificar suas propriedades. Conforme Rabelo (2014) Inteligência pode ser interpretada como: a habilidade de componentes estruturais em sentir, diagnosticar e atuar de forma a manter sua funcionalidade ou um projeto que melhore a integridade estrutural por meio do monitoramento de seus dados, como temperatura, pressão, carregamento, etc., permitindo diagnosticar a natureza e dimensão do problema, para provocar alguma ação de controle do mesmo e, também, armazenar a informação que leve o sistema a “aprender” para poder agir em situações semelhantes no futuro.

Usando desta inteligência é possível obter o auto-diagnóstico, o reparo, a recuperação funcional e o “aprendizado”. As estruturas inteligentes visam atender a sua preservação, ou ainda a melhora das condições de monitoramento.

Dos materiais empregados para as estruturas inteligentes, os mais utilizados são as cerâmicas piezelétricas, os eletroestritivos e magnetoestritivos, os fluidos e os sólidos eletroreológicos e magnetoreológicos, as ligas com memória de forma e fibras óticas. As propriedades destes materiais já são conhecidas há muito tempo, mas apenas mais recentemente é que estas têm sido refinadas para aplicações em estruturas reais. De todo modo, a inserção destes materiais em um sistema inteligente é nova, suas aplicações ainda estão sob intensa investigação, com várias perspectivas possíveis e algumas experiências de sucesso já consolidados (BANKS, et al., 1996).

Para citar um exemplo da importância das estruturas inteligentes no setor aeronáutico, estudos recentes mostram que os requisitos de inspeção para uma aeronave militar (caça) contendo tanto partes metálicas como materiais compósitos em sua estrutura, podem ter 40% ou mais de redução do tempo de inspeção utilizando sistemas inteligentes de monitoramento. O monitoramento contínuo da saúde estrutural juntamente com o monitoramento do uso levam à redução do número de manutenções programadas e não programadas, diminuindo o tempo desta atividade e aumentando a segurança. Especialistas consideram que o custo de manutenção/inspeção pode ser reduzido da ordem de 20% na aviação civil e

militar quando se adotam soluções de monitoramento de dano integradas e on-line (STASZEWSKI et al., 2004).


### 2.2.1 Conceitos básicos sobre materiais piezelétricos

Piezeletricidade é definida como energia elétrica que é acumulada em certos sólidos (cristais, cerâmicas, entre outros) em resposta a tensão mecânica aplicada no material. A palavra piezeletricidade significa eletricidade resultante da aplicação de tensão. Atualmente os materiais piezelétricos são utilizados como sensores e/ou atuadores em aplicações tecnológicas para baixas frequências (Hz) como para altas frequências (GHz).

Além dos materiais naturais que exibem o efeito *piezo* (como o quartzo e a turmalina), existem também materiais cerâmicos policristalinos ferroelétricos tal como o Titanato Zirconato de Chumbo (PZT), que tem sido extensivamente estudado em pesquisas nas duas últimas décadas. Estas cerâmicas ferroelétricas são versáteis e apresentam propriedades piezelétricas, de maneira geral, mais adequadas que outros materiais similares. Também podem assumir várias formas e tamanhos devido ao seu processo de produção, que é a sinterização de pó cerâmico conformado via prensagem ou extrusão (VENET; PEREIRA, 2004).

A figura 10a mostra a aleatoriedade dos domínios do PZT, onde o arranjo assimétrico dos íons positivos e negativos fornece o comportamento permanente do dipolo elétrico para os cristais. A figura 10b ilustra o material em um campo elétrico que é capaz de orientar o sentido dos íons fazendo com que o mesmo tenha expansão na direção do campo e contração na direção perpendicular. Após a aplicação do campo elétrico, os dipolos elétricos ficam direcionados, porém não alinhados, permitindo ao material uma polarização remanescente que pode ser degradada pelo excesso dos limites mecânicos, elétrico e térmico do material (FRANCO, 2009).

Figura 10 - Dipolo elétrico nos domínio, (a) Cerâmica ferroelétrica não polarizada (sem aplicação de campo elétrico ou deformação), (b) durante a polarização e (c) após a polarização




Fonte: Franco (2009).

### 2.2.2 Conceitos básicos sobre ondas de Lamb

O primeiro artigo sobre ondas guiadas aplicadas em placas finas foi publicado em 1917 pelo matemático Horance Lamb, que deu origem ao nome deste tipo de onda. Em seu trabalho, Lamb mostrou que se a espessura da placa for da ordem do comprimento de onda, então esta onda se propaga entre as superfícies da placa de dois modos: simétrico ( $S_i$ ) e antissimétrico ( $A_i$ ) (ZHONGQING SU et al., 2009). A figura 11 mostra como o sistema de coordenadas é atribuído a uma placa de espessura  $2d$ , onde  $x$  representa o eixo de propagação da onda e  $z$  a direção normal a superfície da placa.

Figura 11 - Sistema de coordenada em um placa de espessura  $2d$



Fonte: Zhongqins SU et al. (2009).

A propagação do modo antissimétrico ocasiona o deslocamento das partículas da placa na direção perpendicular da placa. Já a propagação do modo simétrico ocasiona o deslocamento das partículas na direção radial da placa (GRAFF, 1975).

As ondas de Lamb se propagam por uma distância relativamente longa (ZHONGQING SU et al., 2009), e desta forma permite que uma grande área seja coberta por poucos transdutores de PZT. A técnica de localização de danos através das ondas de Lamb se torna atrativa pelas seguintes características: capacidade de análise de uma área relativamente grande com poucos transdutores; alta sensibilidade a danos; possibilidade de um sistema de identificação de danos online e automatizado; baixo consumo de energia e boa relação custo benefício.

As descrições detalhadas deste tipo de ondas, assim como outras características, como por exemplo, atenuação e dispersão, podem ser encontradas em Graff (1975) ou outros diversos livros textos sobre propagação de ondas.

### 2.2.3 Conceitos básicos sobre material isotrópico

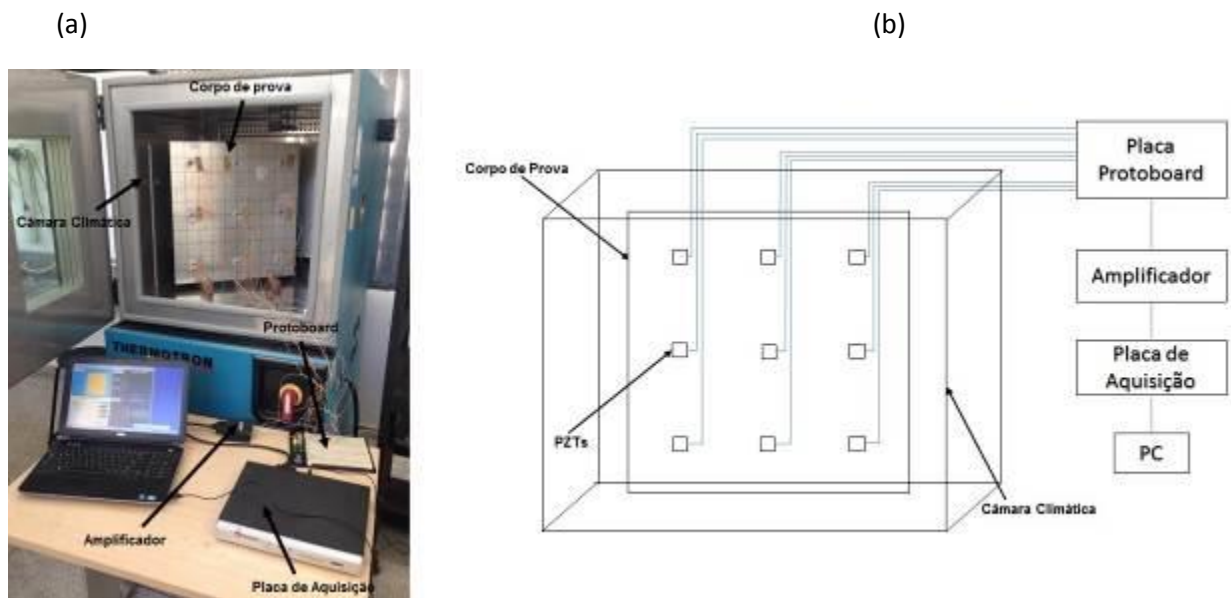
No material isotrópico a velocidade de propagação da onda é independente da direção de propagação da onda e tem o mesmo valor para todas as direções. O material compósito a velocidade de propagação é dependente da direção de propagação, alterando o valor da velocidade de acordo com a direção de propagação.

O presente trabalho utilizou as medidas experimentais de uma placa de alumínio obtidos por Rosa (2016). O alumínio é um material isotrópico. A figura 12 mostra os equipamentos utilizados nos testes experimentais. Os testes foram

realizados em várias condições para ficarem disponíveis aos membros do grupo GMSINT (Grupo de Materiais e Sistemas Inteligentes). Os equipamentos utilizados foram:

- Corpo de prova: Placa de Alumínio;
- 9 Transdutores PZTs modelo T110-H4e-62 fabricado pela Piezo Systems, Inc.;
- Epóxi aeronáutico Henkel Hysol EA 9320NA para fixação dos transdutores;
- Massa adesiva Hexcel para simulação da delaminação;
- Placa de Aquisição Acellent ScanGenie II e Software de aquisição ACCESS 2.1 para aquisição dos sinais;
- Placa Protoboard MSB-400 para entrada dos canais;
- Software de processamento MATLAB® versão R2013a como sistema de processamento e
- Câmara climática Thermotron SM-8 como ambiente para os ensaios.

Figura 12 -Materiais e equipamentos utilizados no experimento com material isotrópico: (a) foto dos materiais e equipamentos utilizados no experimento e (b) Ilustração dos materiais e equipamentos utilizados no experimento



Fonte: Rosa (2016).

Detalhes do experimento e das medidas podem ser obtidos na citada dissertação (ROSA, 2016).


