

Predicción y gestión del riesgo operacional en la Fuerza Aeroespacial Colombiana con técnicas de IA

Carlos Rolando Medina Quijano

Roger Ramiro Romaña Ramos

Milton Robert Ovalle Sanchez

Asesor

Julio Eduardo Mejía Manzano

Universidad Nacional Abierta y a Distancia UNAD

Escuela de Ciencias Básicas, Tecnología e Ingeniería ECBTI

Especialización en Ciencia de Datos y Analítica

2025

Julio Eduardo Mejía Manzano

Director de Trabajo de Grado

Isaac Esteban Camargo Freile

Jurado

Dedicatoria

A nuestras familias, por su amor incondicional, paciencia y apoyo constante durante todo este periodo de estudio.

A nuestros docentes y director de trabajo de grado, por guiarnos con sabiduría y exigencia.

Y a cada uno de nosotros, por el compromiso, la perseverancia y el trabajo en equipo que hicieron posible este logro.

Agradecimientos

Agradecemos a la Universidad Nacional Abierta y a Distancia (UNAD) por brindarnos la formación académica y las herramientas metodológicas necesarias para desarrollar este proyecto. Expresamos nuestro especial reconocimiento al profesor Julio Eduardo Mejía Manzano, Director de Trabajo de Grado, por su orientación, compromiso y valiosos aportes que enriquecieron cada etapa del proceso.

De igual manera, extendemos nuestro agradecimiento a la Fuerza Aeroespacial Colombiana por el respaldo institucional y el suministro de información clave que hizo posible la aplicación práctica de este proyecto en un entorno real.

Resumen

La seguridad operacional es un eje estratégico para la Fuerza Aeroespacial Colombiana (FAC), especialmente en contextos donde la toma de decisiones debe ser precisa y oportuna. Este proyecto tuvo como objetivo aplicar modelos de inteligencia artificial (IA) para predecir riesgos operacionales en aeronaves, integrando datos históricos estructurados y no estructurados mediante técnicas avanzadas como el aprendizaje automático, el procesamiento de lenguaje natural (NLP), la minería de datos y la detección de anomalías.

La metodología empleada fue CRISP-DM, estructurada en seis fases iterativas desde la comprensión del problema hasta el despliegue del modelo. Se analizaron 8.283 registros con más de 100 variables relacionadas con condiciones de vuelo, tipo de aeronave, factores humanos y clasificación de seguridad operacional. Luego de un riguroso preprocesamiento, se seleccionaron variables clave con mayor capacidad predictiva para alimentar dos modelos: un clasificador XGBoost y una red bayesiana.

El modelo XGBoost alcanzó una precisión del 82,86 %, con un F1-score de 0,85 para la clase “Operación” y un AUC de 0,90, destacando su efectividad para clasificar misiones y apoyar decisiones preventivas. Por su parte, la red bayesiana, entrenada con el algoritmo Hill-Climb y el estimador BDeu, logró una inferencia causal con una probabilidad de operación del 60,44 % en escenarios reales. Además, se desarrollaron dos aplicaciones interactivas en Streamlit para facilitar la exploración de escenarios y la toma de decisiones por parte de usuarios no técnicos.

Como conclusión, la integración de estos enfoques permite anticipar incidentes, reducir riesgos operacionales y fortalecer la toma de decisiones estratégicas en la FAC. El modelo

supervisado XGBoost aporta robustez predictiva, mientras que la red bayesiana ofrece interpretabilidad y transparencia sobre las relaciones causales entre variables operativas.

Palabras claves: Seguridad operacional, inteligencia artificial, predicción de riesgos, aprendizaje automático, red bayesiana, XGBoost, Fuerza Aeroespacial Colombiana.

Abstract

Operational safety is a strategic pillar for the Colombian Aerospace Force (FAC), especially in environments where decision-making must be precise and timely. This project aimed to apply artificial intelligence (AI) models to predict operational risks in aircraft by integrating historical structured and unstructured data through advanced techniques such as machine learning, natural language processing (NLP), data mining, and anomaly detection.

The CRISP-DM methodology was used, structured in six iterative phases from problem understanding to model deployment. A total of 8,283 records with over 100 variables were analyzed, including flight conditions, aircraft type, human factors, and operational safety classification. After extensive preprocessing, the most predictive variables were selected to feed two models: an XGBoost classifier and a Bayesian network.

The XGBoost model achieved an accuracy of 82.86%, with an F1-score of 0.85 for the “OPERATION” class and an AUC of 0.90, demonstrating its effectiveness in classifying missions and supporting preventive decisions. The Bayesian network, trained with the Hill-Climb algorithm and the BDeu estimator, provided causal inference with an operational probability of 60.44% in real scenarios. In addition, two interactive Streamlit applications were developed to support scenario exploration and decision-making by non-technical users.

