

# Sistema de Aprendizado de Máquina como Apoio ao Monitoramento da Saúde Estrutural de Aeronaves

Ana Carolina Ribeiro Albino<sup>1</sup>, Cassio Vitor Duvoisin<sup>1</sup> e Gian Ricardo Berkenbrock<sup>1</sup>

<sup>1</sup>LSE/CTJ/Universidade Federal de Santa Catarina (UFSC)

Joinville/SC - Brasil

**Resumo**—A manutenção de aeronaves é essencial para a operação segura, mas o uso de cronogramas baseados em intervalos temporais fixos gera custos elevados, podendo chegar a 15% das despesas operacionais, e não impede falhas inesperadas. O monitoramento da saúde estrutural (MSE), parte da manutenção baseada em condições (CBM), oferece uma alternativa eficaz, reduzindo custos de manutenção em até 30%. Este trabalho desenvolve um modelo de aprendizado de máquina, baseado em perceptrons multicamadas, para classificar a estrutura como saudável ou danificada, utilizando dados da universidade TU Delft. Com acurácia de 90%, o modelo aumenta a confiabilidade do sistema ao localizar falhas com precisão e eliminar falsos positivos.

**Palavras-Chave**—Manutenção de aeronaves, aprendizado de máquina, monitoramento da saúde estrutural.

## I. INTRODUÇÃO

Desde a sua emergência nos anos 30, a aviação tornou-se um dos principais modais de transporte, conhecido pela eficiência e segurança no transporte de cargas e passageiros. Contudo, a manutenção das aeronaves, essencial para garantir sua operacionalidade, enfrenta desafios significativos, principalmente em relação aos custos e eficácia dos métodos tradicionais. Os sistemas de manutenção baseados exclusivamente em intervalos fixos de tempo podem não prevenir falhas críticas efetivamente, resultando em custos operacionais que, segundo [1], podem representar até 15% das despesas totais de operação. A necessidade de métodos mais eficazes e econômicos é evidenciada pelo aumento contínuo na frota global, que demanda abordagens inovadoras para manutenção [2], [3].

O monitoramento da saúde estrutural (MSE) surgiu como uma solução promissora para superar esses desafios. De acordo com [4], ao substituir a manutenção baseada em tempo por uma abordagem condicional (CBM), o MSE utiliza técnicas avançadas para prever falhas antes que elas ocorram, potencialmente economizando significativos recursos financeiros e aumentando a segurança [5], [6]. No entanto, a complexidade dos dados gerados pelo MSE e a necessidade de previsões precisas destacam uma lacuna crítica: a falta de ferramentas robustas de análise e predição [4].

Este artigo aborda essa lacuna integrando aprendizado de máquina ao MSE para criar modelos preditivos mais eficientes. Utilizando dados de teste coletados pela universidade TU Delft no projeto ReMAP [7], desenvolveu-se um modelo baseado em perceptrons multicamadas que classifica a

condição estrutural das aeronaves com uma acurácia de 90%. A contribuição deste trabalho reside não apenas na aplicação de técnicas avançadas de aprendizado de máquina para a análise de dados de MSE, mas também na demonstração de sua eficácia na identificação de falhas potenciais e na prevenção de perdas não programadas.

## II. FUNDAMENTAÇÃO

### A. Escopo da Manutenção Clássica

A manutenção clássica em aviação, fundamentada principalmente em práticas baseadas em intervalos temporais fixos ou no número de operações realizadas, é essencial para garantir a operacionalidade e segurança das aeronaves. Este modelo de manutenção é categorizado em checagens rotineiras [8], cada uma abordando diferentes níveis de profundidade e complexidade:

- *Check A*: Ocorre entre 120 e 150 horas de voo, valida a condição dos principais componentes, leva cerca de 8 horas.
- *Check B*: Ocorre a cada 750 horas de voo, abrange o grupo A e inclui a checagem de sistemas de lubrificação e inspeção aberta de painéis.
- *Check C*: Ocorre a cada 3000 horas de voo, abrange os grupos A e B, chamada de manutenção de hangar. Checa a integridade de sistemas de lubrificação pesado, sistemas de proteção de corrosão, motores e acessórios.
- *Check D*: A cada 20000 horas de voo, inclui os grupos anteriores. O interior da aeronave é desmontado para realizar checagens estruturais detalhadas.