### 3 METODOLOGIA

Neste trabalho, o monitoramento da condição estrutural será através do algoritmo de aprendizado de máquina não-supervisionado de propagação de afinidades. Os testes foram realizados em uma estrutura de alumínio, mostrada na figura 13. Os experimentos foram realizados para a dissertação de Rosa (2016). Os testes foram realizados em diversas situações para servir de dados a outros trabalhos. O presente trabalho tem uma abordagem diferente da proposta de Rosa, que utiliza imagens para detectar e localizar os danos. Transdutores piezelétricos foram colados na estrutura e atuam como sensores e atuadores ao mesmo tempo. Maiores detalhes das medidas podem ser obtidos no referido trabalho. Na sequência será apresentado apenas os aspectos básicos para entendimento de como as medidas foram feitas e como devem ser entendidas.


No experimento foi utilizado uma placa de alumínio com dimensões de 500 x 500 x 2mm, 9 transdutores de PZTs que cobrem a superfície da estrutura, como mostrado na figura 13. A sequência de medidas utiliza 1 PZT como atuador e os outros 8 como sensores. Existem 9 possibilidades de atuadores gerando 8 caminhos e consequentemente 72 caminhos. Como demonstrado na figura 14, que serão designadas como caminhos de propagação.

Figura 13 - (a) Foto da placa utilizada no experimento e (b) Ilustração da placa mostrando posicionamento dos transdutores

(A)




(B)



Fonte: Rosa (2016).




Figura 14 -Caminhos entre atuadores/sensores utilizados na localização dos danos. O quadrado de cor azul significa o atuador, enquanto todos os outros 8 transdutores atuam como sensores. Cada quadro apresenta 8 caminhos




Fonte: Rosa (2016)

Na figura 14,  $P_{12}$  significa que o atuador é o PZT1 e o sensor é o PZT2. De uma maneira geral  $P_{ij}$ , significa que o atuador está na posição  $i$  e o sensor na posição  $j$ . Para análise de localização dos danos foram definidos cinco pontos onde foram colocados os danos em ensaios diferentes. O posicionamento dos danos está apresentado na figura 15. A figura 15a mostra o posicionamento do dano 1, 15b do dano 2, 15c do dano 3, 15d do dano 4 e 15e do dano 5.


Figura 15 - Ilustração do posicionamento dos danos: (A) dano 1, (B) dano 2, (C) dano 3, (D) dano 4 e (E) dano 5




(C)



(D)



(E)



Fonte: Rosa (2016).

Para localização dos danos na estrutura, fez-se uso da análise dos sinais gerados da propagação de ondas de Lamb para cada caminho do arranjo. Para a geração e aquisição dos sinais foi utilizada a placa da Accelent modelo ScanGenie-II Battery Edition juntamente com o software ACESS 2.1. Os sinais foram obtidos nas frequências de 150, 200, 250, 300 e 350 kHz. O sinal de excitação foi o Burst 5, isto é, um sinal senoidal janelado com 5 ciclos, para todas as 5 frequências. A frequência


de amostragem para todos os testes foi de 3MHz e o número de pontos de aquisição foi 1000. Para cada medida, foi considerado uma média de 10 sinais.

Para manipulação dos dados foram analisados os sinais definindo o primeiro pacote do sinal (first packet), isto é, considera-se apenas o intervalo de tempo em que o sinal chega ao sensor sem reflexões e um tempo igual ao tempo de excitação. Os sinais são obtidos na situação sem dano (*baseline*) e, posteriormente nas diversas situações de dano.

O primeiro pacote, ou seja, 80 pontos de um sinal senoidal janelado com 5 ciclos foi definido devido as reflexões que o mesmo pode sofrer na estrutura e devido ao dano, o restante do sinal, além das reflexões, tem os outros modos de onda que chegam ao sensor e, assim, dificultam a análise. Em seguida foi gerado gráficos que mostram claramente quando existem diferenças entre o *baseline* e o sinal atual (ou sinal a ser analisado) captado pelo sensor, conforme mostrado nas figuras 16 a 21.

A figura 16 mostra o gráfico do sinal P<sub>59</sub>, isto é, sinal emitido pelo atuador 5 e recebido pelo sensor 9. Este caminho foi escolhido para mostrar a influência do dano 4 neste caminho. O sinal vermelho representa o sinal *baseline* e o sinal azul representa o sinal com dano.


Figura 16 - Sinal emitido pelo atuador PTZ 5 para 250 kHz, e sinal captado no sensor PTZ 9 para a situação sem dano (*baseline*) e para a situação com dano 4.



Fonte: Próprio autor.

A análise pode ser feita considerando toda a faixa de do tempo. No entanto, esta análise é mais difícil e geralmente se considera apenas o primeiro pacote do sinal, mostrado na figura 17. Como a onda chega primeiro no sensor, ainda não há outras influências além do dano.


Figura 17 - Primeiro pacote do sinal emitido pelo atuador PTZ 5 para 250 kHz e sinal captado no sensor PTZ 9 para a situação sem dano (baseline) e para a situação com dano 4



Fonte: Próprio autor.

A figura 18 mostra o gráfico do sinal P<sub>12</sub>, isto é, atuador 1 e sensor 2 para o mesmo dano 4. Este sinal demonstra a baixa interferência do dano, pois o dano se encontra distante deste caminho. O sinal vermelho representa o sinal baseline e o sinal azul representa o sinal com dano.


Figura 18 - Sinal emitido pelo atuador PTZ 1 para 250 kHz e sinal captado no sensor PTZ 2 para a situação sem dano (baseline) e para a situação com dano 4



Fonte: Próprio autor.

Já na figura 19 visualiza-se o gráfico do primeiro pacote do sinal a ser analisado.


Figura 19 - Primeiro pacote do sinal emitido pelo atuador PTZ 1 para 250 kHz, e sinal captado no sensor PTZ 2 para a situação sem dano (baseline) e para a situação com dano 4



Fonte: Próprio autor.

A figura 20 mostra o gráfico do sinal  $P_{68}$  do atuador 6 e sensor 8 para o mesmo dano 4. O sinal vermelho representa o sinal baseline e o sinal azul representa o sinal com dano. Embora, o dano se localize próximo deste caminho, a variação do sinal não é grande. Nas seções seguintes, serão definidas métricas que procuram quantificar estas variações.


Figura 19 - Sinal emitido pelo atuador PTZ 6 para 250 kHz, e sinal captado no sensor PTZ 8 para a situação sem dano (baseline) e para a situação com dano 4.



Fonte: Próprio autor.

Já na figura 21 visualiza-se o gráfico do primeiro pacote do sinal a ser analisado.

Figura 20 - Primeiro pacote do sinal emitido pelo atuador PTZ 6 para 250 kHz e sinal captado no sensor PTZ 8 para a situação sem dano (baseline) e para a situação com dano 4



Fonte: Próprio autor.

A definição do primeiro pacote foi realizada para os 72 caminhos. Os caminhos próximos ao dano sofrem maiores variações, existem também caminhos que sofrem pequenas variações e outros caminhos que não sofrem nenhuma interferência do dano. As variações no sinal podem ser devidas, também, a fatores externos, como variação de cargas e de temperatura. Nos resultados apresentados no próximo capítulo, estes efeitos não são analisados, pois os dados foram obtidos em laboratório com condições controladas.

Para se avaliar o quanto o dano interfere em cada caminho foi implementado no MATLAB® versão R2013a métricas de processamento de sinais. No caso de SHM estas métricas são utilizadas para a identificação de danos através do processamento de sinais provenientes de ensaios, que compara um sinal captado como uma amostra modelo, também conhecida como *baseline* e um sinal proveniente do mesmo sistema, porém carregando as informações de um estado desconhecido da estrutura.

Mensurar o dano, através de índices, significa atribuir uma quantidade escalar por meio de parâmetros estatísticos. No caso de SHM, o resultado desta comparação representa a existência do dano e sua significância ao sistema.

Para avaliar o quanto o dano interfere em cada caminho foi implementado o valor máximo do pico, valor RMSD (variação do valor médio quadrático), correlação



dos sinais, normas  $H_2$  e  $H_\infty$  entre os sinais baseline e sinais com dano referente ao primeiro pacote definido para cada caminho.

O valor máximo do pico compara os maiores valores dos picos entre o sinal baseline e sinal com dano. A métrica RMSD é o valor em porcentagem da variação dos valores RMS entre os dois sinais. A métrica correlação mostra o quanto um sinal é correlacionado com o outro. A norma  $H_2$  corresponde à área sob a curva do sinal e a norma  $H_\infty$  corresponde ao maior pico do sinal.

Após o cálculo das métricas para todos os danos, foi desenvolvido no MATLAB® versão R2013a os algoritmos de aprendizado de máquina não-supervisionado K-Means e propagação de afinidade e também foi testado no toolbox Weka o algoritmo K-Means.

Para melhor entendimento dos resultados, a tabela 1 mostra a equivalência entre os números e os caminhos.

Tabela 1 – Descrição dos caminhos gerados a partir da rede de atuadores/sensores piezelétricos (continua)

<b>Número</b>	<b>CAMINHOS</b>	<b>ATUADORES</b>	<b>SENSORES</b>
1	P12	1	2
2	P13	1	3
3	P14	1	4
4	P15	1	5
5	P16	1	6
6	P17	1	7
7	P18	1	8
8	P19	1	9
9	P21	2	1
10	P23	2	3
11	P24	2	4
12	P25	2	5
13	P26	2	6
14	P27	2	7
15	P28	2	8
16	P29	2	9
17	P31	3	1
18	P32	3	2
19	P34	3	4
20	P35	3	5
21	P36	3	6
22	P37	3	7

Tabela 1 – Descrição dos caminhos gerados a partir da rede de atuadores/sensores piezelétricos (continuação)

23	P38	3	8
24	P39	3	9
25	P41	4	1
26	P42	4	2
27	P43	4	3
28	P45	4	5
29	P46	4	6
30	P47	4	7
31	P48	4	8
32	P49	4	9
33	P51	5	1
34	P52	5	2
35	P53	5	3
36	P54	5	4
37	P56	5	6
38	P57	5	7
39	P58	5	8
40	P59	5	9
41	P61	6	1
42	P62	6	2
43	P63	6	3
44	64	6	4
45	P65	6	5
46	P67	6	7
47	P68	6	8
48	P69	6	9
49	P71	7	1
50	P72	7	2
51	P73	7	3
52	P74	7	4
53	P75	7	5
54	P76	7	6
55	P78	7	8
56	P79	7	9
57	P81	8	1
58	P82	8	2
59	P83	8	3
60	P84	8	4
61	P85	8	5
62	P86	8	6
63	P87	8	7
64	P89	8	9

Tabela 1 – Descrição dos caminhos gerados a partir da rede de atuadores/sensores piezelétricos (conclusão)

65	P91	9	1
66	P92	9	2
67	P93	9	3
68	P94	9	4
69	P95	9	5
70	P96	9	6
71	P97	9	7
72	P98	9	8

Fonte: Próprio autor.

