



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA MECÂNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AEROESPACIAL

LEANDRO THEODORO RAPOSO DE MELLO

**AVALIAÇÃO DA CLASSIFICAÇÃO DE DANOS PARA MONITORAMENTO DE
FALHAS ESTRUTURAIS EM SUPERFÍCIES AERONÁUTICAS UTILIZANDO
ONDAS GUIADAS**

Recife
2024

LEANDRO THEODORO RAPOSO DE MELLO

**AVALIAÇÃO DA CLASSIFICAÇÃO DE DANOS PARA MONITORAMENTO DE
FALHAS ESTRUTURAIS EM SUPERFÍCIES AERONÁUTICAS UTILIZANDO
ONDAS GUIADAS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Aeroespacial da Universidade Federal de Pernambuco, como requisito parcial para obtenção do título de mestre em Engenharia Aeroespacial.

Área de concentração: Ciências e Tecnologias Aeroespaciais

Orientador: Prof. Dr. Bráulio Silva Barros

Coorientador: Prof. Dr. Tiago Felipe de Abreu Santos

Recife

2024

Catálogo na fonte. UFPE – Biblioteca Central

Mello, Leandro Theodoro Raposo de
Avaliação da Classificação de Danos para Monitoramento de
Falhas Estruturais em Superfícies Aeronáuticas Utilizando Ondas
Guiadas / Leandro Theodoro Raposo de Mello. – Recife, 2024.
77 f.: il.

Orientação: Bráulio Silva Barros
Coorientação: Tiago Felipe de Abreu Santos
Dissertação (Mestrado) – Universidade Federal de Pernambuco,
Centro de Tecnologia e Geociências, Programa de Pós-Graduação em
Engenharia Aeroespacial, 2024.

1. Monitoramento de Integridade Estrutural. 2. Ondas de Lamb. 3.
Algoritmos de Aprendizagem de Máquina. 4. Extreme Gradient Boosting.
I. Barros, Bráulio Silva (Orientação). II. Santos, Tiago Felipe de Abreu
(Coorientação). III. Título.

UFPE-Biblioteca Central

LEANDRO THEODORO RAPOSO DE MELLO

**AVALIAÇÃO DA CLASSIFICAÇÃO DE DANOS PARA MONITORAMENTO DE
FALHAS ESTRUTURAIS EM SUPERFÍCIES AERONÁUTICAS UTILIZANDO
ONDAS GUIADAS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Aeroespacial da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Mestre em Engenharia Aeroespacial.

Área de concentração: Ciências e Tecnologias Aeroespaciais.

Aprovado em: 12 / 09 / 2023.

BANCA EXAMINADORA

Prof. Dr. Bráulio Silva Barros (Orientador)
Universidade Federal de Pernambuco - UFPE

Prof. Dr. Kleber Gonçalves Bezerra Alves (Examinador Interno)
Universidade Federal de Pernambuco - UFPE

Prof. Dr. Alex Oliveira Barradas Filho (Examinador Externo)
Universidade Federal do Maranhão - UFMA

Dedico este trabalho à minha amada família, alicerce sólido e constante fonte de amor e apoio.

AGRADECIMENTOS

Agradeço primeiramente e profundamente aos meus pais Angela Maria Theodoro Raposo de Mello e Arlindo Raposo de Mello Sobrinho. Seu amor incondicional e constante apoio foram pilares essenciais durante toda esta jornada acadêmica.

Ao Prof. Ph.D. Bráulio Silva Barros expresso minha gratidão pela orientação, paciência e suporte. Ao Prof. Dr. Tiago Felipe de Abreu Santos, agradeço pela amizade, expertise e didática. Obrigado por depositarem em mim a confiança de seguir com o tema de pesquisa da área SHM, foi desafiador e engrandecedor.

A colaboração do Prof. Dr. Alex Oliveira Barradas Filho e de Otávio Carvalho, da UFMA, foram fundamentais para o progresso e conclusão deste trabalho. Agradeço sinceramente pela generosidade em compartilhar conhecimento e pela disposição de construir este trabalho comigo.

Agradeço aos colegas de turma do Programa de Pós-Graduação em Engenharia Aeroespacial (PPGEA) - UFPE, em especial a amiga Lizié Almeida Sales, pela ajuda e cumplicidade nos desafios do mestrado.

Aos dedicados colegas pesquisadores dos grupos SOLDAMAT, SUPRAMMAT e DARTlab, meu agradecimento pela atmosfera colaborativa e pela extrema disposição em compartilhar conhecimento.

À FACEPE, agradeço o apoio financeiro.

Ao INTM, PPGEA - UFPE e à Rede Nordeste Aeroespacial (RNA), expresso meu reconhecimento pelo suporte e infraestrutura.

A todos que de alguma forma passaram pelo meu caminho e contribuíram nesta jornada, meu muito obrigado.

RESUMO

Estruturas aeronáuticas e aeroespaciais sofrem com o desgaste e eventos inesperados que podem afetar sua condição original e vida útil. A manutenção destes equipamentos é geralmente baseada em inspeções periódicas e ensaios não destrutivos (NDE) tradicionais. Diferentemente dos NDE, o monitoramento de integridade estrutural (SHM) foca na detecção e avaliação de danos estruturais de forma contínua, aumentando a segurança operacional e eficiência da manutenção. Neste contexto, técnicas de detecção de dano por ondas de Lamb são comumente empregadas e trazem grandes desafios na sua interpretação, um destes desafios é a classificação eficiente de diferentes tipos de dano, sendo importante para o direcionamento das ações de manutenção da estrutura. Neste estudo, o Método dos Elementos Finitos (FEM) é aplicado para simular de forma custo-eficiente diversos estados estruturais através da parametrização de características do dano. Uma Transformada Wavelet Contínua é aplicada aos sinais e a média dos dados de potência do sinal são discretizados, criando os chamados Damage Characteristic Points (DCP), que são utilizados como entrada para treinamento dos algoritmos de Machine Learning. Esta pesquisa investiga metodologias previamente propostas em literatura, expandindo o número de amostras previamente utilizadas e aplicando os DCPs de forma inédita para a classificação de diferentes tipos de dano em chapas metálicas finas. Os algoritmos de Redes Neurais Artificiais (ANN), Support Vector Machines (SVM), comumente utilizados em literatura, são empregados e é proposta a aplicação do algoritmo Extreme Gradient Boosting (XGBoost) como uma melhor opção para utilização em conjunto com DCPs. Os algoritmos são comparados no desempenho da classificação de três diferentes tipos de dano com localização e severidade variadas. Resultados mostram uma acurácia de até 95% do XGBoost frente a 91% e 82% da ANN e SVM, respectivamente, para o mesmo conjunto de dados.

Palavras-chave: Monitoramento de Integridade Estrutural. Método dos Elementos Finitos. Ondas de Lamb. Algoritmos de Aprendizagem de Máquina. Extreme Gradient Boosting.

ABSTRACT

Aeronautical and aerospace structures suffer from wear and unexpected events that can affect their original condition and service life. The maintenance of these equipment is generally based on periodic inspections and traditional non-destructive testing (NDT). Unlike NDT, Structural Health Monitoring (SHM) focuses on the continuous detection and assessment of structural damage, increasing operational safety and maintenance efficiency. In this context, Lamb wave damage detection techniques are commonly employed and pose significant challenges in their interpretation, with one of these challenges being the efficient classification of different types of damage, which is important for directing the maintenance actions on the structure. In this study, the Finite Element Method (FEM) is applied to cost-effectively simulate various structural states by parameterizing damage characteristics. Continuous Wavelet Transform is applied to the signals, and the mean power data of the signals are discretized, creating the so-called Damage Characteristic Points (DCPs), which are used as inputs for training Machine Learning algorithms. This research investigates previously proposed methodologies in the literature, expanding the number of previously used samples and applying DCPs in a novel way for the classification of different types of damage in thin metal plates. Artificial Neural Networks (ANN), Support Vector Machines (SVM), and the Extreme Gradient Boosting (XGBoost) algorithm are utilized for the classification of different types of damage in thin metal plates. These algorithms are compared in terms of their performance, specifically in classifying three different types of damage with varying location and severity. The results show that XGBoost achieves an accuracy of up to 95%, outperforming ANN and SVM, which achieve accuracies of 91% and 82% respectively, using the same dataset. This demonstrates that XGBoost is a promising option for utilizing in conjunction with DCPs for efficient damage classification in thin metal plates.

Keywords: Structural Health Monitoring. Finite Element Method. Lamb Waves. Machine Learning algorithms. Extreme Gradient Boosting.

LISTA DE ILUSTRAÇÕES

Figura 1 – Esquema ilustrativo de um sistema SHM Ativo. Em (a) o PZT atuador gera uma perturbação na placa que gera uma onda elástica, se propagando até chegar ao sensor. Em (b) um dano surge na placa e o sinal obtido é afetado por ele.....	19
Figura 2 - Ilustração dos diferentes níveis de um sistema SHM.....	23
Figura 3 - Exemplificação das diferentes características das ondas longitudinais (a) e transversais (b).....	24
Figura 4 – Tipos de propagação dos modos mecânicos de ondas.	26
Figura 5 – Diferenciação entre velocidade de fase e de grupo.	29
Figura 6 – Exemplo de gráfico de dispersão de ondas de Lamb para uma placa de alumínio.....	29
Figura 7 – Arranjo entre os átomos do PZT para (a) acima da temperatura de Curie e (b) abaixo da temperatura de Curie.....	31
Figura 8 – Paradigma SHM para equipamentos de usinagem.	37
Figura 9 Exemplificação de wavelets, a esquerda a wavelet tipo morlet e a direita do tipo chapéu mexicano.	38
Figura 10 – Taxonomia dos ramos da aprendizagem de máquina.....	41
Figura 11 – Fluxograma do processo de desenvolvimento de um modelo de ML para aprendizado supervisionado.....	42
Figura 12 – Separação da base de dados entre os conjuntos de treino, validação e teste, e implementação da validação cruzada <i>k-fold</i>	43
Figura 13 – Exemplo de matriz de confusão para base de dados com duas classes “1” e “0”.....	45
Figura 14 – Separação de classes com o hiperplano.....	48
Figura 15 – Uso da função kernel para separação de dados não linearmente separáveis.....	48
Figura 16 - Estrutura básica do neurônio.	49
Figura 17 – Estrutura básica do MLP.	50
Figura 18 - Esquema ilustrativo do funcionamento do XGBoost	51
Figura 19 – Fluxograma de etapas do estudo.	52
Figura 20 – Esquema ilustrativo da placa e transdutores do experimento. Dimensões em milímetros.....	54

Figura 21 – Curvas de dispersão com velocidade de grupo e fase em uma placa de 1,6 mm de espessura.	54
Figura 22 – Malha de elementos finitos no modelo. Em (a) destaque para o refino de malha próximo ao PZT e em (b) o refino próximo ao dano.	55
Figura 23 – Tipos de geometria de dano simulados no estudo.	57
Figura 24 – Intervalos de variação de localização e profundidade de dano.	58
Figura 25 – Etapas do processamento de sinais e extração de atributos empregadas no estudo.	60
Figura 26 - Fluxo de avaliação dos modelos de aprendizagem de máquina.	61
Figura 27 – Comparativo entre experimento e simulação da baseline para validação do modelo numérico.	65
Figura 28 – Vista do corte transversal da placa de alumínio com plot em setas mostrando de forma ampliada o deslocamento das ondas de Lamb no momento (a) 30 μ s (b) 50 μ s (c) 100 μ s (d) 150 μ s (e) 200 μ s (f) 250 μ s.	65
Figura 29 - Variação dos atributos para os diferentes tipos de dano.	66
Figura 30 - Matriz de confusão para o algoritmo SVM, em (a) resultados para o grid e em (b) para o Optuna.	67
Figura 31 – Matriz de confusão para o algoritmo MLP, em (a) resultados para o grid e em (b) para o Optuna.	68
Figura 32 – Matriz de confusão para o algoritmo XGBoost, em (a) resultados para o grid e em (b) para o Optuna.	68

LISTA DE TABELAS

Tabela 1 – Comparativo entre técnicas de Ensaios Não Destrutivos (END) e o monitoramento de Integridade estrutural (SHM).	21
Tabela 2 – Valores definidos para os parâmetros da malha.	55
Tabela 3 – Propriedades assumidas para os materiais.....	56
Tabela 4 – Tipos de geometria de dano simulados no estudo.	58
Tabela 5 - Variação dos hiperparâmetros para busca grid.....	62
Tabela 6 – Hiperparâmetros dos modelos.	62
Tabela 7 – p-valores para cada comparativo do teste de ponto com sinal de Wilcoxon.	67
Tabela 12 – Métricas de desempenho por classe para o algoritmo SVM.	69
Tabela 13 – Métricas de desempenho por classe para o algoritmo MLP.	69
Tabela 14 – Métricas de desempenho por classe para o algoritmo XGBoost.	70

SUMÁRIO

1 INTRODUÇÃO	14
1.1 Objetivo Geral	15
1.2 Objetivos específicos	16
2 REVISÃO BIBLIOGRÁFICA	17
2.1 Structural Health Monitoring (SHM) ou monitoramento de integridade estrutural	17
2.1.1 Diferenças entre END e SHM	21
2.1.2 Danos em superfícies aeronáuticas	22
2.1.3 Níveis de um sistema SHM	22
2.2 Ondas guiadas	24
2.2.1 Ondas de Lamb	25
2.2.2 Velocidade de fase e velocidade de grupo	29
2.3 Transdutores Piezoelétricos	30
2.3.1 Propriedades Piezoelétricas	31
2.3.2 Aspectos práticos da geração de ondas de Lamb com Transdutores Piezoelétricos	32
2.4 Modelagem computacional do processo de propagação de ondas de Lamb	33
2.4.1 Parâmetros do modelo FEM	34
2.5 Sistema de monitoramento baseado em dados	35
2.5.1 Criação de um sistema de monitoramento	35
2.5.1.1 Processamento de sinais	37
2.5.1.2 Seleção de atributos em sinais em função do tempo	39
2.5.2 Modelos inteligentes	40
2.5.2.1 Máquinas de vetores de suporte	47
2.5.2.2 Perceptron Multicamadas	49
2.5.2.3 Extreme Gradient Boosting	50
3. MATERIAIS E MÉTODOS	52
3.1 Criação de uma base de dados pelo método dos elementos finitos	53
3.1.1 Modelagem computacional da propagação das ondas de Lamb	53
3.1.2 Situações de dano	57
3.2 Desenvolvimento dos modelos para classificação de dano	59
3.2.1 Preparação dos atributos	59
3.2.2 Modelos para classificação de danos	60
4. RESULTADOS E DISCUSSÕES	64
4.1 Competência do modelo numérico para modelagem da propagação de ondas de Lamb	64
4.2 Desempenho dos modelos de classificação	66

CONCLUSÕES	72
REFERÊNCIAS	74

1 INTRODUÇÃO

A cadeia econômica mundial é significativamente dependente da indústria aeronáutica, seja para o transporte de passageiros, cargas comerciais e militares, agropecuária ou operações das mais diversas. Em algum grau os setores econômicos dependem da correta e eficiente operação dessas máquinas. Do funcionamento adequado desta indústria, a economia se beneficia de forma clara, uma vez que a circulação de pessoas, mercadorias, bens de consumo e tantos outros insumos, dinamiza o setor produtivo do país, gerando riqueza.