Essas manutenções são vitais para assegurar que todos os sistemas da aeronave funcionem adequadamente e para mitigar riscos de falhas catastróficas. No entanto, apesar da rigorosidade dos procedimentos, a manutenção clássica pode não ser eficiente em detectar falhas ocultas antes que se tornem críticas, além de representar uma parcela significativa dos custos operacionais, chegando a 15% do total [1].

### B. Monitoramento da Saúde Estrutural (MSE)

Entre 1990 e 2007, os Estados Unidos registraram 1502 acidentes aéreos com aeronaves de passageiros, dos quais 26% foram fatais, resultando na perda de 1104 vidas, muitos desses acidentes foram causados por falhas estruturais decorrentes do desgaste das aeronaves [6]. Nesse contexto, o uso de técnicas como o Monitoramento da Saúde Estrutural (MSE) se mostra adequado para mitigar esses riscos, permitindo a detecção

precoce de falhas antes que evoluam para problemas maiores e reduzindo o tempo e os custos associados com manutenções programadas e não programadas [9], [5]. O MSE utiliza uma gama de sensores integrados que monitoram continuamente a integridade estrutural, facilitando a identificação e localização de falhas em estágio inicial, reduzindo assim o tempo e os custos associados com manutenções programadas e não programadas, e estimando reduções de custo de manutenção em até 30% [5].

As técnicas de MSE são classificadas em métodos passivos, que estimam o uso da vida útil da aeronave por meio de parâmetros operacionais, e métodos ativos, que requerem instalação de dispositivos adicionais para aferir a saúde da estrutura através de técnicas como ondas Lamb e emissão acústica [6], [10]. Os métodos ativos, em particular, oferecem maior precisão e capacidade de resposta, utilizando abordagens como pitch-catch e pulse-echo para detectar e localizar fissuras ou descontinuidades estruturais. Estas técnicas permitem avaliações detalhadas da condição estrutural, ajudando na tomada de decisões de manutenção mais informadas e eficazes [6], [10].

Neste estudo, será aplicada uma rede neural supervisionada para processar os dados dos sensores do MSE, classificando a estrutura como saudável ou danificada. A abordagem utilizada permitirá a identificação de falhas estruturais com base nas informações coletadas pelos sensores, integrando as leituras em um modelo preditivo para otimizar a manutenção estrutural de aeronaves.

### C. Ondas Lamb

Ondas Lamb, ou ondas planas, são ondas elásticas descobertas e apresentadas, em 1917, por Horace Lamb e passaram a ser estudadas para aplicação de detecção de trincas em 1940. As ondas Lamb percorrem distâncias longas, mesmo em materiais de paredes finas e alta taxa de atenuação, são sensíveis às falhas estruturais, percorrem longas distâncias de propagação. Após percorrer uma região danificada, suas características são modificadas, portanto, ao inserir diversos sensores na estrutura é possível triangular a localização do dano [6]. A Fig. 1 exemplifica ondas Lamb utilizando uma analogia com a audição humana, nesse caso a fonte sonora representa o atuador, o objeto a trinca e o ouvido os sensores receptores.

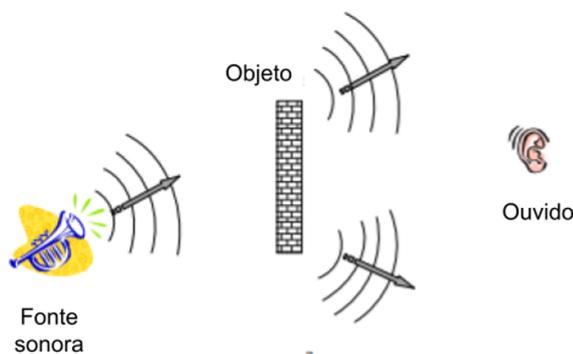


Fig. 1. Exemplificação do funcionamento de ondas Lamb [6].

### D. Aprendizado de máquina (AM)

Aprendizado de máquina (AM) tem se mostrado uma ferramenta computacional eficaz para resolver problemas complexos com custo computacional relativamente baixo, destacando-se principalmente pela sua capacidade de identificar padrões para executar tarefas como encontrar valores numéricos, agrupar dados, e classificar cenários diversos [11]. O AM é categorizado em segmentações principais como aprendizado supervisionado, onde o modelo é treinado com padrões de dados de entrada e saída conhecidos para depois fazer previsões de novos dados, e aprendizado não supervisionado, que organiza dados com base em características determinadas sem intervenção externa. Há também o aprendizado misto, que combina elementos dos dois tipos anteriores, especialmente útil em situações com dados de entrada parcialmente conhecidos [11].