Como a placa tem 9 atuadores e 9 sensores e o sistema adotado é o pitch-catch, isto é, excita com um transdutor e lê com todos os outros, há possibilidade de 72 leituras. Portanto, o número 1 (nas figuras do capítulo 4) significa  $P_{12}$ , o número 2 (nas figuras do capítulo 4) significa  $P_{13}$ , o número 3 (nas figuras do capítulo 4) significa  $P_{14}$ , e assim sucessivamente.

Foi implementado os algoritmos K-Means com pré-determinação do número de cluster e com todas as métricas para cada situação com dano e propagação de afinidade sem pré-determinação do número de cluster tendo como entrada a matriz de similaridade, sendo determinado manualmente o parâmetro de clusterização para cada situação de dano com as métricas separadamente. Também foi testado o algoritmo K-Means na toolbox Weka para verificar como os dados se comportavam.


## 4 RESULTADOS EXPERIMENTAIS

As medidas experimentais utilizadas neste capítulo foram obtidas por Rosa (2016), conforme informado anteriormente. Este estudo de monitoramento estrutural visa localizar danos em estruturas aeronáuticas em situações práticas, isto é, quando não se conhece os sinais com todos os tipos de danos e quando não se tem um modelo onde seria possível obter todas as situações de dano. Os sinais analisados consideram apenas o primeiro pacote (*first packet*), pois é a parte do sinal que melhor representa as alterações devido ao dano.

Após a definição do primeiro pacote para todos os caminhos foram implementadas as métricas Pico, RMSD, Correlação, normas  $H_2$  e  $H_\infty$  para os sinais sem dano (baseline) e o sinal que se deseja analisar. As métricas devem ser sensíveis as variações dos sinais e, portanto, representar quais caminhos possuem maiores índices devido a interferência do dano. Ressaltando que as métricas representam o sinal no domínio em frequência em um escalar, facilitando assim a manipulação dos dados. Este trabalho não teve o objetivo de verificar quais as métricas mais sensíveis e sim utilizar as métricas mais comuns para localização de danos usando ondas de Lamb.

As figuras 22 a 26 mostram as métricas para o dano 1. A figura 22 mostra que os caminhos (8,1), (1,8), (4,9), (9,4), (5,7), (7,5) e (7,6) possuem maiores valores para a métrica pico máximo referente ao dano 1. Nestas figuras, a coordenada x mostra os sensores, a coordenada y os atuadores e a coordenada z o valor da métrica. A posição dos danos foi mostrada na figura 15.


Figura 21 - Métrica pico máximo para o dano 1



Fonte: Próprio autor.

A figura 23 mostra que os caminhos (1,8), (8,1), (6,7), (4,9), (7,6) e (8,4) possuem maiores valores para a métrica RMSD referente ao dano1.

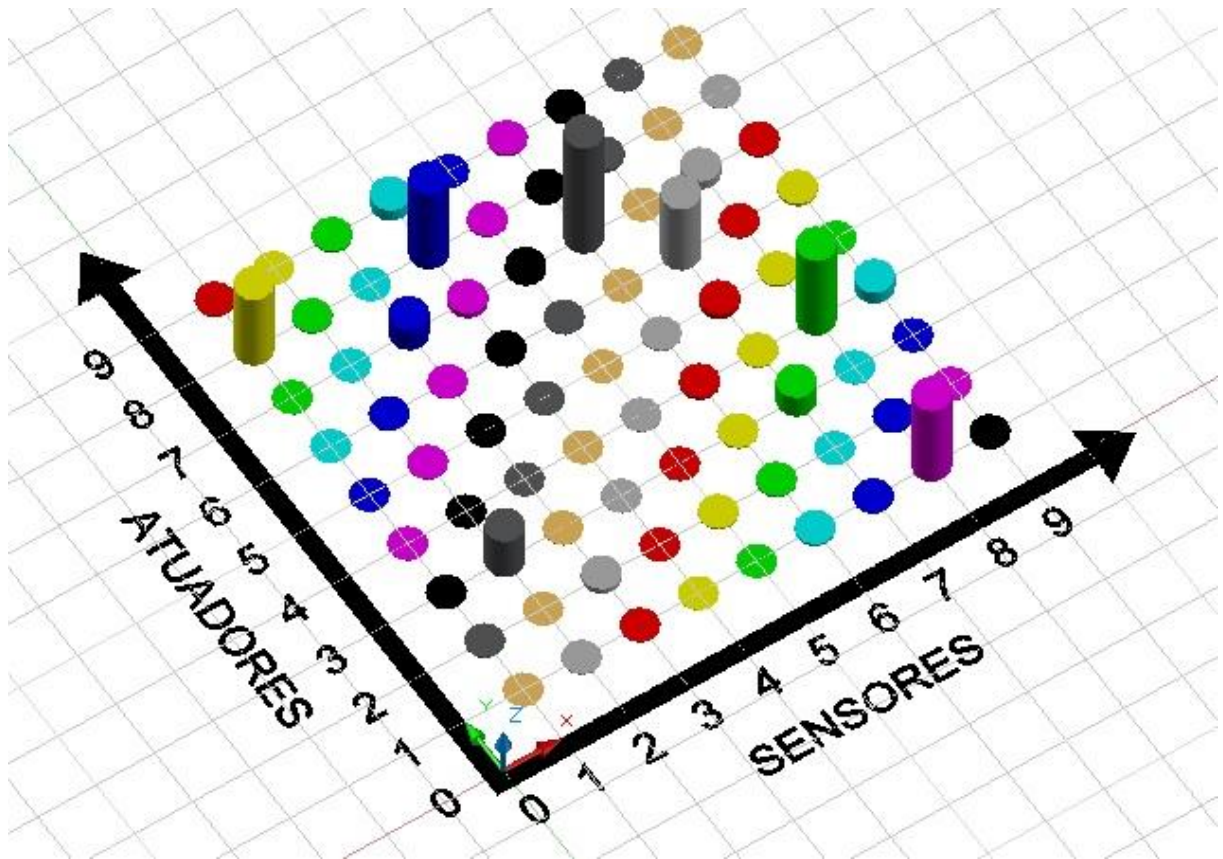
Figura 22 - Métrica RMSD para o dano 1



Fonte: Próprio autor.

A figura 24 mostra que os caminhos (1,8), (8,1), (6,7), (7,6), (4,8) e (8,4), possuem maiores valores na métrica correlação referente ao dano 1.

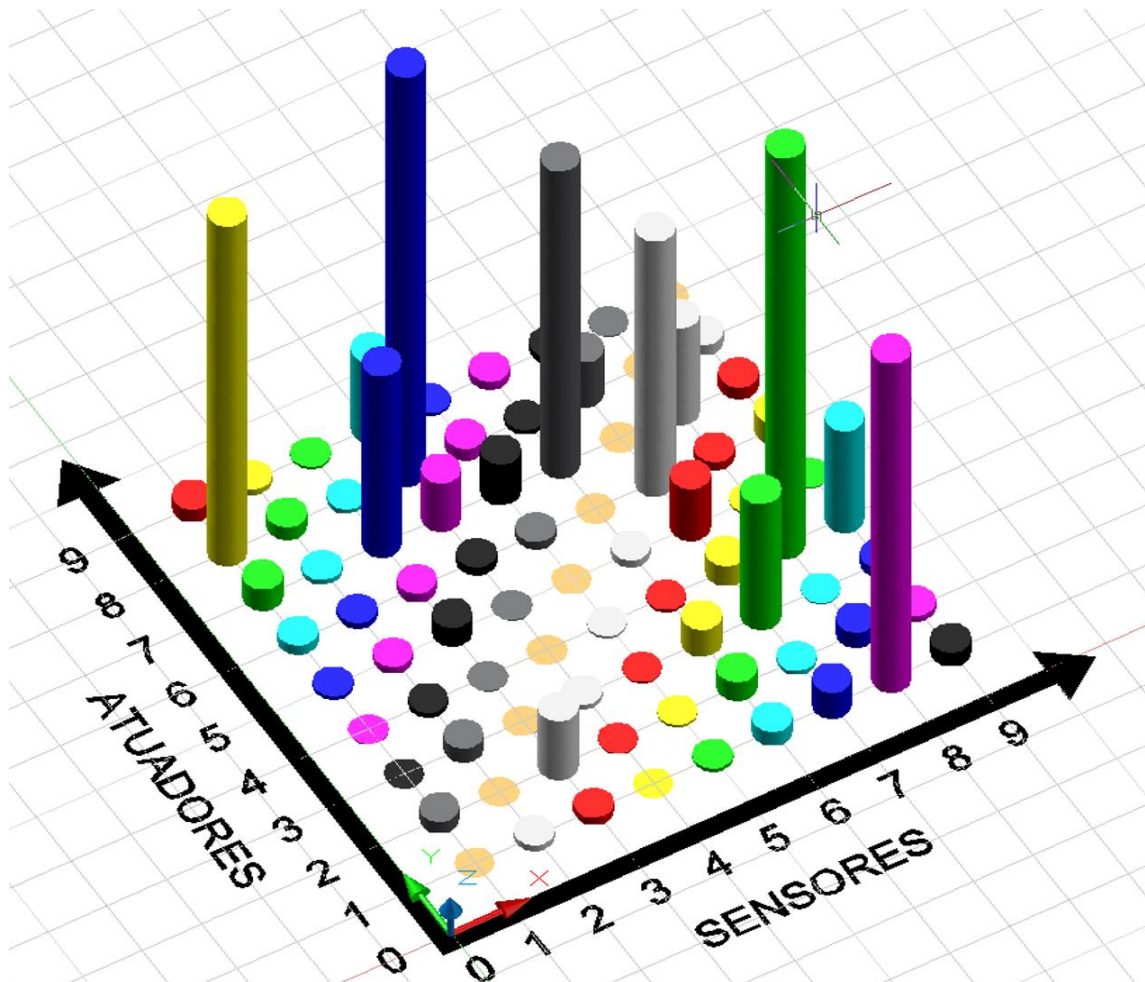
Figura 23 - Métrica correlação para o dano 1



Fonte: Próprio autor.

