

**PRUEBA PILOTO DE MÉTODO DE INSPECCIÓN A COMPONENTES AERONÁUTICOS USANDO
INTELIGENCIA ARTIFICIAL COMO APOYO A LAS FILOSOFÍAS ACTUALES DE MANTENIMIENTO**

GABRIEL ESTEBAN ESCUDERO GÓMEZ

INSTITUCIÓN UNIVERSITARIA PASCUAL BRAVO

FACULTAD DE INGENIERÍA

TECNOLOGÍA EN GESTIÓN DEL MANTENIMIENTO AERONÁUTICO

MEDELLÍN

2025

**PRUEBA PILOTO DE MÉTODO DE INSPECCIÓN A COMPONENTES AERONÁUTICOS USANDO
INTELIGENCIA ARTIFICIAL COMO APOYO A LAS FILOSOFÍAS ACTUALES DE MANTENIMIENTO**

GABRIEL ESTEBAN ESCUDERO GÓMEZ

**TRABAJO DE GRADO PARA OPTAR AL TÍTULO DE TECNÓLOGO EN GESTIÓN DEL
MANTENIMIENTO AERONÁUTICO**

ASESOR

ÓSCAR DAVID HENAO MERCHÁN

ESPECIALISTA EN INGENIERÍA AERONÁUTICA

INSTITUCIÓN UNIVERSITARIA PASCUAL BRAVO

FACULTAD DE INGENIERÍA

TECNOLOGÍA EN GESTIÓN DEL MANTENIMIENTO AERONÁUTICO

MEDELLÍN

2025

Dedicatoria

La aviación es una de mis más grandes pasiones y la he tenido desde siempre, como la gran mayoría de mis compañeros. Se despertó con el sueño de llegar a ser pilotos de aeronaves comerciales y pilotar el avión más grande del mundo, viajar y vivir a lo grande. Pero los sueños también cambian y toman formas diferentes. Así es como estos nos acompañan desde siempre y ha sido ese el motor que impulsó cada uno de mis esfuerzos en esta carrera. La fascinación por el vuelo y el deseo de contribuir al mundo aeronáutico han sido mi norte, guiándome a lo largo de este proceso.

A mi familia, mi pilar fundamental, cuyo amor incondicional y apoyo constante fueron esenciales para que pudiera superar las dificultades que se presentaron en el camino, especialmente en los momentos más oscuros. Gracias a su presencia y fortaleza, pude afrontar la adversidad con esperanza y determinación.

Este logro también es para mí, porque me demostré que, a pesar de los desafíos, como la lucha contra el cáncer, nada es imposible cuando se tiene pasión, perseverancia y el respaldo de quienes nos aman, mi resistencia y mi crecimiento personal. Gracias a todos los que estuvieron a mi lado en este proceso y a mí mismo, por no rendirme nunca.

Agradecimiento

Quiero empezar por expresar mi agradecimiento a todos los docentes que, a lo largo de mi carrera universitaria en la Tecnología de Gestión de Mantenimiento Aeronáutico, contribuyeron con su conocimiento a mi formación profesional.

Deseo expresar mi gratitud a la Institución Universitaria que me brindó la oportunidad de formarme como profesional. Durante mi tiempo como estudiante, pude experimentar un ambiente académico enriquecedor, lleno de retos y oportunidades. A lo largo de mi trayectoria, la institución proporcionó un espacio de aprendizaje que me permitió desarrollar habilidades técnicas y humanas, convirtiéndose en un lugar clave para mi crecimiento y formación integral.

Finalmente, quiero tomar la oportunidad para agradecer profundamente el proceso vivido en mi carrera. Cada experiencia, cada desafío y cada momento de aprendizaje fueron esenciales para llegar hasta aquí. Reconozco que este trabajo no es solo el resultado de mi esfuerzo individual, sino el reflejo de todo el apoyo y la influencia positiva de los profesores y compañeros.

TABLA DE CONTENIDO

GLOSARIO	11
RESUMEN.....	21
INTRODUCCIÓN.....	23
1. GENERALIDADES.....	26
1.1. Identificación y descripción del problema.....	26
1.2. Justificación.....	29
1.3. Objetivos.....	30
1.4. Metodología.....	31
1.5. Cronograma de actividades.....	37
2. FUNDAMENTOS TEÓRICOS.....	38
2.1. La inteligencia artificial y el aprendizaje automático (Machine Learning).....	38
2.2. Estado del arte.....	50
2.2.1. Marco regulatorio EASA European Union Aviation Safety Agency Agencia de Seguridad Aérea de la Unión Europea).....	50
2.2.2. Normas que se van a armonizar con la ley IA de la Unión Europea(EU).....	52
2.2.3. Niveles de caracterización para sistemas IA definidos por EASA.....	60
2.2.4. Objetivos de la EASA con IA (MLEAP).....	60
2.2.5. Casos de uso para IA bajo modalidad MLEAP.....	61

2.2.6. Aplicaciones de la IA en mantenimiento establecido por EASA.	65
2.2.7. Conclusión de la inspección visual automatizada (AVI).	67
2.2.8. Marco regulatorio de la Federal Aviation Administration (FAA).	67
2.2.9. Marco regulatorio de la autoridad de seguridad de aviación civil (CASA).	70
2.3. Mantenimiento aeronáutico e inspección de componentes.	74
2.3.1. Principios del mantenimiento aeronáutico.....	75
2.3.2. Evolución histórica y primeras estrategias de mantenimiento.....	76
2.3.3. El cambio de paradigma: funcionamiento basado en un enfoque analítico.....	78
2.3.4. Filosofías fundamentales del mantenimiento aeronáutico moderno.	78
2.3.5. Otras filosofías y conceptos de gestión que complementan el mantenimiento aeronáutico.	83
2.3.6. Importancia de las inspecciones y tipos de defectos comunes.	87
3. DESARROLLO DEL PROTOTIPO.....	91
3.1. Selección del método de ensayo no destructivo (NDT) para Integración con IA.	91
3.1.1. Criterio de selección del (NDT).	95
3.1.2. Matriz de decisión y selección del método (NDT).	96
3.1.3. Descripción del método de inspección visual.	98
3.2. Aplicación y evaluación del prototipo de IA para inspección visual con (Google Teachable Machine).	102
3.2.1. Descripción del prototipo y metodología experimental.	102

3.2.2. Proceso de entrenamiento del modelo en (Google Teachable Machine).	105
3.2.3. Pruebas y resultados del prototipo.	112
3.2.4. Discusión e interpretación de resultados.	129
3.3. Discusión general: potencial, impacto y desafíos de la IA en la inspección visual aeronáutica.....	136
3.3.1. Potencial de la IA para la mejora de la inspección visual y el mantenimiento detectivo.	137
3.3.2. Implicaciones para el personal técnico y las organizaciones de mantenimiento (OMA).....	139
3.3.3. Impacto general en la seguridad, eficiencia y regulación de la aviación.	141
3.3.4. Desafíos y requisitos para la implementación robusta de IA en inspecciones visuales.	142
CONCLUSIONES.....	145
BIBLIOGRAFÍA.	148

TABLA DE ILUSTRACIONES

Ilustración 1. Cronograma de actividades propuesto para la ejecución del trabajo de grado. ..	37
Ilustración 2. Relación entre el aprendizaje profundo y conceptos simples a complejos.	40
Ilustración 3. Explicación del aprendizaje supervisado y no supervisado	42
Ilustración 4. Ejemplo de clasificación.	43
Ilustración 5. Ejemplo de regresión	44
Ilustración 6. Ejemplo de agrupamiento de datos.....	45
Ilustración 7. Ejemplo de datos estructurados.....	46
Ilustración 8. Proceso y creación y validación de un modelo de aprendizaje supervisado.....	47
Ilustración 9. Ejemplo de estructura neural simple.....	48
Ilustración 10. Ejemplo de estructura neuronal compleja.	49
Ilustración 11. Diagrama de proceso para aprobación de leyes por parte de EASA.	54
Ilustración 12. Taxonomía de IA Híbrida.	55
Ilustración 13. Explicación de desarrollo genérico de implementación IA.	57
Ilustración 14. Metodología W y tareas importantes de EASA para la aprobación de IA MLEAP.	58
Ilustración 15. Aplicaciones técnicas definidas en el estudio de EASA.....	62
Ilustración 16. Ejemplos de daños por abolladuras e impactos de rayo.	66
Ilustración 17. Enfoque CASA con tecnología IA.	71
Ilustración 18. Mapa conceptual pasos a seguir para la clasificación en NDT.	92
Ilustración 19. Interfaz de selección de proyecto en la plataforma Google Teachable Machine.	106

Ilustración 20. Selección y creación del proyecto de imágenes para el modelo de IA.....	108
Ilustración 21. Proceso de definición de clases para el modelo de IA.....	109
Ilustración 22. Proceso de preparación del modelo de IA Google Teachable Machine.	111
Ilustración 23. Proceso general de entrenamiento del modelo de IA en la plataforma Google Teachable Machine.....	112
Ilustración 24. Validación interna, modelo de Google Teachable.....	114
Ilustración 25. Ejemplo de salida del modelo IA sobre imagen de prueba externa.....	121

LISTA DE TABLAS

Tabla 1. Cronograma para la implementación de iniciativas clave relacionadas con la gestión de drones y tecnologías emergentes en la aviación.	73
Tabla 2. Cuadro comparativo de métodos de inspección NDT y su integración con inteligencia artificial.	93
Tabla 3. Matriz de decisión y selección de método.	97
Tabla 4. Indicadores de Desempeño del Prototipo según Validación Interna de Google Teachable Machine (N=16).	119
Tabla 5. Resultados de Clasificación del Prototipo sobre el Conjunto de Prueba Externo Verificado (N=16).	122
Tabla 6. Matriz de Confusiones del Prototipo sobre el Conjunto de Prueba Externo Verificado (N=16).	123
Tabla 7. Indicadores de Desempeño del Prototipo sobre el Conjunto de Prueba Externo Verificado (N=16).	128

GLOSARIO

Abolladura. Deformación plástica localizada en una superficie, causada generalmente por un impacto. En aeronáutica, su criticidad depende de su tamaño, ubicación y profundidad, ya que puede afectar la aerodinámica y la integridad estructural. Fuente: Federal Aviation Administration, 2001, AC 43.13-1B - FAA.

Accuracy (Precisión General). Métrica de evaluación para modelos de clasificación que representa el porcentaje de predicciones correctas (tanto positivas como negativas) con respecto al número total de predicciones realizadas. Fuente: Géron, 2019.

Aeronavegabilidad. Condición técnica, operativa y legal que debe cumplir una aeronave o componente para operar en condiciones seguras, conforme a los estándares de su certificado de tipo. Fuente: Reglamento Aeronáutico de Colombia - RAC.

AMC (Acceptable Means of Compliance / Medios Aceptables de Cumplimiento). Métodos, procedimientos o prácticas no mandatorias desarrolladas por las autoridades aeronáuticas para ilustrar una forma de cumplir con los requisitos de una regulación. Fuente European Union Aviation Safety Agency. (s.f.). Acceptable Means of Compliance (AMC) and Alternative Means of Compliance (AltMoC).

ANN (Artificial Neural Networks / Redes Neuronales Artificiales). Conjunto de algoritmos de aprendizaje automático, inspirados en la estructura y el funcionamiento de las neuronas biológicas, utilizados en inteligencia artificial para reconocer patrones complejos en los datos. Fuente: Goodfellow, Bengio, & Courville, 2016.

AOG (Aircraft On Ground / Aeronave en Tierra). Término utilizado en aviación para describir una aeronave que no puede volar por razones técnicas, requiriendo una atención de mantenimiento urgente. Fuente: Federal Aviation Administration - FAA, 2022.

ATC (Air Traffic Control / Control de Tránsito Aéreo). Servicio proporcionado por controladores en tierra para dirigir aeronaves en el espacio aéreo controlado y en los aeropuertos, con el fin de prevenir colisiones y gestionar el flujo de tráfico. Fuente: International Civil Aviation Organization - ICAO, 2023

ATS (Air Traffic Services / Servicios de Tránsito Aéreo). Término general que engloba los servicios de control de tránsito aéreo, información de vuelo y alerta. Fuente: International Civil Aviation Organization - ICAO, 2023.

AVI (Automated Visual Inspection / Inspección Visual Automatizada). Aplicación de técnicas de visión por computadora e inteligencia artificial para automatizar las tareas de inspección visual, detectando defectos a partir de imágenes. Fuente: Zhang & Wang, 2020.

Big Data. Conjunto de datos (datos masivos) que se caracterizan por alto volumen, alta velocidad y variedad y que requieren tecnologías y métodos analíticos específicos para transformarse en valor . Fuente: De Mauro, Greco y Grimaldi 2016.

Calibración. Conjunto de operaciones que establecen, bajo condiciones especificadas, la relación entre los valores de una magnitud indicados por un instrumento de medida y los valores correspondientes de esa magnitud realizados por patrones de referencia. Fuente: Vocabulario Internacional de Metrología - VIM.

CASA (Civil Aviation Safety Authority / Autoridad de Seguridad de la Aviación Civil).

Organismo regulador de la aviación civil en Australia. Fuente: Civil Aviation Safety Authority.

CBM (Condition-Based Maintenance / Mantenimiento Basado en Condición). Estrategia

de mantenimiento que utiliza datos de monitoreo sobre la condición real de un equipo para determinar el momento óptimo para realizar una intervención. Fuente: Mobley, 2002.

Clasificación. En aprendizaje automático, es el proceso de asignar una etiqueta o categoría predefinida a una entrada de datos (como una imagen) según sus características aprendidas.

Fuente: Géron, A. 2019.

Condition Monitoring (CM). Monitoreo de Condición. Proceso de mantenimiento derivado

de la lógica MSG-3 que implica la observación continua de parámetros de un componente o sistema para detectar degradación o fallas incipientes. Fuente: Air Transport Association, 2021.

Corrosión. Reacción química o electroquímica de un material, usualmente metálico, con su ambiente, que produce el deterioro de sus propiedades. Fuente: Federal Aviation

Administration, 2001, AC 43.13-1B, cap. 6.

Deep Learning (DL) (Aprendizaje Profundo). Subcampo del aprendizaje automático que

utiliza redes neuronales artificiales con múltiples capas (profundas) para aprender representaciones jerárquicas y patrones complejos a partir de grandes volúmenes de datos.

Fuente: Goodfellow, Bengio, & Courville, 2016.

Defecto. Una discontinuidad o anomalía estructural cuyas características (tamaño, forma, ubicación) exceden los límites aceptables definidos por los estándares de diseño o mantenimiento y que por lo tanto puede comprometer la integridad de un componente. Fuente: Hellier, 2013.

Discontinuidad. Interrupción en la estructura física normal o en la uniformidad de un material. Una discontinuidad no se considera un defecto hasta que una evaluación determina que no es aceptable. Fuente: Hellier, 2013.

DIACC (Dirección Técnica de Investigación de Accidentes). Dependencia de la Unidad Administrativa Especial de Aeronáutica Civil (UAEAC), responsable de liderar la investigación de accidentes e incidentes aeronáuticos en Colombia. Fuente: Unidad Administrativa Especial de Aeronáutica Civil. (2023).

EASA (European Union Aviation Safety Agency / Agencia de Seguridad Aérea de la Unión Europea). Organismo de la Unión Europea responsable de la seguridad de la aviación civil. Fuente: European Union Aviation Safety Agency. 2023.

FAA (Federal Aviation Administration / Administración Federal de Aviación). Agencia gubernamental de los Estados Unidos responsable de la regulación de todos los aspectos de la aviación civil en ese país. Fuente: FAA.

FPR (False Positive Rate / Tasa de Falsos Positivos). En un modelo de clasificación, es la métrica que mide la proporción de instancias negativas que son incorrectamente clasificadas como positivas (falsas alarmas). Fuente: Géron, 2019.

GM (Guidance Material / Material de Orientación). Información no mandatoria desarrollada por las autoridades aeronáuticas para ayudar a ilustrar el significado de un requisito o especificación. Fuente: European Union Aviation Safety Agency- EASA.

Grieta. Separación o fisura en un material, generada comúnmente por fatiga (cargas cíclicas), sobrecarga o como consecuencia de la propagación de otros defectos como la corrosión.

Fuente: Federal Aviation Administration – FAA. 2001, AC 43.13-1B, cap. 4.

Hard Time (HT). Límite Estricto. Tarea de mantenimiento preventivo en la cual un componente es removido del servicio o restaurado a sus condiciones originales a un intervalo predeterminado de horas de vuelo, ciclos o tiempo calendario. Fuente: Air Transport Association, 2021.

IA (Inteligencia Artificial / Artificial Intelligence). Rama de la informática dedicada al diseño de sistemas capaces de realizar tareas que normalmente requieren inteligencia humana, como el aprendizaje, el razonamiento y la percepción. Fuente: Russell & Norvig, 2020.

Inspección. Examen de una aeronave o componente para determinar su conformidad con un estándar dado, utilizando técnicas que pueden ir desde la observación visual hasta ensayos no destructivos. Fuente: Reglamento Aeronáutico de Colombia - RAC.

KPIs (Key Performance Indicators / Indicadores Clave de Desempeño). Métricas cuantificables utilizadas para evaluar el rendimiento y el éxito de un proceso, sistema u organización con respecto a sus objetivos estratégicos. Fuente: Parmenter, 2015.

Machine Learning (ML) (Aprendizaje Automático). Disciplina dentro de la IA que permite a los sistemas aprender a partir de datos sin ser programados explícitamente. Fuente: Géron, A. 2019.

Mantenimiento. Conjunto de acciones que incluyen inspección, revisión, reparación, reemplazo y modificación, necesarias para conservar la condición de aeronavegabilidad de una aeronave o componente. Fuente: Reglamento Aeronáutico de Colombia - RAC.

Malware. Abreviatura de "malicious software" (software malicioso). Término general que se refiere a cualquier tipo de software diseñado intencionadamente para causar daños, interrupciones o obtener acceso no autorizado a un sistema informático. Fuente: Instituto Nacional de Ciberseguridad de España - INCIBE.

MLEAP (Machine Learning Application Approval / Aprobación de Aplicaciones de Aprendizaje Automático). Proyecto o proceso de EASA para desarrollar directrices sobre la aprobación de aplicaciones de aprendizaje automático en aviación. Fuente: EASA, 2023.

MPD (Maintenance Planning Document / Documento de Planificación de Mantenimiento). Documento emitido por el fabricante que contiene las tareas de mantenimiento programado requeridas para una aeronave. Fuente. Airbus.

MPE (Manual Programa de Entrenamiento / Training Program Manual). Documento de una OMA que detalla el programa de formación inicial y recurrente para su personal técnico. Fuente: Unidad Administrativa Especial de Aeronáutica Civil, 2018.

MRB (Maintenance Review Board / Junta de Revisión de Mantenimiento). Proceso formal, supervisado por la autoridad aeronáutica, en el cual el fabricante, los futuros operadores y la autoridad revisan y aprueban el programa de mantenimiento inicial desarrollado mediante MSG-3. Fuente: Federal Aviation Administration FAA, 2016.

MSG (Maintenance Steering Group / Grupo Directivo de Mantenimiento). Lógica de análisis desarrollada por la industria aeronáutica para crear un programa de mantenimiento inicial para una aeronave, basado en principios de confiabilidad. Fuente: Air Transport Association - ATA.

NDE (Non-Destructive Evaluation / Evaluación No Destructiva). Término a menudo utilizado como sinónimo de NDT, con un ligero énfasis en la interpretación y cuantificación de las indicaciones encontradas. Fuente: American Society for Nondestructive Testing - ASNT.

NDI (Nondestructive Inspection / Inspección No Destructiva). Término utilizado frecuentemente como sinónimo de NDT, común en la documentación de mantenimiento. Fuente: Federal Aviation Administration - FAA, 2018.

NDT (Non-Destructive Testing / Ensayos No Destructivos). Conjunto de técnicas de análisis utilizadas para evaluar las propiedades de un material, componente o sistema sin causar daño a su integridad. Fuente: Hellier, 2013.

NTSB (National Transportation Safety Board / Junta Nacional de Seguridad en el Transporte) . En el ámbito aeronáutico, la NTSB emite informes técnicos detallados y

recomendaciones de seguridad tras cada accidente o incidente grave. Fuente: National Transportation Safety Board – NTSB.

On Condition (OC). Bajo Condición. Tarea de mantenimiento que consiste en inspeccionar o probar periódicamente un componente para determinar si su condición se ajusta a los estándares de operación definidos. Si no cumple, se realiza una acción de mantenimiento correctivo. Fuente: Air Transport Association, 2021.

OMA (Organización de Mantenimiento Aeronáutico / Approved Maintenance

Organization - AMO). Taller o empresa certificada por la autoridad aeronáutica para realizar tareas de mantenimiento en aeronaves y sus componentes. Fuente: Unidad Administrativa Especial de Aeronáutica Civil, 2023.

Overhaul (Revisión General). Proceso de mantenimiento en el cual un componente es completamente desmontado, limpiado, inspeccionado, reparado según sea necesario y reensamblado para que se ajuste a las tolerancias y especificaciones de una pieza nueva. Fuente: (Federal Aviation Administration - FAA, 14 CFR 43.2).

Precision (Precisión por Clase). Métrica de evaluación que mide la proporción de identificaciones positivas que fueron realmente correctas. Indica qué tan confiable es el modelo cuando predice una clase positiva. Fuente: Géron, 2019.

RAC (Reglamento Aeronáutico Colombiano / Colombian Aeronautical Regulations).

Conjunto de normas y procedimientos que regulan la aviación civil en Colombia. Fuente: Unidad Administrativa Especial de Aeronáutica Civil. (2023).

RCM (Reliability Centered Maintenance / Mantenimiento Centrado en la Confiabilidad). Metodología utilizada para determinar los requisitos de mantenimiento de un activo físico en su contexto operativo, priorizando la preservación de las funciones del sistema. Fuente: Norma SAE JA1011.

Recall (Sensibilidad o Tasa de Verdaderos Positivos). Métrica de evaluación que mide la capacidad de un modelo para encontrar todas las instancias positivas relevantes dentro de un conjunto de datos. Fuente: Géron, 2019.

Red Neuronal. Ver ANN (Artificial Neural Networks).

Reparación. Acción de mantenimiento que restaura un componente a una condición aeronavegable después de haber sufrido un daño o desgaste. Fuente: Reglamento Aeronáutico de Colombia – RAC 43.

Six Sigma. Metodología de mejora de procesos centrada en la reducción de la variabilidad y la eliminación de defectos, cuyo objetivo es alcanzar un nivel de calidad de 3.4 defectos por millón de oportunidades. Fue desarrollada inicialmente por Motorola en la década de 1980 y sistematizada posteriormente en la literatura académica.

Fuente: Tennant, 2001.

SMS (Safety Management System / Sistema de Gestión de la Seguridad Operacional). Enfoque sistemático para la gestión de la seguridad, que incluye las estructuras organizativas, las responsabilidades, las políticas y los procedimientos necesarios. Fuente: International Civil Aviation Organization - ICAO, 2018)

Teachable Machine. Herramienta experimental basada en la web de Google que permite a los usuarios entrenar modelos de aprendizaje automático de manera rápida y sencilla para reconocer sus propias imágenes, sonidos y poses, sin necesidad de programación. Fuente: Google (s.f.).

TPM (Total Productive Maintenance / Mantenimiento Productivo Total). Estrategia de mantenimiento centrada en maximizar la eficiencia de los equipos mediante la participación de todo el personal en su cuidado y mejora continua. Fuente: Nakajima, 1988.

UAEAC (Unidad Administrativa Especial de Aeronáutica Civil). Autoridad de la aviación civil en Colombia, también conocida como Aerocivil. Fuente: Unidad Administrativa Especial de Aeronáutica Civil. (s.f.). Historia.

VI (Visual Inspection / Inspección Visual). Método de ensayo no destructivo que utiliza la vista, a veces con ayuda de herramientas ópticas, para evaluar la superficie de un componente. Fuente: American Society for Nondestructive Testing – ASNT, (s.f.). Inspección visual (VT).

WCM (World Class Manufacturing / Manufactura de Clase Mundial). Filosofía de gestión integral que busca optimizar todos los procesos de producción y soporte para alcanzar los más altos estándares globales de eficiencia, calidad y competitividad. Fuente: Schonberger, 2008.

RESUMEN.

El estudio se enfoca en incorporar la inteligencia artificial (IA) en los procedimientos de inspección no destructiva (NDT) en el cuidado de aeronaves, en el marco de la revolución industrial 4.0. El estudio resalta cómo la inteligencia artificial mediante métodos como el aprendizaje automático, puede potenciar la identificación precoz de fallas en aeronaves, mejorando la eficiencia y la seguridad en las operaciones. A través de una metodología teórico-práctica, se examinan los métodos NDT actuales y se lleva a cabo un análisis comparativo para elegir el método NDT más factible y su incorporación a una prueba piloto o prototipo de inteligencia artificial, con su correspondiente uso y evaluación. Además, se evaluó su impacto en las estrategias de mantenimiento preventivo y predictivo.

De igual manera, aborda el marco regulatorio de la EASA, CASA y la FAA, que están trabajando en la armonización de normas para la aplicación segura de la IA en la aviación. Se sugiere un modelo de incorporación de inteligencia artificial en el NDT mediante inspección visual, resaltando su habilidad para manejar grandes cantidades de información y aumentar la exactitud en la identificación de discontinuidades. Se llevó a cabo un estudio comparativo de los métodos de NDT, conocidos como inspección visual, ultrasonido, radiografías, partículas magnéticas y líquidos penetrantes, centrados en las filosofías de mantenimiento aeronáutico. Se determinó su viabilidad e integración en el método de inspección visual optimizado con la inteligencia artificial.

Para la comprobación de la viabilidad de la inspección visual mejorada con la IA, se decidió implementar un software de aprendizaje automático (Google Teachable Machine) ya

establecido, para crear un prototipo de un modelo IA de clasificación de discontinuidades a partir imágenes, con el objetivo de mejorar la detección temprana de fallas en las aeronaves. Los resultados estuvieron fundamentados con base en porcentajes de tasa de verdaderos positivos, tasa de falsos positivos y vectores de precisión general en la detección de las discontinuidades. Se aplicó este prototipo con la intención de analizar la precisión de la inspección visual mejorada con la IA en comparación con los otros métodos tradicionales de mantenimiento (ultrasonido, partículas magnéticas, radiografías y líquidos penetrantes).

Asimismo, se discuten los impactos potenciales de la IA en las organizaciones de mantenimiento, enfatizando la necesidad de capacitación y adaptación a nuevas tecnologías para garantizar la seguridad operacional.

INTRODUCCIÓN.

El enfoque de la actualidad se ubica en la revolución industrial 4.0, donde se presencia día con día el auge de las tecnologías cibernéticas como la inteligencia artificial, automatización a gran escala y el Big Data, que han dado lugar a cambios rápidos de gran impacto en la sociedad y las industrias en general, incluida la aviación y asimismo sus procesos de mantenimiento. Si bien estos avances en la aviación han sido notables, no son completamente nuevos en esta industria. Basta con analizar la evolución de las cabinas de mando en las aeronaves para apreciar que hoy las cabinas de cristal son más eficientes ya que al ser computarizadas y programadas, permiten alertar a la tripulación al mando sobre posibles anomalías en uno o varios sistemas específicos a través de activaciones de alarmas, contribuyendo así a la toma de decisiones racionales en vuelo.

Es aquí donde entra a jugar un papel importante la inteligencia artificial. Teniendo en cuenta el ejemplo mencionado anteriormente, la tecnología IA tiene ventaja sobre el ser humano ya que esta no tiene límite para leer y analizar la data de una aeronave completa y en cuestión de segundos posee conocimiento de todos los sistemas y sus datos en tiempo real, lo que la hace capaz de predecir posibles fallas en la aeronave antes de que se materialicen. Esto se conoce como Machine Learning y consiste en lograr un mejor uso de la información para la toma de decisiones y resolución de problemas por sí misma, emulando a la perfección la inteligencia humana.

