



**Aeronaves comerciais: uso do aprendizado de máquina para otimizar e simular a engenharia de reparos interiores**

*Commercial Aircraft: applying machine learning for optimized and simulated interior repair Engineering*

*Aeronaves comerciales: uso del aprendizaje automático para optimizar y simular la ingeniería de reparación de interiores*

Originals received: 00/00/2025

Acceptance for publication: 00/00/2025

**Alann Aluir da Silva Mendes de Oliveira**

Graduando em Gestão da Produção Industrial  
Faculdade Tecnologia São José dos Campos/SP, Brasil  
E-mail: [alann\\_aluir@yahoo.com.br](mailto:alann_aluir@yahoo.com.br)

**Débora Valente**

Graduanda em Gestão da Produção Industrial  
Faculdade Tecnologia São José dos Campos/SP, Brasil  
E-mail: [deboravalente\\_21@outlook.com](mailto:deboravalente_21@outlook.com)

**Karina Daniela Garcia Benevides**

Mestranda em Engenharia Mecânica  
Universidade de Taubaté/SP, Brasil  
[karinadaniela@uol.com.br](mailto:karinadaniela@uol.com.br)

**Marcello Pereira Benevides**

Mestrando em Engenharia Mecânica  
Universidade de Taubaté/SP, Brasil  
[marcello.benevides@sp.senai.br](mailto:marcello.benevides@sp.senai.br)

**Roque Antônio de Moura**

Doutor em Engenharia  
Faculdade Tecnologia São José dos Campos/SP, Brasil  
[roque.moura@fatec.sp.gov.br](mailto:roque.moura@fatec.sp.gov.br)

**RESUMO**

O reparo de interiores de aeronaves comerciais é um processo lento, complexo e artesanal, muitas vezes dependente da experiência dos profissionais que consultam manual em vastos bancos de dados de normas e acervos técnicos. Abordagem lenta e morosa suscetível a variabilidades na tomada de decisões. Esta pesquisa explora o uso de Aprendizado de máquina para otimizar esse processo, aplicando visão computacional na identificação e recomendação algorítmica de reparos de danos utilizando processamento de linguagem natural (NLP) para extração de informações de manuais técnicos e modelos preditivos para recomendar soluções baseadas em históricos de manutenção. Como metodologia além da pesquisa em manuais técnicos e publicações inerentes ao tema utilizou-se ferramentas tecnológicas para aprimorar a precisão das recomendações e agilizar o acesso ao conhecimento técnico. Os resultados encontrados reduzem o tempo de



análise, maior assertividade nas soluções de reparos e menor dependência da experiência individual dos profissionais, possibilitando uma padronização. Também foram discutidos desafios como integração com sistemas existentes e segurança da informação no setor aeronáutico.

**Palavras-chave:** Aprendizado de máquina. Gestão da manutenção de aeronaves. Reparos de interiores. Simulação Computacional.

### ABSTRACT

Commercial aircraft interior repair is a slow, complex and artisanal process, often dependent on the experience of professionals who consult manuals in vast databases of standards and technical collections. This slow and time-consuming approach is susceptible to variability in decision-making. This research explores the use of Machine Learning to optimize this process, applying computer vision to identify and algorithmically recommend damage repairs using natural language processing (NLP) to extract information from technical manuals and predictive models to recommend solutions based on maintenance histories. In addition to researching technical manuals and publications related to the topic, technological tools were used as methodology to improve the accuracy of recommendations and speed up access to technical knowledge. The results found reduce analysis time, provide greater assertiveness in repair solutions and reduce dependence on the individual experience of professionals, enabling standardization. Challenges such as integration with existing systems and information security in the aeronautical sector were also discussed.