Redes neurais artificiais (RNA), uma forma de aprendizado de máquina supervisionado, usam um conjunto de dados dividido em grupos de treinamento e validação para modelar e verificar a acurácia das previsões [12]. Essas redes processam dados de entrada em formato matricial, onde as colunas representam características e as linhas os valores numéricos associados. Problemas como overfitting e underfitting podem surgir durante o treinamento, afetando a generalização do modelo para novos dados. Para mitigar esses desafios, é necessária uma análise da acurácia do modelo e, possivelmente, a reconfiguração do treinamento para alcançar resultados mais confiáveis. Análises de séries temporais, outro campo do AM, permitem previsões futuras baseadas em dados sequenciais, capturando assim comportamentos sistêmicos ao longo do tempo [13], [14], [15].

### E. Trabalhos Relacionados

Estudos recentes têm explorado o uso combinado de MSE e técnicas avançadas de análise de dados para melhorar as estratégias de manutenção em vários setores industriais, incluindo a aviação. Por exemplo, projetos como o ReMAP têm demonstrado economias significativas e melhorias na eficiência operacional através da aplicação de MSE integrado com análises preditivas [7]. Tais iniciativas sublinham a importância e o potencial de expansão desta tecnologia não apenas em aeronaves, mas também em outras áreas críticas, como infraestrutura e manufatura, destacando o crescente reconhecimento do valor do monitoramento baseado em condições apoiado por inteligência artificial [5], [9].

## III. METODOLOGIA

Este estudo utiliza aprendizado de máquina supervisionado e análise de séries temporais para avaliar a saúde estrutural de parte de uma asa de aeronave. Implementaram-se RNAs para classificar estruturas como saudáveis ou danificadas, baseando-se em dados de sensores para triangular a localização de danos e reduzir falsos positivos. Os dados foram pré-processados para unificar diferentes cenários em sequências coerentes, permitindo análises consistentes. O treinamento e a previsão das redes neurais foram realizados usando Python, com suporte das bibliotecas Scikit Learn [16] para aprendizado de máquina, Numpy [17] para manipulação de dados e Matplotlib [18] para visualização de resultados.

## A. Conjuntos de Dados

Os dados são provenientes de testes realizados pela universidade holandesa TU Delft, dentro do projeto ReMap, que visa inovar a manutenção de aeronaves para adotar a manutenção baseada em condições (CBM). Os testes foram conduzidos com a estrutura fora de operação, utilizando excitação controlada para simular condições de desgaste e permitir a identificação de falhas potenciais antes que se tornassem críticas. A estrutura utilizada para a aquisição dos dados simula a asa de uma aeronave em contato com uma longarina, e a Fig. 2 ilustra a representação esquemática tridimensional do corpo de prova e a localização dos oito sensores piezoelétricos utilizados durante os testes, responsáveis pela geração de excitação via ondas Lamb e pela aquisição de dados. A estrutura foi submetida a impactos causados por pesos acelerados, e cada formato e força de impacto resultaram em uma configuração de teste diferente.

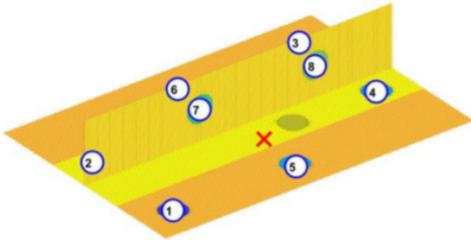


Fig. 2. Desenho tridimensional do corpo de prova [7].

Foram realizadas seis configurações de testes, variando a carga máxima, mínima e a energia do impacto, conforme detalhado na Tabela I. A localização específica de cada impacto é mostrada na Fig. 3. Em cada medição, um sensor atua como atuador enquanto os demais capturam os dados. O sinal de entrada é descrito por 1.

$$x(t) = A \sin(2\pi f_0 t) \sin\left(\frac{\pi f_0 t}{N_c}\right) \quad (1)$$

Onde:

$x(t)$ : Resposta do sinal.

$A$ : Amplitude do sinal.

$f_0$ : Frequência fundamental do sinal.

$t$ : Tempo.

$N_c$ : Fator de escala.

O protótipo foi testado em intervalos de 5000 ciclos, com as cargas dinâmicas também descritas na Tabela I. Este procedimento foi repetido 10 vezes, e em cada medição, todos os sensores excitaram a estrutura, resultando na coleta de 80 dados por medição.