Este tipo de desarrollo tecnológico es inevitable y la industria de la aviación también está investigando el uso de soluciones de IA híbridas, en un intento de superar las posibles

desventajas que el impacto de este auge pueda ocasionar. Es por eso que autoridades aeronáuticas como la EASA se preparan con investigaciones para implementar y regular esta tecnología en la aviación. Según se emitió en su documento titulado *Artificial Intelligence Roadmap 2.0*, se está trabajando en una propuesta para el Reglamento del Parlamento Europeo y del Consejo, por el que se establecen normas armonizadas sobre inteligencia artificial (Ley de IA de la UE), la cual define a la IA como una “tecnología que puede, para un conjunto determinado de objetivos definidos por el ser humano, generar resultados tales como contenido, predicciones, recomendaciones o decisiones que influyen en los entornos con los que interactúan” (EASA, 2024).

Los estudios llevados a cabo por la autoridad aeronáutica europea están enfocados hacia la asistencia a pilotos y servicios ATC. Sin embargo, existe un vacío importante en la aplicación de IA al campo del mantenimiento, particularmente en las tareas de inspección visual, donde el juicio humano sigue siendo la única herramienta dominante.

Las inspecciones en el mantenimiento aeronáutico actualmente se realizan mediante inspección visual y los NDT (Non-Destructive Testing), los cuales permiten localizar y caracterizar fallas sin comprometer la integridad estructural del componente. Estas técnicas, aunque efectivas, dependen en gran medida del criterio del técnico y de las condiciones físicas de inspección (luz, acceso, fatiga visual, etc.). Se encuentra la necesidad de incrementar la calidad de las inspecciones de componentes en el mantenimiento aeronáutico ya que, según informes de la NTSB (2023) y reportes internos de operadores regionales, las fallas estructurales más reportadas en inspecciones visuales incluyen grietas (35%), corrosión superficial (28%) y deslaminación en materiales compuestos (15%), muchas veces no

detectadas oportunamente. Esto evidencia una oportunidad crítica para fortalecer la inspección visual mediante herramientas tecnológicas como la inteligencia artificial.

La implementación de esta tecnología en el campo aeronáutico es un tema de alta complejidad. Si bien las posibles ventajas son amplias y ofrecen un panorama alentador en los procesos de mantenimiento e inspección de componentes, también puede introducir nuevos tipos de vulnerabilidades como los ciberataques, “envenenamiento de datos” y errores de interpretación automatizada. Por ello, este trabajo realiza una aplicación controlada, limitada a la clasificación de imágenes previamente etiquetadas, evitando la toma de decisiones automatizada directa sobre la aeronavegabilidad.

El estudio combina revisión documental normativa y técnica con el desarrollo de un prototipo de IA entrenado con imágenes de defectos visibles, para evaluar su precisión y aplicabilidad como apoyo al mantenimiento preventivo. Además, se plantea con un objetivo de sentar una base experimental para demostrar cómo la inteligencia artificial puede convertirse en una herramienta complementaria en inspecciones visuales, mejorando la detección de defectos críticos y apoyando la toma de decisiones en el mantenimiento aeronáutico.

Palabras Claves: Inteligencia Artificial, Machine Learning, Aviación, Mantenimiento, Inspección De Componentes.

1. GENERALIDADES.

Este capítulo presenta los aspectos generales que enmarcan el desarrollo del presente trabajo de grado. En primer lugar, se expone el planteamiento del problema que motiva la investigación, seguido de la justificación que resalta la relevancia de abordar esta temática dentro del contexto del mantenimiento aeronáutico. Posteriormente, se definen los objetivos del estudio y se describe la metodología empleada, incluyendo los indicadores utilizados para evaluar el prototipo desarrollado. Finalmente, se establece un cronograma de actividades que guió la ejecución del proyecto conforme al cronograma previsto.

1.1. Identificación y descripción del problema.

Las filosofías aplicables al mantenimiento aeronáutico son definidas principalmente por los fabricantes a través de Grupos Directivos de Mantenimiento (MSG) y Juntas de Revisión de Mantenimiento (MRB). Estos grupos se encargan de establecer los requisitos mínimos iniciales de mantenimiento para aeronaves nuevas. El objetivo es anticipar las necesidades de una aeronave antes de que esta entre en servicio; por supuesto, este tipo de procesos también se apoya en la recopilación de datos conocidos de otras aeronaves a lo largo de su vida útil, siendo el objetivo de este proceso el desarrollo del MPD (Maintenance Planning Document), el cual es un documento de planificación de mantenimiento personalizado para cada aeronave.

Este documento contiene procedimientos como tareas, revisión e inspección de componentes, así como también métodos y frecuencias en horas, ciclos y días calendario

recomendados para llevar a cabo el mantenimiento programado de la aeronave y sus componentes y/o piezas destinadas a ser instaladas en una aeronave.

Estas prácticas de mantenimiento son acatadas por los operadores y sus OMA a través de programas de mantenimiento. Sin embargo, las inspecciones de componentes por NDT realizadas por las organizaciones de mantenimiento están restringidas por la lista de capacidades aprobada por la autoridad aeronáutica UAEAC, según lo establecido en el RAC 145. Esta norma exige que las OMA demuestren contar con instalaciones adecuadas y seguras, equipos específicos, personal calificado y entrenado, así como documentación técnica vigente (manuales NDT, licencias FAA, recomendaciones del fabricante, etc.). Pese a estos requisitos, las limitaciones humanas en la inspección visual tradicional aún representan un riesgo operativo relevante.

Las filosofías de mantenimiento aplicables a la aeronáutica y reflejadas en el MPD están estructuradas por bloques de tiempo y varían según el contexto operacional. Por ejemplo, hay aeronaves que cumplen sus inspecciones por horas de vuelo, mientras que otras lo hacen por ciclos (un ciclo = un despegue y un aterrizaje). Los tipos de mantenimiento más comunes son: Hard Time, On Condition, Condition Monitoring y Overhaul, producto de la evolución del sistema de mantenimiento aeronáutico (FAA, 2016; Airbus, 2020).

La aviación es el medio de transporte que más rápido tiende a evolucionar, ya que requiere mantenerse a la vanguardia en la mejora continua de sus procesos. Sin embargo, se presentan contratiempos operacionales inesperados como demoras, aeronaves en condición AOG, mantenimientos no programados, uso adicional de recursos y afectaciones a indicadores

de cumplimiento y seguridad operacional. Por lo tanto, la confiabilidad del mantenimiento se convierte en un factor clave para garantizar la continuidad operativa segura (EASA, 2022).

Actualmente, no se ha integrado de forma efectiva un concepto de mantenimiento predictivo apalancado con inteligencia artificial (IA). Esta estrategia permitiría realizar análisis de datos en tiempo real a partir de la trazabilidad histórica y operativa de tareas e inspecciones (incluidos reportes técnicos, registros de vuelo, datos de MPD, etc.) (IATA, 2023).

La IA, mediante técnicas de aprendizaje automático, permitiría identificar patrones anómalos y prever fallas incipientes antes de su ocurrencia. Esto respaldaría las decisiones de mantenimiento, incrementando su confiabilidad y eficiencia. A pesar del potencial de estas tecnologías, las inspecciones visuales dependen exclusivamente del criterio humano, sin apoyo sistemático por modelos de IA.

HIPÓTESIS: ¿Cómo la inteligencia artificial puede contribuir en la mejora de la precisión, eficiencia y confiabilidad de las inspecciones a componentes aeronáuticos por ensayos no destructivos?

Teniendo en cuenta los cambios acelerados en la industria y las limitaciones de los métodos tradicionales, surge la necesidad de fortalecer los procesos de inspección de componentes. Su confiabilidad impacta directamente en la seguridad operacional, la reducción de tiempos de inactividad y la optimización de recursos técnicos y económicos.

Vale la pena destacar que diversos estudios e informes técnicos como la FAA (AC 43.13-1B) y el reporte MLEAP de EASA (2023) han documentado que hasta el 40% de las no

conformidades estructurales detectadas durante inspecciones visuales están relacionadas con grietas superficiales, corrosión y delaminación no identificadas a tiempo. Estas limitaciones humanas justifican la exploración de soluciones asistidas por IA que permitan aumentar la precisión y confiabilidad en la evaluación visual.

1.2. Justificación.

El mantenimiento aeronáutico se basa en identificar fallas de manera anticipada para prevenir adversidades en el campo aéreo. Estas acciones se enmarcan en el mantenimiento preventivo y predictivo, donde la inspección es una tarea fundamental, ya que permite identificar un daño antes de que cause una falla mayor. La inspección, registro y control son claves para determinar las funcionalidades equivalentes a un buen mantenimiento. Los componentes aeronáuticos son complejos y pueden ser difíciles de inspeccionar, debido a su gran variabilidad que dificulta la interpretación humana. Por esto, es necesaria la implementación de la inteligencia artificial (IA) en el mantenimiento aeronáutico, ya que tiene el potencial de mejorar la eficiencia y precisión de las inspecciones de componentes aeronáuticos, por medio de la sistematización rápida de fallas, capacidad de almacenamiento, aplicación de normatividad con exactitud, percepción diferencial de daños enfocados a respuestas inmediatas y la aplicabilidad de métodos enfocados al modelo de aprendizaje automático. De esta manera, la IA puede ayudar a superar los desafíos de la inspección de componentes, lo que puede contribuir a mejorar la seguridad de las operaciones de vuelo.

El estudio de la inteligencia artificial en aviación se encuentra en desarrollo actualmente, las autoridades como EASA y FAA se encuentran abiertas a recibir propuestas viables que vengan de cualquier parte interesada en contribuir a las investigaciones,

proporcionando diversos enfoques y consideraciones para asumir el gran reto de incorporar la inteligencia artificial en la aviación. Es de resaltar que, hasta ahora, el enfoque está en las operaciones de vuelo. Esto indica que su aplicación en el mantenimiento tiene amplias posibilidades. Los resultados de esta investigación podrían aprovecharse como material de estudio, además de plantear opciones para implementar IA en los NDT utilizados en aviación. Por este motivo, la investigación responde a un vacío teórico-práctico y metodológico en el campo de la inspección de componentes aeronáuticos, teniendo un claro objetivo, el cual es contribuir a la aplicación de un algoritmo de IA fiable y eficaz para la detección temprana de fallas en componentes aeronáuticos.

La investigación planteada es conveniente y de interés académico por su temática, indispensable en las industrias y en el campo aeronáutico, ya que se encuentra en evolución y crecimiento constante, influenciadas por las nuevas tecnologías. Por medio de la IA se logrará responder a las necesidades cambiantes del sector, mejorar continuamente sus procesos y adaptarse a las normas que implican estos cambios. Esto ofrece un enfoque más proactivo en la planificación del mantenimiento, impactando pilares fundamentales como la seguridad operacional, la confiabilidad y los planes de mejora en los distintos procesos.

1.3. Objetivos.

En función de los aspectos planteados en la identificación del problema y la justificación del estudio, se establecen a continuación los objetivos que direccionan el desarrollo de este trabajo de grado. El objetivo general define la finalidad principal del proyecto, mientras que los objetivos específicos detallan los pasos necesarios para su finalización, guiando metodológicamente cada una de las etapas del proceso.

1.3.1. Objetivo general.

Elaborar una prueba piloto con un prototipo de inteligencia artificial basado en clasificación de imágenes como herramienta de apoyo a las tareas de mantenimiento, evaluando la condición de calidad de componentes aeronáuticos mediante la identificación de defectos visuales.

1.3.2. Objetivos específicos.

- Seleccionar el método de inspección más viable para la integración con IA mediante una matriz de decisión con cuatro (4) criterios ponderados.
- Aplicar un prototipo de clasificación de defectos utilizando Google Teachable Machine entrenado con un conjunto de datos de al menos 100 imágenes.
- Analizar la precisión de la prueba piloto frente a métodos tradicionales comparando los indicadores de precisión, tasa de verdaderos positivos (recall) y tasa de falsos positivos identificando sus cambios con el diagnóstico base.

1.4. Metodología.

La investigación se centra en un enfoque teórico-práctico y el diseño es una monografía a través del análisis e interpretación teórica de la literatura existente relacionada con la inteligencia artificial y la práctica de un modelo de aprendizaje automático en este caso elaborado por Google Teachable para la predicción de fallas, limitando su enfoque a componentes aeronáuticos en buen y mal estado por medio de una inspección visual. complementada con el algoritmo de detección de la aplicación, ya que no existe este método actualmente.

La investigación se enmarca en un enfoque mixto, con una fase cualitativa orientada al análisis documental normativo y técnico, una fase cuantitativa aplicada al desarrollo y evaluación de un modelo de clasificación de imágenes mediante inteligencia artificial (IA). El tipo de estudio es aplicado, con alcance descriptivo, pues busca aplicar conocimientos previos a un contexto operativo para aportar soluciones viables al mantenimiento aeronáutico.

El estudio surge como respuesta a evidencias sobre las limitaciones de las inspecciones visuales manuales, las cuales, según la FAA, pueden presentar tasas de detección inferiores al 80% dependiendo del tipo de defecto y condiciones de inspección (FAA, 2018). En especial, se ha reportado que las grietas superficiales son uno de los defectos más comúnmente pasados por alto en inspecciones visuales, representando hasta el 32% de las discrepancias no detectadas oportunamente (EASA, 2023).

La investigación se limitó a las inspecciones aeronáuticas realizadas por NDT y a su impacto directo en el medio, ya que hasta ahora no se cuenta con un estudio sólido sobre la incursión del mantenimiento y la inteligencia artificial; sin embargo, si se cuenta con suficiente información para analizar y realizar un estudio viable sobre este tipo de temas. Esto se logrará a través del análisis de la norma sobre inteligencia artificial y la norma aeronáutica, aplicabilidad de métodos y fiabilidad de esta tecnología.

FASE I: El análisis del estado del arte se realizará de forma teórica para sustentar la investigación con los avances existentes.

FASE II: El análisis de los NDT se realizará con el objetivo de determinar cuál de estas inspecciones es viable para ser complementada con IA; esto como resultado de que no todos

los NDT son viables para ser adaptados con esta tecnología debido a sus procesos, un ejemplo claro de esto es la inspección por ultrasonido, la cual se realiza por medio de ondas sonoras de alta frecuencia para evaluar la integridad de materiales y estructuras, que permiten la detección de las discontinuidades, identificando patrones en tiempo real de las posibles fallas, estos patrones serían un buen complemento para la inteligencia artificial si no fuese por la dificultad de obtener esos datos de manera tangible para que sean analizados y estudiados por la IA. Estas herramientas, más que proporcionar datos sobre las fallas, proporcionan indicaciones, las cuales dependen de la experiencia del técnico para identificar cuando un objeto presenta una alteración; estas indicaciones son complejas de obtener de forma visual y estructurada para entrenar el algoritmo. Por otro lado, la inspección visual complementada con la IA ayuda a la percepción y al criterio del personal a identificar posibles discontinuidades o grietas en los componentes. Esta selección se va a realizar teniendo en cuenta el tipo de aplicación, el método y el criterio propio para determinar si es viable y detallando de manera clara y concisa el porqué de la selección.

FASE III: Está contemplada para tener una idea más clara del panorama que implica la inserción de la inteligencia en la aviación y cómo afecta cada una de las áreas de una organización, enfocándose en su sistema de calidad, SMS, entrenamiento y la confiabilidad. Para esto se van a aplicar métodos de modelo de aprendizaje por medio de Google Teachable, especificando la identificación del problema, el criterio y análisis propio del investigador

Indicadores de desempeño y evaluación del prototipo.

Para evaluar la efectividad del prototipo de inteligencia artificial desarrollado con Google Teachable Machine en la clasificación de imágenes de componentes aeronáuticos, se

utilizarán los siguientes indicadores de desempeño cuantitativos. Estos indicadores permitirán medir la capacidad del modelo para identificar correctamente la presencia y el tipo de defecto visual (corrosión, grieta, abolladura) o sin defecto.

Precisión general (Accuracy).

Este indicador mide el porcentaje total de clasificaciones correctas realizadas por el modelo sobre el conjunto de imágenes de prueba. Representa la frecuencia con la que el modelo acierta en su predicción, independientemente de la clase específica (tipo de defecto o sin defecto).

Fórmula: Precisión (Accuracy) = (Número total de imágenes de prueba X número de Clasificaciones Correctas) \times 100%

Interpretación:

Un 100% de precisión indica que el modelo clasificó correctamente todas las imágenes de prueba sin cometer errores, teniendo en cuenta una selección de defecto visual de manera correcta acorde a la clasificación.

Un resultado $\geq 50\%$ establece un indicador de precisión alta con un grado de falso positivo.

Un resultado $\leq 50\%$ indica un tipo de clasificación aleatoria, donde no se identifica de manera precisa la discontinuidad.

Tasa de verdaderos positivos (Sensibilidad o Recall).

Este indicador es crucial para evaluar la capacidad del modelo para identificar correctamente los casos que sí presentan un defecto específico. Se calcula de forma individual para cada clase de defecto (corrosión, grieta, abolladura). Por ejemplo, para la clase "grieta", la Tasa de Verdaderos Positivos mide cuántas de las imágenes que realmente contenían una grieta fueron correctamente identificadas por el modelo como "grieta".

Fórmula: (para una clase específica, ej. "Grieta"): Tasa de Verdaderos Positivos (Grieta)=
(Número total real de imágenes con Grieta X número de imágenes con Grieta Correctamente Clasificadas) ×100%

Interpretación:

Un 100% para una clase de defecto específica significa que el modelo detectó todas las instancias reales de ese defecto en el conjunto de prueba.

Un 50% indica que el modelo solo identificó la mitad de los defectos reales de esa clase. Para aplicaciones en mantenimiento aeronáutico, es fundamental que este indicador sea lo más elevado posible para minimizar el riesgo de omitir defectos críticos.

Tasa de falsos positivos (False Positive Rate - FPR).

Este indicador mide la frecuencia con la que el modelo clasifica incorrectamente una imagen como si tuviera un defecto específico cuando, en realidad, no lo tiene o pertenece a otra clase (otro tipo de defecto o una pieza sin defecto). Se calcula para cada clase de defecto. Por ejemplo, para la clase "grieta", mide cuántas imágenes que no tenían una grieta fueron erróneamente clasificadas por el modelo como si tuvieran una "grieta".

Fórmula: (para una clase específica, ej. "Grieta"): Tasa de Falsos Positivos (Grieta)=
(Número total real de imágenes sin grieta número de imágenes Sin Grieta Clasificadas
Incorrectamente como Grieta) $\times 100\%$

Interpretación:

Un 0% de Tasa de falsos positivos es el valor ideal, indicando que el modelo no genera "falsos resultados" para esa clase de defecto.

Un 50% de Tasa de falsos positivos sería considerado muy alto, ya que implicaría que la mitad de las veces que el modelo identifica un tipo de defecto (cuando este no está presente o es diferente), está cometiendo un error. Una alta tasa de falsos positivos puede conducir a inspecciones adicionales innecesarias y al descarte prematuro de componentes en buen estado, lo que incrementa los costos de mantenimiento.

Evaluación comparativa.

El desempeño del prototipo se analizará en función de estos indicadores, calculados a partir de un conjunto de datos de prueba independiente. Aunque no se realizará una comparación directa con un sistema certificado, los resultados obtenidos permitirán discutir la viabilidad y el potencial del prototipo como herramienta de apoyo en la identificación preliminar de defectos visuales en el contexto del mantenimiento aeronáutico, sirviendo como una línea de base para futuras investigaciones y desarrollos.

1.5. Cronograma de actividades.

En la Ilustración 1 se presenta el cronograma de actividades del proyecto, representado mediante un Diagrama de Gantt que detalla la secuencia, duración y responsables de cada fase.

Ilustración 1. Cronograma de actividades propuesto para la ejecución del trabajo de grado.

PRUEBA PILOTO DE MÉTODO DE INSPECCIÓN A COMPONENTES AERONÁUTICOS USANDO INTELIGENCIA ARTIFICIAL COMO APOYO A LAS EMPRESAS AERONÁUTICAS DE MANTENIMIENTO				MES																																																			
				1							2							3							4							5							6							7							8		
ITEM	ACTIVIDAD	AVANCE	RESPONSABLE(S)	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32																				
1 INVESTIGACIÓN DEL ESTADO DEL ARTE																																																							
1.1	Investigar conceptos sobre Inteligencia Artificial	10,00%	Gabriel Esteban Escudero Gomez	x	x	x	x																																																
1.2	Investigar la norma FAA, EASA en busca de avances con la Inteligencia Artificial	30,00%	Gabriel Esteban Escudero Gomez																																																				
1.3	Selección de fuentes y documentación de hallazgos	30,00%	Gabriel Esteban Escudero Gomez																																																				
2 ANALISIS Y SELECCIÓN DEL METODO NDT																																																							
2.1	Leer los documentos de ensayos no destructivos de la FAA	5,00%	Gabriel Esteban Escudero Gomez																																																				
2.2	Documentar los aspectos más relevantes de cada metodo	10,00%	Gabriel Esteban Escudero Gomez																																																				
2.3	Realizar un análisis comparativo entre los metodos	5,00%	Gabriel Esteban Escudero Gomez																																																				
2.4	seleccionar el metodo NDT más viable para apalancamiento con IA	5,00%	Gabriel Esteban Escudero Gomez																																																				
2.5	Elaboración y entrenamiento de prototipo IA basado en Google Teachable Machine con la selección de imágenes.	30,00%	Gabriel Esteban Escudero Gomez																																																				
3 PROTOTIPO DE MEJORA EN INSPECCIÓN VISUAL ENTRENADO CON IA																																																							
3.1	Sistematización del prototipo	20,00%	Gabriel Esteban Escudero Gomez																																																				
3.2	Documentación detallada de pasos y criterios con resultados específicos y hallazgos estadísticos.	10,00%	Gabriel Esteban Escudero Gomez																																																				
4 CONCLUSIONES																																																							
4.1	Viabilidad de la inserción de la Inteligencia Artificial en la aviación según resultados de prototipo	10,00%	Gabriel Esteban Escudero Gomez																																																				
4.2	Oportunidades de desarrollo en la industria aeronautica colombiana	10,00%	Gabriel Esteban Escudero Gomez																																																				
4.3	Limitaciones del prototipo en entorno académico	10,00%	Gabriel Esteban Escudero Gomez																																																				
5 Cierre																																																							
5.1	Aprobación y calificación final por parte del asesor académico Óscar David Henao Merchán	0,00%	Gabriel Esteban Escudero Gomez																																																				
5.2	Aceptación por parte de la universidad	0,00%	Gabriel Esteban Escudero Gomez																																																				
AVANCE TOTAL		0,00%																																																					

Fuente: Elaboración propia.

2. FUNDAMENTOS TEÓRICOS.

Este capítulo recopila los conceptos teóricos necesarios para comprender el enfoque del presente trabajo. Se abordan los principios fundamentales de la inteligencia artificial y el aprendizaje automático, incluyendo su evolución, componentes y aplicaciones actuales.

Asimismo, se presenta una revisión del estado del arte en relación con uso de estas tecnologías en procesos de inspección visual. Finalmente, se exploran los fundamentos del mantenimiento aeronáutico y su vínculo con los ensayos no destructivos, estableciendo así la base conceptual para la integración de inteligencia artificial en las inspecciones técnicas.

2.1. La inteligencia artificial y el aprendizaje automático (Machine Learning).

La inteligencia artificial (IA) nace en 1956 en la Universidad de Dartmouth donde tuvo lugar un proceso investigativo que consistía en la emulación de aprendizaje autónomo como lo realiza la mente de un ser humano, para ese momento se emuló la mente de un niño pequeño y a través de proporcionarle información, se analizaba cómo este era capaz de resolver desafíos sencillos y mediante un aprendizaje escalonado se conseguía una mente adulta con capacidad de resolver desafíos mayores. Es así como se llegó a lo que hoy en día se conoce como una inteligencia artificial que es capaz de emular a la perfección la mente humana, es capaz de resolver problemas, tomar decisiones autónomas, realizar predicciones bastante acertadas, realizar tareas en segundos y todo esto a través de aprendizaje supervisado o autónomo guiados por lenguajes de programación. (Bosch Rué et al., 2019).

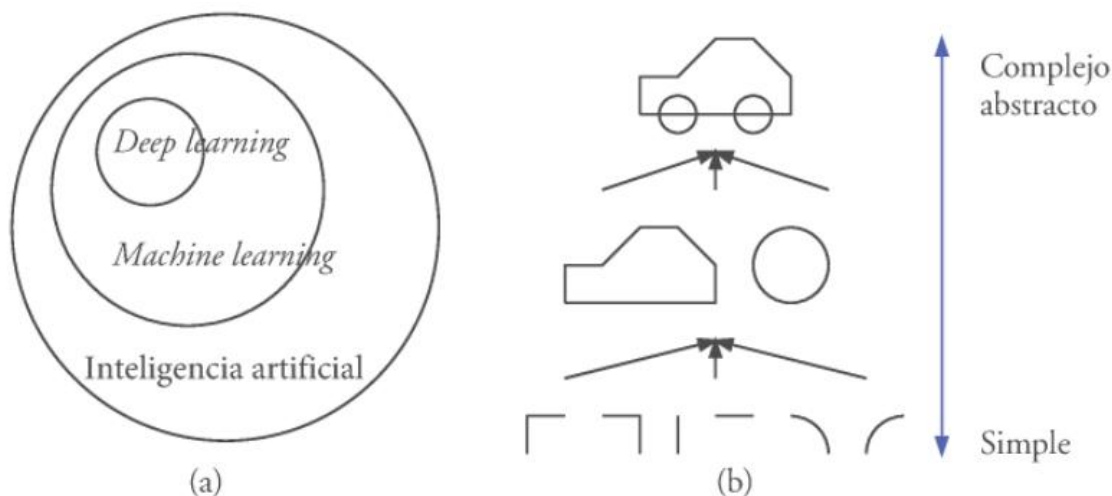
De acuerdo con el contexto histórico se puede inferir que el desarrollo tecnológico de la inteligencia artificial nace desde la necesidad; un ejemplo claro es en el contexto de la

Guerra Fría, donde se necesitaba la traducción del ruso al inglés y fue posible suministrando a la inteligencia artificial reglas de gramática simple, este tipo de avances se fueron perfeccionando a lo largo de la historia pasando por los primeros lenguajes de programación hasta redes neuronales y tipos de aprendizaje los cuales se adaptan a diferentes propósitos globales incluida la aviación.

Los ordenadores y toda máquina capaz de procesar información pueden convertir una tarea de alta complejidad para las capacidades humanas, una tarea “fácil” de desarrollar en poco tiempo y eso es porque son programadas en una modalidad cerrada que se rige por reglas específicas estableciendo herramientas para inferir situaciones futuras a partir de la situación actual y las reglas que rigen el escenario. En muchos de estos casos, las reglas y el conocimiento son introducidos en el sistema en el momento de su programación. Es decir, es el programador el encargado de «transferir» el conocimiento al modelo, el cual después será capaz de inferir nuevo conocimiento a partir de las reglas (Lozano Bagén, 2020).

El concepto de deep learning también conocido como aprendizaje profundo aparece como un subconjunto, dentro del aprendizaje automático, el cual consiste en crear modelos que sean capaces de representar conceptos complejos y/o abstractos a partir de otros más sencillos; creando de forma automática una jerarquía de conceptos, tomando conceptos simples y mezclándolos con otros conceptos para ir creando conceptos cada vez más complejos.

Ilustración 2. Relación entre el aprendizaje profundo y conceptos simples a complejos.



Fuente: Libro Deep Learning Cap 1 Num1.1 Pag 20.

De la Ilustración 2 se entiende cómo a partir de suministrarle conceptos simples como líneas, líneas curvas y cuadradas utilizando el método del aprendizaje automático se pueden construir nuevos conceptos “simples”, resultado de los primeros datos proporcionados hasta llegar a la creación de un concepto más amplio y completo siguiendo la jerarquía como resultado de las líneas que se proporcionaron inicialmente. Esto es lo que se conoce como aprendizaje profundo automático relacionado también con redes neuronales y representa una alternativa al aprendizaje a través de establecer reglas en sistemas cerrados como el que se mencionó inicialmente.