**Keywords:** Machine learning. Aircraft maintenance management. Interior repairs. Computer simulation.

### RESUMEN

La reparación del interior de aeronaves comerciales es un proceso lento, complejo y artesanal, que a menudo depende de la experiencia de profesionales que consultan manuales en extensas bases de datos de normas y colecciones técnicas. Este enfoque lento y laborioso es susceptible a la variabilidad en la toma de decisiones. Esta investigación explora el uso del aprendizaje automático para optimizar este proceso, aplicando visión artificial para identificar y recomendar algorítmicamente reparaciones de daños mediante procesamiento del lenguaje natural (PLN) para extraer información de manuales técnicos y modelos predictivos para recomendar soluciones basadas en historiales de mantenimiento. Además de la investigación de manuales técnicos y publicaciones relacionadas con el tema, se emplearon herramientas tecnológicas como metodología para mejorar la precisión de las recomendaciones y agilizar el acceso al conocimiento técnico. Los resultados obtenidos reducen el tiempo de análisis, proporcionan mayor asertividad en las soluciones de reparación y reducen la dependencia de la experiencia individual de los profesionales, lo que facilita la estandarización. También se abordaron desafíos como la integración con los sistemas existentes y la seguridad de la información en el sector aeronáutico.

**Palabras clave:** Aprendizaje automático. Gestión del mantenimiento de aeronaves. Reparaciones de interiores. Simulación por computadora.



## 1 INTRODUÇÃO

A manutenção e reparo de interiores em aeronaves comerciais representa um desafio pela exigência estreita aos padrões de segurança (ANAC, 2018) e minimização do tempo de inatividade. A aplicação do aprendizado de máquina (ML) oferece uma abordagem transformadora para otimizar e simular a engenharia dos reparos no interior da aeronave (Oliveira; Santos, 2022).

Análise de um enorme volume de dados operacionais como telemetria, histórico de manutenção e dados de inspeção são necessários antes da efetivação do reparo. Nesse sentido, algoritmos de ML podem identificar padrões de degradação e prever falhas de componentes antes que ocorram, permitindo uma manutenção preditiva que reduz reparos reativos sem a exaustão neuroergonômica humana das leituras, pesquisas e interpretações (Moura *et al.*, 2024; Silva; Souza, 2023).

A capacidade simulacional em computadores viabilizada pelo ML possibilita que profissionais de reparos modelem o comportamento de materiais sob diferentes condições de estresse e avaliem a eficácia de diversas estratégias de reparos virtualmente e assim acelerando o planejamento e execução dos reparos com precisão operacional e segurança aeronáutica (Moura *et al.*, 2021; Costa, 2024) uma vez que a utilização de simulação como tecnologias tem se confirmado como um plano essencial no ambiente compartilhado humano-máquina (Moura; Moura, 2019).

Assim incorporar simulação computacional no reparo de aeronaves comerciais contribui para um ambiente profissional e de aprendizagem ágil, otimizado e com menor margem de erros principalmente humanos (Costa *et al.*, 2025).

O suporte técnico para reparos e manutenções depende na maioria das vezes de trabalho manual, envolvendo a análise das requisições recebidas por e-mail, planilhas ou canais gerenciadores de dados. A necessidade de consulta à documentação técnica e alinhamento com diversas equipes de engenharia, torna esse fluxo lento e suscetível aos gargalos operacionais, impactando diretamente na liberação das aeronaves e conseqüentemente aumenta custos e atrasos operacionais (IATA, 2024).



A aplicação de Inteligência Artificial (IA), especialmente ML, surge como uma solução inovadora para mitigar esses problemas, proporcionando maior velocidade, precisão e autonomia no processo de suporte técnico. Modelos de Processamento de Linguagem Natural (PLN) podem ser utilizados para interpretar automaticamente normas técnicas, regulamentos e históricos de manutenção, reduzindo a necessidade de consultas manuais demoradas e minimizar barreiras inclusive para não fluentes ou com necessidades especiais (Benevides *et al.*, 2024; Silva *et al.*, 2024). Sistemas de recomendação inteligentes, baseados em aprendizado supervisionado (XGBoost e LightGBM) analisam padrões e sugerem soluções consistentes e viáveis.