No total, o experimento incluiu 30 ciclos, com os 28 primeiros antes do impacto para avaliar a estrutura em condições normais, um ciclo após o impacto para avaliar as mudanças no perfil de medição e um último ciclo após a ocorrência de fadiga para avaliar danos adicionais. Assim, os dados coletados documentam a transição de uma estrutura saudável para uma danificada, capturando desde o início da operação até o desgaste das propriedades mecânicas devido aos carregamentos dinâmicos e aos eventos subsequentes de impacto e fadiga.

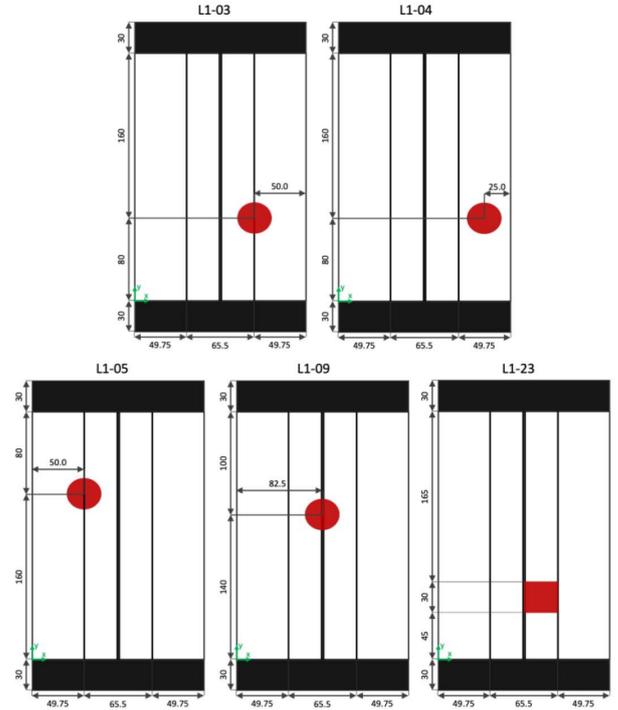


Fig. 3. Localização da região de impacto [7].

TABELA I  
CONFIGURAÇÃO DE TESTE E FORÇA DE IMPACTO [7].

Configuração	L1-03	L1-04	L1-05	L1-09	L1-23 <100000	L1-23 >100000
Carga máxima (kN)	65	65	65	65	50	60
Carga mínima (kN)	6.5	6.5	6.5	6.5	5	6
Dano inicial e força de impacto	10J	10J	10J	10J	30mm	30mm

## B. Pré-processamento

Foi desenvolvido um programa para extrair e armazenar os dados de forma apropriada, minimizando erros de manipulação e otimizando o processo. Para cada sensor, criou-se uma matriz de dimensão  $(n, m)$ , onde  $n$  representa o número de medições ao longo do tempo e  $m$  o número de repetições por ciclo de excitação. Cada coluna desta matriz corresponde a uma série temporal, ou seja, uma medição realizada pelo sensor a cada ciclo de excitação. Já as linhas indicam as medições feitas ao longo do tempo para o mesmo sensor, permitindo acompanhar a evolução do desgaste estrutural. As variações dentro de cada linha mostram a confiabilidade do sensor ao longo do experimento.

As séries temporais de cada coluna contêm 60000 dados, divididos entre as medições antes e após o impacto, e após a ocorrência de fadiga. Estes dados são mantidos sem agregação para preservar a integridade das variações observadas. A análise destas séries busca explorar as mudanças significativas, com a criação de gráficos para visualizar e realizar uma análise exploratória de dados antes de proceder ao desenvolvimento dos modelos de aprendizado de máquina.

## C. Processamento

Um modelo de aprendizado de máquina para cada um dos sensores foi criado, portanto, cada sensor tem uma predição