Redes neuronales artificiales (ANN, por sus siglas en inglés Artificial Neural Networks) consiste en un conjunto de algoritmos que actúan bajo un mecanismo de comunicación inspirado en el de las neuronas biológicas del cerebro humano. Su capacidad de

aprendizaje convierte a las redes neuronales en algoritmos adaptativos y se utilizan cuando la información o el conocimiento es impreciso o presentan muchas variaciones en el tiempo, siendo este método capaz de hallar soluciones y predicciones cambiantes según sea la necesidad se conoce hoy bajo el nombre de Deep Learning o aprendizaje profundo. Es importante aclarar que los conceptos de neurociencia que hacen referencia al cerebro humano y todo aquello que lo compone se utiliza en este tipo de conceptos tecnológicos solo como inspiración y de ningún modo como una guía. Esto se debe a que actualmente, con los múltiples desarrollos, es imposible conocer a ciencia cierta cómo es que funciona el cerebro humano. (Bosch Rué et al., 2019).

Aprendizaje automático (Machine Learning).

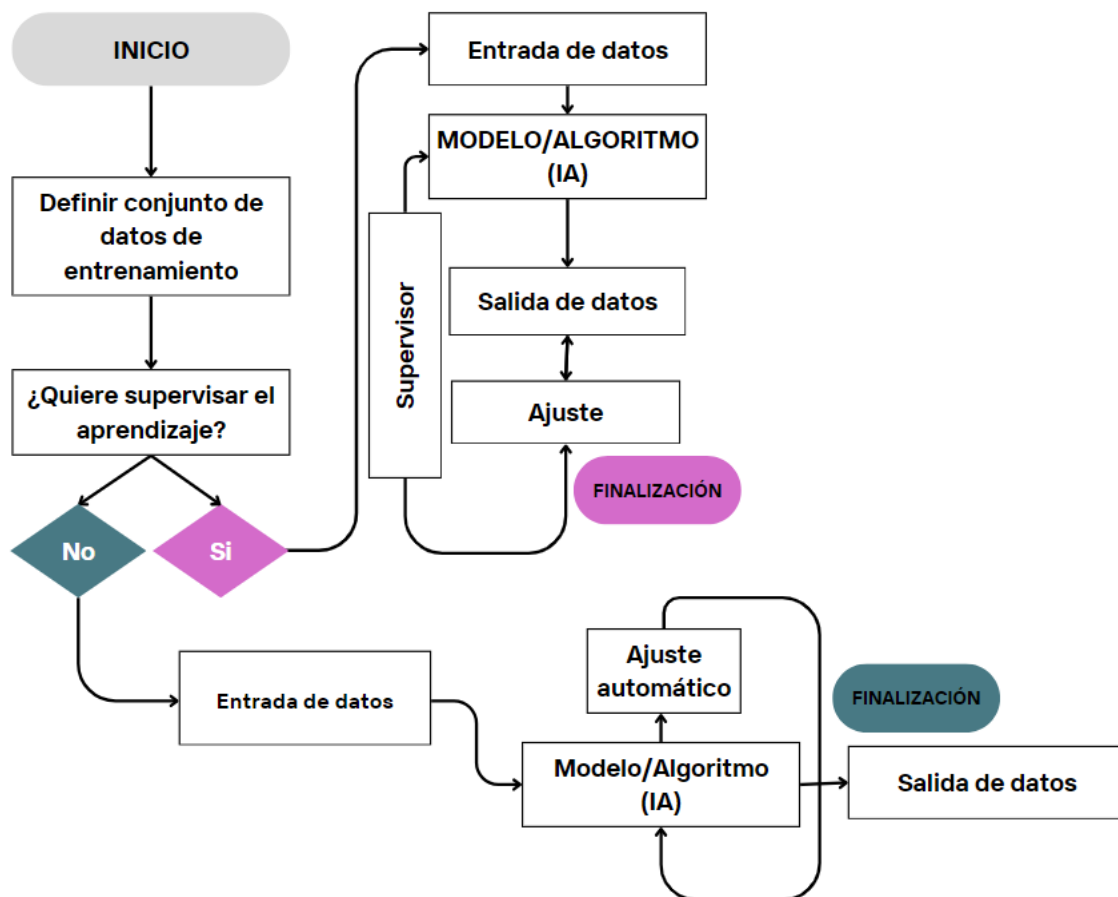
Consiste en sistemas capaces de extraer su propio conocimiento a través de la administración de datos también se le conoce como Machine Learning los métodos para este tipo de modelo de inteligencia artificial son modelos de regresión, modelos estadísticos o las máquinas de vectores soporte (SVM7 support Vector machine). En muchos casos, los modelos son capaces de aprender patrones a partir de los datos, pero no son capaces de aprender conceptos abstractos y complejos a partir de esos mismos datos (Lozano Bagén, 2020). El Machine Learning se utiliza mediante la aplicación de técnicas y algoritmos para que una máquina aprenda de forma automática en base a un conjunto de “experiencias” pasadas.

Existe una variedad de métodos y técnicas para el aprendizaje automático, generalmente, un algoritmo de aprendizaje automático debe construir un modelo con base en un conjunto de datos de entrada (información de aprendizaje/entrenamiento). Durante esta fase, el algoritmo va comparando la salida de los modelos en construcción con la salida ideal

(o lo que se espera que debería entregar). Mediante una retroalimentación, se va ajustando y aumentando la precisión de lo que se espera obtener finalmente. Esta comparación es la que forma una base de aprendizaje, este aprendizaje puede ser supervisado o no supervisado.

(Goodfellow et al., 2016; Bosch Rué et al., 2019).

Ilustración 3. Explicación del aprendizaje supervisado y no supervisado.



Fuente: Elaboración propia.

Las metodologías presentadas en la Ilustración 3 se basan en el paradigma del aprendizaje inductivo, obteniendo de forma inductiva la información base que se proporciona como entrenamiento, el modelo/algoritmo representa el conocimiento que tiene utilidad

predictiva, es decir, puede aplicarse a nuevos datos mediante la retroalimentación. En el aprendizaje no supervisado, el modelo o algoritmo aprende a partir de los datos de entrada, descubriendo y agrupando patrones, características, correlaciones, entre otros mediante su propio ajuste, lo que da lugar a diferentes tipos de tareas, según los patrones identificados.


A continuación, se describen los tipos de tareas más comunes:

Tipos de tareas.

Clasificación: consiste en asignar instancias de un dominio dado, descritas por un conjunto de atributos discretos o de valor continuo, a un conjunto de clases, que pueden ser consideradas valores de un atributo discreto seleccionado, generalmente denominado “clase”.

Este tipo de tarea puede visualizarse en la Ilustración 4, donde se ejemplifica cómo se realiza una clasificación en función de atributos que permiten agrupar instancias dentro de una clase específica.

Ilustración 4. Ejemplo de clasificación.



Fuente: Elaboración propia.


Regresión.

Se puede definir como un problema de “clasificación con clases continuas”. Es decir, los modelos de regresión predicen valores numéricos en lugar de etiquetas de clase discretas.

A veces también se puede hacer referencia a la regresión como «predicción numérica» de valores continuos. Los círculos representan los datos de conocimiento y la línea, la predicción de valores futuros.

La Ilustración 5 permite observar gráficamente cómo funciona un modelo de regresión, mostrando la relación entre los datos de entrada y la predicción de valores continuos.

Ilustración 5. Ejemplo de regresión.



Fuente: Elaboración propia.

Agrupamiento (Clustering).

Consiste en dividir un conjunto de instancias de un dominio dado, descrito por un número de atributos discretos o de valor continuo, en un conjunto de grupos basándose patrones de similitud entre las instancias y crear un modelo que puede asignar nuevas instancias a uno de estos grupos.

La Ilustración 6 muestra cómo funciona el agrupamiento de datos, donde los elementos son organizados en grupos según sus similitudes.

Ilustración 6. Ejemplo de agrupamiento de datos.



Fuente: Elaboración propia.

Procesamiento de datos.

Las redes neuronales artificiales, como el resto de los modelos de aprendizaje automático, requieren que los datos de entrada se encuentren en un formato específico para poder trabajar de forma correcta, recomendablemente en formato binario [1.0]

Datos estructurados: conjunto de datos correctamente etiquetados, aprendizaje automático, prefieren trabajar con valores numéricos, así que se debe transformar los atributos categóricos a atributos numéricos. (Goodfellow et al., 2016).

La Ilustración 7 representa un conjunto de datos estructurados, en el que cada fila contiene múltiples atributos numéricos previamente organizados para ser utilizados en un modelo de aprendizaje automático.

Ilustración 7. Ejemplo de datos estructurados.

$$D_{n,m} = \begin{pmatrix} d_1 = & a_{1,1} & a_{1,2} & \cdots & a_{1,m} & c_1 \\ d_2 = & a_{2,1} & a_{2,2} & \cdots & a_{2,m} & c_2 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ d_n = & a_{n,1} & a_{n,2} & \cdots & a_{n,m} & c_n \end{pmatrix}$$

Fuente: Deep Learning Cap 2 Num2.3.1 pag 30.


Imágenes.

Tamaño y relación de aspecto entre una y otra imagen, escalamiento de imágenes de manera uniforme para todas, normalización de los datos de cada una de las imágenes suministradas como los pixeles tengas una distribución de datos similares y la convergencia de las imágenes. (Bosch Rué et al., 2019).

Datos de entrenamiento y prueba (test).

Validar un algoritmo de aprendizaje o modelo implica asegurarse de que funcionará correctamente para los datos de prueba o test futuros, de forma que capture la esencia del problema que quiere resolver y generalice correctamente. En esencia se trata de evitar que sea dependiente de los datos utilizados durante su entrenamiento, evitando el problema conocido como «sobreentrenamiento»

Ilustración 8. Proceso y creación y validación de un modelo de aprendizaje supervisado.



Fuente: Deep learning Cap 2 Num.2.6 Pag 34.

La Ilustración 8 muestra un modelo de aprendizaje automático de forma esquemática que pasa por etapas de entrenamiento y prueba para evaluar su precisión. Hay que tener en cuenta el principio de funcionamiento de las redes neuronales que por lo general consiste en la entrada y salida de información de un modelo. Una forma matemática explicar cómo funciona es $F(x) = y$ donde (x) se refiere a los datos de entrada, es decir, el conjunto de datos en entrenamiento y $(f(x))$ se refiere a la salida de datos del algoritmos lo que quiere decir que es el resultado que arroja analizando los datos iniciales que se le suministran.


Arquitectura de una red neuronal.

La arquitectura de las redes neuronales hace referencia a la organización de las “neuronas” en función de las entradas de información disponibles en el modelo, esta red de neuronas se encarga de recibir la información inicial y activarla comenzando con su procesamiento y aplicando un conjunto de tareas determinado según sea lo especificado por el operador de este tipo de algoritmos desde un inicio de esto va a depender la salida o el resultado final que entregue el modelo es importante mencionar que cada arquitectura puede ser válida para algunos tipos de problemas y presentar diferentes niveles de calidad en cuanto a los resultados y también diferentes niveles de coste computacional, todo va dependerá del

tipo de estructura neuronal que sea, hay unos sistemas simples y hay otros modelos más elaborados y complejos (Goodfellow et al., 2016).

En la Ilustración 9 muestra una red neuronal simple basada en datos de entrada procesamiento de la información y un resultado de salida, es así como funcionan los sistemas neuronales básicos.


Ilustración 9. Ejemplo de estructura neural simple.



. Fuente: Elaboración propia.

La complejidad del modelo varía según la estructura de la red neuronal. A continuación, se muestra un ejemplo de una arquitectura más avanzada, que permite procesar patrones de entrada más complejos.

Ilustración 10. Ejemplo de estructura neuronal compleja.



Fuente: Elaboración propia.

En la Ilustración 10 se muestra una red con la capa de entrada, una capa oculta de procesamiento, formada por un conjunto variable de neuronas y finalmente la capa de salida con una o más neuronas. Este tipo de redes son capaces de clasificar patrones de entrada más complejos o realizar predicciones sobre dominios de dimensionalidad más alta. El número de neuronas de la capa oculta está relacionado con la capacidad de procesamiento y clasificación (Lozano Bagén, 2020). Dejando claro los conceptos básicos de funcionamiento de un modelo de inteligencia artificial con capacidad de aprendizaje autónomo o supervisado. Más adelante se detallará cómo a este tipo de modelos se les pueden incorporar códigos de ética o condiciones de programación para controlar los resultados esperados. Es importante tener en cuenta que dichos controles se definen desde su programación y dependen de su contexto de operación.

2.2. Estado del arte.

En el contexto del desarrollo tecnológico acelerado que experimenta la industria aeronáutica, comprender el estado del arte es un paso clave para establecer los fundamentos teóricos y técnicos de esta investigación. En esta sección se recopilan y analizan antecedentes relevantes relacionados con la inteligencia artificial y su aplicación en procesos de mantenimiento aeronáutico, particularmente en tareas de inspección no destructiva. El objetivo es identificar los avances más significativos, las brechas actuales en la literatura y las experiencias documentadas a nivel internacional, que sirven como punto de partida para plantear una propuesta pertinente y contextualizada. Asimismo, se resaltan los marcos regulatorios emergentes que están dando forma a la integración segura y confiable de estas tecnologías en el entorno aeronáutico actual.

2.2.1. Marco regulatorio EASA European Union Aviation Safety Agency Agencia de Seguridad Aérea de la Unión Europea).

La inteligencia artificial está impactando toda la industria en general, en cuanto a la aviación y todo su entorno, donde las autoridades aeronáuticas saben y se ocupan de establecer dónde y bajo qué parámetros regulatorios puede o no operar dentro del marco de la aviación. Actualmente solo el parlamento europeo emite el primer marco jurídico aplicable a la IA con el Reglamento (UE) 2024/1689 por el que se establecen normas armonizadas sobre inteligencia artificial y ofrece a los desarrolladores e implementadores de IA requisitos y obligaciones claros en relación con los usos específicos de la IA (European Union, 2024). La EASA está realizando una armonización de esta ley para adoptar los estándares exigidos en la norma aeronáutica europea a través de la RMT.0742 confiabilidad de la inteligencia artificial

de conformidad con el capítulo III de la sección III de la norma IA de EU (European Union). Dicho capítulo trata sobre los sistemas de alto riesgo, definidos como aquellos que están destinados a ser utilizados como componentes de seguridad de un producto o cuando el sistema de IA constituye en sí mismo un producto. También se consideran de alto riesgo los sistemas de IA que deben someterse a una evaluación de conformidad por terceros antes de su comercialización o puesta en servicio, con el fin de garantizar que cumplan con los estándares exigidos por la ley.

La IA en aviación se considera de alto riesgo debido a la utilización que desde EASA han contemplado para ella, de acuerdo con el informe Artificial Intelligence Roadmap 2.0 donde se contempla el uso de la inteligencia artificial para apoyar los servicios de navegación aérea, servicios ATS, ayuda a las tripulaciones en vuelo con toma de decisiones, diseño de aeronaves, producción y mantenimiento incluido el control y manejo de registros.

De acuerdo con el capítulo III un sistema/ producto IA se le considera de alto riesgo cuando esté destinado a realizar tareas dentro de procedimientos limitados, mejorar el resultado de una actividad humana previamente completada y/o detectar patrones o desviaciones en decisiones anteriores, aclarando que no busca reemplazar ni influir en evaluaciones humanas ya realizadas. Cuando un producto IA opere sin una revisión humana adecuada lo que se conoce como mecanismo de supervisión todo lo anterior se da en aras de garantizar la confiabilidad en la inteligencia artificial dentro de la industria, es por esto que la autoridad aeronáutica europea se encuentra tomando acciones concretas para darle cumplimiento al RMT.0742. Dicho documento establece los objetivos y subtarefas que está llevando a cabo la EASA para regular el uso de la inteligencia artificial en aviación, con el fin

de garantizar su operación de forma segura y controlada. Se detallan allí las acciones concretas encaminadas a dar cumplimiento a estos lineamientos, las cuales son:

La propuesta de un marco regulatorio en aviación para la confiabilidad de la IA en respuesta y dando cumplimiento al Capítulo III, Sección 2 de la Ley de IA de la UE modificando y/o armonizando la siguiente normativa (EASA, 2024).

2.2.2. Normas que se van a armonizar con la ley IA de la Unión Europea(EU).

Las siguientes regulaciones hacen parte del marco normativo propuesto en el documento RMT.0742 Issue 1 – Terms of Reference de la Agencia Europea de Seguridad Aérea (EASA):

- Regulation (EU) No 748/2012 (Initial Airworthiness)
- Regulation (EU) No 1321/2014 (Continuing Airworthiness)
- Regulation (EU) 2024/1107 (UAS Airworthiness and Organisation Requirements)
- Regulation (EU) No 965/2012 (Air Operations)
- Regulation (EU) 2019/945 (Unmanned Aircraft Systems)
- Regulation (EU) 2019/947 (Operation of Unmanned Aircraft)
- Regulatory framework for the operation of VTOL and air taxis
- Regulation (EU) No 1178/2011 (Aircrew and Medical)
- Regulation (EU) 2015/340 (ATCO Licensing)
- Regulation (EU) 2017/373 (ATM/ANS)
- Regulation (EU) 2023/1768 (Conformity Assessment DPO)
- Regulation (EU) 2023/1769 (Ground Equipment)
- Regulation (EU) 2021/664 (U-space)

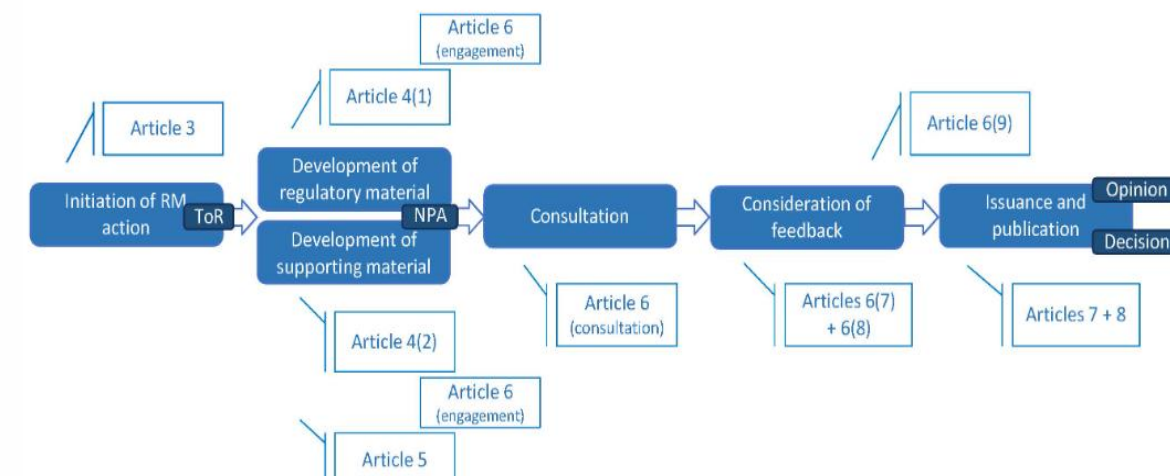
- Regulation (EU) No 139/2014 (Aerodromes)
- Regulatory framework for safety-related aerodromes equipment
- Regulatory framework for the provision of ground handling services
- Regulation (EU) 2023/203 (Part-IS)

Fuente. European Union Aviation Safety Agency (EASA), RMT.0742 Issue 1 – Terms of Reference, 2023.

- Desarrollo del conjunto asociado de medios de cumplimiento aceptables (AMC) y material de orientación (GM) genéricos relacionados con la IA que hace referencia a todas las especificaciones de certificación y especificaciones detalladas relacionadas, así como AMy GM pertinentes.
- Desarrollo de las adaptaciones necesarias al material reglamentario específico del dominio para los dominios de la aviación identificados en el artículo 108 de la Ley de IA de la UE.
- Desarrollo de las adaptaciones necesarias al material reglamentario específico del dominio para otros dominios afectados (por ejemplo, pero no limitado a, aeródromos) (EASA, 2024).

Para garantizar que la integración de tecnologías emergentes como la inteligencia artificial se realice de forma segura, EASA ha estructurado un proceso normativo riguroso. La Ilustración 11 representa este flujo de trabajo, desde la propuesta inicial hasta la publicación oficial de las decisiones regulatorias.

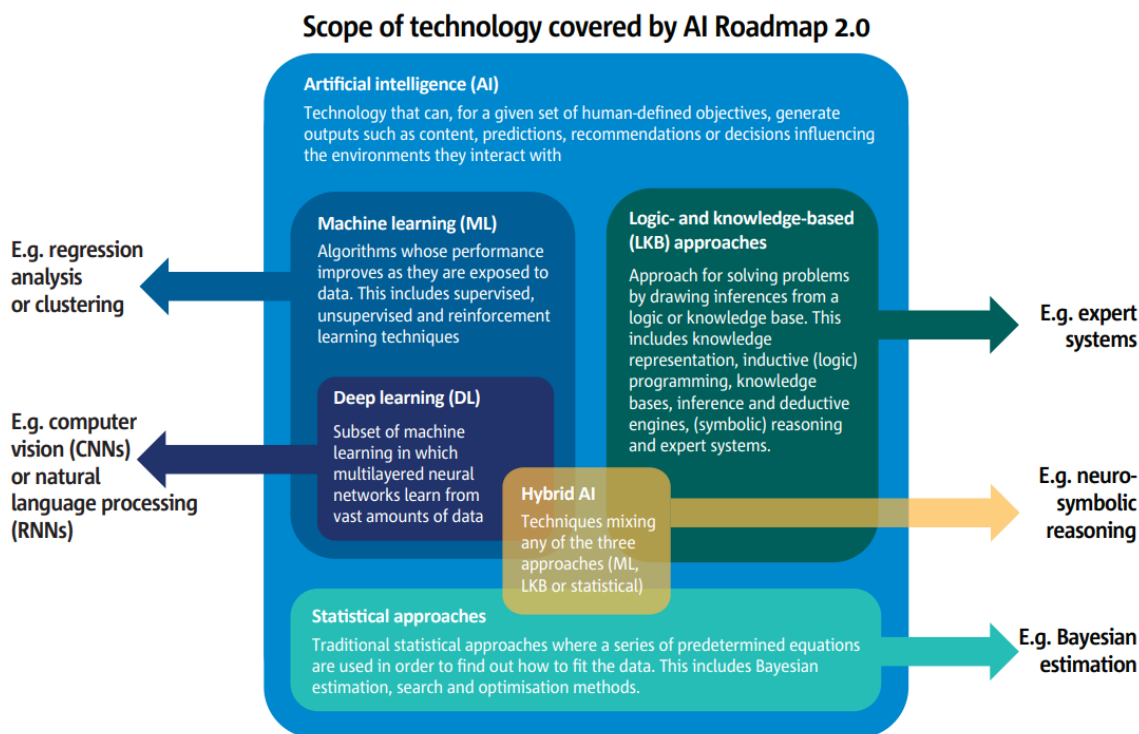
Ilustración 11. Diagrama de proceso para aprobación de leyes por parte de EASA.



Fuente: Pagina web EASA.

La autoridad aeronáutica europea ha estado publicando anualmente hojas de ruta donde documentan la evolución y se profundiza en la mejora mediante los diferentes intercambios de puntos de vista y proyecciones involucrando el trabajo práctico sobre el desarrollo de la IA. Antes de publicar el documento de aprobación final del proyecto de aplicaciones de aprendizaje automático MLEAP en aviación; se publicaron tres documentos adicionales que ofrecían un enfoque seguro para la aviación y antes de que se considerara adecuado confiar en el aprendizaje automático. Primero, se estableció que la tecnología de inteligencia artificial híbrida ofrecía mayores niveles de seguridad para operar dentro de la industria aeronáutica, dada la necesidad crítica de mantener control sobre esta tecnología (una característica no negociable y de carácter imperativo). Además, se recuerda que, dentro del marco legal de la IA, esta tecnología es considerada de alta complejidad.

Ilustración 12. Taxonomía de IA Híbrida.



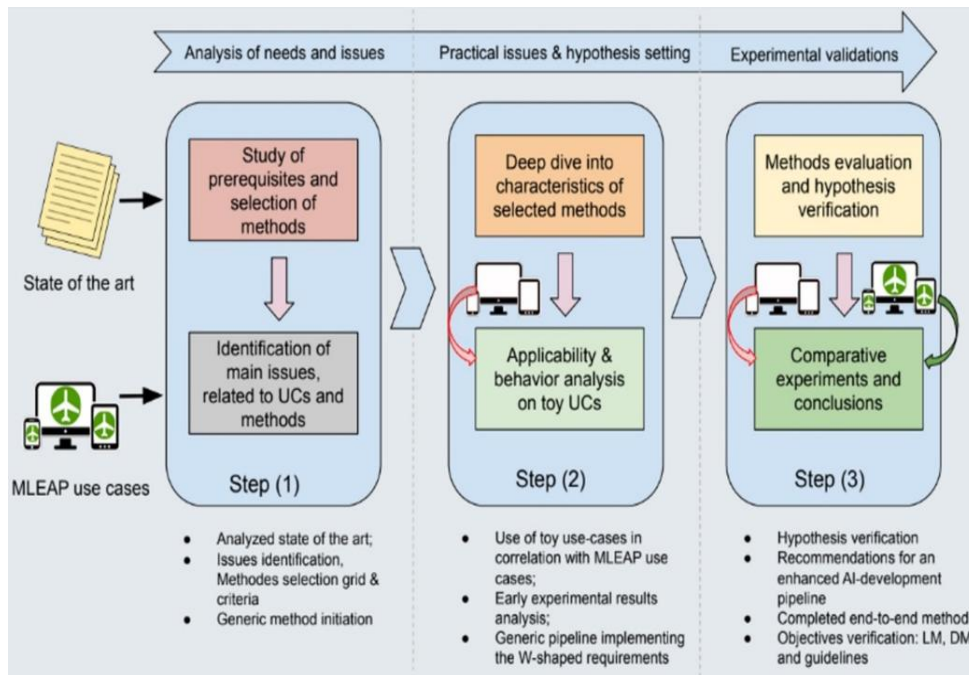
Fuente: Documento EASA IA Roadmap 2.0 de 2023 pag 6 Taxonomía de IA.

En el año 2023 cuando se publicó el documento artificial Intelligence Roadmap 2.0 se identificaban técnicas y enfoques viables para su uso en aviación, los cuales se dividían en enfoques de aprendizaje automático, también conocida como IA simbólica, junto con enfoques estadísticos (EASA, 2023). El aprendizaje automático (ML), tal como se muestra en la Ilustración 12, forma parte de esta taxonomía, al igual que el aprendizaje profundo (DL). Las soluciones de aprendizaje siguen siendo predominantes en las aplicaciones y casos de uso en la industria de la aviación, pero resulta que cumplir con los altos estándares de seguridad que exigen la regulación de aviación y leyes como la ley EU de IA ha direccionado hacia un enfoque renovado de IA basada en conocimiento en aras de cumplir con las exigencias legales

vigentes. Esto dio lugar a que, para el año 2024, fuese publicado el documento final del proyecto de aprobación de aplicaciones de aprendizaje automático MLEAP(EASA, 2024). Dicho documento proporciona un conjunto de recomendaciones sobre métodos y herramientas para lograr los diferentes requisitos asignados a los componentes de aprendizaje automático del sistema centrándose en la garantía del aprendizaje es un componente esencial del concepto de confiabilidad de la IA, que adapta los principios de garantía del desarrollo a los enfoques basados en el aprendizaje en el estudio realizado se propuso un proceso de desarrollo genérico que consiste en una implementación práctica del proceso de desarrollo utilizando una metodología propuesta llamada proceso (W) o ciclo (V) que tiene como finalidad explicar cómo funciona la garantía del aprendizaje en un sistema de aprendizaje automático con inteligencia artificial.

En la Ilustración 13 se evidencia el proceso general que EASA aplica para implementar proyectos de inteligencia artificial bajo el programa MLEAP.