A simulação computacional também detecta danos em imagens com classificação rápida da severidade do problema e a priorização de reparos. Os sistemas inteligentes (FAISS e LangChain) alertam com informações técnicas relevantes, reduzindo o tempo na revisão documental. A automação dos fluxos de suporte técnico aumentam a eficiência operacional, reduzindo custos com a disponibilidade das aeronaves.

## 2 REFERENCIAL TEÓRICO

O aprimoramento de sistema de simuladores e suas aplicações no cotidiano em linha com planos estratégicos minimização tempo, maximizam segurança física-mental (Antônio *et al.*, 2024) e de projetos no setor aeronáutico e garantindo maior conforto, preparo e produtividade dos profissionais (Lawn, 1998) e seu aperfeiçoamento contínuo (Cardoso, 2019).

A manutenção de aeronaves comerciais é um processo altamente regulado e complexo, exigindo precisão, rastreabilidade e eficiência na substituição e reparo de componentes. No entanto, desafios como a descontinuidade de peças, a gestão eficiente da cadeia de suprimentos e a necessidade de manter custos operacionais sob controle tornam esse processo cada vez mais difícil. A evolução das tecnologias digitais tem permitido que soluções baseadas em IA e ML sejam aplicadas para enfrentar esses desafios, trazendo maior previsibilidade, automação e eficiência para o setor aeronáutico (Barbosa, 2021; Silva; Souza, 2023; Moura *et al.*, 2024; Costa, 2024).

### 2.1. Manutenção de interiores de aeronaves e desafios



Os interiores de aeronaves são compostos por uma variedade de componentes mobiliários, como assentos e lavatórios entre outros. Como os componentes de interiores dependem do *design* específico de cada modelo de aeronave e das configurações solicitadas pelas companhias aéreas, a reposição e manutenção desses componentes tornam-se um grande desafio para as empresas do setor aeronáutico viabilizando incorporar simulação na atividade de reparos (Coelho *et al.*, 2017) e também sem erros ou desvios advindos do estresse ou fadiga atribuídas à humanos (Silva *et al.*, 2024).

Segundo Lawn (1998) a simulação auxilia na transposição da teoria para a prática como analisar as interferências na substituição de itens complexos quando eles deixam de ser fabricados ou tem situação difícil por fatores como a dificuldade na previsão de demanda, uma vez que, embora a engenharia de confiabilidade preveja ciclos de falha para determinadas peças, muitos itens de interiores não possuem um histórico estruturado de falhas (Neto; Rebelo; Da Silva, 2019).

Outro desafio está na gestão da cadeia de suprimentos, já que, após o período da pandemia, diversas empresas encerraram suas atividades ou revisaram seus catálogos de peças, tornando alguns itens obsoletos e aumentando o tempo de espera para aquisição, o que impacta diretamente a disponibilidade da aeronave para operação ou que simplesmente tornaram-se obsoletas por regulamentações (ANAC, 2018; Fontes; Fay, 2016).

## **2.2. Aprendizado de máquina aplicado à manutenção**

O aprendizado de máquina (ML) tem emergido como tecnologia transformadora na otimização de processos industriais, demonstrando especial relevância no setor aeronáutico. Estudos recentes comprovam sua eficácia na análise de padrões históricos, predição de falhas e alocação inteligente de recursos (Andrew; Jardine; Dragan, 2006).

Segundo Fontes e Fay (2016) capacitar profissionais da aviação em ambiente virtual fomenta qualificação profissional.

No contexto específico da manutenção de interiores de aeronaves, destacam-se três aplicações principais que evidenciam o potencial transformador do aprendizado de máquina na manutenção aeronáutica com ganhos médios de até 40% em eficiência operacional, embora haja desafios na integração com sistemas legados e garantia de segurança de dados (Zhao *et al.*, 2019).