Neste sentido, quanto mais dinâmico este processo, melhor para os diversos setores, sobretudo nestes novos tempos, marcados pela velocidade das decisões dos agentes econômicos e pela escassez dos recursos naturais. Se uma aeronave permanecer inativa durante muito tempo, isso pode significar custos na casa dos milhares de dólares. Por conseguinte, operações de manutenção são fundamentais e precisam garantir a segurança operacional da aeronave, ao mesmo tempo em que demanda o mínimo possível de recursos financeiros e de tempo.

Ante esta realidade é que se verifica a importância da manutenção da frota, de modo a não travar a produção e, conseqüentemente, impactar a atividade econômica do país. Filosofias de manutenção tradicionais se apoiam em paradas previamente programadas ou reativas à alguma ocorrência. A inspeção de componentes estruturais é usualmente feita através de técnicas de ensaios não destrutivos (END) como o ensaio por ultrassom e, quando bem realizadas, conseguem detectar danos ainda em sua fase inicial de surgimento. Porém, esbarram no tempo de inspeção e dificuldades de acesso a localidades remotas das estruturas da aeronave, uma vez que seu manuseio, na maioria dos casos, está relacionado a um operador humano.

Com essas limitações em mente, e para criar alternativas mais efetivas em termos de custo e operação, a indústria aeronáutica há anos vem estudando metodologias de monitoramento de integridade estrutural, também conhecidas como SHM (*Structural Health Monitoring*). O SHM se propõe a realizar o diagnóstico, e por vezes prognóstico, da estrutura de forma contínua. Sistemas desse tipo também são usualmente concebidos para ficar permanentemente acoplados a estrutura, conseguindo alcançar lugares menos acessíveis para a equipe de manutenção e poupando tempo com a desmontagem de equipamentos para inspeções, além de

poder ativamente localizar e estimar a severidade e o tipo do dano, a depender do sistema.

Ao mesmo tempo em que o conceito e propósito do sistema SHM aparenta simplicidade, sua aplicação em situações reais de uso não é trivial e requer técnicas robustas de processamento de dados. Técnicas de SHM baseadas em vibração são extensivamente abordadas na literatura (GOMES *et al.*, 2019; MITRA; GOPALAKRISHNAN, S, 2016; RAGHAVAN; CESNIK, 2007), em especial com o uso de ondas de Lamb, devido ao seu potencial de monitorar grandes áreas e menor quantidade de sensores necessários para operacionalizar tais tarefas. Aplicações SHM com ondas de Lamb, esbarram na dificuldade de interpretação dos sinais, devido a existência de diversos modos de onda, conversão de modo, superposição de ondas espalhadas devido ao reflexo em bordas, entre outros fatores complicadores. Além disso, incertezas ambientais como mudanças de temperatura, esforço mecânico, ruído e interferências eletromagnéticas comumente causam alterações no sinal, que devem ser abordadas com técnicas adequadas de processamento.

Tendo em vista a importância do processo de detecção de danos, o estudo apresentado nesta dissertação se posiciona de forma a contribuir com o amadurecimento de técnicas de SHM, tanto na diminuição de incertezas para classificação do tipo de dano presente na estrutura quanto para modelagem numérica e simulação de casos de dano via Método dos Elementos Finitos (FEM). Este estudo também explora a eficiência do algoritmo de Extreme Gradient Boosting frente a outros já bem estabelecidos em literatura, que se mostra como uma alternativa promissora (SANTARSIERO *et al.*, 2021). A dissertação também apresenta um resumo bibliográfico sobre metodologias SHM, ondas de Lamb, transdutores piezoelétricos, bem como técnicas FEM e de aprendizagem de máquina aplicáveis a pesquisa aqui tratada.

1.1 OBJETIVO GERAL

Investigar a eficiência de algoritmos de aprendizagem de máquina na classificação de diferentes tipos de danos, a partir de sinais provindos de um sistema de monitoramento de integridade estrutural baseado em ondas guiadas.

1.2 OBJETIVOS ESPECÍFICOS

- Modelar computacionalmente no software COMSOL® Multiphysics a geração, propagação e recepção de ondas de Lamb, de forma a gerar um escopo de situações de dano do banco de dados a ser utilizado na construção do modelo de classificação;
- Validar condições de contorno do modelo computacional através de experimento de bancada com as mesmas características geométricas, visando investigar a confiabilidade e aplicabilidade do modelo FEM na simulação de estados estruturais danificados;
- Empregar técnicas de processamento de dados de forma a extrair características do sinal que suportem a interpretação do estado danificado;
- Treinar, validar e testar algoritmos de aprendizagem de máquina capazes de classificar o tipo de dano.

2 REVISÃO BIBLIOGRÁFICA

Esta seção visa introduzir conceitos fundamentais de um sistema de monitoramento de integridade estrutural baseado em vibração, demonstrando sua base teórica na propagação de ondas guiadas, transdutores piezoelétricos, tratamento de dados e interpretação através das métricas de dano e técnicas de Machine Learning (ML) e, por fim, a observação do fenômeno físico de geração e propagação de ondas pelo modelamento por elementos finitos.

2.1 STRUCTURAL HEALTH MONITORING (SHM) OU MONITORAMENTO DE INTEGRIDADE ESTRUTURAL

O monitoramento de integridade estrutural, ou *Structural Health Monitoring* (SHM) visa fornecer informações sobre o estado da estrutura de forma contínua em intervalos periódicos. Uma vez que o SHM se dedica a detecção e diagnóstico do dano, é primordial ter clara esta definição. Segundo os autores Worden e Farrar (2013), o dano, a despeito de ser intencional ou não, é uma avaria que incide sobre o sistema, suas interfaces e propriedades, afetando a capacidade e o desempenho deste mesmo sistema o que, dependendo da atividade que esteja sendo operada, pode causar sérios riscos aos seus usuários. No caso da indústria aeronáutica, os efeitos provenientes de danos estruturais podem ter sérias consequências materiais e humanas.

A identificação de alterações estruturais deve acontecer o mais cedo possível. Dessa forma, medidas corretivas podem ser tomadas, tendo um impacto significativo na minimização do tempo de inatividade, custos operacionais, custos de manutenção e redução do risco de falha catastrófica, lesão, ou até perda de vidas (CHIACHÍO, J. *et al.*, 2016). Sendo assim, fica claro que um sistema SHM traz benefícios consideráveis não só aos custos de operação como também no que diz respeito à segurança em estruturas civis, mecânicas, navais e aeroespaciais.

A conjuntura típica de um sistema desse tipo normalmente consiste em uma cadeia de sensores e/ou atuadores, atrelada a uma unidade central responsável pelo processamento dos dados, julgando a integridade da estrutura através de parâmetros e critérios predefinidos (RAGHAVAN; CESNIK, 2007). O SHM surge de técnicas de Ensaios Não Destrutivos (END), onde uma dada estrutura pode ser inspecionada sem

malefícios à sua integridade. Porém, difere do END por ter foco no monitoramento contínuo e pouca ou nenhuma intervenção manual (MITRA; GOPALAKRISHNAN, S, 2016).


A avaliação e prognóstico da condição estrutural contribui bastante para os procedimentos de manutenção no setor aeroespacial e aeronáutico. Ações de manutenção podem ser divididas em três categorias: corretiva, preventiva e baseada na condição (CORADDU *et al.*, 2016). A ação corretiva acontece após a falha. A preventiva, de forma pré-programada e a baseada na condição, como implica a nomenclatura, é acionada à medida que há necessidade, sendo apoiada usualmente por dados de sensores. O SHM tem uma relação estreita com a manutenção baseada na condição.

Em seu artigo, Manco et al. (2021) realizou uma revisão de literatura sistemática sobre o estado da arte de sistemas SHM, analisando seus custos e viabilidade no setor aeronáutico. Sendo observado pela análise dos autores que a sincronização entre o SHM e manutenções programadas podem de fato reduzir custos de manutenção a longo prazo. Por outro lado, a aplicação do SHM como método substituto a processos tradicionais ainda não é eficiente do ponto de vista do custo-benefício. Desta forma, é apontado que a utilização exclusiva de sistemas SHM na predição de condições de manutenção ainda é bastante ambiciosa, recomendando os autores a utilização de *datasets* na produção de modelos sofisticados de inteligência artificial a fim de romper esta barreira de confiabilidade.

Sobre sistemas SHM, pode-se dividi-los em ativos e passivos, e com monitoramento *on-line* ou *off-line*. Um sistema passivo não necessita da ação de uma fonte externa de excitação que seja ligada ao próprio sistema SHM, ou seja, a fonte de excitação provém do ambiente por meio, por exemplo, no caso de uma aeronave, da excitação provocada pelo carregamento aerodinâmico. Dependendo de excitações externas traz vantagens a medida que boa parte das máquinas e infraestrutura civil estão sujeitos a carregamentos externos, porém, estas fontes de excitação são de natureza aleatória e normalmente não estacionária, o que exige uma capacidade robusta de normalização dos dados de forma a diferenciar se há de fato alterações estruturais ou o sinal representa apenas variações ambientais (FARRAR, C. R.; WORDEN, K., 2013). Em grandes construções civis muitas vezes esta é a única forma de excitar uma resposta dinâmica global.

Já o sistema ativo conta com uma fonte de excitação que gera deliberadamente perturbações no sistema monitorado. Saber de forma predeterminada as características da excitação, podendo ter controle sobre ela, é de grande utilidade para a detecção de dano em partes específicas da estrutura, induzindo uma frequência predeterminada com comprimento de onda adequado para as características do dano que se deseja encontrar. Uma solução muito utilizada para esse tipo de sistema são materiais piezoelétricos, como o Titanato Zirconato de Chumbo (PZT), que podem ser usados como atuadores na excitação do sinal preterido (que se propaga na estrutura por meio de ondas elásticas) e/ou sensor na captação deste sinal. Por conta dessa capacidade de agir tanto como atuador ou como sensor, muitas vezes refere-se aos PZTs como transdutores. Como mencionado anteriormente, controlar as características de excitação da estrutura torna o processo de detecção menos dispendioso, podendo ser aplicado na grande maioria dos casos de monitoramento. Além disso, transdutores PZT tem em geral baixo custo, necessitam de pouca energia (FARRAR, C. R.; WORDEN, K., 2013), fácil instrumentação (GIURGIUTIU, 2016), além de uma grande amplitude de temperaturas de funcionamento (ZHANG, S. *et al.*, 2018). A Figura 1 exemplifica o funcionamento básico de um sistema ativo utilizando transdutores piezoelétricos.

Figura 1 – Esquema ilustrativo de um sistema SHM Ativo. Em (a) o PZT atuador gera uma perturbação na placa que gera uma onda elástica, se propagando até chegar ao sensor. Em (b) um dano surge na placa e o sinal obtido é afetado por ele.



Fonte: O autor (2024).

No campo dos métodos ativos ainda há a distinção entre os baseados em impedância e baseados em ondas guiadas. Park et al. (2003) conclui em sua revisão de literatura que o método EMI tem vantagens se comparado a métodos END tradicionais. Por utilizar altas frequências de excitação ele é bastante sensível à presença de dano e não é afetado por mudanças em condições de contorno, carregamentos ou vibrações operacionais, além de ser apto a aplicações em monitoramento contínuo, uma vez que a sua operação requer mínima interferência humana. Na e Baek (2018), após a avaliação de trabalhos desenvolvidos entre 2008 e 2018, apontam que problemas como um limitado alcance da área sensoriada, a necessidade de escolha de um intervalo de frequência adequado, e também a compensação de fatores como variações de temperatura e métricas eficientes na compensação de fatores ambientais, ainda limitam a aplicação desta forma de SHM ativo. Uma das formas apontadas para a resolução destes problemas é o uso de Redes Neurais Artificiais (ANN, da sigla em inglês), uma vez que apresentam melhor capacidade de lidar com as dificuldades inerentes a técnica.

O método de ondas guiadas (GW, da sigla em inglês) se baseia na propagação de ondas elásticas, que são forçadas a seguir um caminho delimitado pelas características geométricas da estrutura. Segundo Raghavan e Cesnik (2007), o SHM por GW surgiu como uma opção importante entre esquemas de detecção ativos, já que possibilita uma forma de efetivamente estimar a presença, localização, severidade e tipo de dano, além de já ser usado há bastante tempo em END. Uma das vantagens aqui é que o par atuador e sensor tem uma área de cobertura grande, ajudando a diminuir o número de transdutores utilizados. Um fator complicador da análise de GW é a natureza multimodal e dispersiva dos sinais (GOPALAKRISHNAN, Srinivasan; RUZZENE; HANAGUD, 2011), além disso, com frequência há presença de ruídos e variações ambientais. Todo esse conjunto implica na utilização de ferramentas de processamento de sinais adequados a esta função. Quanto aos sistemas on-line ou off-line, é uma distinção feita apenas para destacar qual o tipo de acesso aos dados do sistema de detecção de falhas. No primeiro o processamento dos dados ocorre durante o uso, indicando em tempo real a condição estrutural. No segundo caso, só é feita a verificação dos dados quando a aeronave está em solo, no hangar para manutenção.

2.1.1 Diferenças entre END e SHM

Como citado na seção 2.1, o sistema SHM surge das técnicas de END baseadas em ondas guiadas. Porém, difere no seu enfoque, que é no monitoramento em tempo real. As principais diferenças entre as duas técnicas são mostradas na Tabela 1.