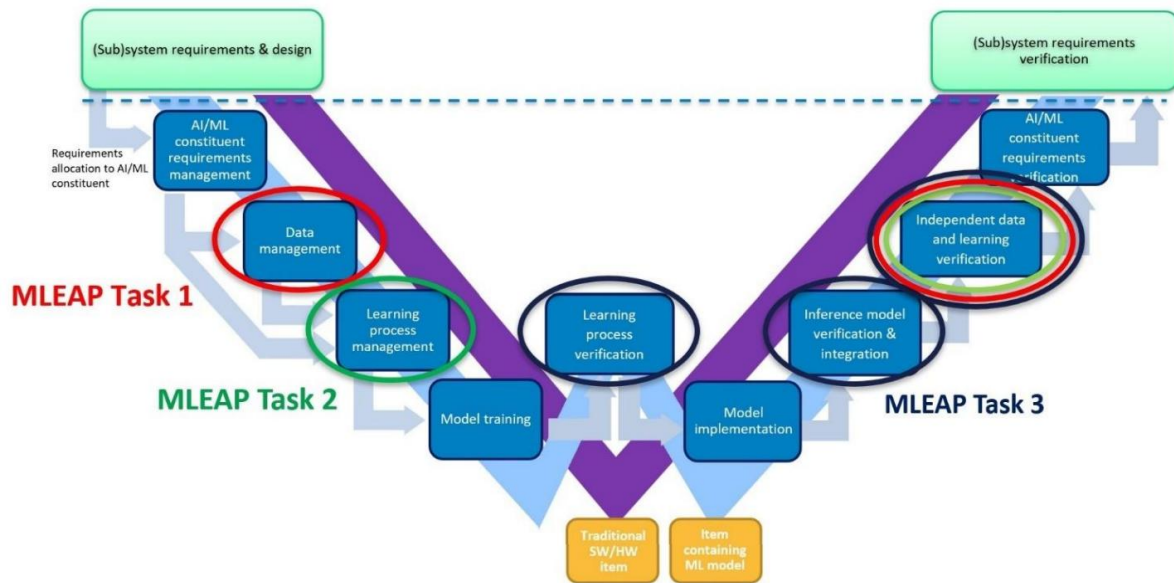
Ilustración 13. Explicación de desarrollo genérico de implementación IA.



Fuente: Página web EASA Newsroom and events.

A continuación, se profundiza en el enfoque metodológico utilizado por EASA en el programa MLEAP, destacando las tareas clave que estructuran el proceso de aprobación de sistemas de inteligencia artificial.

Ilustración 14. Metodología W y tareas importantes de EASA para la aprobación de IA
MLEAP.



Fuente: Pag 5 Document MLEAP final report.

Como se explica en la Ilustración 14, la garantía del aprendizaje establece objetivos específicos para cada etapa del desarrollo, tanto a nivel del sistema como del componente de inteligencia artificial.

Este proceso adapta el ciclo en "V", típico de la garantía en el desarrollo de software, a las aplicaciones basadas en ML/DL, las cuales se encuentran definidas en la Ilustración 12 (Taxonomía de IA Híbrida, fuente: EASA IA Roadmap 2.0, 2023, pág. 6). Esta metodología permite estructurar la guía a través de los bloques que la componen.

“La línea de puntos está aquí para distinguir entre el uso de procesos tradicionales de garantía del desarrollo (arriba) y la necesidad de procesos adaptados a los enfoques de

aprendizaje basados en datos (abajo), donde los procesos de garantía del aprendizaje comienzan debajo de la línea de puntos.” (EASA, 2024).

Para resumir, las tareas realizadas por el grupo de investigación de EASA durante el último año consistieron en el manejo de la integridad y representatividad de los datos, centrándose en la verificación de la calidad mediante una cuadrícula de selección de métodos. Estos métodos permiten asegurar que el proceso de aprendizaje automático se desarrolla de manera confiable, tanto en el dominio como en la aplicación de destino, lo cual está directamente relacionado con la confiabilidad de los modelos ML/DL.

También se revisó el desarrollo de los modelos mediante el análisis de las propiedades de generalización, a la vez que se exploró cómo aprovechar el proceso de aprendizaje para mejorar la capacidad del modelo de escalar su rendimiento ante datos no vistos durante el entrenamiento. Asimismo, se evaluó si el modelo mantiene características deseadas en términos de robustez y estabilidad, a partir de los datos suministrados y con criterios medibles de evaluación.

Esto resulta fundamental, ya que los modelos pueden enfrentarse a cambios en la representación de los datos de entrada y a perturbaciones en entornos reales. Un ejemplo de ello es la variación de datos que puede experimentar un sensor en una aeronave. Por esta razón, es esencial comprobar que el modelo es suficientemente robusto y que su rendimiento permanece estable, incluso frente a datos corruptos o ruidosos. También se abordaron aspectos relacionados con los sistemas de IA y sus tareas más comunes, ya mencionadas en este capítulo.

2.2.3. Niveles de caracterización para sistemas IA definidos por EASA.

Nivel A sistemas: Requisitos técnicos que se asignan a diferentes partes, incluido el componente de IA para ampliar la evaluación de seguridad existente y la guía de garantía del desarrollo.

Nivel B componentes: En este nivel, la IA está totalmente dentro del alcance de MLEAP. Se abordan las particularidades de las tecnologías de IA, incluida la gestión de datos, la gestión y verificación del proceso de aprendizaje, el entrenamiento de modelos de aprendizaje automático y aprendizaje automático y su evaluación y luego la verificación de lo aprendido y de cómo funcionan los modelos en el sistema de destino

Nivel C artículo: Este nivel se apoya en los lineamientos existentes de garantía para el desarrollo de software y hardware, a fin de asegurar la correcta implementación de los modelos y componentes de IA.

2.2.4. Objetivos de la EASA con IA (MLEAP).

Los objetivos se desprenden de las tres tareas principales que se llevan a cabo como se aprecia en la Ilustración 14.

- **Integridad y representatividad de los datos:** Explorar métodos para evaluar la integridad y representatividad de los datos. Esto implica especificar un conjunto de características relacionadas con la definición del dominio operativo de la aplicación de destino, así como las restricciones y especificidades relacionadas con el módulo de aprendizaje automático en particular.
- **Garantías sobre la generalización del modelo:** los objetivos seleccionados se centran en las etapas de gestión del aprendizaje (LM) del proceso en forma de W. Al

estar altamente relacionadas con la calidad y volumetría de los datos, las prestaciones de un modelo entrenado se pueden evaluar en función de varios aspectos de la aplicación de destino, incluidos los resultados esperados y cómo el modelo puede generalizar su rendimiento a nuevas entradas.

- **Robustez y estabilidad:** se centra en analizar cómo la robustez y la estabilidad pueden ponerse en perspectiva con los requisitos o directrices existentes de otras fuentes normativas. Para ello, se investigan tres tipos de métodos: estadístico, formal y empírico, explorando su aplicabilidad en casos de uso concretos, tanto en la fase de diseño como durante la fase operativa.

2.2.5. Casos de uso para IA bajo modalidad MLEAP.

Los casos de aplicación de la IA en aviación ya se venían estableciendo desde formato roaming 2.0 donde se abordó el impacto de la inteligencia artificial en diferentes áreas de la aviación principalmente en aeropuertos, tránsito y navegación aéreo, mantenimiento, diseño de aeronaves entre otros. Sin embargo, en la emisión del documento final se establece con claridad las aplicaciones específicas que la inteligencia artificial tiene en el ámbito aeronáutico, como resultado del estudio.

La Ilustración 15 presenta una síntesis de las aplicaciones técnicas de inteligencia artificial identificadas por EASA en el marco del estudio MLEAP, clasificadas según su nivel de madurez e implementación en el sector aeronáutico.

Ilustración 15. Aplicaciones técnicas definidas en el estudio de EASA.

	ATC-STT	ACAS Xu	AVI
<i>High-level description of the ODD</i>	To correctly detect the spoken instructions, the acoustic and language models should be trained on complete data sets. Full data completeness is defined by several speech-related features targeted for intended system performance: noise types, airports with specific checkpoint names, accents, and speech rates.	The data ¹¹ represents input points of the lookup tables from the RTCA SC-147 resources ¹² . This latter provides the Minimum Operational Performance Standards (MOPS) for ACAS-Xu. The ODD is divided into sub-ODDs to fit 45 ML model elements of the ML model architecture.	The ODD is defined by the set of all pictures of airframe structures in acceptable lighting & blur conditions. There may be indoors or outdoors pictures. If it is outdoors the weather conditions can influence the lighting & blur state.
<i>ML Target tasks</i>	Extract useful information for the pilot from ATC exchanges	Each NN shall replicate the LUT prediction in its allocated ODD (LUT property) 100% accuracy in the allocated ODD for each ML model	Automatic damage detection based on high-resolution pictures. The target accuracy for the ML item is the same as for a human inspection
<i>Model architecture</i>	Different architectures: LSTM, CNN, and TDNN implemented within an open-source toolkit called KALDI The one used for experiments is a TDNN-HMM	L-Lipschitz Neural Networks	CNN & Incremental learning
<i>Data Dimensionality</i>	High Dimension	Low dimension	High Dimension
<i>Model Complexity</i>	The models are made of different deep neural network architectures and shallow classical ML (KALDI models). Hence, methods based on NN architecture for identifying the model complexity (cf. section 5.4.1) apply.	The models are made of simple (shallow) neural network architectures. Hence, methods based on NN architecture for identifying the model complexity apply to this.	The models are made of deep CNN architectures dealing with high-quality images. Methods based on NN architecture for identifying the model complexity apply for this.

	ATC-STT	ACAS Xu	AVI
<i>System description</i>	<ul style="list-style-type: none"> - The model is made of 4 main components: - Feature extractor: Mel filter-bank coefficients (MFCC) are used as input features along with i-vectors - Acoustic model: 2 models have been compared, a Hidden Markov Model (HMM), and a TDNN/LSTM for linking phonemes and audio signals. - Language model: gives the probability distribution over a sequence of words. - Decoder: beam-pruned Viterbi search (LOWERRE, 1976) that conducts a best-path approximation inside the decoding graph. - A final SoftMax layer discriminates, according to the input, what the heard phoneme is. 	<p>1) Identification—All input situations in which the NN and the LUT predictions are different are considered incorrect (the NN does not preserve the LUT property).</p> <p>2) Mitigation—This part is already addressed per the subsystem architecture design: the ACAS-Xu hybrid ML-based controller switches from the ML model (NNs) to the LUTs (Safety Net) when incorrect situations are detected (this is already described in the ACAS-Xu subsystem architecture document).</p>	<p>The inference model is a pipeline made of:</p> <ul style="list-style-type: none"> . The damage detector . The automated generation of windows . The classifier <p>The damage detector can be seen as a data pre-processing stage before the classifier which is the AI/ML constituent.</p>
<i>ML component description</i>	<p>Audio input as a sequence of 20ms frame TDNN layers scans its input according to a splicing parameter;</p> <p>The final SoftMax layer discriminates, according to the input, what is the heard phoneme</p>	<p>the ML model is composed of several elements more precisely, 45 NNs</p>	<p>Transfer learning using the already trained network from the ImageNet project (e.g., VGG16);</p> <p>Completion of the transfer learning network with a couple of layers with a couple of hidden layers;</p> <p>The final layer is a cross-entropy layer;</p> <p>Adam optimiser is used for the training</p>
<i>Data type</i>	<p>Annotated corpus with different accents (French and Chinese)</p>	<p>LUTs binary data</p>	<p>Any type of image standard shall be addressed (.jpg, .bmp, .gif, ...)</p>
<i>Data management</i>	<ul style="list-style-type: none"> - The data corresponds ATC communications, recorded for normal situations (no abnormal or emergency communications have been recorded) - The annotated corpus of recorded real-life speech contains 114.8h, along with corresponding text manually transcribed - Audio input as a sequence of 20ms frame - Not subject to distribution or 	<p>The full raw LUTs are used</p>	<p>Acquisition of pictures: from cameras downloaded to design/deployment environment</p> <p>Labelling is done using VOTT tool;</p> <p>Every image can contain several damages of different classes</p> <p>A typical example using VOTT: The image is not modified, and the labelling is supported by a metadata</p>

	ATC-STT	ACAS Xu	AVI
	sharing for non-involved third parties		file presented as a json file - Not subject to distribution or sharing for non-involved third parties
<i>Performances and safety requirements derived from design & safety¹³ processes</i>	<p>System requirements—Complex background noise. The PESQ evaluation score represents operational conditions. The PESQ returns¹⁴ a score from 1 to 4.5, with higher scores indicating better quality. 3.8 is the acceptable score for the telephone voice.</p> <p>System requirements – High speech rate The speech rate in ATC is higher than that of speech in daily life since ATC requires high timeliness</p> <p>System requirements – Accents The system must operate with French and Chinese accent</p>	<p>System requirements – real-time 1 The controller must execute with a period of 1s.</p> <p>System requirements – anti-collision performance 1 Any implementation must behave similarly as the reference architecture</p> <p>System requirements – ODD 1 The controller must operate on the ranges of the LUTs, i.e.</p> $ODD_{ACAS\ Xu} = \begin{cases} \tau \in [0, 101] & \rho \in [499, 185318] \\ \theta \in [-3.14, +3.14] & \psi \in [3.14, +3.14] \\ v_{out} \in [0, 1200] & v_{outn} \in [50, 1200] \end{cases}$	<p>ML-based requirements: The first targeted performance is to focus on true positives ~ with 80% accuracy. Detection accuracy needs to be tested across different conditions, including variations in surface structure, camera position and viewing angle, and object obstruction.</p> <p>- System requirements: Solutions need to accommodate both indoor and outdoor environments, including night time and changing weather conditions, while extracting unnecessary information from the background of the aircraft. In addition to the ability to detect both identified types of damage (lightning strikes and dent impacts).</p>

Fuente Document MLEAP final report pag 77 hasta 79.

2.2.6. Aplicaciones de la IA en mantenimiento establecido por EASA.

La Agencia Europea de Seguridad Aérea (EASA) ha avanzado en la incorporación de tecnologías de inteligencia artificial en distintos procesos de mantenimiento aeronáutico. Esta sección presenta las principales aplicaciones en desarrollo y evaluación, enfocándose especialmente en aquellas dirigidas a mejorar la inspección visual y en el apoyo a la toma de decisiones técnicas por parte del personal especializado.

Inspección visual automatizada (AVI).

La inspección visual con IA es un proceso basado en la aplicación de un modelo de aprendizaje profundo trabajando en conjunto con visión artificial, para realizar el proceso de inspección y monitoreo ya sea una estructura o componente específica de una aeronave con el propósito de verificar el cumplimiento de especificaciones técnicas establecidas por el fabricante. Los recursos que tiene un modelo de inteligencia artificial para llevar a cabo este tipo de tareas son software con capacidad de procesamiento de imágenes complementado con un escaneo 3D empleado para diferentes tipos de inspección. Sin embargo, incluso con todas estas ayudas, aún no se considera completamente confiable por sí solo, debido a desafíos persistentes como el procesamiento de imágenes y los altos requerimientos en cuanto a calidad, resolución de píxeles, iluminación, entre otros factores. Por esta razón, Airbus, como se menciona en el estudio *EASA Final Report*, se enfoca en la detección de daños ocurridos durante el servicio, con el objetivo de apoyar al recurso humano en los siguientes aspectos:

- Asistencia diagnóstica a inspectores para reducir la duración de mantenimientos y eventos no programados.

- Detección automática de daños externos clasificándolos en impacto de rayos y/o abolladuras mediante la combinación de imágenes y videos.
- Encontrar métricas aceptables para acercar la visión por computadora a problemas clásicos como daños superficiales.

El programa MLEAP (Machine Learning Application Approval, Aprobación de la aplicación de aprendizaje automático) primeramente se centra en la inspección por daños superficiales categorizados solo en abolladuras e impactos de rayos, mas no hay avances en inspecciones por NDT.

La Ilustración 16 muestra ejemplos reales de daños superficiales como abolladuras e impactos de rayo, los cuales representan el enfoque inicial de detección automatizada dentro del programa MLEAP.

Ilustración 16. Ejemplos de daños por abolladuras e impactos de rayo.



Fuente: Research Project EASA. 2021.C38, MLEAP Cap 3 Num3.4 pag 87.

2.2.7. Conclusión de la inspección visual automatizada (AVI).

De acuerdo con lo descrito en el informe MLEAP Final Report las pruebas de viabilidad quedaron inconclusas y actualmente Airbus continúa haciendo pruebas y estudios más exhaustivos para mejorar este método de inspección complementado con IA, los retos que presento esta parte de la investigación se debieron a que los resultados arrojados por el modelo de aprendizaje profundo (automático) se le suministraron diferentes tipos de imágenes con características diferentes en cuanto a dimensiones, luminosidad, ubicación y tamaño tanto de impactos de rayo como de abolladuras en la estructura de la aeronave y los resultados se vieron perjudicados por manchas estructurales el modelo de IA no era capaz de distinguir bien entre otro tipo de anomalías que pudiese tener la estructura, además también se consideró que faltaba un desarrollo más amplio para que este tipo de inspección pudiese operar en condiciones reales, donde ciertas condiciones como la luminosidad son cambiantes y el entorno puede ser ruidoso, refiriéndose, en este caso, al ruido en los datos e imágenes. Todos estos ajustes son necesarios para alcanzar el objetivo inicial, que consiste en lograr una efectividad del 95 % en la determinación de los niveles de gravedad y otros parámetros necesarios para caracterizar correctamente un daño estructural.

2.2.8. Marco regulatorio de la Federal Aviation Administration (FAA).

Actualmente, la FAA está apoyando el desarrollo de estándares de consenso voluntarios aceptables para asegurar la seguridad de la inteligencia artificial, incluyendo la aplicación y posible extensión de estándares existentes como (SAE ARP/4754), (RTCA/DO-254), (RTCA DO-178C) y (RTCA DO-330). Además, está colaborando en el desarrollo de nuevos estándares específicos para la inteligencia artificial en (SAE G-34) y anticipa que se

puedan requerir estándares adicionales para diferentes tipos de aprendizaje de IA. También se están considerando estándares desarrollados por organizaciones fuera de la aviación, como NIST, para promover la armonización global en la regulación de la seguridad de la IA.

Debido a lo anterior, el presidente Biden emitió la Orden Ejecutiva 14110, titulada "Desarrollo y Uso Seguro, Seguro y Confiable de la Inteligencia Artificial", el 30 de octubre de 2023. Esta orden establece la "máxima urgencia en gobernar el desarrollo y uso de la IA de manera segura y responsable" y subraya la importancia del liderazgo estadounidense en este ámbito para la seguridad, economía y sociedad del país. La orden complementa las Órdenes Ejecutivas 13859 y 13960, que también abordan la importancia de la IA en el contexto de la seguridad económica y nacional.

El Comité Asesor de Investigación, Ingeniería y Desarrollo (REDAC) recomendó que la FAA establezca una hoja de ruta para la inteligencia artificial que aclare cómo se puede utilizar esta tecnología innovadora en aplicaciones aéreas y alivie la incertidumbre en la industria. También sugirió que la FAA desarrolle métodos de aseguramiento de la seguridad específicos para la IA, adaptando enfoques convencionales y creando nuevos métodos que aborden los desafíos únicos de la IA. Además, se enfatizó la necesidad de realizar investigaciones sobre el comportamiento aberrante de los sistemas de IA y la capacitación del personal para garantizar la seguridad en la integración de la IA en la aviación, mediante el seguimiento de puntos clave que garanticen:

- **Colaboración:** Fomentar la cooperación continua para compartir experiencias y evitar actividades redundantes.

- **Preparación de la Fuerza Laboral de la FAA:** Mejorar el conocimiento y la experiencia del personal de la FAA para supervisar la integración de tecnologías de IA.
- **Asegurar la Seguridad de la IA:** Desarrollar métodos de aseguramiento de la seguridad adaptados a los desafíos únicos de la IA.
- **Uso de la IA en el Ciclo de Vida de Seguridad:** Aprovechar la IA para mejorar los procesos de seguridad en la aviación.
- **Investigación en Seguridad Aérea:** Realizar investigaciones enfocadas en métodos para asegurar la seguridad de los sistemas de IA y mejorar la seguridad general de la aviación.
- **Mejora de la Seguridad:** Utilizar IA para identificar y mitigar riesgos potenciales en operaciones aéreas, así como para mejorar la capacitación de pilotos y la gestión del tráfico aéreo.
- **Optimización del Diseño:** Aplicar IA en el diseño de aeronaves y sistemas, facilitando la generación de modelos y la clasificación de datos para mejorar la eficiencia y la seguridad.
- **Análisis de Datos:** Emplear IA para analizar grandes volúmenes de datos operativos, identificando patrones y condiciones que podrían predecir eventos adversos antes de que ocurran.
- **Automatización de Procesos:** Implementar IA en sistemas de control y automatización en aeronaves, mejorando la autonomía y la eficiencia operativa.

La FAA, se encuentra en proceso de investigación, apoyo y acoplamiento para la elaboración de estándares y futura norma que regule y ponga en movimiento todo el tema de la inserción de la inteligencia artificial dentro del sector aeronáutico.

2.2.9. Marco regulatorio de la autoridad de seguridad de aviación civil (CASA).

El marco regulatorio de la autoridad aeronáutica australiana ha regulado y cuenta con avances en el tema de AAM, o movilidad aérea avanzada, se refiere a una variedad de tipos de aeronaves, tanto tripuladas como no tripuladas, que transportan pasajeros y carga. Incluye vehículos como multi-rotor, tilt-wing y tilt-rotor, que ofrecen capacidades de despegue y aterrizaje cortos (STOL) y verticales (VTOL). AAM se divide en dos subcategorías operativas: movilidad aérea urbana (UAM) y movilidad aérea regional (RAM).

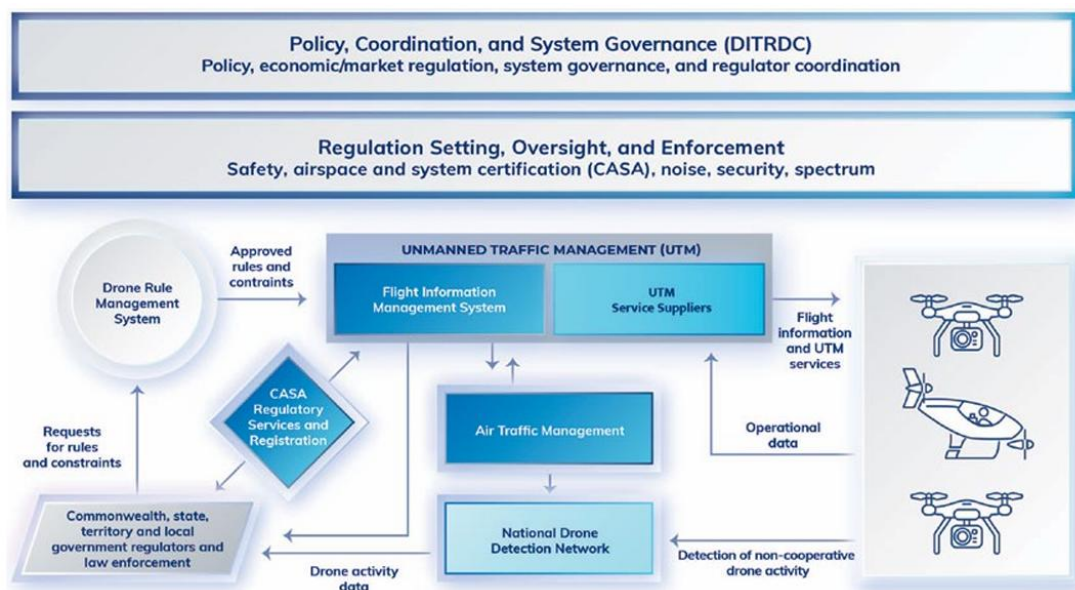
La utilización de drones con control remoto por inteligencia artificial utilizados Australia han sido muy beneficiosos para el abastecimiento de medicamento y/o provisiones en zonas lejanas de difícil de acceso (DITRDCA, 2021) como su aplicación de inteligencia artificial está centrada en drones y vehículos no tripulados.de

El Gobierno Australiano apoyará la adopción de tecnologías emergentes en la aviación a través del establecimiento del programa de Asociaciones de Tecnología de Aviación Emergente (EATP), que fomentará la fabricación y operación de plataformas tecnológicas. Además, se preparará material de orientación sobre las mejores prácticas para integrar estas tecnologías en los procesos de adquisición gubernamentales y se desarrollará un portal web para proporcionar información sobre regulaciones y programas de apoyo.

Este enfoque busca facilitar un entorno operativo que promueva la innovación y el crecimiento en el sector de la aviación. La Ilustración 17 presenta un diagrama que ilustra el enfoque de gestión del mercado para el sector de la aviación. Destaca elementos como la coordinación, la eliminación de trámites innecesarios, la agilidad, la resiliencia y la alineación

internacional, todos orientados a fomentar un entorno competitivo y eficiente. Este enfoque busca garantizar que las regulaciones y políticas apoyen el crecimiento del sector de manera segura y sostenible, considerando las necesidades de todos.

Ilustración 17. Enfoque CASA con tecnología IA.



Fuente: National Emerging Aviation Technologies pag 18.

Las iniciativas clave incluyen el desarrollo del Sistema de Gestión de Reglas de Drones (DRMS) para coordinar las reglas operativas, la creación de un ecosistema de Gestión de Tráfico de Sistemas No Tripulados (UTM) para la integración segura de operaciones y la elaboración de un marco de planificación de infraestructura para la integración de drones y vehículos (EVTOL) en las comunidades. Además, se establecerá el programa de Asociaciones de Tecnología de Aviación Emergente (EATP) para apoyar la fabricación y operación de tecnologías de aviación emergente. También se desarrollará un portal web para proporcionar información sobre procesos regulatorios y programas de apoyo gubernamental.

El portal web llamado "Drone Information Hub", que tiene como objetivo proporcionar información centralizada sobre las regulaciones, procesos y recursos relacionados con el uso de drones. Este hub facilitará el acceso a información relevante para operadores de drones, reguladores y el público en general, promoviendo la transparencia y la comprensión de las normativas.

La creación de este recurso es parte de los esfuerzos del Gobierno Australiano para apoyar la adopción segura y eficiente de tecnologías de drones se esperaba que terminara para el año 2024 todavía no se encuentra disponible para su utilización como se evidencia en la Tabla 1 del documento (DITRDCA, 2021), en la cual se encuentra el plan de implementación de iniciativas clave en Australia para integrar drones y nuevas tecnologías en el sector aeronáutico.

Tabla 1. Cronograma para la implementación de iniciativas clave relacionadas con la gestión de drones y tecnologías emergentes en la aviación.

Initiative	2021	2022	2023	2024
1 Drone Rule Management System	Develop framework	Development and testing	Initial operations	
2 Develop a coordinated approach to enforcement	Develop framework	Enact necessary legislative changes at the Commonwealth, state and territory levels		Complete
3 National Drone Detection Network	Detailed system design	System development and implementation	Initial operations	
4 Infrastructure Planning framework	Develop and agree framework		Complete	
5 UTM Action Plan	Consultation and development	Implementation ongoing		
6 Flight Information Management System	Prototype development	Technology partner selected	Initial operations	
7 Aviation Safety Regulatory Road Map	Develop and consult	Implementation ongoing		
8 Australia's Future Airspace Framework	Develop framework	Implementation of regulatory changes		Complete
9 Noise framework	Develop framework	System development and testing	Initial operations	
10 Privacy guidance	Development	Published	Review	
11 Security measures	Development	Enact legislative changes	Complete	
12 Emerging Aviation Technology Partnerships	Program development and implementation	Partners selected and program operational		Review
13 Best-practice procurement guidance	Development and distribution	Monitoring and evaluation		
14 Drone Information Hub	Development	Complete		

Fuente: Documento National Emerging Aviation Technologies pag 12.

La inteligencia artificial en Australia se está utilizando en aeropuertos mediante la utilización de robots para el servicio y/o atención al pasajero para consultas frecuentes, información relacionada con itinerarios además de su potencial para facilitar al pasajero vías de autogestión. Por ahora, no hay información relacionada con la aplicación de inteligencia

artificial en procesos relacionados con el ámbito aeronáutico ni con el mantenimiento de aeronaves, ya sean de uso comercial o privado (DITRDCA, 2021).

2.3. Mantenimiento aeronáutico e inspección de componentes.

El mantenimiento aeronáutico se basa en la recopilación de métodos de inspección que garanticen el correcto funcionamiento de la aeronave. Es bien sabido que los conceptos fundamentales en el mantenimiento son complejos y sofisticados, ya que son desarrollados con el objetivo de lograr confiabilidad y viabilidad en los diferentes sistemas de operación que establezcan óptimos resultados en su uso y elaboración.