A adoção de aprendizado de máquina na engenharia de reparo de interiores de aeronaves apresenta benefícios significativos mostrados no Quadro 1.



**Quadro 1.** Benefícios alcançados na adoção de Machine Learning

Atividade	Operação otimizada	Benefício
<b>Manutenção Preditiva e Detecção proativa de danos</b>	O ML analisa grande volumes de dados (imagens, vídeos, dados de sensores). Identificar padrões de desgaste, rachaduras, descoloração e danos interiores das aeronaves preventivamente.	Redução da inatividade da aeronave não planejado. Aumento da segurança.
<b>Minimização de Estoque, maximização das peças e recursos de reparos</b>	Prever com maior precisão a demanda por peças de reposição e materiais analisando dados históricos e padrões de desgaste respectivos estoques.	Minimiza o excesso de estoque e, ao mesmo tempo, garante a disponibilidade de itens críticos, evitando atrasos nos reparos que impacta no custo operacional.
<b>Qualidade da manutenção e Consistência dos Reparos</b>	O ML auxilia na padronização dos procedimentos com diretrizes baseadas em dados e melhores práticas, podendo ser verificado a qualidade do reparo concluído por meio de análise de imagem.	Qualidade mais consistente e duradoura dos reparos que impactam intangivelmente em maior satisfação do passageiro e conformidade regulatória.
<b>Reduz custos operacionais e Tempo de inatividade da aeronave</b>	Combinar manutenção preditiva, otimização de estoque e melhora na qualidade dos reparos resulta em uma significativa redução de custos e menor tempo de inatividade da aeronave não planejado.	Maior disponibilidade da frota e consequentemente mais opções de voos, menor desgaste e maior receita para companhias aéreas.

Fonte: Adaptado de Zhao *et al.* (2019).

A implementação do aprendizado de máquina (machine learning - ML) na engenharia de reparo de interiores de aeronaves comerciais oferece vantagens significativas, otimizando processos e aprimorando a segurança beneficiando significativamente a atividade de manutenção e sua aplicação prática (Eler; Tavares, 2017).

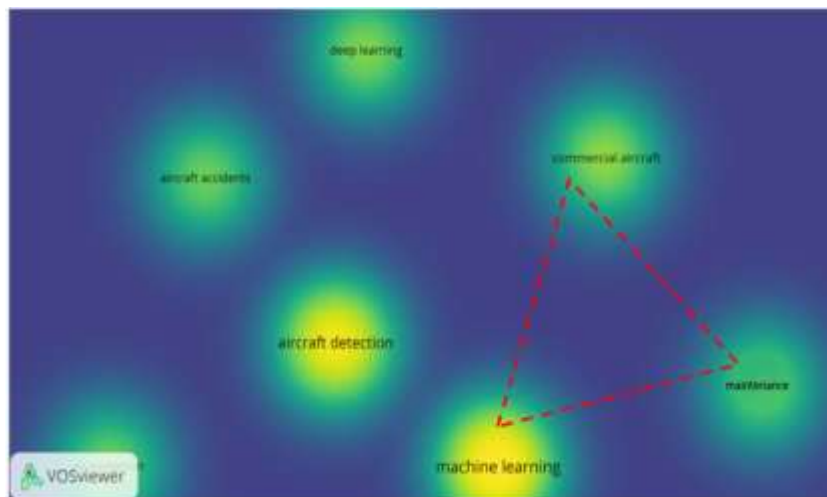
### 3 METODOLOGIA

Como metodologia além da pesquisa em manuais técnicos e publicações inerentes ao tema utilizou-se ferramentas tecnológicas para aprimorar a precisão das recomendações e agilizar o acesso ao conhecimento técnico contando com a ferramenta tecnológica VOSviewer, que é comumente usado para visualização de redes bibliométricas ou interconexão entre palavras-chave. Cada círculo de cor mais clara representa um agrupamento de termos relacionados, com



a intensidade da cor indicando a densidade ou a frequência com que esses termos aparecem juntos em um conjunto de dados conforme ilustra a Figura 1.