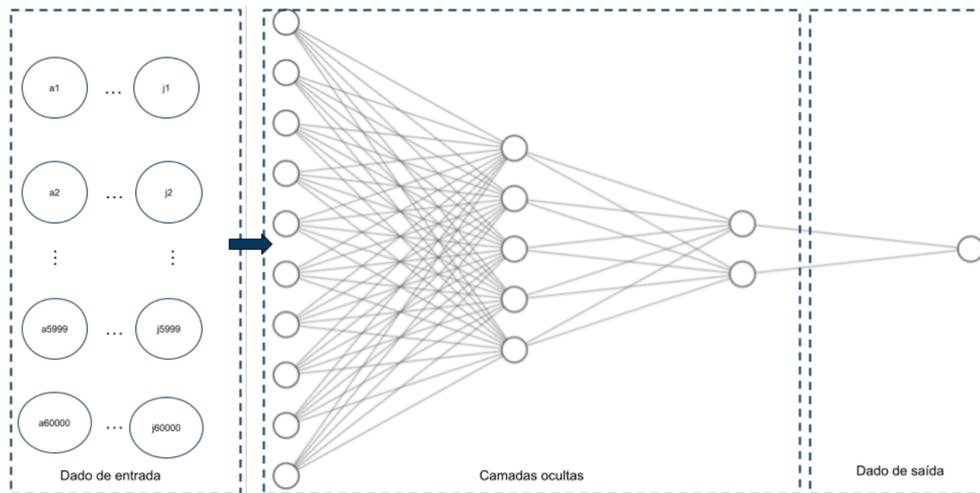


Fig. 4. Formato rede neural.

individual de falha. Esse formato ajuda a analisar o resultado global e triangular a região da falha, pois devido ao comportamento das ondas Lamb, todos os sensores adjacentes as trincas devem indicar a sua presença. Caso isso não ocorra, o resultado pode ser descartado, diminuindo a ocorrência de falsos positivos.

Considerando cada conjunto de 6000 dados disponível por modelo, 80% é usado para fazer o treino da rede e 20% sua validação. Para que o treinamento da rede seja considerado suficientemente bom, a acurácia deve ser superior a 90%, ou seja, dos dados de teste, o nível de acerto deve ter no mínimo esse valor. O dado de entrada é uma medição de tensão, feita pelo sensor e o dado de saída é a classificação em 0 ou 1, dano não potencial e potencial; respectivamente.

Para esse modelo foi criada uma rede neural de classificação - Multilayer perceptron (MLP) - foram usadas três camadas, a primeira com 10 perceptrons, a segunda com 5 e a terceira com 2. O formato de rede é mostrado na Fig. 4. O MLP recebe como dado de entrada a matriz com as 10 séries temporais, (mencionadas na seção de pré-processamento), devido à grande quantidade de conexões, a passagem dos dados para o MLP foi mostrado pela seta azul, que liga o bloco de dados de entrada com o de camadas ocultas.

O resultado é uma classificação binária, entre dano potencial ou não, atrelado a uma estrutura danificada ou saudável, respectivamente. Essa classificação vem do resultado da MLP, na qual fornece um vetor de probabilidade. Nesse vetor cada posição representa uma classe, com uma probabilidade de adequação a ela. A depender desse resultado, o dado é entendido como dano potencial ou estrutura saudável.

Para a preparação e modelagem dos dados, utilizamos várias bibliotecas do pacote *scikit-learn*. A biblioteca *sklearn.preprocessing* foi empregada para normalizar os dados dentro do intervalo  $[-1,1]$ , uma etapa crucial para mitigar o impacto de outliers que poderiam levar a overfitting e, conseqüentemente, reduzir a acurácia das previsões. Para a divisão do conjunto de dados em grupos de treino e teste, utilizamos a *sklearn.model\_selection*. Já a construção e exportação da rede neural de classificação foram realizadas com a *sklearn.neural\_network*, que recebe os dados tratados e parâmetros definidos para a rede MLP.

Os hiperparâmetros configurados para a rede incluíram o

tamanho das camadas ocultas, definidas como três camadas com 10, 5 e 2 perceptrons respectivamente, para equilibrar a capacidade do modelo sem incorrer em overfitting. A função de ativação *relu* foi escolhida para as camadas ocultas devido à sua eficiência em usar o valor máximo em regressões lineares, enquanto o método *adam* foi adotado como solver para otimizar o gradiente estocástico. A taxa de aprendizado foi mantida constante, e o modelo foi configurado para um máximo de 200 iterações para a convergência. Além disso, o parâmetro *random\_state* foi fixado em 1 para garantir a reprodutibilidade dos resultados ao inicializar a rede sempre com os mesmos valores.

#### D. Pós-processamento

Após a classificação dos dados, para cada sensor, o código realiza uma triangulação dos resultados, pois tendo como base a Fig. 2, caso o sensor 7 indique dano potencial, os sensores 2, 5 ou 6 também o indicam o mesmo resultado. Se isso não ocorrer, o resultado é considerado um falso positivo e a predição é descartada. A Tabela II mostra quais sensores devem indicar falha potencial para o resultado não ser descartado. A Fig. 5 mostra o fluxograma dos métodos utilizados nesse trabalho.