In conclusion, the integration of both approaches enables the anticipation of incidents, reduction of operational risks, and enhancement of strategic decision-making in the FAC. The supervised XGBoost model offers predictive robustness, while the Bayesian network provides interpretability and transparency in the causal relationships among operational variables.

Keywords: Operational safety, artificial intelligence, risk prediction, machine learning, Bayesian network, XGBoost, Colombian Aerospace Force.

Tabla de Contenidos

Introducción	15
Planteamiento del Problema	17
Justificación	20
Objetivos	23
Objetivo General	23
Objetivos Específicos	23
Marco Teórico	24
Revisión de Conocimientos y Técnicas Existentes	24
Inteligencia Artificial y Aprendizaje Automático	24
Minería de Datos	24
Contribución del Proyecto en la FAC	24
Metodología	26
Comprensión del Problema	26
Recolección y Comprensión de los Datos	26
Preparación de los Datos	27
Visualización de la Información en Tablero	30
Resumen del Tratamiento de Datos en Power BI (Power Query)	33
Carga de Datos	33
Estandarización Inicial	34
Enriquecimiento	34
Reducción de Variables	34
Limpieza de Datos Faltantes	34

Filtrado de Filas	35
Ordenamiento de Datos	35
Conversión de Fechas.....	35
Preparación de Variables Clave	35
Power Query Editor en Power Bi.....	36
Introducción a los Modelos Predictivos.....	38
XGBoostClassifier.....	38
Red Bayesiana	38
Modelo XGBoost	39
Introducción a la Plataforma de Despliegue (Streamlit)	39
Plataforma de Despliegue	40
Aplicación Interactiva en Streamlit.....	42
Limitaciones Metodológicas	44
Modelo Red Bayesiana	45
Selección de Variables Clave	45
Filtrado y Formato.....	46
Aplicación de Redes Bayesianas para la Predicción de Riesgos Operacionales	47
Estructura del Modelo: Aprendizaje Causal.....	48
Estimación de Parámetros: Cómo se Ajusta el Modelo	48
Inferencia: Obtención de Resultados Probabilísticos	49
Visualización de la Red: Interpretación y Transparencia.....	50
Aplicación Interactiva en Streamlit.....	51
Resultados Modelos	53

Modelo XGBoost	53
Configuración y Entrenamiento del Modelo.....	53
Resultados Obtenidos.....	54
Interpretación y Relevancia	55
Matriz de Confusión.....	58
Curva ROC.....	59
Importancia de Variables	61
Interpretación de Resultados del Modelo XGBoost.....	62
Escenario 1	62
Escenario 2	63
Escenario 3	64
Modelo Red Bayesiana	65
Interpretación de Resultados de la Red Bayesiana.....	66
Escenario 1	66
Escenario 2	67
Escenario 3	68
Conclusiones.....	70
Recomendaciones	71
Referencias Bibliográficas	73
Apéndices.....	76

Lista de Tablas

Tabla 1 *Matriz de Confusión*..... 58

Tabla 2 *Códigos Variable Misión* 62

Lista de Figuras

Figura 1 <i>Variables Evaluadas Data</i>	27
Figura 2 <i>Visualización Variables One-Hot Encoding</i>	28
Figura 3 <i>Matriz de Correlación</i>	29
Figura 4 <i>Tablero de incidentes</i>	31
Figura 5 <i>Transformación de Datos</i>	37
Figura 6 <i>Plataforma Anaconda 3</i>	41
Figura 7 <i>Ejecución App Desde Prompt Anaconda</i>	42
Figura 8 <i>Ciclo de ejecución aplicación Streamlit con Modelo XGBoost</i>	43
Figura 9 <i>Formulario de Ejecución Aplicación Streamlit con Modelo XGBoost</i>	44
Figura 10 <i>Dataset_Red_Bayesiana_Final.csv</i>	46
Figura 11 <i>Target Definido</i>	48
Figura 12 <i>Variables de Entrada</i>	49
Figura 13 <i>Obtención de Resultados Probabilísticos con Umbrales</i>	50
Figura 14 <i>Red Bayesiana Aprendida</i>	50
Figura 15 <i>Ciclo de Ejecución Aplicación Streamlit</i>	51
Figura 16 <i>Visualización App y Resultados Predictivos Red Bayesiana</i>	52
Figura 17 <i>Resultado Modelo XGBoost</i>	55
Figura 18 <i>Resultado Importancia Variables Modelo XGBoost</i>	56
Figura 19 <i>Curva ROC</i>	60
Figura 20 <i>Equivalencias Códigos de Misión</i>	61
Figura 21 <i>Red Bayesiana Aprendida Segundo Resultado</i>	65
Figura 22 <i>Visualización App y Resultados Posteriores Red Bayesiana</i>	66