**Figura 1.** Rede de co-ocorrências de palavras-chave: “Aprendizado de máquina e Manutenção”.



Fonte: Autores (2025).

Em relação à manutenção e à aplicação do aprendizado de máquina a correlação ou agrupamento distinto sugere que “manutenção” é um tópico significativo no conjunto de dados analisados. Embora os círculos de “maintenance” e “machine learning” e “comercial aircraft” não estejam diretamente sobrepostas, elas estão relativamente próximas, e não há barreira técnicas entre elas. Isso sugere que há uma conexão entre o campo da manutenção e o uso de técnicas de aprendizado de máquina e aeronaves comerciais.

A relação intrínseca e crescente entre o aprendizado de máquina (machine learning), a indústria de aeronaves comerciais (commercial aircraft) e a manutenção conectam-se indicando que o aprendizado de máquina está se tornando uma ferramenta fundamental para transformar a manutenção de aeronaves comerciais, impulsionando a transição de abordagens reativas para proativas e preditivas.

Ao analisar grandes volumes de dados operacionais e de sensores de aeronaves, algoritmos de machine learning podem identificar padrões e anomalias que sinalizam potenciais falhas de componentes antes que elas ocorram, permitindo que as companhias aéreas realizem a manutenção no momento ideal, reduzindo o tempo de inatividade não programado.

Nesse sentido a aplicação do aprendizado de máquina na otimização de processos de manutenção pode ser usado como um recurso eficiente, pois algoritmos de aprendizado de máquina podem auxiliar no diagnóstico automático de falhas, identificando padrões em dados



operacionais que indicam problemas principalmente em “commercial aircraft” ou aeronaves comerciais, onde a manutenção de aeronaves é crítica e intensiva em dados, tornando-a um campo fértil para a aplicação de aprendizado de máquina para segurança e eficiência.

A metodologia empregada neste estudo foi estruturada em duas etapas distintas. A primeira delas segue uma abordagem qualitativa fundamentada em revisão bibliográfica, abordando temas centrais. No âmbito da manutenção a abordagem são determinadas exclusivamente pelas exigências científicas, que requerem uma estrutura coerente, consistência argumentativa, originalidade e um nível adequado de objetivação, atributos fundamentais para sua validação no profissional (Prodanov; Freitas, 2013).

A parte seguinte de execução do projeto contou com “mãos à obra” que possibilitou uma compreensão mais aprofundada dos impactos e benefícios práticos proporcionados por uma equipe multidisciplinar na aplicação do aprendizado de máquina na manutenção dos interiores de aeronaves comerciais conforme ilustra Figura 2.

**Figura 2.** Indicação em vermelho da atuação do aprendizado de máquina no interior das aeronaves.



Fonte: Elaborado pelos Autores (2025).

## 4 RESULTADOS E DISCUSSÕES

### 4.1 Simulação algorítmica das prováveis falhas e recomendações de substituição

Como resultado o uso do aprendizado de máquina como suporte técnico, foi desenvolvida uma estrutura de aprendizado de máquina com etapas distintas desde a coleta e processamento



de dados com objetivo de capturar e organizar informações provenientes de múltiplas fontes, como tickets de solicitação, e-mails, planilhas e bases de conhecimento utilizando machine learning.

O processamento de linguagem natural é ajustado (*fine-tuned*) com um *corpus* de textos técnicos aeronáuticos, incluindo manuais de manutenção, relatórios históricos e especificações do padrão ATA Spec 2200 para que o modelo compreenda terminologias específicas, como "mecanismo de travamento da porta do lavatório" ou "painel do *overheadbin* deteriorado" conforme ilustra a Figura 3.