Tabela 1 – Comparativo entre técnicas de Ensaios Não Destrutivos (END) e o monitoramento de Integridade estrutural (SHM).

Atributo	END (Ondas guiadas)	SHM
Aplicação	Localizar e quantificar dano	Monitorar componentes críticos, reduzir custo operacional e de manutenção, estender a vida útil
Posicionamento	Localizações fixas em laboratório ou portátil para uso em campo	Embarcado. Normalmente posicionado em locais de difícil acesso
Intervalos de inspeção	Infrequente, dados de integridade observados durante inspeções periódicas	Dados de integridade adquiridos continuamente ou por demanda
Automação	Majoritariamente manual, com intervenção humana necessária	Majoritariamente automatizado
Área de cobertura	Dano localizado próximo ao sensor, ou escaneamento para uma área maior de cobertura	Dano localizado ou maior cobertura usando ondas guiadas ou fibra ótica
Precisão	Alta precisão	Precisão moderada
Portabilidade	Portátil ou local fixo	In situ
Custo do equipamento	Moderado a alto	Baixo a moderado
Custo operacional	Moderado a alto; depende da frequência de manutenção	Baixo a moderado; não relacionado ao intervalo de inspeção

Fonte: Adaptado de Chiáchio et al. (2016).

2.1.2 Danos em Superfícies Aeronáuticas

Estruturas aeronáuticas e aeroespaciais são comumente fabricadas com materiais compósitos e/ou ligas metálicas e expostas a diversas situações de uso durante o seu ciclo de vida, incluindo variações de carregamento, térmicas, impactos, entre outras. Diferentes tipos de danos são observados, estruturas em material compósito estão sujeitas a ruptura das fibras, inclusões, fissuração da matriz e delaminação. Já para materiais metálicos, podem ser encontradas erosões na superfície causadas por corrosão, fissuras, entre outros. Com a mudança das características originais da estrutura pode se esperar observar alterações em massa e rigidez, alterando de forma sintomática suas características modais. No caso de fissuras, a rápida identificação de tais danos é de suma importância, devido a possibilidade de propagação instável da trinca depois de atingido um nível crítico levando a uma falha completa da estrutura.

2.1.3 Níveis de um Sistema SHM


Um sistema SHM pode ser concebido para atender diferentes níveis de avaliação de danos. Rytter (1993) criou uma definição a partir de quatro níveis de detecção em que um sistema deste tipo pode atuar. Posteriormente recebendo o acréscimo do nível “Classificação” por Worden e Duijze (2004). Cinco possibilidades de atuação são apontadas em literatura, podendo o sistema realizar um ou mais dos métodos a seguir:

1. DETECÇÃO: O método fornece uma indicação qualitativa de que danos podem estar presentes na estrutura.
2. LOCALIZAÇÃO: O método fornece uma estimativa da posição do dano.
3. CLASSIFICAÇÃO: O método fornece informações sobre o tipo do dano.
4. AVALIAÇÃO: O método fornece uma estimativa da extensão do dano.
5. PREDIÇÃO: O método fornece informações sobre a segurança da estrutura, por exemplo, estimando a vida útil restante.

Pode haver uma dependência entre os níveis, ao passo que um sistema que localiza o dano provavelmente também o detecta e assim sucessivamente (Figura 2).

É importante salientar que a correta classificação do dano é fundamental para implementação da predição de vida útil pois este não pode ser realizado sem uma compreensão da física da avaria encontrada, por exemplo, uma trinca tem evolução diferente de uma corrosão o que leva a predições significativamente diferentes de vida útil, também é verdade que o nível de avaliação irá impactar de forma similar a predição (WORDEN, K.; DULIEU-BARTON, 2004). Vale salientar que o desenvolvimento e confecção, mesmo que dos primeiros níveis, não é trivial e requer conhecimentos multidisciplinares para sua correta execução e implementação. São necessários conhecimentos com relação ao envelope de situações de uso da estrutura, posicionamento de sensores, física da propagação de ondas mecânicas, gerenciamento e processamento de dados, interpretação de resultados e medidas de ação para abordar o dano. Cada um destes pontos necessitando de conhecimentos densos e específicos do profissional responsável.

Figura 2 - Ilustração dos diferentes níveis de um sistema SHM.



Fonte: o autor (2024).


Ondas mecânicas são um dos principais meios de observação do dano utilizados em aplicações de saúde estrutural e serão abordadas no tópico a seguir.

2.2 ONDAS GUIADAS

As ondas são perturbações geradas em um meio, seja sólido líquido ou gasoso, que se propagam transportando energia, mas sem transportar matéria. Elas podem ser classificadas em três grandes grupos: gravitacionais, eletromagnéticas e mecânicas (HALLIDAY; RESNICK; WALKER, 2017). As ondas mecânicas são governadas pelas leis de Newton e precisam de um meio físico para se propagar, são geradas por perturbações causadas por choques ou oscilações que, a depender da magnitude, podem originar ondas elásticas ou plásticas. Ondas plásticas causam deformações plásticas, ou seja, permanentes ao meio de propagação. Por sua vez, as ondas elásticas operam somente no regime elástico e não causam deformações permanentes. Naturalmente, não é pretendido danificar o meio monitorado por sistemas SHM e, portanto, somente ondas elásticas são utilizadas para este propósito.

As ondas elásticas se propagam em grupo (também chamados de pacotes) e quando se mantêm confinadas ao longo de uma estrutura com barreiras definidas são denominadas ondas guiadas. Elas são altamente dispersivas, significando que podem ser gerados quase infinitos modos de propagação, através da superposição de ondas longitudinais e transversais (ABBAS; SHAFIEE, 2018). Na propagação longitudinal as vibrações das partículas são paralelas à direção de propagação (Figura 3(a)) e nas transversais são perpendiculares (Figura 3(b)).

Figura 3 - Exemplificação das diferentes características das ondas longitudinais (a) e transversais (b).



Fonte: o autor (2024)

As ondas guiadas são fundamentais para aplicações SHM devido a capacidade de percorrer grandes distâncias em estruturas com poucas perdas energéticas, tendo inclusive capacidade para se deslocar em superfícies curvas, tornando sua utilização valiosa para inspeção de fuselagens aeronáuticas que normalmente apresentam superfícies curvas por conta do formato cilíndrico usado em fuselagens (GIURGIUTIU, 2014).

2.2.1 Ondas de Lamb

O que distingue os tipos de ondas elásticas é a forma da movimentação das partículas. As ondas de Lamb, em específico, surgem em placas finas, ou seja, que têm a espessura muito menor em relação as outras dimensões, e que tem as superfícies superior e inferior livres.

A primeira explicação sobre a propagação de ondas guiadas em uma superfície foi obtida por Lord Rayleigh em 1885, já Horace Lamb no artigo *On Waves in an Elastic Plate* (LAMB, 1917), introduziu conceitos importantes como o de camada homogênea de espessura finita e equações da velocidade de propagação das ondas em placas contínuas com contornos livres, sendo obtida então uma solução para modos de propagação simétricos e outra para modos de propagação assimétricos. Para entender os modos de propagação adequadamente, é necessário a introdução de alguns conceitos.

A interpretação do sinal dessas ondas é complexa devido a sua natureza dispersiva e a superposição de ondas longitudinais e transversais (de cisalhamento). Existem dois tipos básicos de modos, o simétrico e o antissimétrico (por exemplo, S_0 e A_0), ambos com características de propagação diferentes, influenciando na sua aplicabilidade para sistemas SHM. A Figura 4 mostra a esquemática do deslocamento de partículas característico desses modos, considerando uma placa de espessura $2d$, ondas simétricas costumam apresentar movimentação das partículas dentro do plano da placa (longitudinal), enquanto antissimétricas apresentam movimentação perpendicular ao plano (transversal). Ondas em placas finas, independente do modo, podem ser descritas com uma notação tensorial cartesiana, como mostrado na Equação 1.

$$\mu \cdot u_{i,jj} + (\lambda + \mu) \cdot u_{i,ji} + \rho \cdot f_i = \rho \cdot \ddot{u} \quad (1)$$


O deslocamento e força são representados por u_i e f_i , respectivamente, com a direção denotada pelo subscrito i . A densidade e módulo de cisalhamento do material da placa são dados por ρ e μ , respectivamente. Já o λ é a constante de Lamé, com formulação dada na Equação 2.

$$\lambda = \frac{2 \cdot \mu \cdot \nu}{1 - 2 \cdot \nu} \quad (2)$$

Sendo ν o coeficiente de Poisson.

Desta equação derivam representações matemáticas que levam às equações que descrevem o comportamento dos modos de onda simétricos e assimétricos.

Figura 4 – Tipos de propagação dos modos mecânicos de ondas.



Fonte: Adaptado de Su e Ye (2009)

As equações a seguir descrevem a relação entre as propriedades do material e velocidades de onda.

$$\text{Modos simétricos} \quad \frac{\text{tg}(qd)}{\text{tg}(pd)} = -\frac{4k^2 qp}{(k^2 - q^2)^2} \quad (3)$$

$$\text{Modos antisimétricos} \quad \frac{\text{tg}(qd)}{\text{tg}(pd)} = -\frac{(k^2 - q^2)^2}{4k^2 qp} \quad (4)$$

os termos k , q e p correspondem a

$$k = \frac{\omega}{C_p} \quad (5)$$

$$q^2 = \frac{\omega^2}{C_T^2} - k^2 \quad (6)$$

$$p^2 = \frac{\omega^2}{C_L^2} - k^2 \quad (7)$$

onde d é a espessura da placa, k é o número de onda, C_T e C_L a velocidade dos modos transversal e longitudinal, representados nas equações 5 e 6, C_p a velocidade de fase e ω é a frequência angular da onda.

$$C_L = \sqrt{\frac{2\mu(1-\nu)}{\rho(1-2\nu)}} \quad (5)$$

$$C_T = \sqrt{\frac{\mu}{\rho}} \quad (6)$$

Os modos podem ser denotados por S_i e A_i ($i = 0, 1, 2, \dots$), para o simétrico e antissimétrico, respectivamente, sendo o subscrito a ordem do modo. As ordens mais baixas (i. e. S_0 e A_0) são mais comumente utilizadas em aplicações SHM e podem ser induzidas utilizando frequências de excitação menores, ordens como a S_0 e A_0 apresentam menor dispersão se comparado as maiores, ou seja, sua frequência (e por consequência sua velocidade de grupo) sofre menor desvio da frequência original de excitação.

As ondas simétricas tendem a viajar com maior velocidade pela placa, sofrem menor atenuação e por consequência percorrem distancias maiores, também tem menor dispersão do sinal em frequências mais baixas. Já o modo antissimétrico possui comprimento de onda menor, permitindo detectar um dano menor em relação ao simétrico para uma mesma frequência de excitação e maior amplitude, o que melhora a relação sinal-ruído (SNR, *signal to noise ratio*) (SU, Z.; YE, L., 2009).

As formas de interação das ondas guiadas com barreiras e danos incluem reflexão, refração e difração (FRANK PAI; DENG, H.; SUNDARESAN, 2015). Na reflexão, a onda incidente em um obstáculo é completamente refletida de volta ao meio que estava em um ângulo simétrico de incidência e mantendo as mesmas características anteriores (velocidade de propagação, comprimento de onda e frequência). A refração acontece na mudança do meio material de propagação da onda e causa mudanças em suas características. Já a difração acontece quando a onda encontra um obstáculo ou abertura e pode ser entendido como o espalhamento da onda ao redor de um obstáculo ou abertura. Na utilização de ondas guiadas para detecção de falhas é importante observar as dimensões mínimas do dano que se deseja investigar, pois descontinuidades maiores que a metade do comprimento de onda geralmente podem ser detectadas (LEE, B. C.; STASZEWSKI, 2003).

2.2.2 Velocidade de Fase e Velocidade de Grupo


A velocidade de fase (C_p) de uma onda acústica representa a taxa de propagação de um modo individual desta onda no meio em que está sendo dispersada, quando os modos são superposicionados o conjunto, também referido por pacote de ondas, viaja com a velocidade de grupo (C_g). As equações de C_p e C_g são dadas por:

$$C_p = \frac{\omega}{k} \quad (7)$$

$$C_g = \frac{\partial \omega}{\partial k} \quad (8)$$

A Figura 5 mostra uma distinção visual entre C_p e C_g .


Figura 5 – Diferenciação entre velocidade de fase e de grupo.



Fonte: o autor (2024).

A velocidade de grupo é dependente da frequência de excitação (f) e espessura da placa (d) combinadas em um produto de frequência-espessura ($f \cdot d$). Esta informação é importante pois fornece uma relação direta de quais características da onda podemos esperar para um dado input de frequência de excitação no atuador. A Figura 6 mostra o gráfico de dispersão para uma placa de alumínio com espessura de 1 mm.

Figura 6 – Exemplo de gráfico de dispersão de ondas de Lamb para uma placa de alumínio.



Fonte: O autor (2024).

O input de frequência para geração de ondas de Lamb no sistema monitorado é usualmente fornecido por um transdutor piezoelétrico acoplado ao sistema, como será possível entender no tópico a seguir.

2.3 TRANSDUTORES PIEZOELÉTRICOS

Materiais piezoelétricos fazem parte da classe de materiais dielétricos e, mais precisamente, de um subgrupo dos dielétricos chamados materiais ferroelétricos. Os dielétricos são isolantes não metálicos que exibem (ou são produzidos de modo a exibir) uma estrutura de dipolo elétrico a nível molecular ou atômico, ou seja, há uma separação entre entidades positivas e negativas carregadas eletricamente. Usualmente estes materiais exibem o dipolo elétrico quando submetidos a uma tensão elétrica, porém há materiais que possuem essa polarização de forma espontânea em sua estrutura. São os chamados ferroelétricos. Alguns desses ferroelétricos quando submetidos a uma tensão mecânica, tem a capacidade de transformar a deformação que sofrem em carga elétrica ou então, sob um campo elétrico aplicado, geram uma deformação mecânica. Estes materiais têm a chamada propriedade piezoelétrica. Essa capacidade eletromecânica confere a eles uma grande variedade de aplicações, incluindo componentes de circuitos, transdutores ultrassônicos, acelerômetros, entre outros.