En el campo de aplicación del mantenimiento se identifican varios tipos de discontinuidades con predominio, como lo son, grietas, abolladuras y corrosión, contemplados como daños superficiales con alcances internos. El uso de imágenes refleja la precisión para el diagnóstico de los defectos; sin embargo, se requieren parámetros complejos y de manera sutil para garantizar resultados e indicadores de manera integral.

El mantenimiento actual debe responder a una lógica económica y operativa. Las aerolíneas deben planificar sus intervenciones de manera que minimicen el tiempo de inactividad de sus aeronaves, optimicen el uso de recursos y mantengan altos niveles de disponibilidad. En conjunto, estas lógicas han transformado el mantenimiento aeronáutico en una disciplina compleja, basada en el análisis, la planificación estratégica y la tecnología, cuyo propósito fundamental.

2.3.1. Principios del mantenimiento aeronáutico.

El mantenimiento aeronáutico se basa en establecer patrones de funcionamiento ideal en la mecánica de las aeronaves, donde a partir de un conjunto de procesos técnicos y organizativos se asegura que una aeronave se mantenga en condiciones óptimas de seguridad, funcionamiento y confiabilidad a lo largo de su vida útil. Su base conceptual parte de la necesidad de prevenir fallas que puedan comprometer la operación aérea, garantizando no solo la seguridad de los pasajeros y tripulantes, sino también la eficiencia operativa de las aeronaves.

En sus inicios, el mantenimiento se realizaba bajo una lógica correctiva, es decir, solo se intervenía una aeronave cuando presentaba una falla evidente. Sin embargo, a medida que la aviación evolucionó aumentó de manera progresiva la demanda y se hizo evidente la necesidad de adoptar un enfoque más sistemático y preventivo. Surgieron entonces las primeras estrategias de mantenimiento programado, en las que las revisiones y reemplazos de componentes se realizaban en intervalos definidos, ya sea por tiempo, ciclos de vuelo u horas de operación.

Con el avance de la tecnología y la recopilación de datos sobre el comportamiento de los sistemas aeronáuticos, se comenzó a implementar el mantenimiento basado en condiciones reales de operación. Esta evolución dio lugar a nuevas filosofías de mantenimiento, orientadas a mejorar la seguridad y reducir costos operativos. Una de las más importantes es la lógica de confiabilidad, también conocida como mantenimiento centrado en la confiabilidad (RCM, por sus siglas en inglés), que prioriza las acciones de mantenimiento en función del impacto potencial que tendría una falla sobre la seguridad y la operación de la aeronave.

De la misma manera, se ha desarrollado el mantenimiento basado en condición (CBM), que se apoya en tecnologías de monitoreo continuo para detectar desgastes o irregularidades antes de que ocurran fallas críticas. Este enfoque permite anticipar intervenciones de manera más precisa y eficiente. Además, el mantenimiento aeronáutico está fuertemente influenciado por un marco normativo y regulatorio, ya que está regido por organismos internacionales como la OACI, la FAA y la EASA, que establecen estándares obligatorios para asegurar la uniformidad y la seguridad en la aviación a nivel global.

A lo largo del tiempo, el mantenimiento aeronáutico ha experimentado una evolución significativa, transitando desde enfoques principalmente reactivos, en los que las acciones de mantenimiento se realizaban tras la ocurrencia de fallas, hacia estrategias sistemáticas y analíticas basadas en la confiabilidad de los sistemas. Esta transformación ha sido impulsada tanto por el creciente nivel de complejidad tecnológica de las aeronaves como por la necesidad imperativa de garantizar la seguridad, reducir los costos operativos y mejorar la disponibilidad de las flotas.

En este contexto, han surgido múltiples filosofías y metodologías que, con distintos grados de aplicación, han moldeado los actuales programas de mantenimiento. Esta sección examina dicha evolución y presenta las bases conceptuales que sustentan el mantenimiento aeronáutico moderno.

2.3.2. Evolución histórica y primeras estrategias de mantenimiento.

Desde sus inicios, el mantenimiento aeronáutico ha evolucionado a partir de necesidades prácticas y lecciones aprendidas, muchas veces a raíz de eventos no deseados.

Con el paso del tiempo y el crecimiento de la industria, surgió la necesidad de dejar atrás las acciones correctivas basadas en la experiencia individual, para dar paso a estrategias más organizadas, predecibles y centradas en la seguridad. En esta sección se realiza un recorrido por esa evolución, destacando cómo surgieron y se consolidan los primeros enfoques que dieron estructura al mantenimiento, así como el papel de la regulación en la transición hacia modelos más sistemáticos y confiables.

Mantenimiento Reactivo (Correctivo).

El mantenimiento correctivo, o reactivo, fue la forma más básica de mantener aeronaves, ya que, simplemente se intervenía cuando ocurría una falla. Aunque este enfoque puede ser inevitable en determinadas circunstancias, especialmente frente a fallos imprevistos o no críticos, su uso como estrategia principal es inviable en aviación. Las consecuencias de una falla no anticipada pueden ser catastróficas, no solo en términos de seguridad sino también operativos: desde la inmovilización de aeronaves (Aircraft on Ground - AOG) hasta la interrupción de itinerarios y costos logísticos significativos. Por ello, el mantenimiento reactivo quedó rápidamente relegado como último recurso.

Mantenimiento Preventivo Basado en Tiempos Fijos (Hard Time).

Frente a las limitaciones del enfoque reactivo, surgió el concepto de mantenimiento preventivo basado en tiempos fijos, también conocido como "Hard Time". Esta filosofía asume que los componentes sufren desgaste con el tiempo, por lo que deben ser inspeccionados, reparados o reemplazados a intervalos preestablecidos, definidos en horas de vuelo, ciclos o calendario, independientemente de su condición aparente.

Aunque fue una de las primeras formas de mantenimiento programado y representó un avance, su aplicación indiscriminada llevó a problemas de sobre mantenimiento: piezas en buen estado eran reemplazadas prematuramente, generando altos costos sin necesariamente mejorar la seguridad. Además, se descubrió que no todas las fallas están relacionadas con la edad del componente, lo que cuestionó la validez de esta estrategia como solución universal.

2.3.3. El cambio de paradigma: funcionamiento basado en un enfoque analítico.

Durante la evolución del mantenimiento se refleja la necesidad de adoptar un enfoque analítico que da origen al RCM, ya que durante las décadas de 1960 y 1970, con el crecimiento de la aviación comercial y el aumento de la complejidad técnica de las aeronaves, tanto fabricantes como aerolíneas comenzaron a cuestionar la eficiencia de aplicar el modelo "Hard Time" a todos los sistemas.

En este contexto, se desarrolló un estudio fundamental conducido por F. Stanley Nowlan y Howard F. Heap para United Airlines, el cual analizó patrones de fallas en aeronaves y concluyó que la mayoría de las fallas no están relacionadas con la edad del componente, contradiciendo la lógica sobre la que se basaba el mantenimiento preventivo tradicional. Estas conclusiones sentaron las bases del Mantenimiento Centrado en la Confiabilidad (RCM - Reliability Centered Maintenance), que propone una metodología más lógica y eficiente para la gestión del mantenimiento.

2.3.4. Filosofías fundamentales del mantenimiento aeronáutico moderno.

El mantenimiento aeronáutico ha evolucionado hacia enfoques estratégicos donde la confiabilidad, eficiencia y seguridad son claves. Esta sección presenta dos filosofías

fundamentales: el mantenimiento centrado en la confiabilidad (RCM) y la lógica MSG, que permiten diseñar programas más precisos y adaptados al entorno operativo real de cada aeronave.

Mantenimiento centrado en la confiabilidad (RCM).

RCM es una metodología estructurada para desarrollar programas de mantenimiento que aseguren que los activos físicos sigan cumpliendo sus funciones requeridas dentro de su contexto operativo. Su objetivo no es preservar el componente, sino asegurar la continuidad de su función. El proceso de análisis de RCM incluye:

- Identificación de las funciones del sistema o componente.
- Determinación de las fallas funcionales (cómo puede dejar de cumplir su función).
- Identificación de los modos de falla (causas específicas de esas fallas).
- Análisis de las consecuencias (impacto sobre seguridad, operación, costos, medio ambiente).

Con base en estos análisis, se seleccionan las tareas de mantenimiento más efectivas: preventivas, predictivas, detectivas o, en ciertos casos, ninguna acción programada, si esta resulta ser la opción más lógica. El estándar SAE JA1011 define los criterios para considerar un proceso como verdaderamente alineado con RCM.

La lógica MSG (Maintenance Steering Group) como aplicación de RCM.

El Maintenance Steering Group (MSG) representa la formalización de los principios del Mantenimiento Centrado en la Confiabilidad (RCM) para su aplicación práctica en la

amplia industria aeronáutica. Se trata de una metodología desarrollada inicialmente en colaboración entre fabricantes de aeronaves, aerolíneas y autoridades regulatorias, con el fin de establecer programas de mantenimiento más eficientes, seguros y orientados al contexto real de operación de cada aeronave.

La lógica MSG ha evolucionado a lo largo del tiempo a través de varias generaciones, cada una incorporando mayores niveles de análisis y refinamiento metodológico:

- MSG-1 (1968): Fue desarrollado como respuesta a las necesidades de mantenimiento del Boeing 747. Esta versión introdujo una estructura básica para determinar tareas de mantenimiento basadas en la función de los sistemas, en lugar de hacerlo exclusivamente por tiempo o ciclos. Aunque aún limitada, estableció un primer marco lógico que ya se alejaba del enfoque puramente basado en intervalos fijos.
- MSG-2 (1970): Aplicado en aeronaves como el McDonnell Douglas DC-10 y el Airbus A300, MSG-2 introdujo formalmente el concepto de Condition Monitoring, permitiendo que algunos componentes pudieran ser operados hasta que mostraran signos reales de deterioro, monitoreados mediante parámetros específicos. Esta versión también empezó a distinguir entre tareas obligatorias y tareas condicionales, aportando más flexibilidad al mantenimiento programado.

- MSG-3 (actual): Publicado en 1980 y perfeccionado desde entonces, MSG-3 es la metodología estándar actual para el desarrollo de programas de mantenimiento aeronáutico. Su principal aporte fue la incorporación completa del análisis de confiabilidad como núcleo del proceso, adoptando una lógica de tipo “top-down” (de arriba hacia abajo). Este análisis se realiza comenzando por los sistemas principales, descendiendo progresivamente a subsistemas, componentes e ítems individuales.

El proceso MSG-3 se basa en identificar y analizar tres elementos fundamentales:

1. Función del ítem o sistema.
2. Fallos funcionales (de qué manera puede dejar de cumplir su función).
3. Consecuencias de las fallas (impactos sobre seguridad, operación, medio ambiente, costos).

En función de este análisis, se asignan tareas de mantenimiento específicas clasificadas en tres categorías principales:

- Hard Time (HT): Tareas de reemplazo, restauración o renovación de componentes en intervalos fijos. Se aplican generalmente cuando la degradación es predecible y el riesgo es inaceptable.

- On Condition (OC): Inspecciones o controles periódicos que permiten evaluar el estado del componente. Si se detecta que ya no cumple ciertos criterios establecidos, se sustituye o repara. Es una forma de mantenimiento preventivo basado en condición.
- Condition Monitoring (CM): Estrategia de observación continua que permite detectar cambios o tendencias anormales en el rendimiento de un componente o sistema sin intervención directa. Se utiliza generalmente para elementos cuya falla no afecta directamente la seguridad y que pueden ser monitoreados para tomar decisiones informadas sobre su intervención.

Una característica fundamental de la lógica MSG-3 es que no busca mantener cada componente en perfecto estado, sino asegurar que la aeronave como sistema global pueda operar de manera segura y confiable, minimizando las interrupciones y optimizando el uso de recursos. Además, incorpora criterios económicos y operativos en la toma de decisiones: si una tarea no aporta valor real o mejora en la seguridad/confiabilidad, no se incluye en el programa.

De igual manera, vale la pena destacar que los programas de mantenimiento desarrollados bajo MSG-3 no son estáticos, realmente a lo largo de la vida operativa de una aeronave, estos programas son revisados, reestructurados y optimizados mediante procesos de retroalimentación continua, apoyados por datos reales de operación, reportes de fallas y análisis estadísticos.

2.3.5. Otras filosofías y conceptos de gestión que complementan el mantenimiento aeronáutico.

Aunque el Mantenimiento Centrado en la Confiabilidad (RCM) y su implementación a través del proceso MSG-3 constituyen el núcleo del mantenimiento aeronáutico moderno, existen otras filosofías y metodologías complementarias que aportan enfoques valiosos en términos de monitoreo, mejora continua, optimización de recursos y cultura organizacional. Estas estrategias, en conjunto, permiten alcanzar un sistema de mantenimiento más robusto, eficiente y alineado con los objetivos estratégicos de seguridad y disponibilidad operacional.

Mantenimiento basado en condición (CBM- condition based maintenance).

El Mantenimiento Basado en Condición (CBM) es una estrategia centrada en la evaluación del estado real del activo, con el fin de intervenir solamente cuando hay indicios de degradación funcional o inminencia de falla. A diferencia del mantenimiento preventivo tradicional, que actúa por tiempo o uso, CBM busca realizar el mantenimiento justo antes de que ocurra una falla, optimizando recursos y prolongando la vida útil de los componentes.

En aviación, CBM se implementa mediante inspecciones visuales y técnicas periódicas, análisis de aceites y fluidos, medición de vibraciones, temperatura, presión y monitoreo continuo a través de sensores embarcados y sistemas como HUMS (Health and Usage Monitoring Systems).

CBM está conceptualmente integrado en el enfoque MSG-3 a través de las tareas On Condition (OC) y Condition Monitoring (CM) y representa un paso esencial hacia el

mantenimiento predictivo, donde las decisiones se basan en datos concretos más que en supuestos históricos.

Mantenimiento productivo total (TPM- Total Productive Maintenance).

El TPM es una filosofía que promueve la participación activa de todos los niveles de la organización, especialmente los operadores, en el cuidado, monitoreo y mejora continua de los equipos. En aviación, esta filosofía ha encontrado eco en iniciativas donde los técnicos, tripulaciones y personal de tierra colaboran estrechamente en la prevención de fallas. Los pilares clave del TPM incluyen autonomía del mantenimiento (operadores capacitados realizan tareas básicas), eliminación de las “seis grandes pérdidas” (averías, tiempos de preparación, paradas menores, velocidad reducida, defectos de calidad, pérdidas en el arranque), mejora enfocada en la Efectividad Global del Equipo (OEE) y capacitación continua y empoderamiento del personal.

Aunque TPM no fue concebido específicamente para el entorno aeronáutico, sus principios han sido adaptados en programas de mejora organizacional y cultura de seguridad y tienen gran valor en entornos donde la disciplina operacional y la colaboración proactiva son claves.

Gestión de la calidad total (TQM- Total Quality Management).

TQM es una filosofía de gestión que busca la mejora continua de todos los procesos de una organización, con énfasis en la satisfacción del cliente. En aviación, esta satisfacción se traduce en seguridad operacional, puntualidad, disponibilidad de flota y confiabilidad técnica. Los elementos fundamentales de TQM incluyen enfoque en el cliente (externo e interno),

liderazgo comprometido con la calidad, participación de todos los empleados, toma de decisiones basada en datos, mejora continua como objetivo estructural.

TQM contribuye directamente al entorno del mantenimiento aeronáutico al fomentar una cultura organizacional orientada a la excelencia, donde los errores no se ocultan, sino que se analizan para evitar su recurrencia. También promueve la estandarización y documentación rigurosa, aspectos esenciales en un entorno regulado como el aeronáutico.

Six Sigma.

Six Sigma es una metodología rigurosa, basada en el análisis estadístico de datos, que busca reducir la variabilidad de los procesos y eliminar defectos. Su aplicación al mantenimiento aeronáutico permite optimizar procesos, identificar causas raíz de problemas repetitivos y mejorar la eficiencia operativa. Las aplicaciones en mantenimiento aeronáutico se traducen en optimización de procesos de mantenimiento y logística, reducción de variabilidad en tareas repetitivas, análisis causa-raíz de fallas recurrentes y mejora en la precisión de diagnósticos técnicos.

Six Sigma se complementa perfectamente con TQM y puede integrarse dentro de los sistemas de gestión de calidad (SGC) de aerolíneas, talleres de mantenimiento (MROs) y fabricantes, impulsando la eficiencia, confiabilidad y trazabilidad en cada fase del ciclo de vida de un componente.

Mantenimiento de Clase Mundial (WCM - World Class Maintenance)

El Mantenimiento de Clase Mundial (WCM) no es una metodología rígida, sino una meta aspiracional y estratégica que implica alcanzar los más altos estándares de desempeño en mantenimiento, a través de la integración de múltiples herramientas y filosofías ya mencionadas.

Las características clave del WCM se establecen en aplicación sinérgica de RCM, CBM, TPM, TQM y Six Sigma, cultura organizacional fuerte, orientada a la mejora, seguridad y aprendizaje, Gestión basada en indicadores clave de desempeño (KPIs), uso intensivo de tecnologías avanzadas (IA, IoT, análisis predictivo) y priorización de la confiabilidad operativa con eficiencia de costos.

En el ámbito aeronáutico, aspirar a un modelo WCM implica no solo cumplir con los requisitos regulatorios, sino superarlos de forma proactiva, maximizando la seguridad, minimizando el tiempo de inactividad no planificada y utilizando datos en tiempo real para tomar decisiones informadas.

Cada una de estas filosofías aporta un conjunto de principios y herramientas que, al integrarse con RCM y MSG-3, fortalecen el enfoque global del mantenimiento aeronáutico.

Si bien su origen puede ser diverso, su adopción ha sido posible gracias a su alineación con los objetivos esenciales de la aviación moderna: seguridad, confiabilidad, eficiencia y mejora continua.

2.3.6. Importancia de las inspecciones y tipos de defectos comunes.

Las inspecciones representan un pilar fundamental en el mantenimiento aeronáutico, siendo la herramienta principal para implementar estrategias basadas en el estado de la aeronave, como las tareas "On Condition" y el "Condition Monitoring" (EASA, 2021).

A través de estas inspecciones, se logra detectar de manera temprana signos de degradación, deterioro o fallas iniciales que, si no se atienden oportunamente, podrían derivar en fallas funcionales mayores o incluso incidentes críticos para la seguridad del vuelo. Además, las inspecciones permiten verificar que los componentes y sistemas de la aeronave cumplan con las especificaciones de diseño y los estándares regulatorios, garantizando así un nivel adecuado de seguridad y confiabilidad operacional (ICAO, 2023).

El mantenimiento aeronáutico se organiza mediante un programa estructurado de inspecciones que incluyen distintos niveles de chequeos, comúnmente conocidos como inspecciones de tránsito, A, B, C y D, cada uno con una profundidad y alcance diferentes. Dentro de este esquema, la inspección visual (VI) es el método de inspección más básico, pero también el más utilizado debido a su capacidad para proporcionar una evaluación inmediata y directa del estado superficial de las estructuras y componentes.

La VI forma parte de los Ensayos No Destructivos (NDT), un conjunto de técnicas que permiten evaluar la integridad estructural sin causar daño al material inspeccionado. Otras técnicas NDT incluyen ultrasonido, radiografía, partículas magnéticas y líquidos penetrantes, que complementan la inspección visual y aportan mayor precisión en la detección de defectos internos o superficiales complejos (Hellier, 2013).

Las aeronaves están expuestas a múltiples agentes que pueden causar diferentes tipos de daños, tales como el desgaste mecánico por uso continuo, la fatiga material originada por cargas cíclicas repetitivas, la corrosión producto de la exposición a ambientes corrosivos (humedad, salinidad), daños por impacto ambiental (granizo, rayos, aves) y daños discretos ocasionados por golpes accidentales o herramientas caídas. Además, la sobrecarga estructural derivada de maniobras extremas o mal manejo puede generar deformaciones permanentes o fallas prematuras. El conocimiento de esta amplia variedad de daños es crucial para implementar técnicas de inspección efectivas y diseñar programas de mantenimiento preventivo y predictivo que minimicen riesgos y costos operativos.

Para una mejor comprensión, a continuación, se describen brevemente cada uno de estos defectos:

- **Corrosión:** La corrosión es una reacción electroquímica que deteriora los materiales metálicos, manifestándose en formas como superficial, pitting (picaduras), intergranular, filiforme, galvánica o por exfoliación. Cada tipo de corrosión tiene mecanismos específicos de inicio y propagación, que dependen de factores ambientales y materiales, afectando la resistencia mecánica y longevidad de las estructuras aeronáuticas. (FAA, 2012).
- **Grietas:** Las grietas se originan principalmente por fatiga del material debido a cargas cíclicas repetidas que superan los límites elásticos, concentraciones de esfuerzo en discontinuidades geométricas o propagación de daños existentes, como la corrosión bajo tensión. La detección temprana es crucial, ya que una grieta no controlada puede llevar a fallas catastróficas (FAA, 2018).
- **Abolladuras:** Son deformaciones plásticas localizadas, generalmente causadas por impactos de objetos extraños (Foreign Object Damage, FOD), herramientas o granizo, o incluso por manejo inapropiado en tierra. La gravedad de las abolladuras depende de su tamaño, profundidad y ubicación, ya que pueden afectar la aerodinámica y reducir la resistencia estructural (FAA, 2008).

La inspección visual, pese a ser una técnica simple, enfrenta retos importantes como la dependencia del operador, las condiciones ambientales, la geometría compleja de componentes y la dificultad para detectar defectos pequeños o internos. Por ello, la integración de tecnologías de inteligencia artificial (IA) en los procesos de inspección visual representa una oportunidad para mejorar la precisión, rapidez y consistencia en la detección y clasificación de defectos aeronáuticos. La IA puede ayudar a reducir la subjetividad humana y

aumentar la eficacia del mantenimiento predictivo, contribuyendo a elevar los estándares de seguridad y eficiencia operacional (Zhao et al., 2020).

La selección de la corrosión, las grietas y las abolladuras como defectos visuales prioritarios para el desarrollo del prototipo en esta investigación se fundamenta en su elevada prevalencia, creciente incidencia de desarrollo en las aeronaves actuales y su reconocida relevancia para la integridad estructural y la aeronavegabilidad de los componentes aeronáuticos. Diversas autoridades regulatorias y manuales técnicos de la industria destacan la importancia de la detección temprana y precisa de estos tipos de daños. En particular, la Administración Federal de Aviación (FAA) de los Estados Unidos, mediante su Circular de Asesoramiento AC 43.13-1B, titulada “Acceptable Methods, Techniques, and Practices - Aircraft Inspection and Repair”, dedica amplias secciones a la identificación, evaluación y reparación de dichos defectos.

La corrosión, en sus diversas manifestaciones, es señalada como una amenaza significativa para la durabilidad de los materiales metálicos, siendo su control objeto de un detallado tratamiento en el referido documento (FAA, 2001, cap. 6). De igual modo, las grietas, comúnmente originadas por fatiga o sobrecargas y las abolladuras, habitualmente consecuencia de impactos externos, son consideradas defectos estructurales que requieren una evaluación rigurosa para determinar su impacto sobre la seguridad y operatividad de la aeronave (FAA, 2001, cap. 4). Por consiguiente, el desarrollo de herramientas que faciliten la detección visual de estos daños específicos constituye una aportación significativa y de amplia aplicación práctica en el ámbito del mantenimiento aeronáutico.

3. DESARROLLO DEL PROTOTIPO.

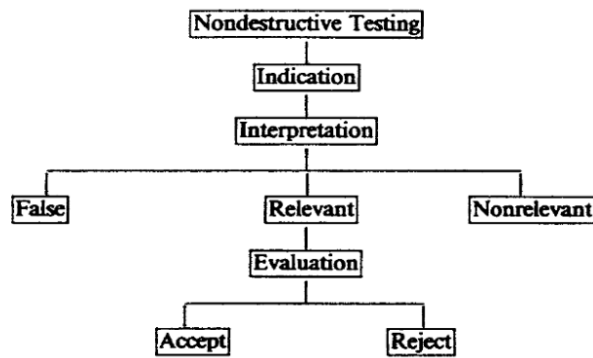
En este capítulo se describe el proceso seguido para el diseño, desarrollo y evaluación del prototipo basado en inteligencia artificial aplicado a la inspección visual de componentes aeronáuticos. Inicialmente, se expone el análisis y selección del método de ensayo no destructivo más adecuado para integrarse con inteligencia artificial. A continuación, se detalla la construcción del modelo utilizando la plataforma Google Teachable Machine, incluyendo la preparación del conjunto de datos, el entrenamiento, las pruebas realizadas y el análisis de resultados. Finalmente, se presenta una discusión general sobre el potencial, impacto y desafíos que implica la incorporación de estas tecnologías en el mantenimiento aeronáutico.

3.1. Selección del método de ensayo no destructivo (NDT) para Integración con IA.

Los métodos más utilizados en aviación para realizar pruebas no destructivas en piezas y componentes incluyen la emisión acústica, pruebas electromagnéticas, radiología gamma y de rayos X, pruebas de fugas, examen con penetrantes líquidos, examen por partículas magnéticas, radiología de neutrones y examen ultrasónico. La finalidad de realizar dichas pruebas es determinar si la condición de una pieza o componente es adecuada para continuar operando con normalidad teniendo en cuenta las condiciones de operación según sea el modelo de la aeronave y su operación, para eso debe seguir un proceso para emitir correctamente un concepto de la pieza.

El siguiente mapa conceptual, presentado en la Ilustración 18, resume los pasos fundamentales que se siguen en la clasificación de discontinuidades en ensayos no destructivos.

Ilustración 18. Mapa conceptual pasos a seguir para la clasificación en NDT.



Fuente: Elaboración propia.

La Tabla 2 muestra los valores estadísticos obtenidos tras aplicar la validación cruzada al modelo.

Tabla 2. Cuadro comparativo de métodos de inspección NDT y su integración con inteligencia artificial.

Método NDT	Funcionamiento	Detección de discontinuidad	Diferencias entre los NDT	Complemento con Inteligencia Artificial
Ultrasonido	Utiliza ondas ultrasónicas de alta frecuencia que se emiten y se reflejan en la pieza para obtener una imagen del interior.	Detecta discontinuidades al medir el tiempo que tardan las ondas ultrasónicas en reflejarse y la intensidad de estas.	Ideal para detectar grietas internas, pero requiere contacto y acoplamiento.	Análisis de patrones complejos en las señales reflejadas para mejorar la precisión y reducir falsos positivos.
Radiografía (Rayos X/Gamma)	Emplea radiación ionizante que atraviesa el material y revela variaciones internas mediante imágenes.	Las discontinuidades generan sombras o anomalías en las imágenes radiográficas.	Brinda imágenes internas detalladas, pero es costoso y requiere	Procesamiento automático de imágenes para segmentar y detectar anomalías con mayor precisión.

			medidas de seguridad.	
Partículas Magnéticas	Se aplica un campo magnético y partículas sobre la superficie; las discontinuidades alteran el campo y agrupan las partículas.	Detecta grietas y fisuras superficiales o cercanas a la superficie.	Rápido y económico, pero sólo útil en materiales ferromagnéticos.	Identificación automatizada de patrones de partículas para reducir el error humano.
Líquidos Penetrantes	Un líquido penetra las grietas superficiales; al aplicar un revelador, se visualizan las discontinuidades.	Muestra grietas abiertas a la superficie que retienen el líquido revelador.	Eficaz en materiales no ferromagnéticos, pero no detecta defectos internos.	Análisis de imágenes del revelador para mejorar la localización y clasificación.
Corrientes de Eddy (Eddy Current)	Campo electromagnético induce corrientes; las	Cambios en impedancia revelan grietas, corrosión o	Ideal para materiales conductores; sensible a	Correlación de variaciones de impedancia con patrones

	discontinuidades alteran su flujo.	alteraciones superficiales.	defectos superficiales.	detectados en tiempo real.
--	---------------------------------------	--------------------------------	----------------------------	-------------------------------

Fuente: Elaboración propia a partir de Aviation Maintenance Technician Handbook – General (2023).