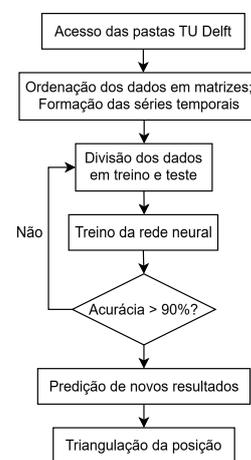


Fig. 5. Fluxograma do código.

TABELA II  
CRITÉRIOS PARA TRIANGULAÇÃO DE RESULTADO .

Sensor analisado	Sensor de validação de falha
2	7
3	4,6 ou 8
4	3,5 ou 8
5	4,7 ou 8
6	2,3,7 ou 8
7	2,5,6 ou 8
8	3,4,5,6 ou 7

#### IV. RESULTADOS

Nesta secção serão discutidas as soluções obtidas aplicando os métodos utilizados. Os seguintes tópicos serão discutidos:

- Abordagem da análise exploratória de dados, devido ao grande volume de dados tratados, provenientes da TU Delft;
- Discussão da acurácia das 7 redes neurais criadas, para a configuração L1-09,
- Triangulação dos dados para validação do conceito;
- Análise de erro ao aplicar a predição com outra configuração de teste, mas mantendo o treinamento com a L1-09; e
- Expansão da triangulação com outros dados.

##### A. Análise exploratória dos dados

Devido ao comportamento das ondas Lamb, espera-se que toda a estrutura tenha um comportamento similar, portando sete sensores, que processam o sinal, devem ter um comportamento similar, porém com aquisições em escalas diferentes, relacionado a distância da fonte de excitação. A presença de dano ou fadiga pode alterar esse padrão.

Ao longo do experimento observaram-se as seguintes características:

- *Na mesma medição:* Há um atraso na leitura realizada pelos sensores em relação ao dado de entrada, ela é proporcional a distância do sensor de leitura ao sensor de excitação;
- *Mesmo sensor entre medições:* Ao comparar o comportamento de um sensor ao longo do tempo, observou-se que não houve diferença significativa em seu tempo de resposta, mas sim na amplitude do sinal recebido.

A fim de concatenar alguns dados e possibilitar a visualização, foi realizado uma média entre os valores obtidos entre cada ciclo, a Fig. 6 mostra a variação dos valores medidos obtidos ao longo do experimento.

##### B. Treinamento da rede

A aplicação dos hiperparâmetros mencionados nos métodos, para cada uma das redes neurais, resultou em uma acurácia de 93,35%. Este valor foi obtido após a triangulação dos dados, um processo no qual os resultados das redes neurais foram validados por sensores adjacentes para reduzir a ocorrência de falsos positivos. Essa triangulação assegura que as falhas indicadas por um sensor são consistentes com as leituras de outros sensores próximos, garantindo maior confiabilidade no diagnóstico. Nenhum falso positivo foi detectado após a triangulação, o que indica que os resultados são consistentes entre si na detecção de falhas.

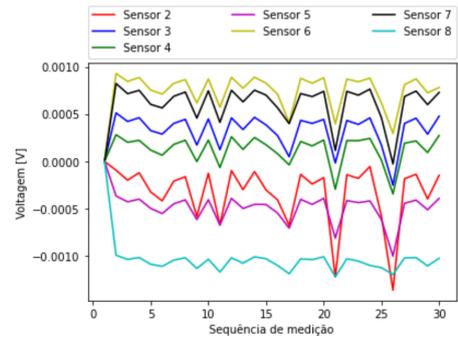


Fig. 6. Evolução média global ao longo do experimento.

##### C. Predição de novos resultados

Uma nova tentativa de classificação foi realizada utilizando os dados de treinamento, desta vez com a introdução de ruído nas medições para verificar a robustez do modelo em cenários com variabilidade nos dados. Nas primeiras cinco medições de cada sensor, foi aplicada a função  $y(t) = 0.01 \sin\left(\frac{\pi}{4}t\right)$ , e nas últimas cinco medições, a função  $y(t) = 0.01 \sin\left(\frac{\pi}{2}t\right)$ , escolhidas devido à sua capacidade de simular variações harmônicas que podem ocorrer durante o monitoramento de saúde estrutural em condições reais. Essas funções representam oscilações de baixa amplitude, comuns em ruídos gerados por sensores durante a operação. A Tabela III apresenta os resultados de acurácia e a quantidade de falsos positivos após a introdução desse ruído harmônico.