2.3.1 Propriedades Piezoelétricas


Propriedades piezoelétricas são encontradas naturalmente em alguns materiais cristalinos, como cristais de quartzo (SiO_2), sal de La Rochelle ($\text{KNaC}_4\text{H}_4\text{O}_6 \cdot 4\text{H}_2\text{O}$) e topázio ($\text{Al}_2\text{SiO}_4(\text{F},\text{OH})_2$). Também é possível manipular materiais para que apresentem, ou intensifiquem, esta propriedade. São exemplos o titanato de bário (BaTiO_3), titanato de chumbo (PbTiO_3), fluoreto de polivinilideno ($-(\text{C}_2\text{H}_2\text{F}_2)_n-$) e o titanato zirconato de chumbo ($\text{Pb}(\text{Zr},\text{Ti})\text{O}_3$). A explicação para o fenômeno piezoelétrico pode se dar pela observação de alterações em nanoescala induzidas na estrutura cristalina de certos materiais, através da aplicação de esforço mecânico e campos elétricos em vários regimes de temperatura (GIURGIUTIU, 2014). As cerâmicas com estrutura da perovskita são conhecidas por representarem tais características piezoelétricas. Este nome é derivado de um mineral específico chamado perovskita e, dessa forma, arranjos com microestrutura idêntica (mesmo que com elementos químicos diferentes) são considerados cerâmicas com estrutura da perovskita. O composto cerâmico da perovskita contém mais de um tipo de cátion e

um ânion. Suas fórmulas químicas podem ser designadas na forma $A_mB_nX_p$, onde A e B representam os cátions e X o ânion (CALLISTER; RETHWISCH, 2020).

Em temperaturas elevadas o arranjo é cúbico de face centrada (CFC), essa forma é chamada de fase paraelétrica da perovskita, pois não existe polarização entre os átomos, ou seja, há perda das propriedades piezoelétricas. A temperatura na qual este fenômeno ocorre é denominada temperatura de Curie (T_C) e varia de acordo com o material. Abaixo dela, a célula unitária exibe simetria tetragonal (um cubo ligeiramente alongado em uma direção). Durante um esforço mecânico esta estrutura de simetria tetragonal, antes em equilíbrio (um dipolo cancela o outro), se deforma e como resultado da assimetria na distribuição de cargas elétricas os dipolos não se cancelam mais, criando uma diferença de potencial entre os polos da célula unitária (Figura 7). Quando há conversão de energia mecânica em energia elétrica, é dado o nome efeito piezoelétrico direto, e ao converter energia elétrica em mecânica, efeito piezoelétrico inverso.

Transdutores piezoelétricos têm sido amplamente utilizados em aplicações SHM devido a sua versatilidade, simplicidade, alta rigidez, alta estabilidade, curto tempo de resposta, operação em ampla faixa de temperaturas, baixo consumo de energia, entre outros (ZHANG, S. *et al.*, 2018). Os materiais mais práticos do mercado são baseados em titanato zirconato de chumbo (abreviado para PZT), que é uma solução sólida de $PbZrO_3$ e $PbTiO_3$.

Figura 7 – Arranjo entre os átomos do PZT para (a) acima da temperatura de Curie e (b) abaixo da temperatura de Curie.



Fonte: Priya et al. (2017).

As equações que relacionam o comportamento deformação-carga (Equação 9) e carga-deformação de um transdutor piezoelétrico podem ser dadas pelas equações:

$$e = d^T E + s\sigma \quad (9)$$

$$D = \varepsilon E + d\sigma \quad (10)$$

onde e é o vetor de deformação do transdutor, d é a matriz de coeficientes piezoelétricos e E simboliza o vetor do campo elétrico. s é a matriz de conformidade elástica, σ o vetor de tensão, D representa o vetor de deslocamento elétrico e, por fim, ε é a matriz de constantes dielétricas.

2.3.2 Aspectos Práticos da Geração de Ondas de Lamb com Transdutores Piezoelétricos

Segundo Su e Ye (2009), um sensor para aplicação em sistemas SHM de uso aeroespacial, em especial fuselagens, deve ter características específicas como dimensões reduzidas, baixa massa, longa durabilidade, baixo custo e consumo de energia, tolerância considerável a ruído e, se possível, utilizar pouca ou nenhuma conexão por fios. Uma grande diversidade de sensores para aplicação em END e SHM já foram utilizados com sucesso, entre os mais comuns estão o sensor de emissão acústica, acelerômetros, extensômetros, sensores de fibra ótica, além de elementos em PZT. Tais sensores podem ser acoplados na superfície da estrutura ou nas camadas internas do material. Porém, o maior destaque para estas aplicações é dos sensores em PZT, pela diversidade de frequências e amplitudes de ativação de frequências e formas de ondas. Com seu uso também é possível diminuir a quantidade de componentes, uma vez que um elemento de PZT pode ser utilizado como atuador ou sensor (transdutor). Na indústria aeroespacial um arranjo de transdutores piezoelétricos é comumente aplicado para monitorar estruturas, esse arranjo é referido na literatura como PWAS, do inglês *piezoelectric wafer active sensors*. ele facilita a excitação do modo de onda Lamb desejado e a triangulação dos dados sensorizados para localização do dano (em sistemas acima do nível II), além de terem baixo custo e peso, bem como fácil integração e instrumentação.

2.4 MODELAGEM COMPUTACIONAL DO PROCESSO DE PROPAGAÇÃO DE ONDAS DE LAMB

A modelagem computacional de problemas estruturais permite estudar o comportamento de fenômenos físicos de forma virtual, auxiliando a antever respostas estruturais que de outra forma teriam maior dificuldade e/ou custo para ser estudadas. Uma das suas utilidades pode ser analisar o fenômeno de propagação de ondas guiadas, permitindo entender características das ondas e sua dispersão, interação onda-dano, intervenções de fatores ambientais, entre outros aspectos. Segundo Mitra e Gopalakrishnan (2016), alguns métodos podem ser utilizados nesta tarefa, o mais comum dentre eles é o Método dos Elementos Finitos (FEM), que tem como vantagens a habilidade de lidar com geometrias complexas além de diversos softwares comerciais disponíveis. Outros métodos para modelagem de problemas de propagação de ondas de Lamb também são apontados em literatura, como por exemplo Diferenças Finitas (FD) e o Método dos Elementos Espectrais (SEM). Em seu livro, Gopalakrishnan et al. (2011) define que a escolha do método computacional mais adequado depende do tamanho do dano que precisa ser observado. Para danos maiores em relação às dimensões da estrutura, métodos como o FEM e FD podem ser suficientes, porém para casos em que o dano é muito pequeno e, por consequência, o impulso do sinal de entrada é muito curto (inferior a casa dos microssegundos) o SEM pode ser a melhor alternativa.

Em um problema de excitação e recepção de ondas de Lamb por transdutores piezoelétricos há interação entre dois sistemas físicos: o estrutural linear e piezoelétrico. Por tratar-se de sistemas diferentes, diz-se que este é um problema de modelagem multifísico. Em seu artigo, Khan et al. (2017) foi bem sucedido na modelagem analítica, numérica e validação experimental da propagação de ondas de Lamb em uma chapa fina de alumínio, utilizando o software COMSOL® Multiphysics (versão 6.1 e chave 9201948). O autor utilizou um modelo 2D de um experimento realizado em laboratório, tal abordagem já é o suficiente para representar os diferentes modos de onda, uma vez que sua propagação é eixo-simétrica. Qiu et al. (2018), também realiza uma modelagem 2D do problema de propagação de ondas, com auxílio do mesmo software e modelagem multifísica, com o intuito de validar um modelo experimental onde atua um carregamento uniaxial, conseguindo legitimar com sucesso a abordagem.

2.4.1 Parâmetros do Modelo FEM

O FEM é uma abordagem discreta, o que significa que a estrutura em estudo é dividida em diversas partes menores chamadas de elementos. Cada elemento possui nós que se interligam com os nós dos demais elementos do meio discretizado e assim é possível abordar problemas sem solução analítica definida, devido a complexidades de carregamento ou geometria, de forma prática com o auxílio de um computador para realização dos cálculos. Estabelecer uma malha adequada para o FEM é fundamental para encontrar uma solução coerente para o problema. O já mencionado Gopalakrishnan et al. (2011), recomenda a seguinte abordagem abaixo.

1. Obtenção do comprimento de onda (Equação 10), λ_{onda} . Onde c_0 é a velocidade da onda para um dado modo de onda, obtido com a ajuda das curvas de dispersão para placa.

$$\lambda_{onda} = \frac{2\pi c_0}{\omega} \quad (11)$$

2. Deixar de 8 a 10 elementos no comprimento de onda (Equação Y).

$$e_{num} = \frac{\lambda_{onda}}{10} \quad (12)$$

Propriedades do material influem de forma direta nos resultados, uma vez que o meio de propagação dita características da onda propagada, como visto em seções anteriores desta revisão bibliográfica. Estas propriedades costumam ser disponibilizadas nas bibliotecas padrão dos softwares FEM, como é o caso do COMSOL® Multiphysics.

2.5 SISTEMA DE MONITORAMENTO BASEADO EM DADOS

Um sistema de monitoramento baseado em dados tem por objetivo extrair características dos dados sensoriados podendo apontar se a estrutura está ou não danificada, assim como determinar o tipo do dano, sua localização e quantificar a

severidade para realização de prognóstico (AMEZQUITA-SANCHEZ; ADELI, 2016), estes objetivos podem variar a depender do sistema. Estas características extraídas dos dados de sensores são variáveis de entrada para o processamento de dados e são comumente chamadas de atributos ou *features*. No caso de ondas de Lamb, os sinais costumam ser de difícil interpretação devido a sua natureza dispersiva, além de fatores como interferências causadas por variações ambientais, ruído e múltiplas reflexões causadas por descontinuidades. Neste contexto, a extração de atributos que possam ser utilizados para o processamento de dados por parte de modelos inteligentes é uma etapa fundamental a ser observada.

2.5.1 Criação de um Sistema de Monitoramento

Farrar et al. (2001) estabelecem um dos primeiros paradigmas para o processamento de dados em sistemas de monitoramento de saúde estrutural, chamado pelos autores de *statistical pattern recognition (SPC) paradigm*, para o reconhecimento de padrão estatístico na detecção de dano. Uma estrutura é estabelecida para aplicações SHM com as etapas demonstradas abaixo:

1. Avaliação operacional;
2. Aquisição de dados;
3. Seleção de atributos;
4. Modelagem estatística para discriminação de atributos.

No paradigma, a avaliação operacional busca responder quais são as condições de operação e ambientais sob a qual o sistema está submetido, e quais as limitações na aquisição de dados nesse ambiente. Na fase de aquisição de dados são escolhidos os tipos e número de sensores a serem utilizados, onde devem ser posicionados e características de hardware para aquisição, armazenamento e transmissão de dados, além da consideração de variação em fatores ambientais presentes. Limpeza e normalização dos dados também são realizadas nessa fase.

A seleção de atributos é uma das áreas que mais recebe atenção na literatura, trata-se da identificação de dados que permitam distinguir entre um estado danificado ou não danificado da estrutura, dentre outras propriedades de saúde estrutural.

Diferentes técnicas estatísticas são utilizadas nessa tarefa de distinção, comumente chamadas de métricas de dano, índices de dano ou indicadores estatísticos.

A experimentação de distintas métricas e seu desempenho sob diferentes condições de dano é importante para estabelecer o escopo operacional de um sistema de detecção de falhas. Entender a diferença de sua leitura na condição sem dano (também referida como *baseline*) e com dano é a forma mais comum de detecção e quantificação de um estado danificado. Segundo Worden e Farrar (2010), a análise de séries temporais permite extrair parâmetros de sinal de forma mais simples se comparada a análise modal, que depende das características de massa e rigidez de uma estrutura. Uma aeronave varia sua massa durante o voo, por exemplo, através da queima de combustível e distinguir entre alterações nas características modais que são malignas ou benignas é um desafio para sistemas SHM dependentes destas características modais.

O modelamento estatístico para discriminação de atributos é a quarta etapa do paradigma e compreende o aprimoramento da detecção através da implementação de algoritmos que, por meio dos atributos extraídos, podem inferir conclusões sobre o estado estrutural. Para a identificação do tipo do dano, dados da estrutura com tipos específicos de dano têm que estar disponíveis para correlação com os atributos extraídos.

Já Nassir e Sassani (2021), em sua revisão bibliográfica, propõem um *framework* para o monitoramento inteligente com o uso de ferramentas como a aprendizagem de máquina (*machine learning*) e aprendizagem profunda (*deep learning*). O *framework* consiste nos passos demonstrados na Figura 8.

Figura 8 – Paradigma SHM para equipamentos de usinagem.



Fonte: adaptado de Nasir e Sassani (2021).

Este sistema tem por objetivo gerar dados de saída que possam guiar tomadas de decisão. O processo inicia com o entendimento de qual tipo de sensor é mais adequado para o monitoramento, o processamento de sinal trata os dados obtidos para então se extrair e selecionar atributos que carreguem informações do sinal de forma que um modelo inteligente possa ser treinado e testado e então direcionado para o auxílio em tomadas de decisão. Os itens de processamento de sinal, seleção de atributos e modelos inteligentes receberão foco nos tópicos a seguir.

2.5.1.1 Processamento de Sinais


Sinais obtidos dos sensores precisam de um manejo adequado para que possam ser utilizados em um sistema de identificação de danos. Esta é a segunda etapa dos paradigmas acima mencionados, por vezes também referenciada por outros autores como pré-processamento de sinais. Algumas operações são comumente utilizadas para esta finalidade, comentadas a seguir.

A coleta do sinal da propagação de ondas de Lamb usualmente se dá em um intervalo de tempo, obtendo-se então uma resposta da estrutura na forma de um gráfico de amplitude do sinal pelo tempo. A segmentação (ou janelamento) consiste em isolar o trecho do sinal que carrega a informação necessária na identificação do dano. Por exemplo, se o primeiro trecho do sinal já carrega o sinal de resposta dos pacotes de onda usados no monitoramento então exclui-se da análise o trecho

seguinte, reduzindo a dimensionalidade dos dados a serem processados pelo sistema. É possível também a aplicação de técnicas de remoção de ruído e média do sinal para, respectivamente, reduzir a sensibilidade dos dados às flutuações aleatórias e diminuir a interferência de alterações no sinal causadas por variações ambientais, além disso a normalização do sinal em relação às suas amplitudes de pico, ou seja, delimitar o sinal a valores entre -1 e 1 de amplitude, permite que diferentes sinais sejam mais facilmente comparados (ATASHIPOUR *et al.*, 2013).