3.1.1. Criterio de selección del (NDT).

Para seleccionar el método de Ensayo No Destructivo (NDT) más adecuado para la integración con un prototipo de Inteligencia Artificial (IA) en el contexto de esta investigación, se han definido los siguientes criterios de selección, los cuales serán ponderados según su relevancia para los objetivos del presente estudio:

- **C1:** Facilidad de obtención de datos para entrenamiento de IA: "Este criterio evalúa la accesibilidad y la simplicidad para recopilar o generar el volumen y la calidad de datos (imágenes, señales, etc.) necesarios para entrenar un modelo de IA de manera efectiva.
- **C2:** Compatibilidad con herramientas de IA accesibles: "Se considera la idoneidad del tipo de datos generados por el método NDT para ser procesados por herramientas de IA de fácil acceso y uso para un proyecto de nivel académico, como Google Teachable Machine para el caso de datos visuales.
- **C3:** Aplicabilidad para defectos estructurales comunes: "Este criterio valora la capacidad del método NDT para detectar eficazmente los defectos de interés para esta investigación por: corrosión, grietas y abolladuras, los cuales son reconocidos por su frecuencia e impacto en la industria aeronáutica.

- **C4:** Viabilidad de implementación en un proyecto académico: "Evalúa la factibilidad de aplicar el método y la herramienta de IA asociada dentro de las limitaciones de tiempo, recursos y alcance de un trabajo de grado de tecnología.

3.1.2. Matriz de decisión y selección del método (NDT).

En la Tabla 3 se presenta la matriz de decisión donde se evalúan los seis métodos NDT más comunes en la industria aeronáutica frente a los criterios definidos anteriormente. A cada criterio se le ha asignado una ponderación (peso) que refleja su importancia para este estudio y cada método NDT ha sido calificado en una escala de 1 (bajo) a 5 (alto) para cada criterio. La asignación del peso a cada criterio se hizo con base en su importancia dentro del contexto del mantenimiento aeronáutico.

Se priorizó la efectividad en la detección debido a su impacto directo en la seguridad operacional. En cuanto al costo, se consideró clave porque influye directamente en la viabilidad de implementar cada método en los entornos reales de mantenimiento. La facilidad de implementación se valoró tomando en cuenta los recursos y la infraestructura generalmente disponibles en talleres aeronáuticos. El tiempo requerido también tuvo un peso importante, ya que afecta los tiempos de respuesta en operaciones. Por otro lado, la capacidad de automatización se incluyó pensando en los avances tecnológicos actuales y la compatibilidad con inteligencia artificial se ponderó especialmente, ya que es un eje central del presente trabajo. Estas ponderaciones se definieron con base en la revisión bibliográfica y en criterios técnicos aplicables al sector.

Tabla 3. Matriz de decisión y selección de método.

Método	C1: Facilidad Datos (Peso: 30%)	C2: Compatibilidad Herramientas IA (Peso: 40%)	C3: Aplicabilidad Defectos (Peso: 20%)	C4: Viabilidad Académic a (Peso: 10%)	Puntaje Ponderado Final
Inspección Visual	5	5	4	5	4.80
Ultrasonido	2	1	4	2	2.00
Partículas Magnéticas	3	1	3	3	2.20
Líquidos Penetrantes	3	1	4	4	2.50
Eddy Current	2	1	3	2	1.80
Radiografía	3	1	5	2	2.50

Fuente: Elaboración propia.

Tras realizar un análisis cuantitativo a partir de la Tabla 3 mediante la matriz de decisión ponderada, se ha evidenciado que la Inspección Visual es el método más viable para los objetivos de esta investigación (Puntaje: 4.80). Su superioridad radica en la máxima compatibilidad con herramientas de IA basadas en imágenes accesibles (C2: 5) y la mayor

facilidad para construir un conjunto de datos de entrenamiento visual (C1: 5), criterios que fueron ponderados con la mayor importancia (40% y 30% respectivamente). Si bien métodos como Líquidos Penetrantes (Puntaje: 3.50) y Partículas Magnéticas (Puntaje: 3.40) también ofrecen resultados visuales compatibles y los Rayos X (Puntaje: 3.20) proporcionan imágenes directas, la complejidad en la preparación de la pieza o la obtención de un conjunto de datos estandarizado y seguro (especialmente para Rayos X) los hace menos viables en el contexto de este proyecto académico. El Ultrasonido (Puntaje: 2.40), aunque potente, presenta desafíos significativos para la compatibilidad directa de sus datos gráficos con herramientas de IA visuales simples como Google Teachable Machine, a menos que se disponga de imágenes C-scan procesadas, cuya obtención es más compleja.

3.1.3. Descripción del método de inspección visual.

Como resultado del análisis presentado en la matriz de decisión, se determinó que el método de inspección visual es el más adecuado para integrarse con un sistema basado en inteligencia artificial. A continuación, se presenta una descripción detallada de dicho método, sus características, alcances y aplicaciones dentro del contexto del mantenimiento aeronáutico.

La Inspección Visual (VI, por sus siglas en inglés, *Visual Inspection*) es la técnica más fundamental y ampliamente utilizada dentro de los Ensayos No Destructivos (NDT) en el mantenimiento aeronáutico, destacándose como un método efectivo y práctico para la detección y evaluación de diversos tipos de discontinuidades, incluyendo la corrosión. Este método consiste en el examen sistemático y cuidadoso de la superficie de un componente o estructura, empleando principalmente la vista para observar directamente el área de interés o

inspeccionarla desde un ángulo de incidencia bajo, con el fin de identificar cualquier anomalía (FAA, 2023).

Principios y técnicas del método.

El principio fundamental de la inspección visual radica en la detección de cualquier alteración visible en las características superficiales esperadas de un componente. El sentido del tacto también puede complementar la inspección visual, siendo un método efectivo para la detección de corrosión oculta o en etapas avanzadas de desarrollo. La efectividad de la inspección visual puede ser considerablemente mejorada mediante el uso de herramientas auxiliares como una fuente de luz brillante, lupas y espejos. Otras herramientas incluyen micrómetros ópticos y medidores de profundidad.

En situaciones donde las áreas de inspección están obstruidas o son de difícil acceso visual directo, es imperativo obtener un acceso adecuado. Esto puede implicar la remoción de paneles, la limpieza del área y la eliminación de selladores o pintura suelta. Para la observación de estas áreas, herramientas como espejos, boroscopios y sistemas de fibra óptica resultan particularmente útiles (FAA, 2023).

Alcance y limitaciones.

Aunque algunos defectos son tan aparentes que incluso no se requieren métodos de inspección adicionales, la falta de fallas visuales no significa automáticamente que la inspección más profunda no es necesaria. Es esencial tener en cuenta que la inspección visual, incluso con la ayuda de una lupa, tiene desde el principio una limitación intrínseca para detectar discontinuidades superficiales, ya que algunas fallas pueden estar dentro del subsuelo

o ser demasiado pequeñas para ser visibles para la percepción humana. Por lo tanto, la inspección visual a menudo sirve como un primer paso, que puede complementarse con otros métodos NDT más sofisticados cuando se sospecha la presencia de daños no visibles o se requiere una caracterización más detallada (FAA, 2023).

Ventajas del método:

- **Económico:** Generalmente, es el método NDT menos costoso, ya que en su forma más básica no requiere equipos complejos ni consumibles costosos.
- **Rápido y directo:** Permite obtener resultados inmediatos.
- **Versátil:** Aplicable a una amplia gama de materiales, componentes y tipos de defectos superficiales.
- **Portátil:** Las herramientas básicas son fáciles de transportar y utilizar en diversas ubicaciones.

Limitaciones del Método:

- **Detecta solo defectos superficiales:** No puede identificar discontinuidades internas o subsuperficiales a menos que estas se manifiesten en la superficie.
- **Dependencia del inspector:** La fiabilidad de los resultados está fuertemente ligada a la capacitación, experiencia, condición física (especialmente la vista) y atención al detalle del inspector.
- **Condiciones de inspección:** La calidad de la iluminación, el ángulo de visión, la limpieza de la superficie y el acceso a la zona inspeccionada son críticos y pueden limitar la efectividad.

- **Interpretación:** Diferenciar entre una indicación relevante y una no relevante (ej. un rayón superficial vs. una grieta incipiente) requiere criterio y experiencia.

Aplicaciones típicas en mantenimiento aeronáutico.

La inspección visual es una tarea omnipresente en el mantenimiento aeronáutico, utilizada en:

- Inspecciones programadas (chequeos A, B, C, D) y no programadas.
- Detección de corrosión superficial en estructuras y componentes.
- Identificación de grietas visibles en el fuselaje, alas, superficies de control, tren de aterrizaje y componentes del motor.
- Evaluación de abolladuras, deformaciones o daños por impacto (ej. impacto de ave, daños en tierra).
- Verificación del estado de recubrimientos protectores (pintura, selladores).
- Inspección de la seguridad y el estado de fijaciones (remaches, tornillos, pernos).
- Detección de fugas de fluidos (hidráulico, combustible, aceite).

Herramientas de apoyo comunes

Para mejorar la capacidad de detección, la inspección visual a menudo se complementa con herramientas como:

- Lupas o magnificadores de diferentes aumentos.
- Espejos (planos y angulados) para inspeccionar áreas de difícil acceso.

- Boroscopios y videoscopios para examinar el interior de cavidades, motores o estructuras sin necesidad de desmontaje extensivo.
- Fuentes de luz de alta intensidad y linternas especializadas.
- Cámaras fotográficas y de video para documentar las observaciones, lo cual es un precursor natural para la aplicación de técnicas de Inteligencia Artificial en el análisis de estas imágenes.

3.2. Aplicación y evaluación del prototipo de IA para inspección visual con (Google Teachable Machine).

En el presente capítulo se detalla el proceso de aplicación y evaluación del prototipo de Inteligencia Artificial (IA) desarrollado con la herramienta Google Teachable Machine. Este prototipo fue diseñado para la clasificación de defectos visuales en componentes aeronáuticos, basándose en la metodología experimental y el conjunto de datos descritos a continuación. Se abordarán los pasos seguidos para el entrenamiento del modelo, la configuración de sus parámetros y la preparación para la posterior evaluación de su desempeño.

3.2.1. Descripción del prototipo y metodología experimental.

La herramienta seleccionada para el desarrollo del prototipo es Google Teachable Machine. Esta es una plataforma que permite crear modelos de aprendizaje automático (machine learning) de manera simplificada, sin necesidad de programación avanzada. Es capaz de clasificar imágenes, sonidos y poses. La razón por la cual fue seleccionada para esta prueba experimental fue su facilidad de uso, eficacia y sencilla interpretación, por lo tanto, era un candidato ideal para llevar a cabo este proyecto.

Este caso de estudio se centró en la detección y clasificación de defectos comunes, como lo son abolladuras, grietas y corrosión. La selección de estos defectos se basa en su alta frecuencia y relevancia, como se indicó anteriormente en el Marco Teórico (ver sección 2.3.2). El objetivo fue entrenar el modelo de IA para que distinga entre estas cuatro clases (incluyendo una categoría para componentes sin defecto aparente) a partir de imágenes, utilizando ejemplos visuales lo más claros posibles para una mejor interpretación por parte del prototipo.

Recopilación y preparación del conjunto de datos (Dataset):

- **Fuente de las imágenes:** El conjunto de datos para el entrenamiento y prueba del modelo se construyó a partir de diversas fuentes. Una cantidad significativa de estas imágenes, especialmente para asegurar la claridad, calidad y cantidad necesaria para el entrenamiento inicial, se generó mediante herramientas de inteligencia artificial generativa. También se recopilaron imágenes de manuales técnicos aeronáuticos (ej. FAA, Aerocivil), foros especializados de mantenimiento y bases de datos públicas de imágenes.
- **Número total de imágenes y distribución por clase:** Se recopilaron un total de 116 imágenes, conjunto utilizado para para el (dataset) y entrenamiento del prototipo. La selección de esta cantidad fue basada en la disponibilidad de ejemplos visuales claros y verificables obtenidos de las fuentes consultadas, teniendo en cuenta el balance entre la viabilidad de la recolección y la necesidad de una cantidad considerable de datos para una prueba de concepto.
 - Abolladuras: 25 imágenes.

- Corrosión: 25 imágenes.
- Grietas: 25 imágenes.
- Sin Defecto: 25 imágenes.

Lo cual genera un total de 100 imágenes por cada clase. Adicionalmente, se conformó un conjunto independiente de 16 imágenes con diagnóstico técnico verificado (provenientes de reportes de investigación de accidentes de la DIACC-UAEAC) este conjunto se reservó exclusivamente para la evaluación final y comparativa del prototipo, asegurando que el modelo fuera probado con datos que no había visto durante su entrenamiento.

Independientemente de que el volumen de imágenes sea suficiente para el alcance académico de una prueba de concepto, se tiene presente que una mayor precisión y eficacia del modelo requeriría ampliar significativamente el conjunto de datos. Para lograrlo, sería recomendable recopilar por lo menos varias centenas de imágenes por clase, incluyendo una mayor diversidad de condiciones (ángulos, iluminación, variaciones de severidad en los daños) y aplicar técnicas de aumento de datos (data augmentation), lo cual permitiría mejorar la capacidad de generalización del modelo y reducir la sensibilidad a variaciones no relevantes.

- **Criterios de selección de imágenes:** Para el entrenamiento del prototipo se utilizaron imágenes que mostraran el defecto de la manera más evidente posible. También se intentó variar, tanto como fue factible, los tipos de componentes y perspectivas para que el modelo tuviera un margen más alto de reconocimiento. Para las imágenes que se utilizarían como prueba del funcionamiento del prototipo, se consideraron aquellas que ya contaban con un diagnóstico emitido por un taller o entidad autorizada.

- **Generalización de defectos:** Es importante clarificar que existe una gran cantidad de variaciones en los defectos mencionados (abolladuras, grietas, corrosión), cuyo entrenamiento detallado sería ideal para su detección. Sin embargo, debido a la complejidad en la obtención de un volumen suficiente de datos para cada variación específica y con el objetivo de lograr la finalización del prototipo de la mejor manera posible, se optó por generalizar cada uno de estos defectos en una categoría única. Este enfoque permitió la obtención de una mayor cantidad de imágenes o documentación necesaria para el entrenamiento del prototipo.
- **División del conjunto de datos:** Inicialmente, se había planteado tomar las imágenes de prueba de un porcentaje (al menos el 10-20%) del total del conjunto de datos recopilado. No obstante, en el transcurso de la obtención e implementación del prototipo, se optó por conseguir estas imágenes de prueba específicas de forma independiente, contando ya con un diagnóstico establecido por un taller o entidad competente. De esta manera, se busca realizar una comparativa más directa sobre la eficiencia potencial de este prototipo.

3.2.2. Proceso de entrenamiento del modelo en (Google Teachable Machine).

Una vez recopilado el conjunto de datos (dataset), se procedió al entrenamiento del prototipo o modelo de clasificación por medio de la plataforma Google Teachable Machine, Herramienta en línea que permite la construcción de modelos de aprendizaje automático de forma práctica y accesible. Esta herramienta fue seleccionada debido a su facilidad de uso, compatibilidad con formatos de imagen y su idoneidad para llevar a cabo este prototipo. A continuación, se describen los pasos seguidos en la configuración, carga del conjunto de datos,

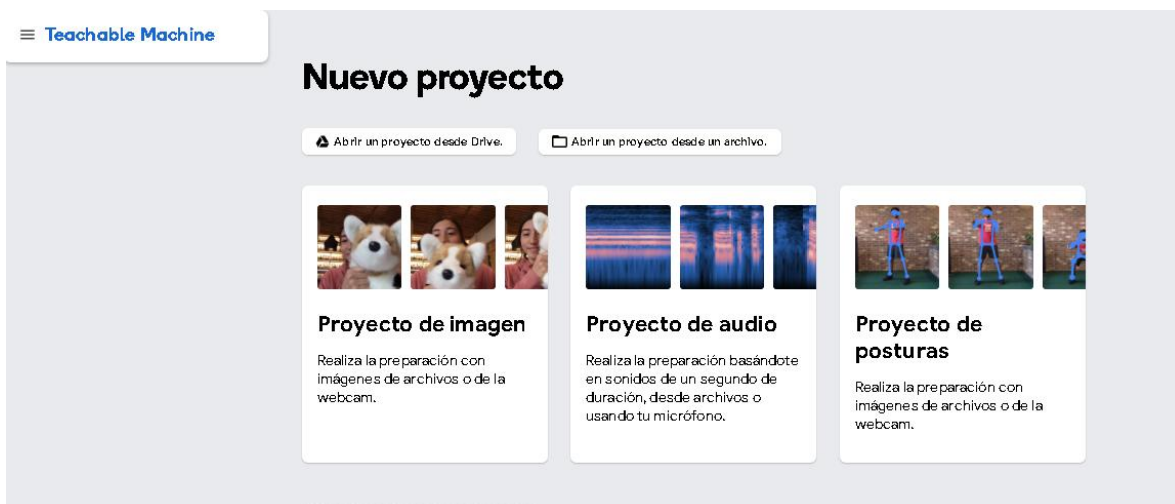
definición de clases y parámetros de entrenamiento, los cuales permitieron un modelo funcional orientado a la clasificación de imágenes.

Descripción de los pasos seguidos en la plataforma:

- **Selección del tipo de proyecto:** El primer paso en la plataforma Google Teachable Machine fue la selección del tipo de proyecto. La herramienta ofrece opciones para modelos basados en imágenes, audio o posturas corporales. Para este estudio, se seleccionó 'Proyecto de Imagen'.

La Ilustración 19 evidencia la interfaz inicial de Google Teachable Machine, donde se elige el tipo de proyecto a desarrollar. En este caso, se seleccionó la opción basada en imágenes.

Ilustración 19. Interfaz de selección de proyecto en la plataforma Google Teachable Machine.



Fuente: Google Teachable Machine. <https://teachablemachine.withgoogle.com/train>.

- **Selección y creación del proyecto de imágenes:** Dentro de la opción Proyecto de Imagen, Teachable Machine ofrece dos tipos de modelos: Modelo de imagen estándar y Modelo de imagen insertada. Se optó por el modelo de imagen estándar debido a su adecuación para tareas de clasificación general de imágenes y por la simplicidad requerida para la detección en este prototipo. El 'Modelo de imagen insertada' está optimizado para su uso en microcontroladores y dispositivos con recursos limitados, lo cual no era el enfoque principal de esta fase. La Ilustración 20 muestra las opciones disponibles para configurar el tipo de modelo en un proyecto de clasificación de imágenes dentro de la plataforma Teachable Machine. En este caso, se eligió el modelo estándar por su enfoque en tareas generales de clasificación, sin requerimientos de optimización para hardware específico.

Ilustración 20. Selección y creación del proyecto de imágenes para el modelo de IA.

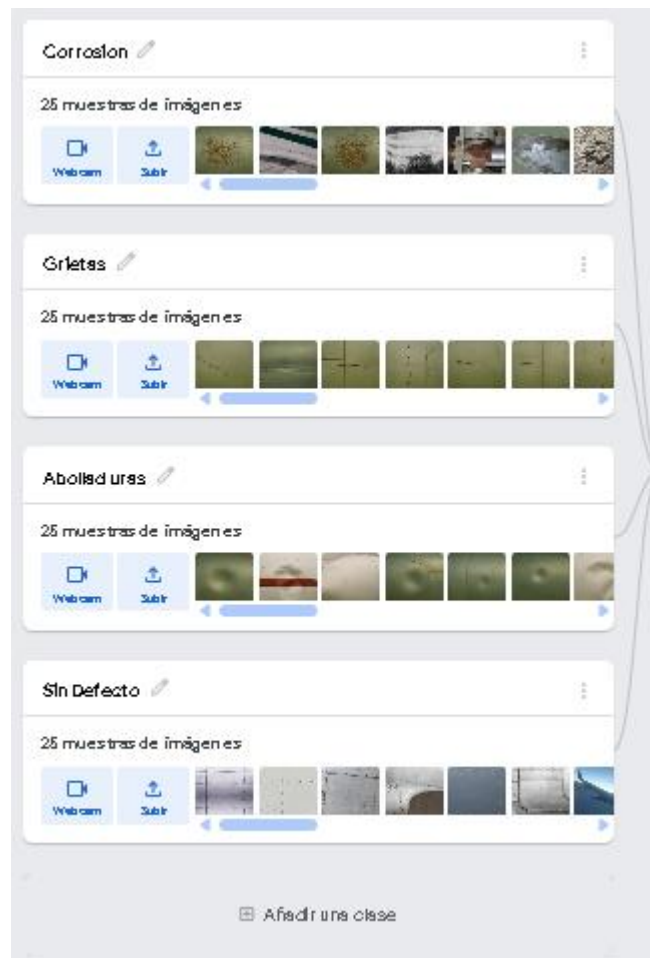


Fuente: Google Teachable Machine. <https://teachablemachine.withgoogle.com/train>.

- **Definición de las clases:** Posteriormente, se procedió a la definición de las clases para la clasificación. Se crearon cuatro categorías distintas: 'Corrosión', 'Grieta', 'Abolladura' y 'Sin Defecto'. La plataforma permite nombrar cada clase y luego cargar las imágenes correspondientes, ya sea subiendo archivos previamente guardados o capturando imágenes en tiempo real con una cámara web. Se requiere un mínimo de dos clases por proyecto.

La Ilustración 21 representa la interfaz de Teachable Machine utilizada para definir las clases del modelo de inteligencia artificial. Cada clase fue creada y nombrada de forma personalizada según los tipos de discontinuidad a identificar.

Ilustración 21. Proceso de definición de clases para el modelo de IA.



Fuente: Google Teachable Machine. <https://teachablemachine.withgoogle.com/train>.

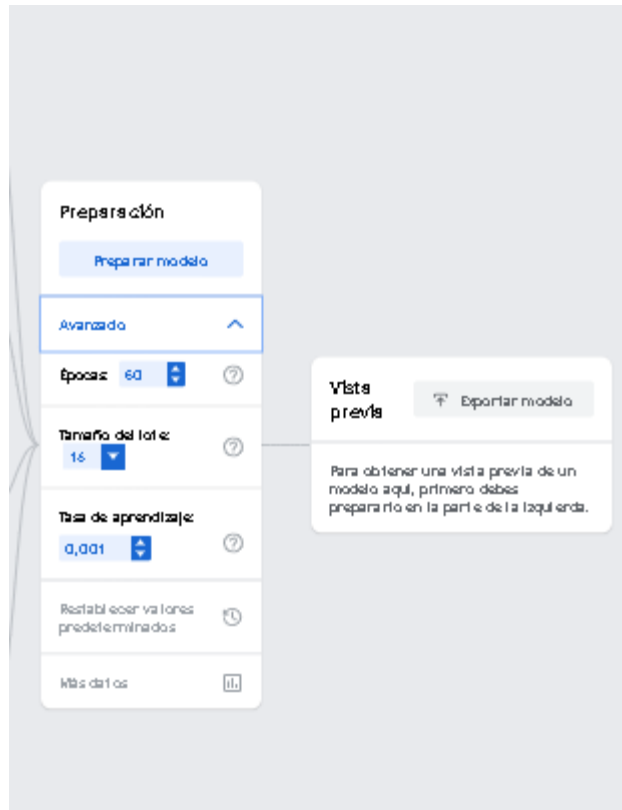
- **Carga de las imágenes de entrenamiento para cada clase:** Para cada una de las cuatro clases definidas, se cargaron las imágenes de entrenamiento recopiladas (como se detalló en la sección 3.2.1). Una vez completada la carga de todas las imágenes, se procedió a la fase de preparación y entrenamiento del modelo haciendo clic en el botón 'Preparar modelo' (o 'Train Model'). Teachable Machine permite ajustar algunos

parámetros avanzados del entrenamiento, los cuales para este prototipo se configuraron de la siguiente manera:

- **Épocas (Epochs):** Una época representa una pasada completa del algoritmo de entrenamiento a través de todo el conjunto de datos de entrenamiento. El modelo aprende y ajusta sus parámetros internos con cada época. Para este prototipo, se utilizó el valor predeterminado por el sistema de **50 épocas**.
- **Tamaño del lote (Batch Size):** Este parámetro define el número de muestras de entrenamiento que se procesan antes de que los pesos internos del modelo se actualicen. Por ejemplo, si el conjunto de entrenamiento tiene 100 imágenes y el tamaño del lote es 20, se necesitarán 5 lotes (iteraciones) para completar una época. En este prototipo, se mantuvo el tamaño de lote predeterminado por Teachable Machine, que es de **16**.
- **Tasa de aprendizaje (Learning Rate):** La tasa de aprendizaje es un hiperparámetro que controla la magnitud de los ajustes realizados a los pesos del modelo durante el proceso de optimización en cada iteración. Un valor demasiado alto puede hacer que el modelo no converja, mientras que uno muy bajo puede ralentizar excesivamente el entrenamiento. Para este proyecto, se utilizó la tasa de aprendizaje predeterminada por el sistema, establecida en 0.001.

La Ilustración 22 muestra el entorno visual en el que se cargaron las imágenes de entrenamiento para cada clase y donde se ajustaron parámetros como el número de épocas, el tamaño del lote y la tasa de aprendizaje para iniciar el entrenamiento del modelo.

Ilustración 22. Proceso de preparación del modelo de IA Google Teachable Machine.

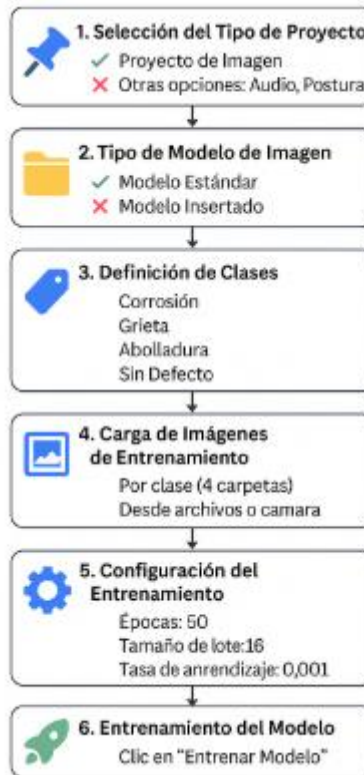


Fuente: <https://teachablemachine.withgoogle.com/train>.

La Ilustración 23 esquematiza el proceso completo de entrenamiento del modelo de IA en Teachable Machine, desde la preparación del conjunto de datos hasta la finalización del aprendizaje supervisado.

Ilustración 23. Proceso general de entrenamiento del modelo de IA en la plataforma Google

Teachable Machine.



Fuente: Elaboración propia.

3.2.3. Pruebas y resultados del prototipo.

En esta sección se presentan las pruebas realizadas al prototipo entrenado para evaluar su desempeño en diferentes escenarios. El proceso incluyó la validación interna del modelo utilizando los datos de entrenamiento, pruebas con imágenes externas no vistas y el análisis de métricas de precisión por clase. Estos resultados permiten identificar fortalezas, limitaciones y posibles ajustes requeridos en el sistema propuesto, proporcionando una base objetiva para

valorar su aplicabilidad dentro de procesos de inspección visual en mantenimiento aeronáutico.

Metodología de prueba y validación interna del modelo.

La validación interna del modelo es un proceso automático que realiza la propia plataforma Google Teachable Machine durante la etapa de entrenamiento. Esta validación permite obtener métricas de precisión por clase, con base en los datos suministrados, sin necesidad de intervención o ajuste manual. A través de esta funcionalidad, se puede observar cómo el modelo clasifica las imágenes dentro de cada categoría y qué nivel de acierto alcanza, permitiendo un análisis preliminar sobre su desempeño y consistencia.

Análisis de los resultados de la validación Interna.

A partir de la Ilustración 24, que muestra la matriz de confusiones y la precisión por clase obtenida durante la validación interna de Google Teachable Machine con un subconjunto de las imágenes de entrenamiento (aproximadamente el 15%, es decir, 16 imágenes en este caso), se observa lo siguiente:

Ilustración 24. Validación interna, modelo de Google Teachable.



Fuente: Google Teachable Machine durante la fase entrenamiento y previsualización del modelo. <https://teachablemachine.withgoogle.com/>.

Matriz de confusiones (Validación Interna).