A figura 25 mostra que os caminhos (1,8), (8,1), (3,7), (7,3), (4,8), (8,4), (6,7) e (7,6) possuem maiores valores na métrica da norma H2 referente ao dano 1.

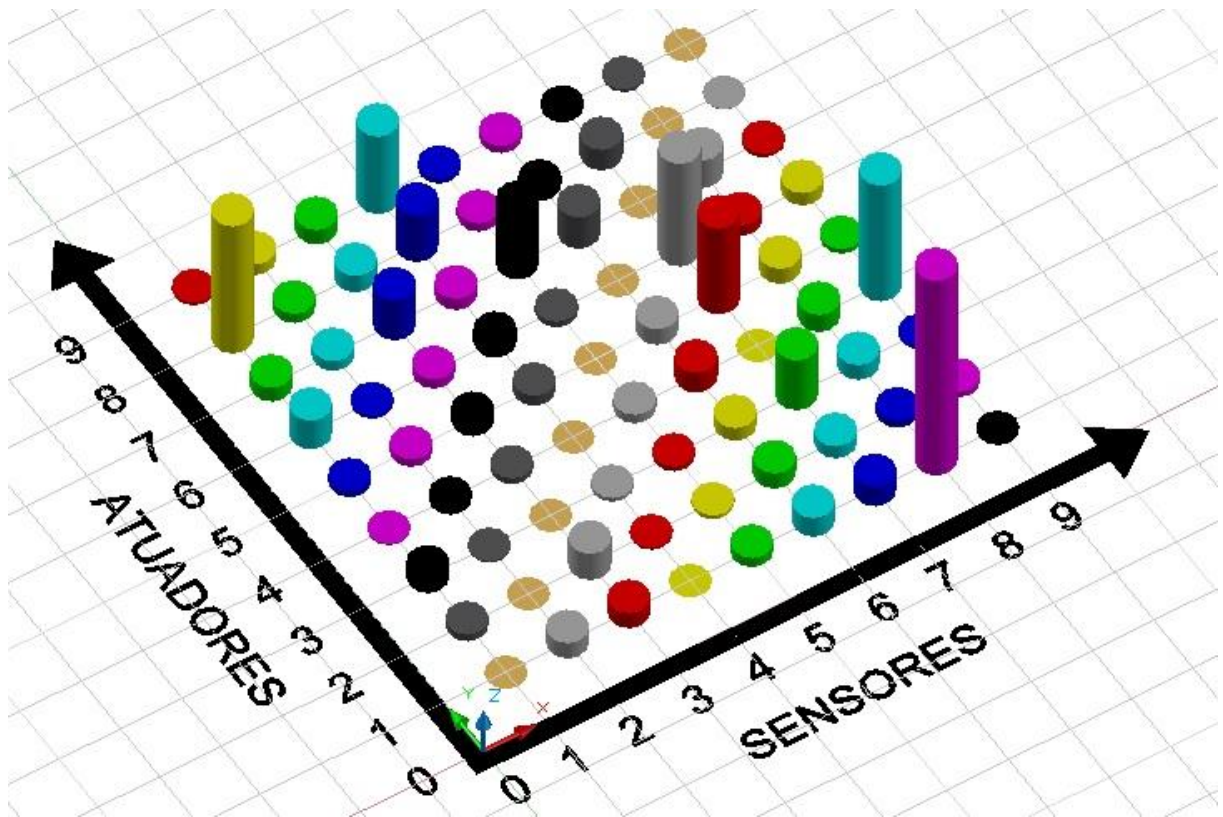
Figura 24 - Métrica da norma H2 para o dano 1



Fonte: Próprio autor.

A figura 26 mostra que os caminhos (8,1), (1,8), (4,9), (9,4), (5,7), (7,5) e (7,6) possuem maiores valores na métrica da norma  $H^\infty$  referente ao dano 1.




Figura 25 - Métrica da norma  $H^\infty$  dano 1

Fonte: Próprio autor.

O algoritmo K-Means foi implementado usando as cinco métricas para todos os danos. O algoritmo K-Means classificou os dados em dois clusters (sem defeito e com defeito). O eixo x corresponde aos números (caminhos) e o eixo y corresponde ao número de cluster pré-definido.

Os pontos representados por asterisco (\*) representam os caminhos, cada conjunto de asteriscos representam um cluster, ou seja, há formação de dois clusters. A figura 27 mostra o resultado para o dano 1, onde um cluster representa os caminhos com dano e outro cluster representa os caminhos sem dano. O cluster com dano é representado pelos caminhos: (1,8), (3,7), (3,9), (4,8), (4,9), (6,1), (6,2), (6,3), (6,4), (6,7), (6,9), (7,3), (7,5), (7,6), (8,1), (8,4), e (9,4).


Figura 27 - Resultado do algoritmo K-Means considerando as cinco métricas referente ao dano 1.



Fonte: Próprio autor.

Para melhor visualização, a figura 28 mostra os caminhos que foram identificados com dano no algoritmo K-Means, onde a posição do dano 1 é representada por um círculo vermelho.


Figura 26 - Caminhos que foram identificados com dano no algoritmo K-Means referente ao dano 1.



Fonte: Próprio autor.

As figuras 29 a 33 mostram as métricas para o dano 2. A figura 29 mostra que os caminhos (3,6), (6,3), (3,9), (9,3) possuem maiores valores na métrica pico máximo referente ao dano 2.


Figura 29 - Métrica pico máximo para o dano 2



Fonte: Próprio autor.

A figura 30 mostra que os caminhos (6,3), (3,6), (9,3) e (3,9) possuem maiores valores na métrica RMSD referente ao dano 2.


Figura 27 - Métrica RMSD para o dano 2



Fonte: Próprio autor.

A figura 31 mostra os que caminhos (3,6), (6,3), (3,9) e (9,3) possuem maiores valores na métrica correlação referente ao dano 2.


Figura 28 - Métrica correlação para o dano 2



Fonte: Próprio autor.


A figura 32 mostra que os caminhos (6,3), (3,6), (9,3) e (3,9) possuem maiores valores na métrica da norma H2 referente ao dano 2.

Figura 29 - Métrica da norma H2 para o dano 2



Fonte: Próprio autor.


A figura 33 mostra que os caminhos (6,3), (3,9), (9,3) e (3,6) possuem maiores valores na métrica da norma  $H^\infty$  referente ao dano 2.

Figura 30 - Métrica da norma  $H^\infty$  dano 2

Fonte: Próprio autor.

A figura 34 mostra o resultado do algoritmo K-Means implementado referente ao dano 2, onde um cluster representa os caminhos com dano e outro cluster representa os caminhos sem dano. O cluster com dano é representado pelos caminhos: (3,6), (3,9), (6,3) e (9,3).


Figura 31 - Resultado algoritmo K-Means considerando as cinco métricas referente ao dano 2.



Fonte: Próprio autor.

Para melhor visualização, a figura 35 mostra os caminhos que foram identificados com dano no algoritmo K-Means e a posição do dano 2 é representada por um círculo vermelho.

Figura 32 - Caminhos que foram identificados com dano no algoritmo K-Means referente ao dano 2.




Fonte: Próprio autor.



As figuras 36 a 40 mostram as métricas para o dano 3. A figura 36 mostra que os caminhos (4,3), (3,4), (7,2), (2,7) (1,8) e (8,1) possuem maiores valores na métrica pico máximo referente ao dano 3.


Figura 33 - Métrica pico máximo para o dano 3



Fonte: Próprio autor.

A figura 37 mostra que os caminhos (8,1), (1,8), (3,4) e (4,3) possuem maiores valores na métrica RMSD referente ao dano 3.


Figura 37 - Métrica RMSD para o dano 3



Fonte: Próprio autor.

A figura 38 mostra que os caminhos (3,4), (4,3), (1,8) e (8,1) possuem maiores valores na métrica correlação referente ao dano 3.


Figura 34 - Métrica correlação para o dano 3



Fonte: Próprio autor.


A figura 39 mostra que os caminhos (3,4) (4,3), (1,8), (8,1), (2,7) e (7,2) possuem maiores valores na métrica da norma H2 referente ao dano 3.

Figura 39 - Métrica da norma H2 para o dano 3



Fonte: Próprio autor.


A figura 40 mostra que os caminhos (1,8), (8,1), (4,3), (3,4), (7,2) e (2,7) possuem maiores valores na métrica da norma  $H^\infty$  referente ao dano 3.

Figura 35 - Métrica da norma  $H^\infty$  dano 3

Fonte: Próprio autor.

A figura 41 mostra o resultado do algoritmo K-Means implementado referente ao dano 3, onde um cluster representa os caminhos com dano e outro cluster representa os caminhos sem dano. O cluster com dano é representado pelos caminhos: (1,5), (1,8), (1,9), (2,4), (2,7), (3,4), (4,2), (4,3), (5,1), (6,4), (6,7), (7,2), (7,6), (8,1) e (9,1).


Figura 36 - Resultado algoritmo K-Means considerando as cinco métricas referente ao dano 3.



Fonte: Próprio autor.

Para melhor visualização, a figura 42 mostra os caminhos que foram identificados com dano no algoritmo K-Means e a posição do dano 3 é representada por um círculo vermelho.


Figura 37 - Caminhos que foram identificados com dano no algoritmo K-Means referente ao dano 3.



Fonte: Próprio autor.

As figuras 43 a 47 mostram as métricas para o dano 4. A figura 43 mostra que os caminhos (1,9), (9,1), (2,9), (9,2), (9,4), (4,9), (7,9) e (9,7) possuem maiores valores na métrica pico máximo referente ao dano 4.


Figura 38 - Métrica pico máximo para o dano 4



Fonte: Próprio autor.

A figura 44 mostra que os caminhos (9,1), (1,9), (2,9), (9,2), (4,9), (9,4), (9,5), (5,9), (6,9) e (9,6) possuem maiores valores na métrica RMSD referente ao dano 4.

Figura 39 - Métrica RMSD para o dano 4




Fonte: Próprio autor.