Transformadas Wavelet (WT) são amplamente utilizadas no processamento e análise de sinais no espectro de tempo-frequência. A wavelet é uma forma de onda com duração limitada em uma dada janela de tempo (Figura 9) e possui dois parâmetros, escala e tempo, comumente denotadas pelas letras a e b , respectivamente. Aumentar a escala significa proporcionar uma visão mais global do sinal ao custo de uma menor resolução, a variável de tempo varia conforme a wavelet passa pelo do sinal analisado.

Figura 9 - Exemplificação de wavelets, a esquerda a wavelet tipo morlet e a direita do tipo chapéu mexicano.



Fonte: O autor (2024).

As WT têm a vantagem de não perder informação do sinal durante a transformação. Podendo ser do tipo contínua (CWT) ou discreta (DWT), as DWT são uma versão computacionalmente mais eficiente das CWT. Pode-se dizer que, para um sinal de ondas de Lamb $f(t)$, seu coeficiente CWT em escala (a) e tempo (t) será

$$CWT(a, b) = \int_{-\infty}^{\infty} f(t) \Psi^* \left(\frac{t-b}{a} \right) dt \quad (13)$$

onde Ψ^* representa o conjugado complexo de Ψ .

2.5.1.2 Seleção de atributos em sinais em função do tempo

Diferentes formas de extração de atributos em sinais em função do tempo podem ser utilizadas para obter dados capazes de serem utilizados em modelos inteligentes a fim de melhorar sua eficiência em aplicações de SHM. Su e Ye (2005a, 2005b) introduziram o conceito de *Digital Damage Fingerprints* (DDFs), aplicando-o na identificação de danos em uma placa de epóxi reforçada com fibra de carbono. Durante o estudo, os autores utilizaram também como método de processamento de sinais uma transformada wavelet, de forma a extrair características de energia do sinal no espectro tempo-frequência. Este espectro de energia do sinal serve como base para extração dos DDFs, que são pontos extraídos ao longo deste mapa de energia do sinal gerado pela transformada wavelet. Vários conjuntos de DDFs são criados para cada caso de dano e caminho atuador-sensor, criando uma base de dados nomeada de *Damage Parameters Database* (DPD). Estes pontos armazenados na DPD são então utilizados como entrada para treinamento de uma Rede Neural Artificial (ANN) para identificação de dano. Como resultados, os autores perceberam uma excelente capacidade da ANN treinada com dados da DPD em mapear as relações entre parâmetros de dano e parâmetros estruturais dinâmicos. Perceberam também que a ANN sobretreinada (*overtreined*) contribui para o aumento da exatidão da identificação, porém requer significativo custo computacional e recomendam que a escolha da aplicação da técnica deve ser analisada para cada caso de forma a equilibrar a relação custo-eficiência.

Visando abordar as desvantagens percebidas na implementação de DDFs, Atashipour et al. (2013) desenvolveu o conceito de *Damage Characteristic Points* (DCPs) que operam de forma similar aos DDPs, porém possui convergência mais rápida e maior exatidão na identificação do dano e severidade, como observado em seus resultados comparativos. Na metodologia proposta o autor realiza o processamento do sinal bruto para remoção de ruídos e interferências ambientais, o sinal passa por uma CWT e na sequência é processado pela chamada potência wavelet média em escala baseada em CWT (SAP), representada pela Equação 14 como

$$SAP(n) = \frac{1}{M} \sum_{i=1}^M |CWT(a_i, n)|^2 \quad (14)$$

onde M é a maior escala durante a CWT. Esta função consegue, em um sinal digital $f[n]$ ($n = 1, 2, \dots, N$), encontrar o pico de energia do pacote de ondas, determinando a frequência onde o pico se encontra e criando um gráfico com um envelope da variação da energia ao longo do tempo para a dada frequência. Os DCPs são pontos extraídos ao longo do envelope da SAP, que foram então utilizados para treinamento de uma ANN. Os responsáveis por essa pesquisa perceberam que quanto mais DCPs forem extraídos ao longo da curva SAP maior a precisão observada no método, porém ao custo de um maior tempo de treinamento e convergência da ANN.


2.5.2 Modelos inteligentes

Modelos inteligentes são a penúltima parte do paradigma de Nassir e Sassani (2021) e, em última instância, auxiliarão na tomada de decisão, completando o paradigma. Para discorrer sobre modelos inteligentes é preciso primeiramente falar sobre o campo da inteligência artificial (IA), que trata do desenvolvimento de algoritmos que tem a capacidade de autoaprendizagem e ganham conhecimento a partir de dados podendo então inferir previsões baseado no que foi aprendido. Alguns grandes grupos de pesquisa estão compreendidos na área da IA, como visão computacional, processamento de linguagem natural, robótica e aprendizagem de máquina, também conhecido como *machine learning* (ML). Algoritmos de ML conseguem analisar padrões em grandes quantidades de dados, aprendendo com eles e auxiliando na tomada de decisões em problemas complexos (RASCHKA, 2015). O sucesso da aplicação do ML em diversas áreas do conhecimento vêm chamando atenção para sua aplicação também no campo do SHM, sendo visto como uma forma de lidar com a complexidade e grande quantidade de dados gerados por um sistema desta natureza (BAO; LI, H., 2021).

Existem diferentes tipos de ML: supervisionado, não supervisionado e por reforço (Figura 10). No aprendizado supervisionado, o modelo é treinado com dados que contém as respectivas saídas esperadas, ou seja, contém rótulos (*labels*). Assim, ele aprende a relação entre os dados de entrada, e saída para fazer previsões mais precisas em novos dados. O aprendizado não supervisionado acontece quando o

algoritmo é treinado com dados que não contém rótulos, o objetivo é explorar a estrutura oculta nos dados e então identificar padrões e agrupamentos presentes. Já o aprendizado por reforço objetiva desenvolver um sistema que irá melhorar seu desempenho baseado nas interações com o ambiente, para este tipo de aprendizado funcionar é necessário um sistema de recompensas ou penalidades que irão guiar o processo. Os dois primeiros tipos de aprendizado são mais comumente encontrados em aplicações SHM. No contexto do SHM, o aprendizado não supervisionado é mais utilizado quando há disponível, única ou majoritariamente, dados para o estado não danificado (*baseline*). Isto pode acontecer em situações em que a estrutura está em operação e não possui registrado seu comportamento na condição danificada, sendo assim, atributos sensíveis a danos são utilizados no treinamento destes algoritmos. Tais algoritmos de aprendizado não supervisionado foram utilizados com sucesso para detecção e localização de danos, porém são altamente dependentes da quantidade e variedade dos dados utilizados para treinamento, informações do tipo e severidade do dano são comumente obtidas com modelos de aprendizado supervisionado (FIGUEIREDO *et al.*, 2019).

Figura 10 – Taxonomia dos ramos da aprendizagem de máquina.




Fonte: adaptado de Badillo et al. (2020).

Modelos de aprendizado supervisionado seguem as etapas de pré-processamento, aprendizado, avaliação e, finalmente, previsão. No pré-processamento, a base de dados é tratada e subdividida entre treinamento e teste, dados para treinamento são utilizados no aprendizado e ajuste do algoritmo ML escolhido que, após a conclusão desta etapa, tem seu desempenho avaliado utilizando a base de teste. Ao ser apresentado à novos dados, o algoritmo ML bem ajustado ao problema, consegue então realizar previsões (Figura 11). A divisão da


base de dados entre treinamento e teste deve ser feita de forma a evitar que o algoritmo ML tenha sobreajuste (referido também como *overfitting*) aos dados, ou seja, evitar que o algoritmo memorize os dados ao invés de aprender os padrões gerais. Memorizar significará um bom desempenho em dados já vistos, porém desempenho baixo aprendendo padrões gerais de novos dados. Para evitar tal problemática, recorre-se a técnicas de validação cruzada (CV) para se obter um modelo inteligente com maior capacidade de generalização, ou seja, capaz de desempenhar bem em dados nunca vistos. A CV consiste em particionar os dados de forma a aumentar a variedade de treinamento e teste. Um simples procedimento CV é a *k-fold*, que consiste em dividir aleatoriamente os dados em *k* subconjuntos (partição dos dados) e, de forma iterativa, selecionar cada partição como dados de teste, enquanto o modelo é treinado com as partições restantes, com isso *k* modelos são criados e avaliados, observando-se a média do seu desempenho e assim compreendendo de forma mais robusta o desempenho do modelo inteligente (Figura 12), usualmente são utilizados entre 5 e 10 *folds* para o CV (MATHAI; CHEN, Y.; KIRCHMAIR, 2019).

Figura 11 – Fluxograma do processo de desenvolvimento de um modelo de ML para aprendizado supervisionado.



Fonte: adaptado de Raschka (2015).

Figura 12 – Separação da base de dados entre os conjuntos de treino, validação e teste, e implementação da validação cruzada *k-fold*.



Fonte: o autor (2024).

Modelos de aprendizado supervisionado podem ser de dois campos, classificação ou regressão (Figura 10). Modelos de classificação permitem categorizar objetos em classes conhecidas, enquanto modelos de regressão tem como saída valores numéricos e contínuo, podendo representar uma estimativa ou valor previsto. Por exemplo, aplicações para um algoritmo de classificação podem incluir classificar se um e-mail é ou não spam ou, no contexto SHM, predizer o tipo de dano presente em uma estrutura. Já um algoritmo de regressão pode, por exemplo, prever o preço de uma casa baseado em suas características, estimar a quantidade de vendas em um mês, dentre diversas outras aplicações.

Algoritmos ML precisam passar por um processo de ajuste de seus parâmetros fundamentais, tais parâmetros controlam a arquitetura e comportamento do modelo, com o melhor ajuste sendo influenciada também pelos dados de treinamento utilizados, tal processo de ajuste é chamado de otimização de hiperparâmetros. Esta otimização encontra a combinação ideal de hiperparâmetros que leva a um modelo mais preciso, com boa capacidade de generalização e menos suscetível ao sobreajuste. Existem algumas abordagens de otimização de hiperparâmetros, a busca em grade (*grid search*) define uma grade de valores de hiperparâmetros e busca sistematicamente todas as combinações possíveis no dado intervalo de valores definido, chegando por força bruta nos melhores valores. Esta abordagem tem um

custo computacional elevado, especialmente se a quantidade de dados for grande. Para melhorar o processo de otimização, existem abordagens mais eficientes, como o Optuna. O Optuna utiliza um algoritmo de otimização bayesiana chamado Árvore de Parzen Estimado (TPE). Através do uso de um histórico de tentativas, o Optuna estima uma área promissora no intervalo de hiperparâmetros e testa novos valores nesta região. Com base nos resultados obtidos, ele estima uma região ainda mais promissora e continua iterando este processo usando os dados do histórico de tentativas já realizadas. Dessa forma, o Optuna utiliza a informação acumulada sobre as tentativas para guiar a busca para regiões mais promissoras do espaço de hiperparâmetros, tornando o processo de otimização mais eficiente e permitindo encontrar uma combinação ótima com menos tentativas. Essa abordagem é particularmente útil quando o espaço de hiperparâmetros é complexo e requer um número significativo de avaliações para ser explorado de forma eficaz.

Modelos de classificação podem ser avaliados por diferentes métricas, como matriz de confusão, acurácia, precisão, revocação ou F1-score. A matriz de confusão mostra o sucesso do algoritmo, em números absolutos, ao classificar corretamente ou erroneamente um dado. No contexto do SHM, levando em consideração um caso de distinção entre o estado normal ou danificado, tem-se uma classificação binária. Neste caso, uma matriz de confusão para duas classes consiste em quatro áreas com resultados de predição: verdadeiros positivos (TP), falsos positivos (FP), verdadeiros negativos (TN) e falsos negativos (FN) e, considerando um exemplo com dois rótulos 0 (chamado negativo) e 1 (chamado positivo), a Figura 13 exemplifica a matriz de confusão adequada. A interpretação do que é adequado ou não em termos de resultados é dependente da natureza do problema estudado, em um sistema SHM é preferível falsos positivos à falsos negativos pois isto significa a não identificação de um dano potencialmente perigoso. A partir dos resultados da matriz de confusão podem se obter outras métricas.

- Acurácia: representa a proporção de previsões corretas em relação ao total de previsões.

$$\frac{TP + TN}{TP + FP + FN + TN} \quad (15)$$

- Precisão: Proporção de verdadeiros positivos em relação à soma de verdadeiros positivos e falsos positivos. Mede a precisão das previsões positivas do modelo.

$$\frac{TP}{TP + FP} \quad (16)$$

- Revocação (ou sensibilidade): A proporção de verdadeiros positivos em relação à soma de verdadeiros positivos e falsos negativos. Mede a capacidade do modelo de encontrar todos os casos positivos.

$$\frac{TP}{TP + FN} \quad (17)$$

- F1-score: A média harmônica entre precisão e revocação. Pode ser útil quando as classes estão desequilibradas.

$$\frac{2 \times (Precisão + Revocação)}{Precisão + Revocação} \quad (18)$$

Figura 13 – Exemplo de matriz de confusão para base de dados com duas classes “1” e “0”.

		Rótulos previstos pelo modelo	
		1	0
Rótulos reais	1	Verdadeiro Positivo (TP)	Falso Negativo (FN)
	0	Falso Positivo (FP)	Verdadeiro Negativo (TN)

Fonte: o autor (2024).

A avaliação de desempenho dos algoritmos é relevante para estabelecer o quão adequado é um algoritmo para atuar na classificação de danos. Contudo, é importante também comparar os algoritmos entre si de forma a observar se há diferenças relevantes ou se o desempenho é similar a ponto de terem um desempenho estatisticamente equivalente. Para tanto, o teste de postos com sinal de Wilcoxon é

adequado para esta análise, por se tratar de um teste não paramétrico, mais apropriado para avaliação de algoritmos ML (TRAWINSKI *et al.*, 2012).