TABELA III  
PARÂMETROS DE QUALIDADE - APÓS ADIÇÃO DE RUÍDO NOS DADOS.

Rede neural sensor correspondente	Acurácia	Quantidade de falso positivos
2	93,30	0
3	93,32	0
4	93,30	0
5	93,30	0
6	93,30	0
7	93,30	0
8	93,30	0

Para verificar a sensibilidade da rede a variações não harmônicas, foram gerados dois vetores com números aleatórios (intervalo de 0 a 200), observados na Fig. 7, adicionados às primeiras e últimas cinco medições de cada sensor. Os valores foram normalizados para manter a mesma ordem de grandeza dos dados dos sensores. A Tabela IV apresenta a acurácia e a quantidade de falsos positivos após a adição de ruído aleatório.

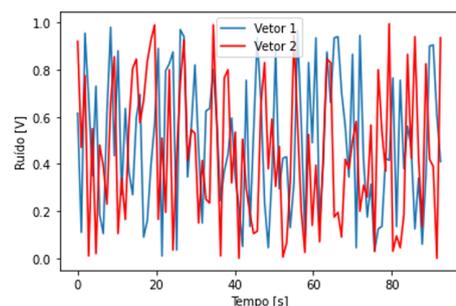


Fig. 7. Representação do ruído adicionado aos dados.

TABELA IV

PARÂMETROS DE QUALIDADE - APÓS ADIÇÃO DE RUÍDO ALEATÓRIO NOS DADOS.

Rede neural sensor correspondente	Acurácia	Quantidade de falso positivos
2	93,33	0
3	93,33	0
4	93,33	0
5	93,33	0
6	93,33	0
7	93,33	0
8	93,33	0

## V. DISCUSSÕES

A rede neural desenvolvida é uma MLP, com camadas ocultas e parâmetro ajustado para mitigar a propagação de erros. Os dados de entrada foram separados em 80% para o treinamento e 20% para o teste, a acurácia é medida pela taxa de acerto na classificação binária de: dano potencial ou não. Durante o treinamento, a rede recebe as 10 séries temporais (leituras redundantes) como entrada e realiza a classificação, que pode ser ajustada para diferentes quantidades de dados para predição.

Os resultados mostraram uma boa acurácia, e o código desenvolvido para a localização de falsos positivos não indicou a ocorrência desse problema. O critério de validação considera que, para um sensor indicar um erro com confiabilidade, pelo menos um sensor adjacente deve apresentar o mesmo resultado. Essa abordagem reduz a probabilidade de falsos positivos, porém não elimina totalmente a possibilidade de predições incorretas pelos sensores validadores, o que limita a confiança total no sistema.

Embora os resultados de acurácia e ausência de falsos positivos sejam promissores, a pequena variação na acurácia após a introdução de ruído é um ponto de atenção, sugerindo que o modelo pode não estar suficientemente sensível a pequenas perturbações nos dados. Além disso, a ausência de falsos positivos mesmo após a introdução de ruído harmônico e aleatório levanta a necessidade de investigar mais detalhadamente esses parâmetros de qualidade em trabalhos futuros.

Este trabalho representa um passo inicial no uso do Monitoramento da Saúde Estrutural como ferramenta auxiliar para a manutenção de aeronaves. A análise exploratória dos dados demonstrou o potencial das ondas Lamb para monitoramento estrutural, evidenciando correlações significativas nas séries temporais capturadas pelos sensores piezoelétricos. Para aplicações práticas, recomenda-se continuar investigando a eficiência do código de validação na detecção de falsos positivos e sua sensibilidade a diferentes configurações de teste. Futuros estudos devem focar na robustez do sistema em cenários adversos e na otimização dos hiperparâmetros da rede neural para garantir predições mais precisas e confiáveis.

## VI. CONCLUSÃO

Os resultados alcançados neste trabalho demonstraram que a manutenção baseada em condições (CBM), especificamente através do Monitoramento da Saúde Estrutural (MSE), pode ajudar a melhorar os planos de manutenção de aeronaves, buscando a redução do tempo em solo necessário para as inspeções. A implementação do MSE, utilizando ensaios não destrutivos com sensores piezoelétricos e ondas Lamb, possibilitou a detecção precoce de falhas estruturais, de modo

a buscar uma melhoria na segurança e na disponibilidade das aeronaves.