En esta sección se presentan los resultados obtenidos durante la validación interna del modelo de inteligencia artificial, utilizando una matriz de confusión para evaluar su desempeño. A partir de estos datos, se analiza la precisión del modelo al clasificar distintos tipos de discontinuidades y se calculan métricas clave como la tasa de falsos positivos (FPR) por clase, aportando una visión detallada de su efectividad.

Análisis detallado de la matriz de confusión (Validación Interna).

- Para la clase "**Corrosión**": El modelo clasificó correctamente las 4 muestras como "Corrosión".
- Para la clase "**Grietas**": 3 de las 4 muestras fueron clasificadas correctamente; sin embargo, 1 muestra real de "Grietas" fue incorrectamente clasificada como "Corrosión".
- Para la clase "**Abolladuras**": 2 de las 4 muestras fueron clasificadas correctamente. Una muestra de "Abolladuras" fue incorrectamente clasificada como "Grieta" y otra como "Sin Defecto".
- Para la clase "**Sin Defecto**": Solo 1 de las 4 muestras fue clasificada correctamente. Dos muestras de "Sin Defecto" fueron incorrectamente clasificadas como "Grieta" y una como "Abolladura".

Cálculo de la tasa de falsospositivos (FPR) por Clase (Validación Interna).

A partir de la matriz de confusiones obtenida de la (Ilustración 24), se calculó la Tasa de Falsos Positivos (FPR) para cada clase. La fórmula general utilizada para el FPR es:

Formula: $FPR = FP + TNFP$

Donde:

- FP (Falsos Positivos) representa el número de instancias que fueron incorrectamente clasificadas como pertenecientes a la clase de interés.

- TN (Verdaderos Negativos) representa el número de instancias que fueron correctamente clasificadas como no pertenecientes a la clase de interés.
- (FP + TN) es el número total de instancias que realmente no pertenecen a la clase de interés.

FPR para la clase "Corrosión":

- FP (Predicho "Corrosión" cuando NO era Corrosión): 1 (era "Grietas") + 0 (era "Abolladuras") + 0 (era "Sin Defecto") = 1
- Total de imágenes que NO eran "Corrosión": 4 (Grietas) + 4 (Abolladuras) + 4 (Sin Defecto) = 12
- TN (Predicho correctamente como NO "Corrosión"):
 - De las "Grietas" reales: 3 (Predicho "Grietas") + 0 (Predicho "Abolladuras") + 0 (Predicho "Sin Defecto") = 3
 - De las "Abolladuras" reales: 1 (Predicho "Grietas") + 2 (Predicho "Abolladuras") + 1 (Predicho "Sin Defecto") = 4
 - De las "Sin Defecto" reales: 2 (Predicho "Grietas") + 1 (Predicho "Abolladuras") + 1 (Predicho "Sin Defecto") = 4
 - Total TN = 3 + 4 + 4 = 11
- FPR Corrosión = $1 / (1 + 11) = 1 / 12 = 0.0833... \approx 8.33\%$

FPR para la clase "Grietas":

- FP (Predicho "Grietas" cuando NO era Grieta): 0 (era "Corrosión") + 1 (era "Abolladuras") + 2 (era "Sin Defecto") = 3

- Total de imágenes que NO eran "Grieta": 4 (Corrosión) + 4 (Abolladuras) + 4 (Sin Defecto) = 12
- TN (Predicho correctamente como NO "Grieta"):
 - De las "Corrosión" reales: 4 (Predicho "Corrosión") + 0 (Predicho "Abolladuras") + 0 (Predicho "Sin Defecto") = 4
 - De las "Abolladuras" reales: 0 (Predicho "Corrosión") + 2 (Predicho "Abolladuras") + 1 (Predicho "Sin Defecto") = 3
 - De las "Sin Defecto" reales: 0 (Predicho "Corrosión") + 1 (Predicho "Abolladuras") + 1 (Predicho "Sin Defecto") = 2
 - Total TN = 4 + 3 + 2 = 9
- FPR Grieta = $3 / (3 + 9) = 3 / 12 = 0.25 = 25.00\%$

FPR para la clase "Abolladuras":

- FP (Predicho "Abolladuras" cuando NO era Abolladura): 0 (era "Corrosión") + 0 (era "Grietas") + 1 (era "Sin Defecto") = 1
- Total de imágenes que NO eran "Abolladura": 4 (Corrosión) + 4 (Grietas) + 4 (Sin Defecto) = 12
- TN (Predicho correctamente como NO "Abolladura"):
 - De las "Corrosión" reales: 4 (Predicho "Corrosión") + 0 (Predicho "Grietas") + 0 (Predicho "Sin Defecto") = 4
 - De las "Grietas" reales: 1 (Predicho "Corrosión") + 3 (Predicho "Grietas") + 0 (Predicho "Sin Defecto") = 4

- De las "Sin Defecto" reales: 0 (Predicho "Corrosión") + 2 (Predicho "Grietas") + 1 (Predicho "Sin Defecto") = 3
- Total TN = 4 + 4 + 3 = 11

- FPR Abolladura = $1 / (1 + 11) = 1 / 12 = 0.0833... \approx 8.33\%$

FPR para la clase "Sin Defecto":

- FP (Predicho "Sin Defecto" cuando SÍ tenía defecto): 0 (era "Corrosión") + 0 (era "Grietas") + 1 (era "Abolladura") = 1
- Total de imágenes que SÍ tenían defecto (es decir, que NO eran "Sin Defecto"): 4 (Corrosión) + 4 (Grietas) + 4 (Abolladura) = 12
- TN (Predicho correctamente como NO "Sin Defecto" [o sea, predicho como algún defecto cuando realmente tenía defecto]):
 - De las "Corrosión" reales: 4 (Predicho "Corrosión") + 0 (Predicho "Grietas") + 0 (Predicho "Abolladuras") = 4
 - De las "Grietas" reales: 1 (Predicho "Corrosión") + 3 (Predicho "Grietas") + 0 (Predicho "Abolladuras") = 4
 - De las "Abolladura" reales: 0 (Predicho "Corrosión") + 1 (Predicho "Grietas") + 2 (Predicho "Abolladuras") = 3
 - Total TN = 4 + 4 + 3 = 11
- FPR Sin Defecto = $1 / (1 + 11) = 1 / 12 = 0.0833... \approx 8.33\%$

Indicadores de desempeño (Validación Interna): Con base en la matriz de confusiones anterior, se calcularon los siguientes indicadores de desempeño para la validación interna, los cuales se presentan en la Tabla 4, la cual contiene con el resumen de todos los indicadores de desempeño de la validación interna, incluyendo estos valores de FPR.

Tabla 4. Indicadores de Desempeño del Prototipo según Validación Interna de Google Teachable Machine (N=16).

Indicador/Clase	Resultado
Precisión General (Accuracy)	62.5%
Tasa de Verdaderos Positivos (Recall):	
Corrosión	100%
Grietas	75%
Abolladuras	50%
Sin Defecto	25%
Tasa de Falsos Positivos (FPR):	
Corrosión	8.33%

Grietas	25.00%
Abolladuras	8.33%
Sin Defecto	8.33%

Fuente: Google Teachable Machine. <https://teachablemachine.withgoogle.com/>.

Nota: Como se discutió, para N=4 muestras por clase en la validación, la "Precisión por Clase" que da Teachable Machine es igual al Recall. Se a incluido ambos para claridad). Cálculo de Precisión General: (4+3+2+1) aciertos / 16 muestras totales = $10/16 = 62.5\%$.

Evaluación con conjunto de prueba externo verificado.

Adicionalmente a la validación interna proporcionada por la plataforma, se evaluó el prototipo utilizando un conjunto de prueba externo e independiente. Este conjunto estuvo compuesto por 16 imágenes (4 por cada una de las clases definidas: Corrosión, Grietas, Abolladuras y Sin Defecto), las cuales no fueron empleadas durante la fase de entrenamiento del modelo. Cada una de estas imágenes contaba con un diagnóstico técnico previamente verificado sobre la presencia y tipo de defecto o su ausencia, obtenido de la DIACC-UAEAC (Dirección Técnica de Investigación de Accidentes).

A continuación, se evidencia en la Ilustración 25 un ejemplo de salida generada por el prototipo durante la evaluación del conjunto de prueba externo. En la imagen se puede observar el análisis visual realizado por el modelo y la probabilidad asignada a cada una de las clases definidas.

Ilustración 25. Ejemplo de salida del modelo IA sobre imagen de prueba externa.



Fuente. Google Teachable Machine. <https://teachablemachine.withgoogle.com/>.

Los resultados de la clasificación de estas 16 imágenes por el modelo de Google Teachable Machine se presentan en la Tabla 5.

Tabla 5.Resultados de Clasificación del Prototipo sobre el Conjunto de Prueba Externo
Verificado (N=16).

ID Imagen de Prueba	Clase Real (Verificada)	Clase Predicha por IA	¿Correcto? (Sí/No)
Corrosion prueba 1	Corrosión	Corrosión	Sí
Corrosion prueba 2	Corrosión	Corrosión	Sí
Corrosion prueba 3	Corrosión	Grietas	No
Corrosion prueba 4	Corrosión	Corrosión	Sí
Grieta prueba 1	Grieta	Corrosión	No
Grieta prueba 2	Grieta	Corrosión	No
Grieta prueba 3	Grieta	Sin Defecto	No
Grieta prueba 4	Grieta	Grietas	Sí
Abolladura prueba 1	Abolladura	Sin Defecto	No
Abolladura prueba 2	Abolladura	Sin Defecto	No
Abolladura prueba 3	Abolladura	Sin Defecto	No
Abolladura prueba 4	Abolladura	Corrosión	No
Sin defecto prueba 1	Sin Defecto	Sin Defecto	Sí
Sin defecto prueba 2	Sin Defecto	Sin Defecto	Sí
Sin defecto prueba 3	Sin Defecto	Abolladuras	No

Sin defecto prueba 4	Sin Defecto	Grietas	No
----------------------	-------------	---------	----

Fuente: Elaboración propia a partir de pruebas con el prototipo.

Con base en los resultados presentados en la Tabla anterior, se construyó la siguiente matriz de confusiones ubicado en la Tabla 6.

Tabla 6. Matriz de Confusiones del Prototipo sobre el Conjunto de Prueba Externo Verificado (N=16).

	Predicho: Corrosión	Predicho: Grieta	Predicho: Abolladura	Predicho: Sin Defecto	Total Real
Real: Corrosión	3	1	0	0	4
Real: Grieta	2	1	0	1	4
Real: Abolladura	1	0	0	3	4
Real: Sin Defecto	0	1	1	2	4

Fuente: Elaboración propia a partir de los resultados.

De la matriz de confusiones para el conjunto de prueba externo Tabla 6 se observa lo siguiente:

- Para la clase "**Corrosión**": 3 de las 4 muestras reales fueron clasificadas correctamente como "Corrosión", mientras que 1 muestra fue incorrectamente clasificada como "Grietas".
- Para la clase "**Grietas**": Solo 1 de las 4 muestras reales fue clasificada correctamente como "Grietas". Dos muestras fueron incorrectamente clasificadas como "Corrosión" y 1 muestra fue incorrectamente clasificada como "Sin Defecto".
- Para la clase "**Abolladuras**": Ninguna de las 4 muestras reales fue clasificada correctamente como "Abolladuras". Una muestra fue incorrectamente clasificada como "Corrosión" y los 3 restantes fueron incorrectamente clasificadas como "Sin Defecto".
- Para la clase "**Sin Defecto**": 2 de las 4 muestras reales fueron clasificadas correctamente como "Sin Defecto". Una muestra fue incorrectamente clasificada como "Grietas" y la otra como "Abolladuras".

Cálculo detallado de la tasa de falsos positivos (FPR) por clase.

Se presenta el cálculo de la Tasa de Falsos Positivos (FPR) para cada una de las clases definidas, basado en los resultados de la Tabla 6 (Matriz de Confusiones del Conjunto de Prueba Externo). La fórmula general utilizada para el FPR es:

$$FPR = \frac{FP}{FP + TNFP}$$

Donde:

- FP (Falsos Positivos) representa el número de instancias que fueron incorrectamente clasificadas como pertenecientes a la clase de interés.

- TN (Verdaderos Negativos) representa el número de instancias que fueron correctamente clasificadas como no pertenecientes a la clase de interés.
- (FP + TN) es el número total de instancias que realmente no pertenecen a la clase de interés.

FPR para la clase "Corrosión":

- FP (Predicho "Corrosión" cuando NO era Corrosión): 2 (eran "Grieta") + 1 (era "Abolladura") + 0 (era "Sin Defecto") = 3
- Total de imágenes que NO eran "Corrosión": 4 (Grieta) + 4 (Abolladura) + 4 (Sin Defecto) = 12
- TN (Predicho correctamente como NO "Corrosión"):
 - De las "Grieta" reales: 1 (Predicho "Grieta") + 1 (Predicho "Sin Defecto") = 2
 - De las "Abolladura" reales: 0 (Predicho "Grieta") + 0 (Predicho "Abolladura") + 3 (Predicho "Sin Defecto") = 3
 - De las "Sin Defecto" reales: 1 (Predicho "Grieta") + 1 (Predicho "Abolladura") + 2 (Predicho "Sin Defecto") = 4
 - Total TN = 2 + 3 + 4 = 9
- FPR Corrosión = $3 / (3 + 9) = 3 / 12 = 0.25 = 25.00\%$

FPR para la clase "Grieta":

- FP (Predicho "Grieta" cuando NO era Grieta): 1 (era "Corrosión") + 0 (era "Abolladura") + 1 (era "Sin Defecto") = 2

- Total de imágenes que NO eran "Grieta": 4 (Corrosión) + 4 (Abolladura) + 4 (Sin Defecto) = 12
- TN (Predicho correctamente como NO "Grieta"):
 - De las "Corrosión" reales: 3 (Predicho "Corrosión") + 0 (Predicho "Abolladura") + 0 (Predicho "Sin Defecto") = 3
 - De las "Abolladura" reales: 1 (Predicho "Corrosión") + 0 (Predicho "Abolladura") + 3 (Predicho "Sin Defecto") = 4
 - De las "Sin Defecto" reales: 0 (Predicho "Corrosión") + 1 (Predicho "Abolladura") + 2 (Predicho "Sin Defecto") = 3
 - Total TN = 3 + 4 + 3 = 10
- FPR Grieta = $2 / (2 + 10) = 2 / 12 = 0.1666... \approx 16.67\%$

FPR para la clase "Abolladura":

- FP (Predicho "Abolladura" cuando NO era Abolladura): 0 (era "Corrosión") + 0 (era "Grieta") + 1 (era "Sin Defecto") = 1
- Total de imágenes que NO eran "Abolladura": 4 (Corrosión) + 4 (Grieta) + 4 (Sin Defecto) = 12
- TN (Predicho correctamente como NO "Abolladura"):
 - De las "Corrosión" reales: 3 (Predicho "Corrosión") + 1 (Predicho "Grieta") + 0 (Predicho "Sin Defecto") = 4
 - De las "Grieta" reales: 2 (Predicho "Corrosión") + 1 (Predicho "Grieta") + 1 (Predicho "Sin Defecto") = 4

- De las "Sin Defecto" reales: 0 (Predicho "Corrosión") + 1 (Predicho "Grieta") + 2 (Predicho "Sin Defecto") = 3
- Total TN = 4 + 4 + 3 = 11
- FPR Abolladura = $1 / (1 + 11) = 1 / 12 = 0.0833... \approx 8.33\%$

FPR para la clase "Sin Defecto":

- FP (Predicho "Sin Defecto" cuando SÍ tenía defecto): 0 (era "Corrosión") + 1 (era "Grieta") + 3 (era "Abolladura") = 4
- Total de imágenes que SÍ tenían defecto (es decir, que NO eran "Sin Defecto"): 4 (Corrosión) + 4 (Grieta) + 4 (Abolladura) = 12
- TN (Predicho correctamente como NO "Sin Defecto" [o sea, predicho como algún defecto cuando realmente tenía defecto]):
 - De las "Corrosión" reales: 3 (Predicho "Corrosión") + 1 (Predicho "Grieta") = 4
 - De las "Grieta" reales: 2 (Predicho "Corrosión") + 1 (Predicho "Grieta") = 3
 - De las "Abolladura" reales: 1 (Predicho "Corrosión") = 1
 - Total TN = 4 + 3 + 1 = 8
- FPR Sin Defecto = $4 / (4 + 8) = 4 / 12 = 0.3333... \approx 33.33\%$

A partir de esta matriz de confusiones, se calcularon los indicadores de desempeño del prototipo para el conjunto de prueba externo, los cuales se detallan en la Tabla 7.

Tabla 7. Indicadores de Desempeño del Prototipo sobre el Conjunto de Prueba Externo

Verificado (N=16).

Indicador/Clase	Resultado
Precisión General (Accuracy)	37.5%
Tasa de Verdaderos Positivos (Recall):	
Corrosión	75%
Grietas	25%
Abolladuras	0%
Sin Defecto	50%
Tasa de Falsos Positivos (FPR):	
Corrosión	25.00%
Grietas	16.67%
Abolladuras	8.33%
Sin Defecto	33.33%

Fuente: Elaboración propia a partir de la matriz de confusiones.

Estos indicadores de desempeño evidenciados en la Tabla 7, tanto de la validación interna como del conjunto de prueba externo, serán analizados en detalle en la siguiente sección para discutir las capacidades, limitaciones y posibles causas del comportamiento observado en el prototipo.

3.2.4. Discusión e interpretación de resultados.

Con base en los resultados obtenidos en la sección anterior (3.2.3), tanto de la validación interna del prototipo como del análisis y evaluación del conjunto de prueba externo, se cuenta con una base sólida para discutir sobre el desempeño del prototipo de IA, identificar sus limitaciones y analizar su potencial como herramienta de apoyo. A continuación, se profundizará en estos aspectos:

Análisis de los indicadores de desempeño.

Tras un análisis exhaustivo, se identifican varios puntos críticos en los indicadores de desempeño asociados al prototipo. Se observó un rendimiento general que, si bien muestra potencial, se situó por debajo de las expectativas ideales, especialmente en la evaluación con el conjunto de prueba externo. Este comportamiento puede atribuirse a diversos factores que se discutirán a continuación, analizando cada indicador principal:

- **Precisión general (Accuracy):**

La precisión del prototipo fue evaluada inicialmente de forma automática por Google Teachable Machine durante su validación interna, utilizando aproximadamente el 15% de las

imágenes cargadas para el entrenamiento. La precisión general obtenida en este análisis interno fue de un 62.5%. Si bien este valor podría mejorarse, no se considera un resultado deficiente para una prueba piloto inicial, ya que supera significativamente el umbral de clasificación aleatoria (25% para cuatro clases), como se discutió en la sección 1.4.1. Esto sugiere que el modelo logró un aprendizaje básico a partir de los datos de entrenamiento.

En contraste, el porcentaje de precisión general obtenido con el conjunto de prueba externo fue del 37.5%. Considerando la interpretación de los indicadores de desempeño, este valor se acerca a un nivel de clasificación aleatoria, lo que sugiere dificultades del modelo para generalizar su aprendizaje con el conjunto de prueba externo. Aunque no es el resultado ideal, es importante analizar los factores que pudieron influir y las posibilidades de mejora.

Esta diferencia entre la precisión de validación interna (62.5%) y externa (37.5%) es significativa y plantea la pregunta sobre sus posibles causas. Para abordar esta interrogante, se deben considerar factores como las características de las imágenes utilizadas para el entrenamiento en comparación con las del conjunto de prueba, así como la cantidad de imágenes en ambos. El conjunto de prueba externo se compuso de imágenes provenientes de investigaciones de accidentes, las cuales, si bien proporcionaron un diagnóstico verificado, podrían presentar mayor variabilidad, menor calidad visual o contextos más complejos que las imágenes predominantemente utilizadas para el entrenamiento. Adicionalmente, el carácter de prueba piloto del prototipo implicó no incluir una gran cantidad de imágenes con amplia variación de los defectos, lo que pudo haber afectado el resultado de generalización. Por otro lado, la validación interna, al utilizar una porción de las imágenes almacenadas para el entrenamiento, probablemente se benefició de la similitud en características como tipo de

daño, zona y tipo de aeronaves, facilitando la interpretación del prototipo y arrojando un resultado superior al obtenido con el conjunto de prueba externo.

- **Tasa de verdaderos positivos (Recall/Sensibilidad) por clase:**

Se observaron tasas de verdaderos positivos (Recall) variables entre las diferentes clases y conjuntos de prueba. En el conjunto de (Validación Interna), la clase "Corrosión" alcanzó un 100% de Recall, posiblemente debido a características visuales distintivas (color y forma) que facilitaron su identificación. En contraste, la clase "Abolladuras" (50% de Recall) y especialmente "Sin Defecto" (25% de Recall) presentaron mayores dificultades, lo que podría atribuirse a la sutileza de algunas abolladuras o a la variabilidad de las superficies sin defecto que pudieron confundirse con características de otros daños. La presencia de defectos múltiples en una sola imagen también pudo condicionar la respuesta del prototipo.

En el conjunto de prueba externo, la "Corrosión" nuevamente obtuvo el Recall más alto (75%), aunque menor que en la validación interna. Las demás clases mostraron un desempeño considerablemente más bajo: "Grietas" con un 25%, "Sin Defecto" con un 50% y "Abolladuras" con un 0%. Este último resultado para "Abolladuras" sugiere que las características visuales de estos defectos en las imágenes de prueba externa (posiblemente más complejas, con fondos contaminados o daños sutiles, al provenir de contextos de accidentes) fueron particularmente desafiantes para el modelo entrenado. Aunque en algunas predicciones incorrectas para "Abolladuras" se identificó un mínimo porcentaje de confianza hacia la clase correcta, la clasificación final fue errónea.

Implicaciones de un bajo Recall: En el contexto del mantenimiento aeronáutico, donde la seguridad es primordial, una baja tasa de Recall para cualquier clase de defecto es crítica. Implica que el sistema no detecta una proporción significativa de los daños existentes, lo que comprometería directamente la seguridad operacional si se dependiera exclusivamente de una herramienta con estas limitaciones. Si bien el objetivo es que sirva de complemento, un rango aceptable de detección es indispensable.

- **Tasa de falsos positivos (FPR) por clase:**

La Tasa de Falsos Positivos (FPR), se observaron diferentes comportamientos. En la validación interna, la clase 'Grietas' presentó el FPR más alto (25.00%), lo que indica una tendencia del modelo a clasificar incorrectamente otras condiciones como si fueran grietas. Por otro lado, 'Corrosión', 'Abolladuras' y 'Sin Defecto' tuvieron un FPR más bajo (8.33%), sugiriendo menos falsas alarmas para estas categorías en el conjunto de validación interna.

Para el conjunto de prueba externo, el FPR para 'Corrosión' fue del 25.00% y para 'Grietas' del 16.67%. Notablemente, 'Abolladuras' tuvo un FPR del 8.33%. Sin embargo, la clase 'Sin Defecto' presentó el FPR más elevado (33.33%), lo que es problemático, ya que indica que el modelo clasificó incorrectamente una proporción significativa de piezas con defectos como si estuvieran 'Sin Defecto'..."

Identificación de errores comunes y confusiones del modelo.

Un análisis más detallado de la Matriz de Confusiones del conjunto de prueba externo (Tabla 6) permite identificar los patrones de error más frecuentes del prototipo. Se observó una tendencia del modelo a confundir las instancias reales de "Grietas" con "Corrosión" (2 de

4 casos) y una con "Sin Defecto" (1 de 4 casos). Esta dificultad podría atribuirse a que algunas grietas finas o en etapas iniciales comparten características visuales sutiles con texturas superficiales o inicios de corrosión, especialmente si las imágenes de entrenamiento para "Grietas" no capturaron suficiente variabilidad de estos casos límite.

La clase "Abolladuras" fue la que presentó el mayor desafío, siendo todas las instancias reales clasificadas incorrectamente. La confusión predominante fue con la clase "Sin Defecto" (3 de 4 casos) y una con "Corrosión". Esto sugiere que las características visuales de las abolladuras en el conjunto de prueba (provenientes de informes de accidentes) eran posiblemente muy sutiles, con poca definición de sombras o en superficies con reflejos complejos o contaminación visual, dificultando su distinción de una superficie normal o con otros tipos de daño por parte del modelo entrenado.

También se observaron errores en la clasificación de "Sin Defecto", donde instancias fueron confundidas con "Grietas" y "Abolladuras". Esto podría indicar que el modelo no aprendió suficientemente las características de una superficie intacta bajo diversas condiciones de iluminación o texturas presentes en las imágenes de prueba. La calidad y la representatividad de las imágenes de entrenamiento para la clase "Sin Defecto" son cruciales para evitar este tipo de errores. Si una porción significativa de las imágenes de entrenamiento fue generada por IA, las posibles diferencias entre estas imágenes sintéticas y la complejidad visual de las imágenes reales del conjunto de prueba podrían haber contribuido a estas confusiones.

Limitaciones del prototipo y del estudio.

Es fundamental reconocer las limitaciones inherentes a este estudio y al prototipo desarrollado para interpretar adecuadamente los resultados:

- **Tamaño y diversidad del conjunto de datos:** El número total de imágenes utilizadas para el entrenamiento (100) y especialmente para la prueba externa (16) es limitado para los estándares de proyectos de aprendizaje profundo. Una mayor cantidad y diversidad de imágenes (diferentes componentes, materiales, condiciones de iluminación, ángulos y niveles de severidad de cada defecto) sería necesaria para entrenar un modelo más robusto y generalizable.
- **Fuente y calidad de las imágenes:** La dependencia de imágenes recopiladas de diversas fuentes, incluyendo la generación mediante IA, puede introducir variabilidad en la calidad (resolución, iluminación) y en la representatividad de los defectos reales. Las imágenes generadas por IA, aunque sean útiles para aumentar el volumen de datos, podrían no capturar todos los detalles y variaciones de los defectos encontrados en condiciones operativas reales.
- **Generalización de los defectos:** Al clasificar "Corrosión", "Grietas" y "Abolladuras" como categorías únicas sin distinguir sub-tipos o niveles de severidad, se simplificó el problema de clasificación. Un sistema para uso real requeriría una cantidad mucho mayor de datos para la identificación de los defectos.
- **Capacidades de (Google Teachable Machine):** Si bien es una herramienta excelente por su accesibilidad y facilidad de uso, Teachable Machine opera en gran medida como si fuera una "caja negra". Que ofrece un control limitado sobre la arquitectura de la red neuronal y los parámetros avanzados del entrenamiento, lo que dificulta un ajuste más específico del modelo o un análisis profundo de sus mecanismos internos de decisión.

- **Alcance del prototipo:** El sistema desarrollado es un prototipo conceptual para demostrar la viabilidad de aplicar IA a la inspección visual con herramientas accesibles. No es, en su estado actual, un sistema validado para su implementación en entornos de mantenimiento aeronáutico reales.
- **Validación limitada:** La evaluación con un conjunto de prueba externo de 16 imágenes, aunque valiosa por contar con diagnósticos verificados, es estadísticamente pequeña y los resultados deben interpretarse como preliminares y no generalizables sin pruebas más exhaustivas.

Comparación con la línea base (Conceptual) y potencial de la herramienta.

Aunque este estudio no incluyó una comparación experimental directa y formal contra el desempeño de inspectores humanos certificados, los resultados obtenidos permiten una discusión conceptual sobre el potencial de este tipo de herramientas de IA:

- **Potencial como herramienta de apoyo:** A pesar de las limitaciones y los resultados de precisión moderados en la prueba externa, el prototipo demostró la capacidad de aprender a distinguir entre diferentes tipos de defectos visuales a partir de imágenes. Esto sugiere que, con un mayor desarrollo y entrenamiento con datos más robustos, herramientas similares podrían servir como un apoyo preliminar o un "segundo par de ojos" para los inspectores, ayudando a señalar áreas de posible interés o a preclasificar hallazgos para una revisión humana más detallada.
- **Estandarización y entrenamiento:** Podrían contribuir a una mayor estandarización en la detección inicial de defectos y servir como herramientas didácticas interactivas para la capacitación de nuevos técnicos, exponiéndose a una variedad de ejemplos visuales.