O teste de postos de Wilcoxon funciona da seguinte forma, considere duas amostras, X_i representa os escores da amostra 1 e Y_i os da amostra 2, onde o subíndice i é o número da amostra. Calcula-se as diferenças de cada par de escores

$$d_i = X_i - Y_i \quad (19)$$

atribui-se postos, ou seja, a ordem de classificação, baseado em $|d_i|$ e em seguida acrescenta-se o sinal das diferenças d_i . Ocorrendo um empate, se $|d_i| = 0$, retira-se o par da análise. Caso contrário, se as diferenças em valor absoluto ($|d_i|$) forem iguais, atribuem-se à essas diferenças a média dos postos que as receberiam se não fossem empatadas. Em seguida, acrescentam-se aos postos os sinais das diferenças.

Na próxima seção serão comentados os algoritmos ML de Máquinas de Vetores de Suporte, Perceptron Multicamadas e *Extreme Gradient Boosting*.

2.5.2.1 Máquinas de Vetores de Suporte

Um modelo de Máquinas de Vetores de Suporte, também chamado de *Support Vector Machines* (SVM), busca separar duas classes de dados utilizando um hiperplano, ou linha no caso de duas dimensões. A Figura 14 mostra duas classes de dados que são separáveis linearmente, muitos hiperplanos são capazes de separar dos dados, porém a maioria deles não são efetivos em generalizar, uma vez que passam muito perto dos dados. O SVM irá selecionar o hiperplano ótimo, ou seja, que generaliza melhor os dados. A margem é definida como a distância entre o hiperplano e as amostras de treinamento que estão mais próximas a este hiperplano. Os hiperplanos positivo e negativo que geram a margem podem ser descritos pelas equações abaixo.

$$w_0 + w^T x_{pos} = 1 \quad (20)$$

$$w_0 + w^T x_{neg} = -1 \quad (21)$$

Onde w_0 representa o peso zero, w é o vetor de pesos e x é o vetor de valores de entrada. Subtraindo as Equações 1 e 2 uma da outra temos


$$w^T(x_{pos} - x_{neg}) = 2 \quad (22)$$

normalizando a Equação 21 pelo vetor w

$$\frac{w^T(x_{pos} - x_{neg})}{\|w\|} = \frac{2}{\|w\|} \quad (23)$$


o lado esquerdo da Equação 22 representa a distância entre os hiperplanos e, portanto, é o que se objetiva maximizar, ou seja, a minimização do termo $\|w\|$. Trata-se de um problema de otimização, denominado de programação quadrática (HEARST *et al.*, 1998) e pode ser resolvido utilizando o método de multiplicadores de Lagrange (LIMA, 2002). Para problemas que não são linearmente separáveis, ou seja, não é possível separá-los linearmente com um hiperplano, há alguns parâmetros que auxiliam a lidar com este tipo de estrutura de dados. No parâmetro de regularização, C , quanto maiores os valores mais rigorosa a penalização de erros de classificação durante o treinamento, um menor valor de C irá agir de forma oposta. A função *kernel* (ϕ), aumenta a dimensionalidade dos dados de forma que um hiperplano de separação das classes possa ser achado (Figura 15), existem tipos diferentes de *kernel* como o linear, polinomial, *radial basis function* (rbf) e sigmoide. Para o parâmetro *gamma* (γ), regula o grau de suavização das margens de separação entre as classes de amostras.

Figura 14 – Separação de classes com o hiperplano.



Fonte: o autor (2024).

Figura 15 – Uso da função kernel para separação de dados não linearmente separáveis.




Fonte: Raschka (2015).

2.5.2.2 Perceptron multicamadas

Também conhecido como *Multilayer Perceptron* (MLP), é uma classe de Rede Neural Artificial (ANN). ANNs são modelos de ML que seguem estrutura e organização similar aos neurônios biológicos, disparando ou não a partir de um sinal de entrada. O MLP é constituído de perceptrons, que são redes neurais uma única camada e único neurônio, cuja estrutura básica é apresentada na Figura 16.

Figura 16 - Estrutura básica do neurônio.



Fonte: o autor (2024).


Uma rede neural constituída de mais de uma camada é chamada de MLP (Figura 17), normalmente constituído por uma camada de entrada interligada às camadas internas (*hidden layers*) que possuem número variável a depender da MLP e, por fim, a última camada com as saídas. Os valores de entrada no perceptron x_i ($i = 1, 2, \dots, n$) são ponderados por um fator w_i ($i = 1, 2, \dots, n$) antes de passarem para o corpo do neurônio. Estes valores de entrada ponderados são então somados para produzir o sinal de ativação z .

$$z = \sum_{i=1}^n w_i x_i \quad (24)$$

O valor obtido em z passa para uma função de ativação não linear (também referida como função de transferência), que dita se o valor de z irá ou não ativar o neurônio se ele exceder um valor β , isto é exemplificado na Equação 24, onde o neurônio dispara com um valor 1 e não dispara caso o valor seja 0. Por fim, o neurônio ativado, se ativado, indica a classe y .

$$f_{\beta} = \begin{cases} 1 & z > \beta \\ 0 & z \leq \beta \end{cases} \quad (25)$$

Figura 17 – Estrutura básica do MLP.




Fonte: o autor (2024).

2.5.2.3 Extreme Gradient Boosting

O algoritmo *Gradient Boosting* (GB) vem sendo gradualmente explorado para aplicações de SHM (LEON-MEDINA *et al.*, 2021). Trata-se de um método de aprendizado por conjunto (*ensemble method*), onde algoritmos classificadores fracos (*weak learners*) como as árvores de decisão, que possuem baixa capacidade preditiva quando utilizados isoladamente, são utilizados em conjunto e aumentam consideravelmente o desempenho do modelo. Os *weak learners* são aplicadas de forma sequencial aos dados com o objetivo de que cada modelo minimize o erro do modelo anterior através de uma função de perda (Figura 18). O GB pode ser implementado através de uma biblioteca de *Extreme Gradient Boosting* (XGBoost). O XGBoost é uma versão de processamento paralelizado do GB, o que significa que pode ser implementado para treinamento com utilização de múltiplos núcleos de CPU, também possui funcionalidades internas que ajudam a evitar *overfitting* e adaptar melhor o algoritmo à dados não lineares (CHEN, T.; GUESTRIN, 2016).

Figura 18 - Esquema ilustrativo do funcionamento do XGBoost.




Fonte: o autor (2024).

3 MATERIAIS E MÉTODOS

O estudo em questão foi desenvolvido a partir de uma base de dados criada através de um modelo FEM, sem e com tipos diferentes de dano, incluindo diferentes localidades e severidades. Inicialmente, este modelo é validado através de um estudo experimental análogo à simulação, verificando-se a proximidade entre calculado numericamente e o fenômeno real. Na sequência, os dados obtidos são organizados e categorizados em três diferentes tipos de dano e os sinais em função do tempo são devidamente pré-processados para então servir ao propósito de treinamento, validação e teste de diferentes modelos de ML. Um resumo da metodologia do estudo é apresentado na Figura 19. O software COMSOL Multiphysics® é utilizado para construção e solução dos modelos FEM, modelos de ML são desenvolvidos em linguagem Python com utilização da biblioteca Scikit-learn (PEDREGOSA *et al.*, 2012).

Figura 19 – Fluxograma de etapas do estudo.



Fonte: O autor (2024).


3.1 CRIAÇÃO DE UMA BASE DE DADOS PELO MÉTODO DOS ELEMENTOS FINITOS

A criação de um banco de dados experimental com diversas situações estruturais pode ser um processo longo e custoso, e a geração de amostras por meio de métodos de modelagem computacional, como o FEM, é uma alternativa para baratear e acelerar este processo. Lu et al. (2009) e Atashipour et al. (2013) utilizam modelos numéricos na geração de sua base de dados, em ambos os trabalhos os resultados numéricos são associados aos experimentais como meio de aumentar o número de amostras. Finotti et al. (2019) e Zhang et al. (2020) também usam o FEM para gerar uma base de dados e testar suas metodologias de detecção de danos, posteriormente adicionando ruído aos sinais para emular incertezas ambientais no sinal colhido, porém ambos optam por usar uma base de dados inteiramente constituída dos resultados do modelo numérico. Como demonstrado por Khan et al. (2017), é possível atingir um alto grau de correlação entre os resultados analítico, simulado e experimental com um modelo FEM 2D, quando conhecido bem as características geométricas e materiais.

3.1.1 Modelagem Computacional da Propagação de Ondas de Lamb


No presente estudo, um modelo FEM 2D foi criado no software COMSOL Multiphysics® baseado no estudo experimental de Cano (2015). O modelo FEM, foi utilizado como uma solução custo-benefício para simular diversas condições estruturais. O experimento, trata-se de uma placa de alumínio de 1,6 mm de espessura, instrumentada com dois PZTs retangulares de dimensões 7 mm x 7 mm x 0,27 mm (Figura 20), onde o PZT 1 trabalha como atuador excitando frequências que se propagam pela placa e o PZT 2 como sensor, captando as perturbações mecânicas geradas. Um *tone-burst* de 5 picos com frequência de 200 kHz foi utilizado como sinal de excitação da estrutura, as curvas de dispersão com as velocidades de fase e grupo para os pacotes de onda, respectivamente, podem ser vistas na Figura 21.

Figura 20 – Esquema ilustrativo da placa e transdutores do experimento. Dimensões em milímetros.



Fonte: O autor (2024).


Figura 21 – Curvas de dispersão com velocidade de grupo e fase em uma placa de 1,6 mm de espessura.



Fonte: O autor (2024).

O modelo FEM 2D representa um recorte da seção longitudinal (seção A-A) da placa, esta representação é possível devido a característica simétrica da placa e posicionamento dos transdutores. A malha de elementos finitos segue os padrões mostrados na Figura 22 e Tabela 2.

Figura 22 – Malha de elementos finitos no modelo. Em (a) destaque para o refino de malha próximo ao PZT e em (b) o refino próximo ao dano.



Fonte: O autor (2024).

Tabela 2 – Valores definidos para os parâmetros da malha.

Parâmetros da malha (COMSOL)	Valor
<i>Maximum element size</i>	0,00125 [m]
<i>Minimum element size</i>	6,5E-6 [m]
<i>Maximum element growth rate</i>	1,1
<i>Curvature fator</i>	0,2
<i>Resolution of narrow regions</i>	0,7

Fonte: O autor (2024).

Foi utilizado as propriedades padrão para o alumínio disponível na biblioteca de materiais do software FEM, apresentado na Tabela 3.

Tabela 3 – Propriedades assumidas para os materiais.

Alumínio	Valor
Densidade	2700 [kg/m ³]
Módulo de elasticidade	70e9 [Pa]
Coeficiente de Poisson	0,33
Titanato Zirconato de Chumbo	Valor
Densidade	7750 [kg/m ³]
Matriz de elasticidade	{1.20346e+011[Pa], 7.51791e+010[Pa], 1.20346e+011[Pa], 7.50901e+010[Pa], 7.50901e+010[Pa], 1.10867e+011[Pa], 0[Pa], 0[Pa], 0[Pa], 2.10526e+010[Pa], 0[Pa], 0[Pa], 0[Pa], 0[Pa], 2.10526e+010[Pa], 0[Pa], 0[Pa], 0[Pa], 0[Pa], 0[Pa], 2.25734e+010[Pa]}
Matriz de acoplamento	{0[C/m ²], 0[C/m ²], -5.35116[C/m ²], 0[C/m ²], 0[C/m ²], -5.35116[C/m ²], 0[C/m ²], 0[C/m ²], 15.7835[C/m ²], 0[C/m ²], 12.2947[C/m ²], 0[C/m ²], 12.2947[C/m ²], 0[C/m ²], 0[C/m ²], 0[C/m ²], 0[C/m ²], 0[C/m ²]}
Permissividade	{919.1, 919.1, 826.6}

Fonte: O autor (2024).

A Figura 23 retrata as condições de contorno utilizadas no modelo, através do módulo *Eletrostatics*, as faces A são consideradas com potencial elétrico nulo e nas faces B, aterradas, e um *tone-burst* de cinco picos foi utilizado como função para o sinal de entrada no transdutor piezoelétrico (face C). O sinal de saída do modelo foi coletado até 250 μ s poupando tempo de computação, uma vez que o primeiro modo dos pacotes de ondas está contido neste intervalo e é sensível à presença de danos. Por fim, a chapa foi considerada fixa nas duas extremidades (faces D).

Figura 23 – Condições de contorno da análise FEM.




Fonte: O autor (2024).

3.1.2 Situações de dano

Para obtenção dos sinais para diferentes estados estruturais, quatro modelos FEM foram criados. O primeiro, sem dano, sendo utilizado para verificação da *baseline* e validação. Os outros três modelos, um para cada geometria de dano: entalhe, retangular e elíptico (Figura 24), cada um deles busca representar um dano passível de ser encontrado em uma estrutura aeronáutica, os danos retangular e elíptico representam uma perda de massa como uma corrosão em chapa metálica, diferenciando-se pela agressividade da perda de massa nas bordas, onde o retangular simula uma transição abrupta de perda de massa e o elíptico uma transição suave, o que implica em diferenças na dispersão das ondas ao interagir com estes dois tipos. Já o dano entalhe busca representar uma trinca em fase inicial de surgimento, sendo sua detecção de grande importância para que não venha a evoluir de forma abrupta e catastrófica.

Figura 24 – Tipos de geometria de dano simulados no estudo.



Fonte: O autor (2024).


Cada tipo tem sua particularidade e deve interagir de forma diferente com a onda, por consequência tendo características de sinal diferentes. Como danos podem se apresentar em diferentes formas e severidades, características de localização e profundidade foram parametrizadas e variadas para cada tipo de dano, conforme a Tabela 4 e Figura 25 – Intervalos de variação de localização e profundidade de dano.. Em suas observações de conclusão, Atashipour et al. (2013), que utilizou 95 testes para formar o banco de dados do seu estudo, destaca que um incremento menor entre as variações de localização e severidade do dano pode aumentar a acurácia do algoritmo, uma vez que aumenta o envelope de situações de dano para treinamento. Portanto, este estudo totaliza 315 testes em seu conjunto de dados, com classes perfeitamente balanceadas contendo 105 exemplos de cada tipo de dano.

Tabela 4 – Tipos de geometria de dano simulados no estudo.

Tipo	Amostras de cada tipo	Largura [mm]	Profundidade [mm]	Localização [mm]
Entalhe	105	0,2	5 valores, de 0,2 até 1,0	20 valores, de 112,5 até 212,5
Retangular	105	7,0		
Elíptico	105			

Fonte: O autor (2024).