**Figura 3.** Processamento de Linguagem Natural

ETAPA	DESCRIÇÃO	EXEMPLO
Pré-processamento	Tokenização e normalização de textos para remover ruídos (caracteres especiais, variações de formatação).	Texto bruto: "Defeito no mecanismo de travamento!!!" → Texto normalizado: "defeito mecanismo travamento"
Extração de Entidades	Identificação de componentes, tipos de falha e contexto (e.g., manutenção corretiva).	Componente: "porta do lavatório", Falha: "travamento", Contexto: "manutenção corretiva"
Estruturação	Conversão de textos livres em formatos JSON estruturados.	JSON: {"componente": "porta do lavatório", "falha": "mecanismo de travamento", "tipo": "mecânica"}

Na prática, um *e-mail* com a descrição "defeito no mecanismo de travamento da porta do lavatório foi reportado na aeronave "A320" é processado para gerar um registro estruturado, pronto para análise posterior. Um formulário técnico escaneado de um componente é convertido em texto, permitindo a extração de parâmetros como pressão operacional ou ciclos de manutenção, devidamente datado conforme ilustra a Figura 4.

**Figura 4.** Registro detalhado da situação problema e informações complementares

ETAPA	DESCRIÇÃO	EXEMPLO
Extração	Conexão com APIs de sistemas de tickets (e.g., ServiceNow), servidores de e-mail (via IMAP) e repositórios de arquivos (e.g., SharePoint)	Extração de um ticket do ServiceNow, um e-mail via IMAP e uma planilha do SharePoint.
Transformação	Uso da biblioteca Pandas para padronizar formatos, como converter datas de "DD/MM/AAAA" para "AAAA-MM-DD", unificar unidades (e.g., psi para kPa) e tratar valores ausentes com interpolação ou imputação.	Data: "25/12/2023" → "2023-12-25". Unidade: "100 psi" → "689.5 kPa"
Carregamento	Armazenamento em um banco de dados relacional (e.g., PostgreSQL), com índices otimizados para consultas rápidas.	Dados inseridos em uma tabela PostgreSQL com colunas: <i>id_falha</i> , <i>componente</i> , <i>descricao</i> , <i>data_registro</i> .
Orquestração	Apache Airflow gerencia a execução do pipeline, agendando tarefas diárias e monitorando falhas.	Pipeline agendado para rodar às 02:00, com alertas para falhas via e-mail.



Quando um novo ticket é registrado, o sistema captura automaticamente os dados associados (e-mail, anexos, planilhas), processa-os e os armazena no banco de dados para análise que posteriormente são categorizadas quanto a gravidade e o nível de severidade, priorizando assim ações com base em critérios técnicos e históricos utilizando.

Por exemplo na dobradiça há danos que foram processados, resultando na classificação "Dobradiça - Trinca Estrutural - Prioridade Alta" conforme ilustra a Figura 5.