- **Necesidad de mejora significativa:** Es evidente que, para una aplicación práctica y confiable en el mantenimiento aeronáutico, el prototipo requeriría mejoras sustanciales. Esto incluye el uso de conjuntos de datos mucho más grandes y representativos de defectos reales, la exploración de algoritmos de IA más sofisticados y la validación rigurosa en condiciones operativas.
- **Complemento, no reemplazo:** Es crucial reiterar que la IA, especialmente en el estado actual de desarrollo para tareas de inspección visual complejas, debe considerarse un complemento a la pericia, el juicio y la responsabilidad final del inspector humano cualificado y no un sustituto. La inspección visual humana se beneficia de la comprensión del contexto, la experiencia y la capacidad de adaptación que los modelos de IA actuales aún no pueden replicar completamente. Sin embargo, la IA puede ayudar a mitigar factores humanos como la fatiga o la variabilidad en la detección inicial si se integra cuidadosamente en los procesos existentes.

3.3. Discusión general: potencial, impacto y desafíos de la IA en la inspección visual aeronáutica.

La utilización de la inteligencia artificial, específicamente en la inspección visual como método de Ensayo No Destructivo (NDT), para piezas y componentes aeronáuticos (incluyendo aquellos clasificados como críticos, como los de clase 1 y 2), representa un avance significativo para el mantenimiento. El impacto potencial es considerable dada la criticidad de los componentes inspeccionados y las implicaciones directas para la seguridad operacional. Este análisis se centra en cómo la optimización de la inspección visual mediante IA puede reducir errores humanos y mejorar los procesos de mantenimiento.

3.3.1. Potencial de la IA para la mejora de la inspección visual y el mantenimiento detectivo.

Las estrategias de mantenimiento predominantes en la industria aeronáutica, derivadas de filosofías como RCM y MSG-3, se centran en enfoques preventivos y detectivos. La inteligencia artificial, aplicada a la inspección visual, tiene un potencial considerable para fortalecer estas estrategias:

- **Mejora en la estandarización y consistencia:** La inteligencia artificial (IA) podría considerablemente ayudar a aplicar criterios de inspección de manera más completa, reduciendo así la variabilidad inherente al juicio humano entre distintos inspectores o momentos.
- **Optimización del tiempo de inspección:** Independientemente de que el prototipo actual sea realmente básico, un sistema (IA) más avanzado, con un software mejorado podría incluso analizar imágenes con una gran rapidez, de esta manera permitiría a los técnicos enfocar su atención en problemas o indicaciones más relevantes y reducir potencialmente los tiempos de inspección.
- **Mejora en la documentación y trazabilidad:** Como complemento al prototipo, se puede tener en cuenta el uso de herramientas IA que puedan facilitar el registro automatizado de las imágenes, clasificaciones de defectos, la posible ubicación (si se integra con otros sistemas) y la fecha, generando una mejora sustancial a calidad y accesibilidad de los registros de mantenimiento. Adicionalmente, esto posiblemente

podría ayudar a la detección y análisis de tendencias de daños o defectos en el transcurso del tiempo, ya sea en una flota o tipo de componente.

- **Apoyo a la formación y capacitación:** Hay una cantidad considerable de sistemas de inteligencia artificial (IA), prototipos incluyendo el trabajado en este proyecto, que podrían ser utilizados como herramientas didácticas interactivas para entrenar una nueva generación de técnicos, exponiendo una amplia variedad de ejemplos visuales de defectos y sus tipos de clasificación.
- **Reducción de errores por factores humanos:** Así como se consideran los posibles errores en el prototipo, se destaca también el potencial que tiene la IA de mitigar el impacto de factores humanos como la fatiga, la distracción o subjetividad en la detección de defectos visuales.
- **Facilitación de Inspecciones en Áreas de Difícil Acceso:** Combinada con tecnologías de captura de imágenes como drones o boroscopios avanzados, la IA podría analizar imágenes de zonas complejas, reduciendo la necesidad de acceso físico directo en muchos casos.

La inteligencia artificial, con su capacidad para procesar información y analizarla, se alinea directamente con el fortalecimiento del mantenimiento detectivo. Si bien la posibilidad de alcanzar un mantenimiento predictivo robusto a partir de datos de inspección visual requeriría la acumulación y análisis de grandes volúmenes de datos históricos y la integración con otros parámetros operativos, la mejora en la detección temprana y consistente de defectos es un paso fundamental. Actualmente, para la aplicación directa de la IA en la inspección

visual de defectos existentes, como se aborda en este prototipo, el enfoque principal es el apoyo al mantenimiento detectivo y por extensión, al preventivo, ya que las pruebas e inspecciones se realizan en intervalos específicos conforme al programa de mantenimiento.

3.3.2. Implicaciones para el personal técnico y las organizaciones de mantenimiento (OMA).

La implementación de IA en la inspección visual conlleva implicaciones significativas tanto para el personal técnico como para la estructura y procesos de las Organizaciones de Mantenimiento Aprobadas (OMA):

Para el técnico de mantenimiento: Existen fuentes de apoyo que ayudan a la regularización de un buen mantenimiento técnico, con el objetivo de mejorar su aplicabilidad en las diferentes tareas de mantenimiento.

En la siguiente sección se describen herramientas de apoyo a la decisión, reducción de carga cognitiva y acceso a conocimiento visual consolidado,

- **Herramienta de apoyo a la decisión:**

No se pretende o visualiza la IA como el reemplazo de un técnico cualificado, sino como un asistente avanzado que puede pre-analizar imágenes, establecer o resaltar zonas de posible interés o incluso proponer una clasificación inicial, ayudando al técnico a enfocar su atención en la verificación y toma de decisiones complejas.

- **Reducción de carga cognitiva:**

Al establecer patrones de reconocimiento automatizado en defectos visuales comunes, La (IA) podría ayudar a disminuir en gran parte la carga cognitiva de los técnicos

asociada a tareas de inspección visual repetitivas o con periodos extensos, de esta manera permitiendo al técnico enfocarse en defectos más ambiguos o incluso en la interpretación completa o integral de la condición del componente.

- **Acceso a conocimiento visual consolidado:**

Un sistema de IA bien entrenado puede actuar como una base de conocimiento visual, recordando y comparando con miles de ejemplos de defectos, lo que podría ser especialmente útil para identificar tipos de daños menos frecuentes o para técnicos con menor experiencia.

Para la organización de mantenimiento aprobada (OMA): De acuerdo con una entrevista con personal activo dentro del medio, el impacto de implementar este tipo de cambios dentro de una OMA dependerá de su lista de capacidades. Para poder realizar inspecciones visuales asistidas por IA en componentes de aeronaves y/o prestar este servicio, las OMAs deberán adaptar sus procesos y demostrar cumplimiento. Si el cambio en el proceso de ejecución de la inspección visual mediante IA es impulsado por requisitos mandatorios (ej. directivas de aeronavegabilidad, boletines de servicio), diversas áreas se verían impactadas.

- **Aseguramiento de la calidad:** Deberá actualizar manuales y procesos, definir procedimientos para la validación y uso de herramientas de IA y gestionar la certificación de estos nuevos métodos. Se requerirá una estrecha colaboración con personal clave para la certificación de estas nuevas capacidades.
- **Área de compras:** Encargada de evaluar y adquirir el nuevo software, hardware (ej. cámaras de alta resolución, dispositivos de procesamiento) y las licencias necesarias.

- **Área de incoming y/o inspección de recibo:** Deberá verificar la correcta implementación y calibración de los nuevos sistemas de inspección asistida por IA.
- **Área de almacén:** Podría necesitar gestionar nuevos tipos de equipos o consumibles asociados.
- **Área de entrenamiento:** Será fundamental capacitar al personal (inspectores, ingenieros) en el uso de las nuevas herramientas de IA, la interpretación de sus resultados y la comprensión de sus limitaciones. Se deberán programar entrenamientos iniciales y recurrentes.
- **Área de SMS (Seguridad Operacional):** Deberá realizar una exhaustiva gestión del cambio, analizando los nuevos peligros y riesgos asociados con la implementación de IA (ej. exceso de confianza en la herramienta, errores de la IA, ciberseguridad del sistema). La 'docena maldita' (Dirty Dozen) de los factores humanos deberá ser reevaluada en este nuevo contexto; por ejemplo, la complacencia podría llegar a darse si el personal confía de forma excesiva en la IA sin realizar una verificación humana adecuada, especialmente si la herramienta es percibida como facilitadora de las tareas.

Nota: Las áreas específicas y el grado de impacto dependerán del tamaño y tipo de empresa, así como de su estructura organizacional. Sin embargo, lo anterior proporciona una idea del panorama de cambios.

3.3.3. Impacto general en la seguridad, eficiencia y regulación de la aviación.

Actualmente, todas las autoridades aeronáuticas del mundo están estudiando y financiando programas para la implementación segura de la inteligencia artificial en la

aviación, no solo en el espacio aéreo, sino también en el mantenimiento. Aunque los usos iniciales se han centrado en potenciar el registro y la documentación técnica, se espera que esta limitación sea superada.

La principal preocupación sigue siendo la seguridad y confiabilidad de los sistemas de IA. Una tecnología vulnerable a ciberataques (como hackeos, virus, envenenamiento de datos) o que produzca resultados erróneos podría comprometer sistemas enteros y, en última instancia, la seguridad operacional. La integridad y confiabilidad de los datos utilizados para entrenar y operar los modelos de IA son vitales en la aviación.

El impacto en las empresas que desarrollen o implementen estos programas de IA es también considerable. Más allá del desarrollo tecnológico, aspectos como la validación continua de los algoritmos, las actualizaciones de software, la creación de manuales de usuario detallados y los programas de formación para su correcta utilización resultan fundamentales.

En general, la inteligencia artificial, aplicada correctamente, tiene un potencial enorme para optimizar los procesos de inspección visual, reducir tiempos de tarea, mejorar la detección de defectos y, como resultado, contribuir a la reducción de errores humanos, lo que impactaría positivamente en la seguridad y eficiencia general de la aviación.

3.3.4. Desafíos y requisitos para la implementación robusta de IA en inspecciones visuales.

Para que la IA en inspecciones visuales alcance su máximo potencial y sea una herramienta robusta y confiable en el mantenimiento aeronáutico, se deben abordar varios desafíos y cumplir con requisitos estrictos:

- **Conjuntos de datos (Datasets) de alta calidad:** Se necesitan bases de datos extensas, diversas y representativas, con imágenes de alta resolución de defectos reales en una amplia variedad de componentes, materiales y bajo diferentes condiciones de iluminación y ángulos. Estos datos deben ser minuciosamente etiquetados y validados por expertos en NDT.
- **Algoritmos de IA avanzados y específicos:** Para aplicaciones críticas, se requerirán modelos de *Deep Learning* más sofisticados que los utilizados en prototipos básicos, posiblemente arquitecturas convolucionales personalizadas o modelos de segmentación que puedan no solo clasificar, sino también localizar y delinear los defectos.
- **Validación rigurosa y pruebas exhaustivas:** Los sistemas de IA deben someterse a pruebas exhaustivas en condiciones lo más cercanas posible a las operativas reales, con una comparación sistemática contra la efectividad de inspectores humanos certificados. Se deben establecer métricas claras de desempeño y criterios de aceptación.
- **Integración con sistemas y herramientas existentes:** La IA debe poder integrarse fluidamente con el ecosistema tecnológico de las OMAs, incluyendo software de gestión de mantenimiento (MRO), herramientas de captura de imágenes (boroscopios, drones con cámaras) y dispositivos de visualización para los técnicos.
- **Consideraciones de factores humanos:** Es crucial la capacitación adecuada del personal, el desarrollo de confianza en la herramienta (entendiendo sus capacidades y limitaciones) y la definición clara de los roles y responsabilidades en un proceso de inspección asistido por IA. Además, la interfaz de usuario debe ser intuitiva y estar diseñada para el entorno del taller.

- **Certificación y aprobación regulatoria:** Las autoridades aeronáuticas (EASA, FAA, UAEAC) están desarrollando los marcos para la certificación de software basado en IA, especialmente para funciones que impactan la seguridad. Cualquier sistema de IA para inspección deberá cumplir con estos futuros estándares.
- **Explicabilidad y transparencia (XAI - Explainable AI):** Para tareas críticas, es deseable que los modelos de IA puedan ofrecer justificaciones o indicaciones sobre cómo llegaron a una conclusión (ej. resaltar las características de la imagen que llevaron a una clasificación). Esto aumenta la confianza y permite una mejor verificación por parte de los humanos.

CONCLUSIONES.

El presente proyecto tuvo como propósito explorar la integración de inteligencia artificial (IA) en procesos de inspección visual aeronáutica mediante métodos accesibles y aplicables en un entorno académico, mediante la elaboración de un prototipo basado en un software de la aplicación Google Teachable Machine. Esta sección en específico recopila los hallazgos claves que se obtuvieron del análisis metodológico, desarrollo práctico y evaluación del prototipo de inteligencia artificial (IA) para la inspección visual de componentes aeronáuticos. A partir de los objetivos trazados, se lograron los siguientes resultados:

En primer lugar, mediante el uso de una matriz de decisión estructurada con cuatro criterios ponderados (facilidad de obtención de datos, compatibilidad con herramientas accesibles de IA, aplicabilidad para defectos estructurales y viabilidad académica), se seleccionó la inspección visual (VI) como el método de ensayo no destructivo (NDT) más adecuado para este estudio, debido a que la VI resultó ser la alternativa óptima gracias a su bajo requerimiento tecnológico, la facilidad para generar y capturar datos visuales y su alta compatibilidad con herramientas como Google Teachable Machine.

Posteriormente, se desarrolló un prototipo funcional de clasificación de defectos, entrenado con un conjunto de 100 imágenes y validado tanto internamente como con un conjunto de prueba externo. El modelo fue capaz de distinguir entre cuatro clases (corrosión, grietas, abolladuras y sin defecto), demostrando un desempeño inicial alentador, con una precisión interna de 62.5%, valor que supera ampliamente la clasificación aleatoria para cuatro clases. No obstante, la precisión externa (37.5%) reveló limitaciones importantes en la

capacidad de generalización del modelo, lo cual se atribuyó principalmente a la baja cantidad de datos, la variabilidad visual de las imágenes externas y las limitaciones inherentes a la herramienta utilizada.

El análisis comparativo de los indicadores clave de desempeño (precisión, tasa de verdaderos positivos (recall) y tasa de falsos positivos (FPR)) evidenció comportamientos diferenciales por clase. La clase "Corrosión" mostró el mejor desempeño en ambas fases, mientras que "Abolladuras" presentó desafíos significativos, con un recall de 0% en el conjunto externo. Asimismo, el análisis de la matriz de confusión permitió identificar errores sistemáticos en la clasificación, como la tendencia a confundir grietas con corrosión o abolladuras con superficies sin defecto. Estos resultados revelan la necesidad de ampliar el conjunto de datos, mejorar la representatividad de las imágenes y considerar herramientas de IA más avanzadas para optimizar el desempeño.

De manera integral, el aporte principal de este proyecto investigativo es la demostración teórico-práctica de un flujo de trabajo para desarrollar y evaluar una solución de IA para una problemática real en el mantenimiento aeronáutico utilizando herramientas de fácil acceso. Se determina también el potencial de este tipo de tecnología, el cual no pretende o reside en reemplazar al inspector humano, sino en servir más como un complemento. La inserción de inteligencia artificial en los procesos de inspección visual, si se desarrolla adecuadamente, puede mejorar significativamente la precisión y eficiencia en la detección de fallas, permitiendo una identificación más temprana de problemas que podrían comprometer la seguridad operacional.

De igual manera, la investigación resalta la importancia de un marco regulatorio fuerte, como el que están desarrollando EASA y FAA, para garantizar la implementación segura de la IA en la aviación, donde la armonización de normas y la creación de estándares claros son fundamentales. Se concluye que la adaptación de IA en las organizaciones de mantenimiento aeronáutico requerirá una capacitación adecuada del personal y una adaptación significativa de los procesos internos, incluyendo la actualización de manuales y una alta y exigente gestión del cambio. Para trabajos futuros con base en esta investigación, se recomienda lo siguiente: replicar el experimento con un conjunto de datos mucho más grande y diverso compuesto exclusivamente de imágenes reales y verificadas, explorar algoritmos de IA más avanzados que permitan no solo clasificar, sino también localizar y medir los defectos y finalmente realizar una validación en un entorno controlado con la participación de inspectores certificados para comparar el desempeño de la IA con el juicio experto humano.

BIBLIOGRAFÍA.

Airbus Protect, LNE, & Numalis. (2024). MLEAP final report (Report No. EASA.2021.C38).

European Union Aviation Safety Agency.

<https://www.easa.europa.eu/sites/default/files/dfu/mleap-d4-public-report-issue01.pdf>

Air Transport Association. (2022). MSG-3: Operator/Manufacturer Scheduled Maintenance Development, Volume 1 – Fixed-Wing Aircraft (Rev. 2022.1). ATA e-Business Program.

<https://publications.airlines.org/products/msg-3-operator-manufacturer-scheduled-maintenance-development-volume-1-fixed-wing-aircraft-revision-2022-1>

Anderson, M. J., Kroes, M. J., Watkins, W. A., Delp, F., & Sterkenburg, R. (2013). Aircraft Maintenance and Repair (7.^a ed.). McGraw-Hill Education.

<https://www.mheducation.com/highered/mhp/product/aircraft-maintenance-repair-seventh-edition.htm>

ASTM International. (2016). Standard practice for ultrasonic testing of wrought products (Standard No. E2375-16). <https://doi.org/10.1520/E2375-16>

ASTM International. (2020). Standard practice for electromagnetic (Eddy current) sorting of nonferrous metals (Standard No. E0703-20). <https://doi.org/10.1520/E0703-20>

Bosch Rué, A., Casas Roma, J., & Lozano Bagén, T. (2019). Deep learning: Principios y fundamentos. Editorial UOC. <https://dialnet.unirioja.es/servlet/libro?codigo=868713>

Casado, J. (2015). Gestión de cambios en los sistemas funcionales [Presentación]. AEMET.
https://repositorio.aemet.es/bitstream/20.500.11765/9304/1/AEMEt_cambios_JCasado_ForoU_su2015.pdf

De Mauro, A., Greco, M., & Grimaldi, M. (2016). A formal definition of Big Data based on its essential features. *Library Review*, 65(3), 122–135. <https://doi.org/10.1108/LR-06-2015-0061>

Department of Infrastructure, Transport, Regional Development and Communications. (2021). National emerging aviation technologies policy statement. Australian Government.
<https://www.infrastructure.gov.au/sites/default/files/documents/national-emerging-aviation-technologies-policy-statement.pdf>

European Union Aviation Safety Agency. (2021). Continuing airworthiness – Acceptable Means of Compliance (AMC) & Guidance Material (GM).
<https://www.easa.europa.eu/document-library/acceptable-means-of-compliance-and-guidance-materials>

European Union Aviation Safety Agency. (2023, 10 de mayo). Artificial intelligence roadmap: A human-centric approach to AI in aviation. EASA.
<https://www.easa.europa.eu/en/domains/research-innovation/ai>

European Union Aviation Safety Agency. (2024a, 31 de mayo). Artificial intelligence: EASA publishes final report of the Machine Learning application approval research project. EASA.
<https://www.easa.europa.eu/en/newsroom-and-events/news/artificial-intelligence-easa-publishes-final-report-machine-learning>

European Union Aviation Safety Agency. (2024b, 11 de septiembre). TOR RMT.0742 - Artificial intelligence trustworthiness. EASA. <https://www.easa.europa.eu/en/document-library/terms-of-reference-and-rulemaking-group-compositions/tor-rmt0742>

European Union Aviation Safety Agency. (s.f.). Inteligencia artificial y aviación. EASA. Recuperado el 9 de junio de 2025, de <https://www.easa.europa.eu/es/light/topics/artificial-intelligence-and-aviation-0>

Federal Aviation Administration. (1998, septiembre 8). AC 43.13-1B: Acceptable methods, techniques, and practices – Aircraft inspection and repair (Change 1, 27 septiembre 2001). U.S. Department of Transportation.

https://www.faa.gov/documentLibrary/media/Advisory_Circular/ac_43.13-1b_w-chg1.pdf

Federal Aviation Administration. (2012). Advisory Circular AC 43-4B: Corrosion control for aircraft. U.S. Department of Transportation.

https://www.faa.gov/documentLibrary/media/Advisory_Circular/AC_43-4B.pdf

Federal Aviation Administration (FAA). (2018). Aviation Maintenance Technician Handbook – Airframe, Volume 1 (FAA-H-8083-31A). U.S. Department of Transportation.

https://www.faa.gov/regulations_policies/handbooks_manuals/aircraft/airframe_handbook/

Federal Aviation Administration. (2023). Aviation maintenance technician handbook–general (Report No. FAA-H-8083-30B). U.S. Department of Transportation.

https://www.faa.gov/regulations_policies/handbooks_manuals/aviation/amtg_handbook.pdf

Federal Aviation Administration. (s.f.). Artificial intelligence safety assurance. Recuperado el 9 de junio de 2025, de

https://www.faa.gov/aircraft/air_cert/step/disciplines/artificial_intelligence

Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. MIT Press.

Google. (s.f.). Teachable Machine. Recuperado el 9 de junio de 2025, de

<https://teachablemachine.withgoogle.com>

Hellier, C. (2013). Handbook of nondestructive evaluation (2nd ed.). McGraw-Hill Education.

International Civil Aviation Organization (ICAO). (2023). Manual on the Approval of Training Organizations (Doc 9841, 3rd ed.).

<https://www.icao.int/publications/pages/publication.aspx?docnum=9841>

Russell, S., & Norvig, P. (2020). Artificial intelligence: A modern approach (4th ed.). Pearson.

Manrique Sanz, E. (2023). Utilización de Blockchain e Inteligencia artificial para el mantenimiento de aviones [Tesis de grado, ICAI Universidad Pontificia Comillas].

Repositorio Comillas.

<https://repositorio.comillas.edu/xmlui/bitstream/handle/11531/74744/TFG%20Eva%20Manrique%20Firmado%20Entregar.pdf>

Mateus Rodríguez, L. F. (2020). Modelo de gestión del cambio para la implementación de los RAC 141, 142 y 147 en los centros de instrucción o de entrenamiento certificados por una autoridad aeronáutica civil [Tesis de maestría, Universidad Militar Nueva Granada].

Repositorio Unimilitar. <https://repository.unimilitar.edu.co/handle/10654/38992>

Mobley, R. K. (2002). An introduction to predictive maintenance (2nd ed.). Butterworth-Heinemann.

Nakajima, S. (1988). Introduction to TPM: Total productive maintenance. Productivity Press.

Tennant, G. (2001). Six Sigma: SPC and TQM in manufacturing and services. Gower Publishing.

Organización de Mantenimiento Aprobada LATAM Airlines Perú. (s.f.). Manual de pruebas no destructivas. OMA LATAM Airlines Perú. <https://srvsop.aero/site/wp-content/uploads/2020/03/MANUAL-NDT-R4.pdf>

Parlamento Europeo. (2024). Reglamento (UE) 2024/1689 por el que se establecen normas armonizadas sobre inteligencia artificial (Ley de Inteligencia Artificial). Diario Oficial de la Unión Europea. <https://eur-lex.europa.eu/legalcontent/ES/TXT/?uri=CELEX%3A32024R1689>

Parmenter, D. (2015). Key performance indicators: Developing, implementing, and using winning KPIs (3rd ed.). Wiley.

Ramos Arévalo, H. R., Torres Rivera, D. O., & Suyón Tejada, J. S. (2021). Metodología basada en inteligencia artificial en la gestión del mantenimiento 4.0 [Tesis de grado, Universidad de Piura]. Repositorio Institucional PIRHUA. <https://pirhua.udep.edu.pe/backend/api/core/bitstreams/5783f46b-2d9e-4bcd-9d57-dfac1aa62a49/content>

SAE International. (2009). Evaluation criteria for reliability-centered maintenance (RCM) processes (Standard No. JA1011_200908).

https://www.sae.org/standards/content/ja1011_200908/

Schonberger, R. J. (2008). World class manufacturing: The next decade: Building power, strength, and value. Free Press.

Unidad Administrativa Especial de Aeronáutica Civil. (2023). Reglamento Aeronáutico de Colombia (RAC 1): Definiciones, Abreviaturas y Símbolos.

<https://www.aerocivil.gov.co/normatividad/RAC/RAC%201.pdf>

Unidad Administrativa Especial de Aeronáutica Civil. (2016). Reglamento Aeronáutico de Colombia (RAC) 43 – Mantenimiento [Reglamento].

<https://www.aerocivil.gov.co/normatividad/RAC/RAC%2043%20-%20Mantenimiento.pdf>

Unidad Administrativa Especial de Aeronáutica Civil. (2024). Reglamento Aeronáutico de Colombia (RAC 145): Organizaciones de Mantenimiento Aprobadas.

<https://www.aerocivil.gov.co/normatividad/RAC/RAC%20145%20-ORGANIZACIONES%20DE%20MANTENIMIENTO%20APROBADAS.pdf>

Unidad Administrativa Especial de Aeronáutica Civil – DIACC. (2024, 9 de septiembre). Informe preliminar del accidente HK-1937 (Mitú) [Informe preliminar].

<https://www.aerocivil.gov.co/autoridad-de-la-aviacion->

[civil/investigacion/Histicos%20Accidentes/COL-24-58-DIACC%20Prelim%20Acc%20HK1937%20Mitu%CC%81%2009-sep-24.pdf](https://www.aerocivil.gov.co/autoridad-de-la-aviacion-civil/investigacion/Histicos%20Accidentes/COL-24-58-DIACC%20Prelim%20Acc%20HK1937%20Mitu%CC%81%2009-sep-24.pdf)

Unidad Administrativa Especial de Aeronáutica Civil – DIACC. (s.f.). Informe final del accidente HK-419 [Informe]. <https://www.aerocivil.gov.co/autoridad-de-la-aviacion-civil/investigacion/Histicos%20Accidentes/HK419.pdf>

Unidad Administrativa Especial de Aeronáutica Civil – DIACC. (s.f.). Informe final del accidente HK-1680 [Informe]. <https://www.aerocivil.gov.co/autoridad-de-la-aviacion-civil/investigacion/Histicos%20Accidentes/ACCID%20HK1680.pdf>

Unidad Administrativa Especial de Aeronáutica Civil – DIACC. (2023, 24 de noviembre). Informe preliminar del accidente HK-2140G (Urrao) [Informe preliminar]. <https://www.aerocivil.gov.co/autoridad-de-la-aviacion-civil/investigacion/Histicos%20Accidentes/COL-23-60-DIACC%20Prelim%20Acc%20HK2140G%20Urrao%2024-nov-23.pdf>

Unidad Administrativa Especial de Aeronáutica Civil – DIACC. (2023, 29 de diciembre). Informe preliminar del accidente HK-1658G (Paz de Ariporo) [Informe preliminar]. <https://www.aerocivil.gov.co/autoridad-de-la-aviacion-civil/investigacion/Histicos%20Accidentes/COL-23-68-DIACC%20Prelim%20Acc%20HK1658G%20Paz%20Ariporo%2029-dic-23.pdf>

Unidad Administrativa Especial de Aeronáutica Civil – DIACC. (2025, 22 de marzo). Informe preliminar del accidente HK-1035G (Madrid) [Informe preliminar]. <https://www.aerocivil.gov.co/autoridad-de-la-aviacion->

[civil/investigacion/Histricos%20Accidentes/COL-25-12-DIACC%20Prelim%20ACCID%20HK1035G%20Madrid%202022-mar-25.pdf](#)

Unidad Administrativa Especial de Aeronáutica Civil – DIACC. (2024, 18 de octubre).

Informe preliminar del accidente HK-1535 (Cabuyaro) [Informe preliminar].

<https://www.aerocivil.gov.co/autoridad-de-la-aviacion-civil/investigacion/Histricos%20Accidentes/22.%20Preliminar%20Acc%20HK1535%20Cabuyaro%2018-oct-24.pdf>

Zhao, Y.-P., Wang, J.-J., Li, X.-Y., Peng, G.-J., & Yang, Z. (2020). Extended least squares support vector machine with applications to fault diagnosis of aircraft engine. *ISA Transactions*, 97, 189–201.

<https://www.sciencedirect.com/science/article/abs/pii/S0019057819303829>