A figura 45 mostra que os caminhos (9,1), (1,9), (2,9), (9,2), (4,9), (9,4), (9,5) e (5,9) possuem maiores valores na métrica correlação referente ao dano 4.




Figura 40 - Métrica correlação para o dano 4



Fonte: Próprio autor.


A figura 46 mostra os que caminhos (1,9), (9,1), (2,9), (9,2), (4,9) (9,4), (5,9) e (9,5) possuem maiores valores na métrica da norma H2 referente ao dano 4.

Figura 41 - Métrica da norma H2 para o dano 4



Fonte: Próprio autor.


A figura 47 mostra que os caminhos (1,9), (9,1), (2,9), (9,2), (4,9), (9,4), (7,9) e (9,7) possuem maiores valores na métrica da norma  $H^\infty$  referente ao dano 4.

Figura 42 - Métrica da norma  $H^\infty$  dano 4

Fonte: Próprio autor.

A figura 48 mostra o resultado do algoritmo K-Means implementado referente ao dano 4, onde um cluster representa os caminhos com dano e outro cluster representa os caminhos sem dano. O cluster com dano é representado pelos caminhos: (1,9), (2,9), (4,9), (5,9), (6,9), (9,1), (9,2), (9,4), (9,5) e (9,6).


Figura 43 - Resultado algoritmo K-Means considerando as cinco métricas referente ao dano 4.



Fonte: Próprio autor.

Para melhor visualização, a figura 49 mostra os caminhos que foram identificados com dano no algoritmo k-Means e a posição do dano 4 é representada por um círculo vermelho.


Figura 49 - Caminhos que foram identificados com dano no algoritmo K-Means referente ao dano 4.



Fonte: Próprio autor.

As figuras 50 a 54 mostram as métricas para o dano 5. A figura 50 mostra que os caminhos (4,6), (6,4), (2,9), (9,2), (8,3) e (3,8) possuem maiores valores na métrica pico máximo referente ao dano 5.


Figura 50 - Métrica pico máximo para o dano 5



Fonte: Próprio autor.

A figura 51 mostra que os caminhos (2,9), (9,2), (3,8), (8,3), (5,6), (6,5), (6,4) e (4,6) possuem maiores valores na métrica RMSD referente ao dano 5.


Figura 44 - Métrica RMSD para o dano 5



Fonte: Próprio autor.

A figura 52 mostra que os caminhos (2,9), (9,2), (3,8), (8,3), (4,6), (6,4), (5,6) e (6,5) possuem maiores valores na métrica correlação referente ao dano 5.


Figura 45 - Métrica correlação para o dano 5



Fonte: Próprio autor.

A figura 53 mostra que os caminhos (2,9), (9,2), (3,8), (8,3), (6,4), (4,6), (5,6) e (6,5) possuem os maiores valores na métrica da norma H2 referente ao dano 5.


Figura 46 - Métrica da norma H2 para o dano 5



Fonte: Próprio autor.

A figura 54 mostra que os caminhos (2,9), (9,2), (3,8), (8,3), (4,6), (6,4) (5,6) e (6,5) possuem os maiores valores na métrica da norma  $H^\infty$  referente ao dano 5.




Figura 47 - Métrica da norma  $H^\infty$  dano 5

Fonte: Próprio autor.

A figura 55 mostra o resultado do algoritmo K-Means implementado referente ao dano 5, onde um cluster representa os caminhos com dano e outro cluster representa os caminhos sem dano. O cluster com dano é representado pelos caminhos: (2,9), (3,8), (4,6), (5,6), (6,4), (6,5), (6,7), (7,6), (8,3) e (9,2).


Figura 48 - Resultado algoritmo K-Means considerando as cinco métricas referente ao dano 5.



Fonte: Próprio autor.

Para melhor visualização, a figura 56 mostra os caminhos que foram identificados com dano no algoritmo K-Means e a posição do dano 5 é representada por um círculo vermelho.

Figura 49 - Caminhos que foram identificados com dano no algoritmo K-Means referente ao dano 5.




Fonte: Próprio autor.


Os resultados do algoritmo K-Means implementado não foram bons para os danos 1 e 3. Sendo assim, foi testado o mesmo algoritmo K-Means no toolbox Weka para todas as métricas em todas as situações com dano para verificar como os dados se comportam.

A figura 57a mostra o resultado do dano 1, 57b mostra o resultado do dano 2, 57c mostra o resultado do dano 3, 57d mostra o resultado do dano 4 e 57e mostra o resultado do dano 5.


Figura 50 - Resultados do algoritmo K-Means considerando as cinco métricas simultaneamente referente aos danos: (A) dano 1, (B) dano 2, (C) dano 3, (D) dano 4 e (E) dano 5




(C)



(D)



(E)



Fonte: Próprio autor.

Para comparação dos algoritmo K-Means implementado em relação ao K-Means na toolbox Weka os resultados estão descritos na Tabela 2.

Tabela 2 – Números de Caminhos em cada Cluster

Danos	Cluster	Caminhos	K-Means (Matlab)		K-Means (Weka)	
			Padrão	%	Padrão	%
Dano 1	1	72	16	22,2	6	8,3
Dano 1	2	72	56	77,7	66	91,6
Dano 2	1	72	4	5,5	4	5,5
Dano 2	2	72	68	94,4	68	94,4
Dano 3	1	72	15	20,8	4	5,5
Dano 3	2	72	57	79,1	68	94,4
Dano 4	1	72	10	13,8	8	11,1
Dano 4	2	72	62	86,1	64	88,8
Dano 5	1	72	10	13,8	8	11,1
Dano 5	2	72	62	86,1	64	88,8

Fonte: Próprio autor.

Os resultados do algoritmo K-Means implementado com o toolbox Weka foram bem próximos para os danos 2, 4 e 5, porém não teve o mesmo sucesso para os danos 1 e 3. O toolbox Weka não permite alterações nas variáveis. Uma grande desvantagem deste algoritmo é a pré-determinação do número de clusters. Para sobrepor esta desvantagem, propõe-se implementar um algoritmo de aprendizado de máquina não-supervisionado com propagação de afinidades, onde não é necessário a definição do número de clusters.

O algoritmo com propagação de afinidades foi desenvolvido para todas as métricas separadamente em cada situação de dano.

A priori, para cada situação de dano foi definido como parâmetro de clusterização a mediana dos índices de cada métrica em 20% acima e 20% abaixo. Esta opção não se mostrou adequada.

Fez-se necessário realizar a análise de variabilidade dos índices de cada métrica e confirmando que existe uma alta variabilidade dos índices das métrica para

cada situação com dano, sendo impossível determinar o mesmo parâmetro de clusterização.


Então foi realizado o ajuste manual do parâmetro de clusterização por meio de tentativa e erro, sendo também ajustado o valor do lambda (porcentagem acima e abaixo do parâmetro de clusterização) para cada métrica em todas as situações com dano.

A determinação do número de clusters do algoritmo com propagação de afinidades é determinada pela matriz de similaridades, conforme pseudocódigo descrito na revisão bibliográfica.

No algoritmo com propagação de afinidades foi testado cada métrica separadamente para todas as situações com dano. Os pontos representados por asterisco (\*) representam os caminhos, cada conjunto de asteriscos representa um cluster. O algoritmo com propagação de afinidades classificou os dados em dois ou três clusters. O eixo x corresponde aos caminhos e o eixo y corresponde aos caminhos definidos como clusters e determinados pelas similaridades existente entre os dados.

A figura 58 mostra o resultado do algoritmo com propagação de afinidades para a métrica pico máximo referente ao dano 1. O cluster com dano é representado pelos caminhos: (1,8), (4,9), (5,7), (7,3), (7,5), (7,6), (8,1) e (9,4).


Figura 51 - Resultado do algoritmo com propagação de afinidades para métrica pico máximo referente ao dano 1



Fonte: Próprio autor.

Para melhor visualização, a figura 59 mostra os maiores índices da métrica pico máximo referente ao dano 1. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.


Figura 59 - Métrica pico máximo referente ao dano 1



Fonte: Próprio autor.

A figura 60 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica pico máximo. A posição do dano 1 é representada por um círculo vermelho.


Figura 52 - Caminhos que foram identificados com dano no algoritmo propagação de afinidade referente ao dano 1.



Fonte: Próprio autor.

A figura 61 mostra o resultado do algoritmo com propagação de afinidades para a métrica RMSD referente ao dano 1. O cluster com dano é representado pelos caminhos: (1,8), (4,8), (6,7), (7,6), (8,1) e (8,4). Na figura 61, verifica-se que o algoritmo identificou 3 clusters. Isto ocorre devido a variabilidade dos índices. Via de regra, os índices são maiores para os caminhos que interceptam o dano e menores para os caminhos mais distantes dos danos. No entanto, os sinais também variam, embora em menor intensidade, para caminhos próximos aos danos. Nestes casos o algoritmo que trabalha com propagação de afinidades identifica três clusters.

Figura 53 - Resultado do algoritmo com propagação de afinidades para a métrica RMSD referente ao dano 1




Fonte: Próprio autor.

Para melhor visualização, a figura 62 mostra os maiores índices da métrica RMSD referente ao dano 1. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.




Figura 54 - Métrica RMSD referente ao dano 1



Fonte: Próprio autor.

A figura 63 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica RMSD. A posição do dano 1 é representada por um círculo vermelho.

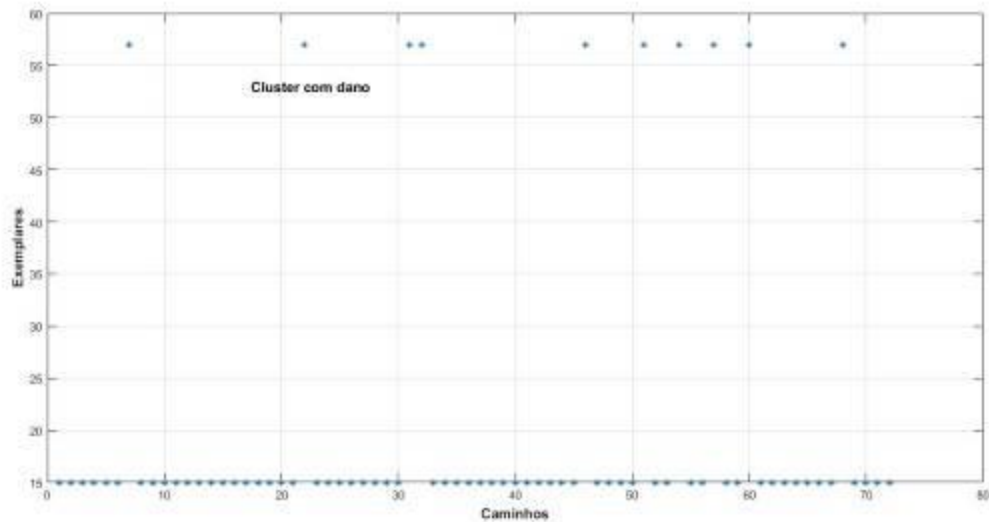
Figura 55 - Caminhos que foram identificados com dano no algoritmo propagação de afinidades referente ao dano 1.