**Figura 5.** Análise dpo histórico e padrão: Dobradiça - trinca estrutural - prioridade alta

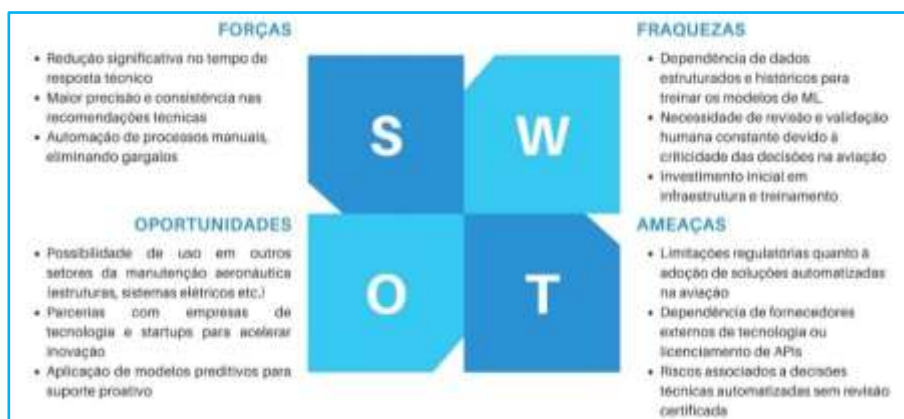
ETAPA	DESCRIÇÃO	EXEMPLO
Pré-processamento	Normalização de variáveis numéricas (e.g., tempo de reparo) e codificação de variáveis categóricas (e.g., tipo de componente).	Tempo de reparo: "4h" → Normalizado: 0.4; Componente: "Dobradiça" → Codificado: 1
Clusterização	K-Means agrupa falhas com base em similaridades, como "falhas repetitivas na dobradiça de poltronas A320".	Cluster: "Falhas repetitivas na dobradiça de poltronas A320".
Análise de Padrões	Identificação de causas sistêmicas, como "80% das quebras de poltronas ocorrem no mesmo pino de articulação".	Padrão identificado: "80% das quebras de poltronas no pino de articulação".

Com ajuda do aprendizado de máquina há o processamento do *ticket* com texto e imagem, classificando em falha como "Reparo crítico - estrutura comprometida – dobradiças poltronas" e destaca casos históricos similares, facilitando a análise de causas e a priorização de recursos.

## 4.2 Análise SWOT do Projeto

Como forma de consolidar os principais achados da metodologia e avaliar estrategicamente a proposta, foi elaborada uma análise SWOT (Strengths, Weaknesses, Opportunities, Threats) conforme ilustra a Figura 6 quanto aos benefícios, riscos e oportunidades do uso do aprendizado de máquina no suporte técnico ao reparo de interiores de aeronaves.

**Figura 6.** Análise SWOT: uso do ML na manutenção de interiores das aeronaves





### 4.3 Atendimento dos Objetivos de Desenvolvimento Sustentável (ODS)

A ODS número 9 dedica-se à Indústria, Inovação e Infraestrutura assegurando acesso a modernização. Portanto, o ODS 9 é o mais diretamente relacionado, pois a inovação tecnológica do aprendizado de máquina fortalece a infraestrutura e os processos da indústria de aviação, tornando-os mais eficientes e sustentáveis (Sousa *et al.*, 2024).

## 5 CONSIDERAÇÕES FINAIS

A aplicação do aprendizado de máquina (*machine learning*) no reparo de interiores de aeronaves apresenta-se como uma solução viável frente aos desafios enfrentados pela indústria aeronáutica, como a execução manual de tarefas e a dispersão de informações técnicas. Esses obstáculos comprometem a eficiência e aumentam a possibilidade de falhas no processo.

Por meio de entrevistas, levantamentos práticos e testes com inteligência artificial, o estudo confirmou que modelos de aprendizado de máquina podem apoiar os engenheiros na identificação e resolução de problemas técnicos. A proposta integra ferramentas como Processamento de Linguagem Natural, sistemas de recomendação e automação em um fluxo de trabalho mais dinâmico e eficiente.

Entre os principais ganhos estão a agilidade nas respostas, a precisão nas recomendações e a padronização dos procedimentos. O uso de *dashboards* e indicadores possibilita acompanhar o desempenho e impulsionar melhorias constantes.

Embora haja desafios quanto à integração com sistemas antigos e à proteção dos dados, os avanços recentes em soluções corporativas demonstram que a implementação é possível, segura e alinhada à modernização do setor aeronáutico.

Os benefícios obtidos incluem respostas mais rápidas, decisões mais assertivas, melhor rastreabilidade e maior autonomia das equipes. Questões como segurança da informação e validação humana também foram consideradas, respeitando as normas do setor.

Conclui-se que o uso de aprendizado de máquina (*machine learning*) impulsionou a transformação digital na manutenção de aeronaves comerciais em ambiente controlados e com monitoramento contínuo dos resultados.



## REFERÊNCIAS