Figura 25 – Intervalos de variação de localização e profundidade de dano. Em (a) o intervalo de localização e em (b) o intervalo mínimo e máximo de profundidade.



Fonte: O autor (2024).


3.2 DESENVOLVIMENTO DOS MODELOS PARA CLASSIFICAÇÃO DE DANO

Nesta seção é abordada a etapa de extração de atributos dos sinais obtidos através dos modelos FEM.

3.2.1 Preparação dos atributos

Os sinais de todos os estados estruturais presentes na base de foram tratados para extração dos DCPs, como o objetivo do presente trabalho é o desenvolvimento de algoritmo capaz de adequadamente classificar o tipo de dano presente na estrutura, o sinal da *baseline* não é utilizado como entrada neste trecho do estudo. Cada sinal tem sua amplitude normalizada para homogeneizar as amostras, evitando variabilidades que causem discrepância entre os sinais e, portanto, tornando difícil compará-los. O sinal também é segmentado (janelado) em $200\ \mu s$, já que este trecho contém ambos os pacotes de onda S_0 e A_0 , que são sensíveis a presença de danos (Figura 26(a)). A CWT é aplicada sobre o sinal para obtenção de características de energia, como apresentado na Figura 26 (b), e então é aplicado a SAP (Figura 26 (c)), por fim extraídos 50 DCPs ao longo da curva SAP (Figura 26 (d)), e são organizados em um vetor 50 por 2 contendo a amplitude normalizada para cada ponto extraído, a amplitude para cada um dos pontos é utilizada como entrada no algoritmo de ML.

Figura 26 – Etapas do processamento de sinais e extração de atributos empregadas no estudo. Em (a) o janelamento do sinal normalizado, (b) aplicação da transformada wavelet contínua, (c) aplicação da SAP e (d) extração dos DCPs.




Fonte: O autor (2024).

3.2.2 Modelos para classificação de danos

Três modelos preditivos de classificação são empregados neste trabalho: SVM, MLP e XGBoost e, apesar das diferenças na forma que funcionam, possuem etapas metodológicas em comum, como a validação cruzada e seleção de atributos, mencionada na seção anterior, e otimização de hiperparâmetros. O estudo dos modelos segue o fluxo mostrado na Figura 27.

Figura 27 - Fluxo de avaliação dos modelos de aprendizagem de máquina.



Fonte: O autor (2024).

Neste estudo foram utilizados dois diferentes métodos para selecionar os hiperparâmetros: estratégia de busca por *grid* e utilização da ferramenta Optuna (AKIBA *et al.*, 2019; WU, J. *et al.*, 2019). Na busca *grid* os hiperparâmetros foram variados conforme a Tabela 5. As funções *radial basis* e polinomial são abreviadas como “rbf” e “poly”, respectivamente. Já as funções logística sigmoide, tangente hiperbólica e *rectified linear unit* são abreviadas como “logistic”, “tanh” e “relu”, respectivamente. Para cada modelo ML as duas abordagens de otimização foram aplicadas e os melhores hiperparâmetros foram obtidos baseado nos melhores resultados de acurácia, a validação cruzada foi realizada com a técnica *k-fold*, com $k = 5$. A Tabela 6 abaixo mostra os hiperparâmetros selecionados para os algoritmos. No MLP optou-se pela utilização de duas camadas ocultas, baseado no trabalho de referência de Atashipour *et al.* (2013).

Tabela 5 - Variação dos hiperparâmetros para busca grid.

Algoritmo	Hiperparâmetro	Mínimo	Máximo	Espaçamento
SVM	<i>C</i>	0,001	500	10
	<i>gamma</i>	0,0001	1	10
	<i>kernel</i>	-	-	<i>linear, poly, rbf, sigmoid</i>
MLP	<i>n_layers</i>	-	2	-
	<i>Hidden_layer_sizes</i>	100	200	10
	<i>activation</i>	-	-	<i>Identity, logistic, tanh, relu</i>
XGBoost	<i>reg_alpha</i>	1e-08	1	10
	<i>reg_lambda</i>	1e-08	1	10
	<i>n_estimators</i>	1	200	15
	<i>booster</i>	-	-	<i>gbtree, gblinear, dart</i>

Fonte: O autor (2024).

Tabela 6 – Hiperparâmetros dos modelos.

	Hiperparâmetro	Valor
SVM	<i>C</i>	67,595
	<i>gamma</i>	0,386
	<i>kernel</i>	rbf
MLP	<i>Hidden_layer_sizes</i>	(198, 112)
	<i>max_iter</i>	2000
	<i>random_state</i>	30
	<i>activation</i>	relu
XGBoost	<i>reg_alpha</i>	1e-08
	<i>reg_lambda</i>	1e-08
	<i>learning_rate</i>	0,02
	<i>n_estimators</i>	184
	<i>objective</i>	multi:softprob

Fonte: O autor (2024).

A classificação de danos impõe desafios específicos, uma vez que o formato e regularidade da avaria bastam bastante em uma estrutura real e influenciam significativamente na forma que diferentes pacotes de ondas irão interagir com ele, já que as ondas são dispersadas e refletidas, e se espalham de forma distinta. Portanto, um sistema que se propõe a fazer este tipo de previsão deve ter boa capacidade de generalização, se adaptando às nuances encontradas no meio monitorado.

4 RESULTADOS E DISCUSSÕES


Nesta seção são apresentados os resultados obtidos para o modelo numérico e o desempenho dos modelos de ML na classificação quanto aos tipos de dano.

4.1 COMPETÊNCIA DO MODELO NUMÉRICO PARA MODELAGEM DA PROPAGAÇÃO DE ONDAS DE LAMB

Os resultados do experimento e modelo numérico foram comparados para a condição não danificada (Figura 28), com ambos os sinais normalizados no intervalo $[-1, 1]$. É possível perceber uma diferença de amplitude entre ambos no pacote de onda S_0 , assim como diferenças no momento de recepção do pacote de onda A_0 e nas ondas refletidas pelas bordas, isto pode ser atribuído a incertezas geométricas e especificações materiais entre experimento e simulação (ZHANG, Z. *et al.*, 2020). O crosstalk, visto no sinal do experimento, é uma interferência causada no sinal por outros equipamentos eletrônicos. O modelo numérico, no entanto, apresentou um comportamento coerente com o esperado fisicamente, com as ondas A_0 e S_0 se desprendendo e propagando em velocidades e amplitudes distintas. O pacote A_0 com movimentação das partículas para fora do plano da placa e velocidade menor que as S_0 , enquanto as S_0 apresentando um movimento das partículas dentro do plano e com velocidade maior que as A_0 (Figura 29). Em seu artigo, Qiu et al. (2019) também conclui que os resultados obtidos a partir da simulação numérica são equivalentes àqueles de resultados experimentais, indicando assim que modelos FEM são eficazes na avaliação de situações com propagação de ondas de Lamb.


Na Figura 29, é possível observar que, no momento (a) as ondas geradas pelo PZT 1 começam a se propagar pela placa, em (b) o pacote S_0 se separa devido a sua maior velocidade de grupo, e em (c) após passar pelo PZT 2 e refletir na borda o pacote S_0 volta e se encontrar com o A_0 que está indo em direção ao PZT 2, no instante (d) $150 \mu s$ o pacote A_0 é recepcionado no PZT 2 e o S_0 retorna ao extremo esquerdo da placa. Em (e) e (f) é possível observar as reflexões e subsequentes superposição de modos.

Figura 28 – Comparativo entre experimento e simulação da baseline para validação do modelo numérico.



Fonte: O autor (2024).

Figura 29 – Vista do corte transversal da placa de alumínio com plot em setas mostrando de forma ampliada o deslocamento das ondas de Lamb nos momentos (a) 30 μs (b) 50 μs (c) 100 μs (d) 150 μs (e) 200 μs (f) 250 μs .




Fonte: O autor (2024).

4.2 DESEMPENHO DOS MODELOS DE CLASSIFICAÇÃO

É fundamental que os atributos extraídos sejam sensíveis às distinções entre diferentes características geométricas do dano. Na Figura 30, são mostradas as variações no sinal bruto normalizado, SAP e DCPs para cada um dos danos, para localização no centro da placa e profundidade de 0,55 mm. Assim como Atashipour et al. (2013) observa em seu trabalho, a curva SAP é sensível ao dano presente na estrutura, sendo possível visualizar a modificação nas características do sinal de saída e sua consequente alteração na amplitude normalizada dos DCPs.

Figura 30 - Variação dos atributos para os diferentes tipos de dano.



Fonte: O autor (2024).

Testes estatísticos foram realizados através do teste de postos com sinal de Wilcoxon, conforme mencionado na Seção 2.5.2. A acurácia é adotada como métrica para avaliação dos modelos e a decisão de rejeitar a hipótese nula (H_0), indicando que os modelos não são estatisticamente equivalentes, é tomada quando o valor-p é inferior a 0,05. Os resultados da análise comparativa estão na Tabela 7.


Tabela 7 – p-valores para cada comparativo do teste de ponto com sinal de Wilcoxon.

	SVM	MLP	XGBoost
SVM	-	0,0137	0,0058
MLP	-	-	0,0268
XGBoost	-	-	-

Fonte: O autor (2024).


As matrizes de confusão, apresentadas nas Figura 31, Figura 32 e Figura 33, mostram o desempenho dos três modelos avaliados: SVM, MLP e XGBoost, respectivamente. Como dois otimizadores foram utilizados na busca pelos hiperparâmetros, em (a) é mostrado resultados obtidos com a busca em *grid* e em (b) com o uso da ferramenta Optuna.

Figura 31 - Matriz de confusão para o algoritmo SVM, em (a) resultados para o grid e em (b) para o Optuna.




Fonte: O autor (2024).

Figura 32 – Matriz de confusão para o algoritmo MLP, em (a) resultados para o grid e em (b) para o Optuna.



Fonte: O autor (2024).

Figura 33 – Matriz de confusão para o algoritmo XGBoost, em (a) resultados para o grid e em (b) para o Optuna.



Fonte: O autor (2024).

A partir das matrizes de confusão, extraem-se as principais métricas de avaliação do desempenho nos modelos, como é possível observar nas Tabela 8, Tabela 9 e Tabela 10.

Tabela 8 – Métricas de desempenho por classe para o algoritmo SVM.

Métrica	Classe	Valor (<i>grid</i>)	Valor (<i>Optuna</i>)
Precisão	Elíptico	0,76	0,92
	Entalhe	0,83	0,94
	Retangular	0,90	0,47
Revocação	Elíptico	0,85	0,80
	Entalhe	0,93	0,80
	Retangular	0,69	1,00
F1-score	Elíptico	0,80	0,86
	Entalhe	0,88	0,86
	Retangular	0,78	0,64
Acurácia	Geral	0,82	0,82

Fonte: O autor (2024).

Tabela 9 – Métricas de desempenho por classe para o algoritmo MLP.

Métrica	Classe	Valor (<i>grid</i>)	Valor (<i>Optuna</i>)
Precisão	Elíptico	0,88	0,85
	Entalhe	0,93	0,96
	Retangular	0,92	0,85
Revocação	Elíptico	0,96	0,85
	Entalhe	0,89	0,93
	Retangular	0,89	0,88
F1-score	Elíptico	0,92	0,85
	Entalhe	0,91	0,95
	Retangular	0,91	0,86
Acurácia	Geral	0,91	0,89

Fonte: O autor (2024).

Tabela 10 – Métricas de desempenho por classe para o algoritmo XGBoost.

Métrica	Classe	Valor (<i>grid</i>)	Valor (<i>Optuna</i>)
Precisão	Elíptico	0,92	0,92
	Entalhe	1	0,96
	Retangular	0,92	0,88
Revocação	Elíptico	1	0,96
	Entalhe	0,93	0,93
	Retangular	0,92	0,88
F1-score	Elíptico	0,96	0,94
	Entalhe	0,96	0,95
	Retangular	0,92	0,88
Acurácia	Geral	0,95	0,92

Fonte: O autor (2024).

Comparativamente, a técnica de busca *grid* conseguiu melhores valores de acurácia para as principais métricas de desempenho, isto se deve à sua natureza de busca exaustiva, onde são procurados valores em todo o intervalo definido, e é esperado que seus resultados de busca sejam melhores, como demonstrado aqui. Contudo, nem sempre será melhor a utilização da busca *grid*, esta pode ser tida como um bom ponto de partida para exploração, mas para uma busca com grande número de hiperparâmetros esta técnica pode consumir tempo e recursos computacionais significativos, portanto, ao realizar um estudo de otimização de hiperparâmetros cabe a ponderação entre as vantagens e desvantagens de cada técnica.

É de grande relevância que em um sistema SHM cujo objetivo é a identificação quanto a presença do dano haja o menor número possível de falsos negativos, uma vez que a falha em destacar a presença de danos pode contribuir negativamente na tomada de decisões que buscam evitar a falha em uma estrutura aeronáutica. Neste caso, a revocação é um bom indicador, uma vez que relaciona diretamente verdadeiros positivos e falsos negativos. Vale destacar que a incorreta classificação quanto a características do dano também pode interferir na tomada de decisão, já que ações de reparo irão variar de acordo com a natureza do problema observado, somado a isto, para o conjunto de dados utilizado neste estudo tem-se um perfeito balanceamento entre classes (105 exemplos para cada dano), ambos os fatos

apontam para acurácia como um bom indicador de performance a ser observado. Todos os três algoritmos desempenham de forma similar, com os melhores resultados ficando por parte do XGBoost, com uma acurácia de 95%, frente a 91% do MLP e 82% do SVM. O XGBoost também apresenta a vantagem de ser melhor otimizado para funcionar com arquiteturas mais modernas de processamento (CHEN, T.; GUESTRIN, 2016). Estes resultados estão em concordância com os obtidos por Santarsiero et al. (2021) que, ao avaliar o desempenho de algoritmos ML, incluindo os mencionados SVM, MLP e XGBoost, para a predição de falha em uma junta viga-coluna, concluiu que o XGBoost supera os demais algoritmos em todas as métricas consideradas pelos autores. Isto reforça a eficácia e potencial do XGBoost para aplicações na área SHM.