Fonte: Próprio autor.

A figura 64 mostra o resultado do algoritmo com propagação de afinidades para a métrica correlação referente ao dano 1. O cluster com dano é representado pelos caminhos: (1,8), (3,7), (4,8), (4,9), (6,7), (7,3), (7,6), (8,1), (8,4) e (9,4).


Figura 56 - Resultado algoritmo com propagação de afinidades para a métrica correlação referente ao dano 1



Fonte: Próprio autor.

Para melhor visualização, a figura 65 mostra os maiores índices da métrica correlação referente ao dano 1. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.


Figura 57 - Métrica correlação referente ao dano 1



Fonte: Próprio autor.

A figura 66 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica correlação. A posição do dano 1 é representada por um círculo vermelho.


Figura 58 - Caminhos que foram identificados com dano no algoritmo propagação de afinidade referente ao dano 1.



Fonte: Próprio autor.

A figura 67 mostra o resultado do algoritmo com propagação de afinidades para a métrica da norma H2 referente ao dano 1. O cluster com dano é representado pelos caminhos: (1,8), (3,2), (3,7), (4,8), (4,9), (6,7), (7,3), (7,6), (8,1), (8,4), (8,7) e (9,4).


Figura 59 - Resultado do algoritmo com propagação de afinidades para a métrica da norma H2 referente ao dano 1



Fonte: Próprio autor.

Para melhor visualização, a figura 68 mostra os maiores índices da métrica da norma H2 referente ao dano 1. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.


Figura 60 - Métrica da norma H2 referente ao dano 1



Fonte: Próprio autor.

A figura 69 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica H2. A posição do dano 1 é representada por um círculo vermelho.


Figura 69 - Caminhos que foram identificados com dano no algoritmo propagação de afinidade referente ao dano 1.



Fonte: Próprio autor.

A figura 70 mostra o resultado do algoritmo com propagação de afinidades para métrica da norma  $H^\infty$  referente ao dano 1. O cluster com dano é representado pelos caminhos: (1,8), (4,9), (5,7), (7,3), (7,5), (7,6), (8,1) e (9,4).


Figura 61 - Resultado algoritmo com propagação de afinidades para a métrica da norma  $H^\infty$  referente ao dano 1



Fonte: Próprio autor.

Para melhor visualização, a figura 71 mostra os maiores índices da métrica da norma  $H^\infty$  referente ao dano 1. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.


Figura 62 - Métrica da norma  $H^\infty$  referente ao dano 1



Fonte: Próprio autor.

A figura 72 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica  $H^\infty$ . A posição do dano 1 é representada por um círculo vermelho.


Figura 63 - Caminhos que foram identificados com dano no algoritmo propagação de afinidade referente ao dano 1.



Fonte: Próprio autor.

A figura 73 mostra o resultado do algoritmo com propagação de afinidades para a métrica pico máximo referente ao dano 2. O cluster com dano é representado pelos caminhos: (1,6), (3,6), (3,8), (3,9), (6,3) e (9,3). Neste caso o algoritmo também identificou três clusters.


Figura 64 - Resultado algoritmo com propagação de afinidades para a métrica pico máximo referente ao dano 2



Fonte: Próprio autor.

Para melhor visualização, a figura 74 mostra os maiores índices da métrica pico máximo referente dano 2. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.


Figura 65 - Métrica pico máximo referente ao dano 2



Fonte: Próprio autor.

A figura 75 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica pico máximo. A posição do dano 2 é representada por um círculo vermelho.

Figura 66 - Caminhos que foram identificados com dano no algoritmo propagação de afinidade referente ao dano 2.




Fonte: Próprio autor.



A figura 76 mostra o resultado do algoritmo com propagação de afinidades para a métrica RMSD referente ao dano 2. O cluster com dano é representado pelos caminhos: (3,6), (3,9), (6,3) e (9,3).


Figura 67 - Resultado algoritmo com propagação de afinidades para a métrica RMSD referente ao dano 2



Fonte: Próprio autor.

Para melhor visualização, a figura 77 mostra os maiores índices da métrica RMSD referente ao dano 2. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.


Figura 68 - Métrica RMSD referente ao dano 2



Fonte: Próprio autor.

A figura 78 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica RMSD. A posição do dano 2 é representada por um círculo vermelho.


Figura 69 - Caminhos que foram identificados com dano no algoritmo propagação de afinidade referente ao dano 2.



Fonte: Próprio autor.

A figura 79 mostra o resultado do algoritmo com propagação de afinidades para a métrica correlação referente ao dano 2. O cluster com dano é representado pelo caminho: (3,6), (3,7), (3,9), (5,6), (6,3), (6,5), (6,7) e (9,3).


Figura 79 - Resultado algoritmo com propagação de afinidades para a métrica correlação referente ao dano 2



Fonte: Próprio autor.

Para melhor visualização, a figura 80 mostra os maiores índices da métrica correlação referente ao dano 2. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.


Figura 70 - Métrica correlação referente ao dano 2



Fonte: Próprio autor.

A figura 81 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica correlação. A posição do dano 2 é representada por um círculo vermelho.


Figura 71 - Caminhos que foram identificados com dano no algoritmo propagação de afinidade referente ao dano 2.



Fonte: Próprio autor.

A figura 82 mostra o resultado do algoritmo com propagação de afinidades para a métrica da norma H2 referente ao dano 2. O cluster com dano é representado pelos caminhos: (3,6), (3,9), (5,6), (6,3), (7,3), (8,7) e (9,3).


Figura 72 - Resultado algoritmo com propagação de afinidades para a métrica da norma H2 referente ao dano 2



Fonte: Próprio autor.

Para melhor visualização, a figura 83 mostra os maiores índices da métrica da norma H2 referente ao dano 2. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.


Figura 73 - Métrica da norma H2 referente ao dano 2



Fonte: Próprio autor.

A figura 84 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica da norma H2. A posição do dano 2 é representada por um círculo vermelho.


Figura 74 - Caminhos que foram identificados com dano no algoritmo propagação de afinidade referente ao dano 2.



Fonte: Próprio autor.

A figura 85 mostra o resultado do algoritmo com propagação de afinidades para a métrica da norma  $H^\infty$  referente ao dano 2. O cluster com dano é representado pelos caminhos: (1,6), (3,6), (3,8), (3,9), (6,3) e (9,3).


Figura 75 - Resultado algoritmo com propagação de afinidades para a métrica da norma  $H^\infty$  referente ao dano 2



Fonte: Próprio autor.

Para melhor visualização, a figura 86 mostra os maiores índices da métrica da norma  $H^\infty$  referente ao dano 2. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.


Figura 76 - Métrica da norma  $H^\infty$  referente ao dano 2



Fonte: Próprio autor.

A figura 87 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica da norma  $H^\infty$ . A posição do dano 2 é representada por um círculo vermelho.


Figura 77 - Caminhos que foram identificados com dano no algoritmo propagação de afinidade referente ao dano 2.



Fonte: Próprio autor.

A figura 88 mostra o resultado do algoritmo com propagação de afinidades para a métrica pico máximo referente ao dano 3. O cluster com dano é representado pelos caminhos: (2,7), (3,4), (4,3), (7,2) e (8,1).


Figura 78 - Resultado algoritmo com propagação de afinidades para a métrica pico máximo referente ao dano 3



Fonte: Próprio autor.

Para melhor visualização, a figura 89 mostra os maiores índices da métrica pico máximo referente ao dano 3. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.


Figura 89 - Métrica pico máximo referente ao dano 3



Fonte: Próprio autor.

A figura 90 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica pico máximo. A posição do dano 3 é representada por um círculo vermelho.

Figura 79 - Caminhos que foram identificados com dano no algoritmo propagação de afinidade referente ao dano 3.




Fonte: Próprio autor.



A figura 91 mostra o resultado do algoritmo com propagação de afinidades para a métrica RMSD referente ao dano 3. O cluster com dano é representado pelos caminhos: (1,8), (3,4), (4,3) e (8,1).


Figura 80 - Resultado algoritmo com propagação de afinidades para a métrica RMSD referente ao dano 3



Fonte: Próprio autor.

Para melhor visualização, a figura 92 mostra os maiores índices da métrica RMSD referente ao dano 3. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.


Figura 81 - Métrica RMSD referente ao dano 3



Fonte: Próprio autor.

A figura 93 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica RMSD. A posição do dano 3 é representada por um círculo vermelho.


Figura 82 - Caminhos que foram identificados com dano no algoritmo propagação de afinidade referente ao dano 3.



Fonte: Próprio autor.

A figura 94 mostra o resultado do algoritmo com propagação de afinidades para a métrica correlação referente ao dano 3. O cluster com dano é representado pelos caminhos: (1,8), (3,4), (4,3) e (8,1).


Figura 83 - Resultado algoritmo com propagação de afinidades para a métrica correlação referente ao dano 3



Fonte: Próprio autor.

A figura 95 mostra os maiores índices da métrica correlação referente ao dano 3. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.


Figura 84 - Métrica correlação referente ao dano 3



Fonte: Próprio autor.

A figura 96 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica correlação. A posição do dano 3 é representada por um círculo vermelho.


Figura 85 - Caminhos que foram identificados com dano no algoritmo propagação de afinidade referente ao dano 3.



Fonte: Próprio autor.

A figura 97 mostra o resultado do algoritmo com propagação de afinidades para a métrica da norma H2 referente ao dano 3. O cluster com dano é representado pelos caminhos: (1,5), (1,8), (1,9), (2,4), (2,7), (3,4), (3,7), (4,2), (4,3), (5,1), (7,2), (7,3), (8,1) e (9,1).