O projeto ReMap da TU Delft contribuiu significativamente para o avanço do MSE, fornecendo dados controlados que permitiram estudar o comportamento das estruturas de maneira mais precisa, além de validar o processo de fixação dos sensores e a escolha do tipo de sensor mais adequado para cada aplicação. A aplicação de aprendizado de máquina na análise desses dados permitiu uma alta acurácia na predição de danos e na redução de falsos positivos, mostrando uma melhora substancial em relação às abordagens tradicionais.

Estes avanços ajudam a remodelar o problema da manutenção de aeronaves, tornando-a menos intrusiva. No entanto, ainda existem lacunas que precisam ser exploradas. Trabalhos futuros podem focar na expansão do MSE para outras partes críticas da aeronave, na melhoria da integração de dados sensoriais e na otimização dos algoritmos de aprendizado de máquina para lidar com uma maior variedade de condições operacionais. A exploração dessas novas áreas permitirá a evolução contínua do MSE e aprimorará ainda mais a manutenção preditiva em aeronaves.

## REFERÊNCIAS

- [1] D. Vieira and P. Loures, "Maintenance, repair and overhaul (mro) fundamentals and strategies: An aeronautical industry overview," *International Journal of Computer Applications*, vol. 135, no. 12, pp. 21–29, 2016.
- [2] A. G. dos produtores de aviões GAMA, "Gama annual report 2019 and 50th anniversary edition," Associação Geral dos produtores de aviões, Tech. Rep., 2019.
- [3] Boeing, "Commercial market outlook," Boeing, Tech. Rep., 2022.
- [4] G. Toh and J. Park, "Review of vibration-based structural health monitoring using deep learning," *MDPI applied sciences*, vol. 10, no. 5, 2020.
- [5] T. Dong and N. Kim, "Cost-effectiveness of structural health monitoring in fuselage maintenance of the civil aviation industry," *MDPI*, vol. 5, no. 87, 2018.
- [6] Z. Su and L. Ye, *Identification of Damage Using Lamb Waves: From Fundamentals to Applications*. Springer, 2009, vol. 42.
- [7] "Strategic action plan for future cbm adoption," TUDelft, Tech. Rep., 2020.
- [8] H. Kinnison and T. Siddiqui, *Aviation Maintenance Management*. MC Graw Hill, 2012, vol. 2.
- [9] V. Giurgiutiu, *Structural Health Monitoring with Piezoelectric Wafer Active Sensors*. Elsevier, 2014, vol. 2.
- [10] R. Norton, *Projeto de máquinas: uma abordagem integrada*. Bookman, 2013, vol. 4.
- [11] M. Harisson, *Machine Learning – Guia de Referência Rápida: Trabalhando com dados estruturados em Python*. O'Reilly, 2020, vol. 1.
- [12] C. A. Muller and S. Guido, *Introduction to Machine Learning with Python: A Guide for Data Scientists*. s, 2016, vol. 1.
- [13] B. Auffart, *Machine Learning for Time-Series with Python: Forecast, predict, and detect anomalies with state-of-the-art machine learning methods*. Packt, 2021, vol. 1.
- [14] P. Barbetta, M. Reis, and A. Bonia, *Estatística para Curso de Engenharia e Informática*. Atlas, 2010, vol. 3.
- [15] P. Barbetta, A. Bonia, and M. Reis, *Anomaly Detection Principles and Algorithms*. Springer, 2017, vol. 1.
- [16] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg et al., "Scikit-learn: Machine learning in python," *Journal of machine learning research*, vol. 12, no. Oct, pp. 2825–2830, 2011.
- [17] C. R. Harris, K. J. Millman, S. J. van der Walt, R. Gommers, P. Virtanen, D. Cournapeau, E. Wieser, J. Taylor, S. Berg, N. J. Smith, R. Kern, M. Picus, S. Hoyer, M. H. van Kerkwijk, M. Brett, A. Haldane, J. F. del R'io, M. Wiebe, P. Peterson, P. G' erard-Marchant, K. Sheppard, T. Reddy, W. Weckesser, H. Abbasi, C. Gohlke, and T. E. Oliphant, "Array programming with NumPy," *Nature*, vol. 585, no. 7825, pp. 357–362, Sep. 2020. [Online]. Available: <https://doi.org/10.1038/s41586-020-2649-2>
- [18] J. D. Hunter, "Matplotlib: A 2d graphics environment," *Computing in Science & Engineering*, vol. 9, no. 3, pp. 90–95, 2007.