Como observado no trabalho aqui apresentado, é notável que o SVM tem mais dificuldades para classificar o formato retangular, ambos MLP e XGBoost apresentam seus valores mais baixos de revocação para este tipo. Isto pode acontecer pela combinação entre perda de espessura ao longo de uma região mais extensa (como visto no dano elíptico) e uma mudança abrupta em espessura (como visto no dano entalhe), tornando a dispersão dos pacotes de onda mais proeminentes e, portanto, causando uma maior variação nas características das ondas à medida que o dano retangular muda de posição e profundidade durante a parametrização.

5 CONCLUSÕES

O trabalho apresenta uma abordagem de Structural Health Monitoring (SHM) voltada para classificação de danos, devido à sua importância para desenvolver sistemas SHM mais abrangentes. Para explorar o potencial de algoritmos ML na classificação de danos em chapas finas de alumínio, um modelo FEM é usado para reproduzir cenários de dano e validado com dados experimentais. Esta abordagem não apenas oferece uma visão mais custo-eficiente em problemas com dados limitados, mas também é capaz reproduzir a complexa interação dano-onda.

Na extração de atributos, técnicas de processamento como janelamento, normalização, CWT e SAP, se apresentam como ferramentas adequadas para o processamento do sinal no domínio do tempo e extração dos DCPs que, por sua vez, mostram-se eficazes na criação de modelos ML, tendo sensibilidade à variações nos parâmetros de dano.

Os algoritmos SVM e MLP, amplamente conhecidos na literatura, exibem desempenho sólido em diversas aplicações na área de SHM. No entanto, o destaque recai sobre o XGBoost, um algoritmo mais recente, que se sobressai frente aos demais avaliados, conseguindo melhores resultados nas métricas de classificação, o que está em linha com descobertas de pesquisas recentes da área.

Em síntese, este trabalho contribui para o campo de estudo de SHM ao expandir o escopo de aplicação dos DCPs na classificação de danos em chapas finas e simulação de ondas de Lamb pelo método dos elementos finitos. Além disso, destaca-se o papel proeminente do XGBoost, oferecendo resultados superiores quando comparado a algoritmos tradicionais. Esses insights têm implicações práticas no desenvolvimento de estratégias avançadas de SHM, proporcionando uma base sólida para futuras pesquisas e aplicações práticas na área.

6 SUGESTÕES PARA TRABALHOS FUTUROS

Para além dos aspectos apresentados neste trabalho, algumas considerações podem ser feitas para trabalhos futuros:

- Estudo para utilização isolada dos pacotes de onda A_0 e S_0 para extração de atributos com capacidade de identificação de danos com características distintas;
- Utilizar a mesma metodologia apresentada neste trabalho aplicada à identificação de danos em materiais compósitos, como polímeros reforçados com fibra de carbono, bastante utilizados na indústria aeronáutica;
- Estudar como a metodologia apresentada neste estudo, em especial o algoritmo XGBoost, desempenha em uma base de dados com variáveis ambientais, como temperatura e esforços mecânicos no meio monitorado. Tal estudo permitirá observar como esta metodologia se aplica em condições mais próximas a aplicações in situ.
- Explorar a inclusão de novos atributos derivados de métodos de processamento alternativos. Isso pode envolver a avaliação de diferentes técnicas de processamento de sinal ou a incorporação de atributos específicos (alternativos aos DCPs) para aprimorar a capacidade de classificação de danos.
- Integrar o processo de classificação de danos apresentado neste trabalho com os demais níveis de um sistema SHM observando, por exemplo, como os dados obtidos na classificação servem de embasamento para os níveis superiores de avaliação e predição.

REFERÊNCIAS

- ABBAS, M.; SHAFIEE, M. Structural Health Monitoring (SHM) and Determination of Surface Defects in Large Metallic Structures using Ultrasonic Guided Waves. **Sensors**, 15 nov. 2018. v. 18, n. 11, p. 3958.
- AKIBA, T. *et al.* **Optuna: A Next-generation Hyperparameter Optimization Framework**. arXiv. Disponível em: <<http://arxiv.org/abs/1907.10902>>. Acesso em: 2 ago. 2023.
- AMEZQUITA-SANCHEZ, J. P.; ADELI, H. Signal Processing Techniques for Vibration-Based Health Monitoring of Smart Structures. **Archives of Computational Methods in Engineering**, mar. 2016. v. 23, n. 1, p. 1–15.
- ATASHIPOUR, S. A. *et al.* An effective damage identification approach in thick steel beams based on guided ultrasonic waves for structural health monitoring applications. **Journal of Intelligent Material Systems and Structures**, mar. 2013. v. 24, n. 5, p. 584–597.
- BADILLO, S. *et al.* An Introduction to Machine Learning. **Clinical Pharmacology and Therapeutics**, abr. 2020. v. 107, n. 4, p. 871–885.
- BAO, Y.; LI, H. Machine learning paradigm for structural health monitoring. **Structural Health Monitoring**, jul. 2021. v. 20, n. 4, p. 1353–1372.
- CALLISTER, W. D.; RETHWISCH, D. G. **Ciência e Engenharia de Materiais - Uma Introdução**. 10ª edição ed. [S.l.]: LTC, 2020.
- CANO, W. F. R. [UNESP. **Aplicação da análise de séries temporais para detecção e prognóstico de danos em estruturas inteligentes**. [S.l.]: Universidade Estadual Paulista (UNESP), 2015. Disponível em: <<https://repositorio.unesp.br/handle/11449/127896>>. Acesso em: 6 ago. 2023.
- CHEN, T.; GUESTRIN, C. XGBoost: **A Scalable Tree Boosting System**. [S.l.]: [s.n.], 2016. p. 785–794. Disponível em: <<http://arxiv.org/abs/1603.02754>>. Acesso em: 1º jul. 2023. arXiv:1603.02754 [cs].
- CORADDU, A. *et al.* Machine learning approaches for improving condition-based maintenance of naval propulsion plants. **Proceedings of the Institution of Mechanical Engineers, Part M: Journal of Engineering for the Maritime Environment**, fev. 2016. v. 230, n. 1, p. 136–153.
- FARRAR, C. R.; WORDEN, K. **Structural health monitoring: a machine learning perspective**. Chichester, West Sussex, U.K. ; Hoboken, N.J.: Wiley, 2013.
- FARRAR, Charles R.; DOEBLING, S. W.; NIX, D. A. Vibration-based structural damage identification. **Philosophical Transactions of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences**, 15 jan. 2001. v. 359, n. 1778, p. 131–149.

FIGUEIREDO, E. *et al.* Finite Element–Based Machine-Learning Approach to Detect Damage in Bridges under Operational and Environmental Variations. **Journal of Bridge Engineering**, jul. 2019. v. 24, n. 7, p. 04019061.

FINOTTI, R. P.; CURY, A. A.; BARBOSA, F. De S. An SHM approach using machine learning and statistical indicators extracted from raw dynamic measurements. **Latin American Journal of Solids and Structures**, 2019. v. 16, n. 2, p. 165.

FRANK PAI, P.; DENG, H.; SUNDARESAN, M. J. Time-frequency characterization of lamb waves for material evaluation and damage inspection of plates. **Mechanical Systems and Signal Processing**, out. 2015. v. 62–63, p. 183–206.

GIURGIUTIU, V. **Structural Health Monitoring with Piezoelectric Wafer Active Sensors**. [S.I.]: Elsevier, 2014.

_____. **Structural health monitoring of aerospace composites**. Amsterdam: Elsevier, 2016.

GOMES, G. F. *et al.* A Review of Vibration Based Inverse Methods for Damage Detection and Identification in Mechanical Structures Using Optimization Algorithms and ANN. **Archives of Computational Methods in Engineering**, set. 2019. v. 26, n. 4, p. 883–897.

GOPALAKRISHNAN, Srinivasan; RUZZENE, M.; HANAGUD, S. **Computational Techniques for Structural Health Monitoring**. London: Springer London, 2011.

HALLIDAY, D.; RESNICK, R.; WALKER, J. **Fundamentos de Física - Vol. 2 - Gravitação, Ondas e Termodinâmica**. 10ª edição ed. [S.I.]: LTC, 2017.

HEARST, M. A. *et al.* Support vector machines. **IEEE Intelligent Systems and their Applications**, jul. 1998. v. 13, n. 4, p. 18–28.

KHAN, S. Z. *et al.* Response of Gaussian-modulated guided wave in aluminum: An analytical, numerical, and experimental study. **Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science**, ago. 2017. v. 231, n. 16, p. 3057–3065.

LAMB, H. On waves in an elastic plate. **Proceedings of the Royal Society of London. Series A, Containing Papers of a Mathematical and Physical Character**, mar. 1917. v. 93, n. 648, p. 114–128.

LEE, B. C.; STASZEWSKI, W. J. Modelling of Lamb waves for damage detection in metallic structures: Part II. Wave interactions with damage. **Smart Materials and Structures**, 1 out. 2003. v. 12, n. 5, p. 815–824.

LEON-MEDINA, J. X. *et al.* Structural Damage Classification in a Jacket-Type Wind-Turbine Foundation Using Principal Component Analysis and Extreme Gradient Boosting. **Sensors**, jan. 2021. v. 21, n. 8, p. 2748.

LIMA, A. R. G. L. **Máquinas de vetores suporte na classificação de impressões digitais**. [S.I.]: UFC, 2002. Dissertação. Disponível em:

<http://www.dominiopublico.gov.br/pesquisa/DetalheObraForm.do?select_action=&o_obra=160842>. Acesso em: 3 ago. 2023.

LU, Y. *et al.* Artificial Neural Network (ANN)-based Crack Identification in Aluminum Plates with Lamb Wave Signals. **Journal of Intelligent Material Systems and Structures**, jan. 2009. v. 20, n. 1, p. 39–49.

MANCO, P. *et al.* Aircraft Maintenance: Structural Health Monitoring Influence on Costs and Practices. **Macromolecular Symposia**, abr. 2021. v. 396, n. 1, p. 2000302.

MATHAI, N.; CHEN, Y.; KIRCHMAIR, J. Validation strategies for target prediction methods. **Briefings in bioinformatics**, 9 abr. 2019. v. 21.

MITRA, M.; GOPALAKRISHNAN, S. Guided wave based structural health monitoring: A review. **Smart Materials and Structures**, 1 maio. 2016. v. 25, n. 5, p. 053001.

NA, W.; BAEK, J. A Review of the Piezoelectric Electromechanical Impedance Based Structural Health Monitoring Technique for Engineering Structures. **Sensors**, 24 abr. 2018. v. 18, n. 5, p. 1307.

NASIR, V.; SASSANI, F. A review on deep learning in machining and tool monitoring: methods, opportunities, and challenges. **The International Journal of Advanced Manufacturing Technology**, ago. 2021. v. 115, n. 9–10, p. 2683–2709.

PARK, G. *et al.* Overview of Piezoelectric Impedance-Based Health Monitoring and Path Forward. **The Shock and Vibration Digest**, 1 nov. 2003. v. 35, n. 6, p. 451–463.

PEDREGOSA, F. *et al.* Scikit-learn: Machine Learning in Python. **Journal of Machine Learning Research**, 2 jan. 2012. v. 12.

PRIYA, S. *et al.* A Review on Piezoelectric Energy Harvesting: Materials, Methods, and Circuits. **Energy Harvesting and Systems**, 1 jan. 2017. v. 4, n. 1, p. 3–39.

QIU, L. *et al.* Multiphysics simulation method of lamb wave propagation with piezoelectric transducers under load condition. **Chinese Journal of Aeronautics**, maio. 2019. v. 32, n. 5, p. 1071–1086.

RAGHAVAN, A.; CESNIK, C. E. S. Review of Guided-wave Structural Health Monitoring. **The Shock and Vibration Digest**, 1 mar. 2007. v. 39, n. 2, p. 91–114.

RASCHKA, S. **Python Machine Learning, 1st Edition**. Birmingham Mumbai: Packt Publishing, 2015.

RYTTER, A. **Vibrational Based Inspection of Civil Engineering Structures**. 1993. Disponível em: <<https://vbn.aau.dk/en/publications/vibrational-based-inspection-of-civil-engineering-structures>>. Acesso em: 4 ago. 2021.

SANTARSIERO, G. *et al.* Structural health monitoring of exterior beam–column subassemblies through detailed numerical modelling and using various machine learning techniques. **Machine Learning with Applications**, 15 dez. 2021. v. 6, p. 100190.

SU, Z.; YE, L. **Identification of damage using Lamb waves: from fundamentals to applications**. Berlin: Springer-Verlag, 2009.

SU, Zhongqing; YE, Lin. Lamb Wave Propagation-based Damage Identification for Quasi-isotropic CF/EP Composite Laminates Using Artificial Neural Algorithm: Part I - Methodology and Database Development. **Journal of Intelligent Material Systems and Structures**, fev. 2005a. v. 16, n. 2, p. 97–111.

_____. Lamb Wave Propagation-based Damage Identification for Quasi-isotropic CF/EP Composite Laminates Using Artificial Neural Algorithm: Part II - Implementation and Validation. **Journal of Intelligent Material Systems and Structures**, fev. 2005b. v. 16, n. 2, p. 113–125.

TRAWINSKI, B. *et al.* Nonparametric statistical analysis for multiple comparison of machine learning regression algorithms. **International Journal of Applied Mathematics and Computer Science**, 28 jan. 2012. v. 22.

WORDEN, K.; DULIEU-BARTON, J. M. An Overview of Intelligent Fault Detection in Systems and Structures. **Structural Health Monitoring**, 1 mar. 2004. v. 3, n. 1, p. 85–98.

WORDEN, Keith; FARRAR, C. **New trends in vibration based structural health monitoring**. Wien New York: Springer, 2010.

WU, J. *et al.* Hyperparameter Optimization for Machine Learning Models Based on Bayesian Optimization. **Journal of Electronic Science and Technology**, 1 mar. 2019. v. 17, n. 1, p. 26–40.

YUAN, Fuh-Gwo (Org.) **Structural Health Monitoring (SHM) in Aerospace Structures**. [S.l.]: Woodhead Publishing, 2016.

ZHANG, S. *et al.* Recent Developments in Piezoelectric Crystals. **Journal of the Korean Ceramic Society**, 30 set. 2018. v. 55, n. 5, p. 419–439.

ZHANG, Z. *et al.* Machine Learning-Enriched Lamb Wave Approaches for Automated Damage Detection. **Sensors**, 24 mar. 2020. v. 20, n. 6, p. 1790.