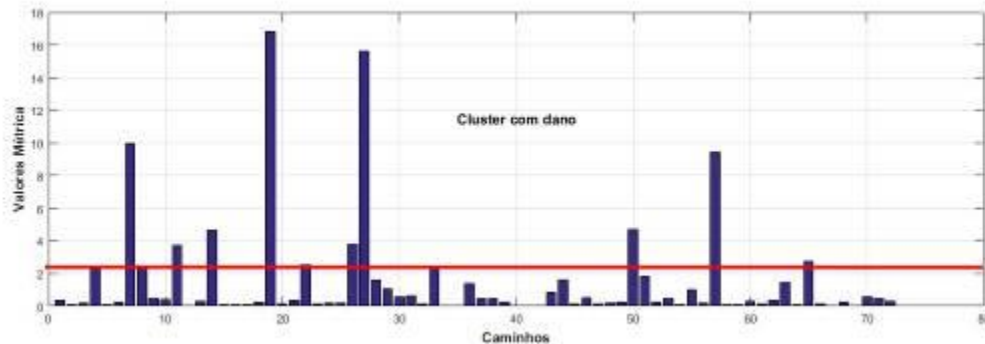
Figura 86 - Resultado algoritmo com propagação de afinidades para a métrica da norma H2 referente ao dano 3



Fonte: Próprio autor.

Para melhor visualização, a figura 98 mostra os maiores índices da métrica da norma H2 referente ao dano 3. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.


Figura 87 - Métrica da norma H2 referente ao dano 3



Fonte: Próprio autor.

A figura 99 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica da norma H2. A posição do dano 3 é representada por um círculo vermelho.


Figura 99 - Caminhos que foram identificados com dano no algoritmo propagação de afinidade referente ao dano 3.



Fonte: Próprio autor.

A figura 100 mostra o resultado do algoritmo com propagação de afinidades para a métrica da norma  $H^\infty$  referente ao dano 3. O cluster com dano é representado pelos caminhos: (2,7), (3,4), (4,3), (7,2) e (8,1).


Figura 88 - Resultado algoritmo com propagação de afinidades para a métrica da norma  $H^\infty$  referente ao dano 3



Fonte: Próprio autor.

Para melhor visualização, a figura 101 mostra os maiores índices da métrica da norma  $H^\infty$  referente ao dano. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.


Figura 89 - Métrica da norma  $H^\infty$  referente ao dano 3



Fonte: Próprio autor.

A figura 102 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica da norma  $H^\infty$ . A posição do dano 3 é representada por um círculo vermelho.


Figura 90 - Caminhos que foram identificados com dano no algoritmo propagação de afinidade referente ao dano 3.



Fonte: Próprio autor.

A figura 103 mostra o resultado do algoritmo com propagação de afinidades para a métrica pico máximo referente ao dano 4. O cluster com dano é representado pelos caminhos: (1,9), (4,9), (9,1) e (9,4).


Figura 103 - Resultado algoritmo com propagação de afinidades para a métrica pico máximo referente ao dano 4.



Fonte: Próprio autor.

Para melhor visualização, a figura 104 mostra os maiores índices da métrica pico máximo referente ao dano 4. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.

Figura 91 - Métrica pico máximo referente ao dano 4




Fonte: Próprio autor.

A figura 105 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica pico máximo. A posição do dano 4 é representada por um círculo vermelho.




Figura 92 - Caminhos que foram identificados com dano no algoritmo propagação de afinidade referente ao dano 4.



Fonte: Próprio autor.

A figura 106 mostra o resultado do algoritmo com propagação de afinidades para a métrica RMSD referente ao dano 4. O cluster com dano é representado pelos caminhos: (1,9), (2,9), (4,9), (5,9), (6,9), (9,1), (9,2), (9,4) e (9,5).


Figura 93 - Resultado algoritmo com propagação de afinidades para a métrica RMSD referente ao dano 4.



Fonte: Próprio autor.

Para melhor visualização, a figura 107 mostra os maiores índices da métrica RMSD referente ao dano 4. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.


Figura 94 - Métrica RMSD referente ao dano 4



Fonte: Próprio autor.

A figura 108 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica RMSD. A posição do dano 4 é representada por um círculo vermelho.


Figura 108 - Caminhos que foram identificados com dano no algoritmo propagação de afinidade referente ao dano 4.



Fonte: Próprio autor.

A figura 109 mostra o resultado do algoritmo com propagação de afinidades para a métrica correlação referente ao dano 4. O cluster com dano está representado pelos caminhos: (1,9), (2,9), (4,9), (5,9), (9,1), (9,2), (9,4) e (9,5).


Figura 95 - Resultado algoritmo com propagação de afinidades para a métrica correlação referente ao dano 4.



Fonte: Próprio autor.

Para melhor visualização, a figura 110 mostra os maiores índices da métrica correlação referente ao dano 4. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.


Figura 96 - Métrica correlação referente ao dano 4



Fonte: Próprio autor.

A figura 111 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica correlação. A posição do dano 4 é representada por um círculo vermelho.


Figura 97 - Caminhos que foram identificados com dano no algoritmo propagação de afinidade referente ao dano 4.



Fonte: Próprio autor.

A figura 112 mostra o resultado do algoritmo com propagação de afinidades para a métrica da norma H2 referente ao dano 4. O cluster com dano é representado pelos caminhos: (1,9), (4,9), (5,9), (9,1), (9,2), (9,4) e (9,5).


Figura 98 - Resultado algoritmo com propagação de afinidades para a métrica da norma H2 referente ao dano 4.



Fonte: Próprio autor.

Para melhor visualização, a figura 113 mostra os maiores índices da métrica da norma H2 referente ao dano 4. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.


Figura 99 - Métrica da norma H2 referente ao dano 4



Fonte: Próprio autor.

A figura 114 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica da norma H2. A posição do dano 4 é representada por um círculo vermelho.


Figura 100 - Caminhos que foram identificados com dano no algoritmo propagação de afinidade referente ao dano 4.



Fonte: Próprio autor.

A figura 115 mostra os resultados do algoritmo com propagação de afinidades para a métrica da norma  $H^\infty$  referente ao dano 4. O cluster com dano é representado pelos caminhos: (1,9), (4,9), (9,1) e (9,4).


Figura 101 - Resultado algoritmo com propagação de afinidades para a métrica da norma  $H^\infty$  referente ao dano 4.



Fonte: Próprio autor.

Para melhor visualização, a figura 116 mostra os maiores índices da métrica da norma  $H^\infty$  referente dano 4. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.


Figura 102 - Métrica da norma  $H^\infty$  referente ao dano 4



Fonte: Próprio autor.

A figura 117 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica  $H^\infty$ . A posição do dano 4 é representada por um círculo vermelho.


Figura 103 - Caminhos que foram identificados com dano no algoritmo propagação de afinidade referente ao dano 4.



Fonte: Próprio autor.

A figura 118 mostra o resultado do algoritmo com propagação de afinidades para a métrica pico máximo referente ao dano 5. O cluster com dano é representado pelos caminhos: (1,6), (2,9), (3,8), (4,6), (5,6), (6,1), (6,4), (6,5), (7,6), (8,3) e (9,2).


Figura 118 - Resultado algoritmo com propagação de afinidades para a métrica pico máximo referente ao dano 5.



Fonte: Próprio autor.

Para melhor visualização, a figura 119 mostra os maiores índices da métrica pico máximo referente ao dano 5. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.

Figura 104 - Métrica pico máximo referente ao dano 5




Fonte: Próprio autor.



A figura 120 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica pico máximo. A posição do dano 5 é representada por um círculo vermelho.


Figura 105 - Caminhos que foram identificados com dano no algoritmo propagação de afinidade referente ao dano 5.



Fonte: Próprio autor.

A figura 121 mostra o resultado do algoritmo com propagação de afinidades para a métrica RMSD referente ao dano 5. O cluster com dano é representado pelos caminhos: (2,9), (3,7), (3,8), (4,6), (4,7), (5,6), (6,4), (6,5), (6,7), (7,3), (7,6), (7,8), (8,3), (8,7) e (9,2).


Figura 106 - Resultado algoritmo com propagação de afinidades para a métrica RMSD referente ao dano 5.



Fonte: Próprio autor.

Para melhor visualização, a figura 122 mostra os maiores índices da métrica RMSD referente ao dano 5. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.


Figura 107 - Métrica RMSD referente ao dano 5



Fonte: Próprio autor.

A figura 123 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica RMSD. A posição do dano 5 é representada por um círculo vermelho.


Figura 123 - Caminhos que foram identificados com dano no algoritmo propagação de afinidade referente ao dano 5.



Fonte: Próprio autor.

A figura 124 mostra o resultado do algoritmo com propagação de afinidades para a métrica correlação referente ao dano 5. O cluster com dano é representado pelos caminhos: (2,9), (3,8), (4,6), (5,6), (6,4), (6,5), (8,3) e (9,2).


Figura 108 - Resultado algoritmo com propagação de afinidades para a métrica correlação referente ao dano 5.



Fonte: Próprio autor.

Para melhor visualização, a figura 125 mostra os maiores índices da métrica correlação referente ao dano 5. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.


Figura 109 - Métrica correlação referente ao dano 5



Fonte: Próprio autor.

A figura 126 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica correlação. A posição do dano 5 é representada por um círculo vermelho.


Figura 110 - Caminhos que foram identificados com dano no algoritmo propagação de afinidade referente ao dano 5.



Fonte: Próprio autor.

A figura 127 mostra o resultado do algoritmo com propagação de afinidades para a métrica da norma H2 do dano 5. O cluster com dano é representado pelos caminhos: (3,8), (4,6), (5,6), (6,4), (6,5) e (9,2).


Figura 111 - Resultado algoritmo com propagação de afinidades para a métrica da norma H2 referente ao dano 5.



Fonte: Próprio autor.

Para melhor visualização, a figura 128 mostra os maiores índices da métrica da norma H2 do dano. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.


Figura 112 - Métrica da norma H2 referente ao dano 5



Fonte: Próprio autor.

A figura 129 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica da norma  $H_2$ . A posição do dano 5 é representada por um círculo vermelho.


Figura 113 - Caminhos que foram identificados com dano no algoritmo propagação de afinidade referente ao dano 5.



Fonte: Próprio autor.

A figura 130 mostra o resultado do algoritmo com propagação de afinidades para a métrica da norma  $H_\infty$  referente ao dano 5. O cluster com dano é representado pelos caminhos: (1,6), (2,9), (3,8), (4,6), (5,6), (6,1), (6,4), (6,5), (7,6), (8,3) e (9,2).


Figura 114 - Resultado algoritmo com propagação de afinidades para a métrica da norma  $H^\infty$  referente ao dano 5.



Fonte: Próprio autor.

Para melhor visualização, a figura 131 mostra os maiores índices da métrica da norma  $H^\infty$  referente ao dano 5. A linha vermelha representa o parâmetro de clusterização do algoritmo com propagação de afinidades identificando os caminhos com dano.

Figura 115 - Métrica da norma  $H^\infty$  referente ao dano 5



Fonte: Próprio autor.

A figura 132 mostra os caminhos que foram identificados com dano no algoritmo com propagação de afinidades para a métrica  $H^\infty$ . A posição do dano 5 é representada por um círculo vermelho.





## 5 CONCLUSÕES E ETAPAS FUTURAS

Este trabalho propõe um método de monitoramento da integridade de estruturas utilizando algoritmo de aprendizado de máquina não-supervisionado.

As variações dos sinais foram monitoradas através das ondas de Lamb utilizando sensores e atuadores piezelétricos. O sinal de excitação foi o burst 5 (um seno janelado com cinco períodos) e para a saída foi considerado apenas o primeiro período de tempo do sinal (primeiro pacote). Este procedimento é feito para evitar que as reflexões nos sinais. Os sinais foram adquiridos e analisados apenas no domínio do tempo e se utilizou cinco métricas: Pico máximo do sinal, valor RMSD, Correlação, norma  $H_2$  e norma  $H_\infty$  comparando os sinais (com defeito e sem defeito). Após as implementações das métricas foi testado o algoritmo K-Means no matlab e no toolbox Weka. O resultado do algoritmo K-Means no toolbox Weka obteve melhores resultados do que o mesmo algoritmo K-Means implementado no matlab. Estes algoritmos são “pacotes” fechados e não se permite alteração das variáveis.

Para a implementação do algoritmo K-Means é necessário definir o número de clusters. Desde que a situação analisada é desconhecida, isto é, não se sabe se há ou não danos na estrutura, esta necessidade se torna um problema para o monitoramento de integridade das estruturas mecânicas na prática. Então, fez-se necessário implementar o algoritmo de aprendizado com propagação de afinidades sem pré-determinar o número de clusters.

O algoritmo com propagação de afinidades determina o número de clusters por meio das similaridades existentes entre os índices das métricas. Os parâmetros de clusterização foram definidos manualmente para cada métrica separadamente em todas as situações de dano, pois a variabilidade dos sinais é grande.

O algoritmo com propagação de afinidades se mostrou adequado para a metodologia proposta, mesmo considerando resultados não tão bons para alguns danos. Estes resultados podem ser melhorados, pois alguns parâmetros foram determinados manualmente. Existem algoritmos de otimização para obter estes parâmetros.

Conclui-se que o presente trabalho localizou e detectou os danos em diferentes situações com os algoritmos de aprendizado de máquina não-

supervisionado K-Means e com propagação de afinidades obtendo resultados que podem ser melhorados com auxílio de um algoritmo de otimização

## 5.1 ETAPAS FUTURAS

Como etapa futura sugere-se a implementação do algoritmo de otimização EDA (Estimation Distribution Algorithm) para determinar de forma automática os parâmetros de clusterização.

Sugere-se, também, a implementação de um algoritmo próprio K-Means, pois neste caso se tem o controle das variáveis.

Os dados experimentais utilizados foram obtidos de outro trabalho, onde não se tinha a situação de reparo, após o dano. Portanto, não foi possível testar uma situação desconhecida que não existia dano. Nos trabalhos futuros, sugere-se que seja incluída nas medidas estas situações sem dano.

## REFERÊNCIAS

ALPAYDIN, E. **Introduction to machine learning**. 2. ed. Cambridge: MIT, 2010. 30 p.

ANAYA, M; TIBADUIZA, A. D; POZO, F. A bioinspired methodology based on an artificial system for damage detection in structural health monitoring. **Shock & Vibration**, Nova Iorque, v. 10, n. 40, p. 1-2, maio 2015.

ARTERO, A. O. **Inteligência artificial teórica e prática**. São Paulo: Livraria da Física, 2009. 45 p.

BANKS, T. H; SMITH, C. R; WANG, Y. **Smart material structures modeling, estimation and control**. Paris: Masson, 1996. 55 p.

BARBER, D. **Bayesian reasoning and machine learning**. Cambridge: Cambridge University Press, 2012. 67 p.

BARBOSA, B. H. G. **Computação evolucionária e máquinas de comitê na identificação de sistemas não-lineares**. 2009. 224 f. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia Elétrica, Universidade Federal de Minas Gerais, Belo Horizonte, 2009.

DOEBLING, S. W.; FARRAR, C. R.; PRIME, M. B. A summary review of vibration-based damage identification methods. **The Shock and Vibration Digest**, Thousand Oaks, v. 30, n. 2, p. 91-105, 1998.

DOMINGOS, P. A few useful things to know about machine learning. **Communications of the ACM**, Seattle, v. 55, n. 10, p. 78-87, out. 2012.

FARRAR, C. R.; LIEVEN, N. A. J.; BEMENT, M. T. An introduction to damage prognosis. In: INMAN, D. J.; FARRAR, C. J.; LOPES JUNIOR, V.; STEFFEN JUNIOR, V. **Damage prognosis for aerospace, civil and mechanical systems**. England: John & Sons, 2005. p. 1-12.

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

FIGUEIREDO, E.; FARRAR, C. R.; PARK, G.; WORDEN K.; FIGUEIRAS, J. Machine learning algorithms for damage detection under operational and environmental variability. **Structural Health Monitoring**, England, v. 10, n. 45, 2010.

FLACH, P. **Machine learning: the art and science of algorithms that make sense of data**. Cambridge: Cambridge University Press, 2012. 36 p.

FRANCO, V. R. **Monitoramento da integridade em estruturas aeronáuticas**. 2009. 202 f. Dissertação (Mestrado Engenharia Mecânica) – Faculdade de Engenharia, Universidade Estadual Paulista – UNESP, Ilha Solteira, 2009.

GRAFF, K. F. **Wave motion in elastic solids**. New York: Oxford University Press, 1975. 649 p.

GONSALES, C.G. **Metodologias para reconhecimento de padrões em sistemas SHM utilizando a técnica da impedância eletromecânica (E/M)**. 2012. 116 f. Dissertação (Mestrado em Engenharia Mecânica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira 2012.

INMAM, D. J. Smart structures: example and new problems. In: CONGRESSO BRASILEIRO DE ENGENHARIA MECÂNICA – COBREM, 16., 2001, Uberlândia. **Anais...** Uberlândia: ABREM, 2001. p. 26-30.

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.

LOPES, I. L.; PINHEIRO, C. A. M.; SANTOS, F. A. O. **Inteligência artificial**. Rio de Janeiro: Elsevier, 2014. 12 p.

LOPES JUNIOR, V.; GYUHAE, P.; HARLEY, H. C.; DANIEL, J. I. Impedance based structural health monitoring with artificial neural networks. **Journal of Intelligence Material Systems and Structures**, England, v. 4, n. 15, p. 45, 2000.

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

MARQUI, C. R. **Modelagem de estruturas piezelétricas para aplicação em localização de falhas**. 2007. 220 f. Dissertação (Mestrado em Engenharia Mecânica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2007.

MICHELL, T. M. **Machine learning**. England: McGraw-Hill Education: ISE Editions, 1997. 37 p.

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

MONARD, M. C.; BARANAUSKAS, J. A. Conceitos de aprendizado de máquina. In: RESENDE, O. (Ed.). **Sistemas Inteligentes: fundamentos e aplicações**. São Paulo: Manole, 2003. p. 89-104.

RABELO, D. S., **Monitoramento de integridade estrutural baseado na técnica de impedância eletromecânica incorporando compensação do efeito da variação da temperatura**. 2014. 120 f. Dissertação (Mestrado Engenharia Mecânica) – Faculdade de Engenharia Mecânica de Uberlândia, Universidade Federal de Uberlândia, 2014.

ROSA, V. A.M; **Localização de danos em estruturas anisotrópicas com a utilização de ondas guiadas**. 2016. 81 f. Dissertação (Mestrado Engenharia Mecânica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2016.

RUSSEL, S.; NORVIG, P. **Inteligência artificial**. 3. ed. Rio de Janeiro: Elsevier, 2013. 67 p.

SANTANA, R; LARRANAGA, P; LOZANO, J. A. **Learning factorizations in estimation of distribution algorithms using affinity propagation**. England: Department of Computer Science and Artificial Intelligence University of the Basque Country, 2010. 70 p.

SMOLA, A. J.; VISHWANATHAN S. V. N. **Introduction to machine learning**. Cambridge: Cambridge University Press, 2008. 81 p.

STASZEWSKI, W.; BOLLER, C., TOMLINSON, R. G. **Health monitoring of aerospace structures: smart sensor technologies and signal processing**. Cambridge: Cambridge University Press, 2004. 288 p.

SOUZA, S. F. S; LIMA, P. A. F.; CHAVARETTE, R. F. Monitoring of structural integrity using unsupervised data clustering techniques. **International Journal of Pure and Applied Mathematics**, Cambridge, v. 104, n. 17, p. 119-133, 2015.

VENET, M. E.; PEREIRA, A. H. P. **Materiais e dispositivos piezelétricos: fundamentos e desenvolvimento**. São Carlos: ATCP do Brasil, 2004. 18 p. Apostila 1 do Curso. Disponível em: < <http://www.atcp.com.br/pt/produtos/ultra-som/ceramicas-piezoelétricas.html>>. Acesso em: 10 ago. 2015.

ZHONGQING SU et al. On selection of data fusion schemes for structural damage evaluation. **Structural Health Monitoring**, Cambridge, v. 8, n. 3, p. 223-241, 2009.