Figura 23 <i>Visualización App y Resultados Posteriores Red Bayesiana</i>	67
Figura 24 <i>Visualización App y Resultados Posteriores Red Bayesiana</i>	68

Lista de Apéndices

Apendice A *Codigo Pyhton Anaconda 3* 76

Apendice B *Archivos App – Streamlit (Local)*..... 77

Introducción

La seguridad operacional es un componente esencial para el éxito de las misiones aéreas de la Fuerza Aeroespacial Colombiana (FAC). En un entorno donde la precisión, la confiabilidad y la toma de decisiones oportunas son determinantes, la prevención de accidentes aéreos no solo protege vidas y recursos, sino que asegura la continuidad de las operaciones y el cumplimiento de estándares tanto nacionales como internacionales. Aunque los índices de accidentalidad en Colombia han mostrado una tendencia favorable a lo largo de los años, la creciente complejidad de las operaciones aéreas, sumada a los factores humanos y técnicos involucrados, plantea nuevos retos que requieren soluciones innovadoras. (ICAO, 2018).

En este contexto, el uso de tecnologías basadas en inteligencia artificial y las herramientas para el análisis de los datos se presentan como una herramienta poderosa para fortalecer la gestión de riesgos en la aviación militar. El análisis predictivo de datos, combinado con modelos avanzados de aprendizaje automático y técnicas de procesamiento de lenguaje natural, permite no solo anticipar posibles incidentes, sino también comprender mejor las causas subyacentes que los generan. Así, es posible adoptar medidas preventivas más eficaces y oportunas, disminuyendo tanto los riesgos operativos como los costos asociados a fallos técnicos o errores humanos. (Russell & Norvig, 2021)

Este trabajo de grado en su modalidad de proyecto aplicado tiene como propósito aplicar un modelo de inteligencia artificial capaz de integrar y analizar información operacional, estructurada y no estructurada, proveniente de reportes de seguridad operacional, con el fin de identificar patrones de riesgo y generar alertas tempranas. La aplicación de este enfoque innovador no solo busca mejorar la seguridad y eficiencia de las operaciones aéreas, sino

también sentar las bases para una transformación digital dentro de la FAC, alineada con las tendencias globales en seguridad aeronáutica.

A través de la implementación de este modelo, se espera contribuir significativamente a la reducción de incidentes, optimizar los procesos de mantenimiento y operación, y fortalecer la cultura de prevención en la institución. Este proyecto, por tanto, no solo responde a una necesidad técnica, sino también estratégica, al ofrecer una solución sustentada en tecnología avanzada que permite anticiparse a los riesgos y garantizar la seguridad de las misiones aéreas en un entorno cada vez más exigente.

Planteamiento del Problema

La seguridad en la aviación es un pilar fundamental a nivel mundial debido al impacto que los accidentes e incidentes aéreos tienen en las vidas humanas, la infraestructura y la confianza en la industria aeronáutica. A pesar de los avances tecnológicos y regulatorios, factores como errores humanos, fallos en la comunicación y problemas en la gestión del tráfico aéreo siguen siendo causas recurrentes de incidentes, según la Organización de Aviación Civil Internacional (ICAO, 2018).

En el caso de la Fuerza Aeroespacial Colombiana (FAC), las operaciones aéreas militares y de defensa presentan riesgos adicionales debido a la complejidad de sus misiones, teniendo en cuenta la geografía de del territorio nacional, las condiciones operacionales exigentes y la diversidad de escenarios en los que se despliegan sus aeronaves. A lo largo del tiempo, el análisis de los datos históricos de seguridad operacional de la FAC ha evidenciado que, a pesar de los rigurosos protocolos de prevención y gestión de riesgos, gestionados por la Inspección General y su departamento de Seguridad Operacional, siguen ocurriendo incidentes relacionados con factores humanos, fallos mecánicos y decisiones tomadas bajo presión (Alvarado et al., 2025).

Si bien la FAC dispone de grandes volúmenes de datos, tanto estructurados (registros de vuelos, mantenimiento de aeronaves, condiciones meteorológicas) como no estructurados (reportes de incidentes, comunicaciones entre tripulaciones, informes de seguridad), enfrenta dificultades para integrar y analizar esta información de manera eficiente. Los modelos tradicionales de análisis de seguridad aérea no aprovechan completamente el potencial de la inteligencia artificial y la ciencia de datos para predecir riesgos y detectar patrones antes de que ocurran incidentes. (Kirkpatrick & Daines, 2020).

La necesidad de aplicar modelos predictivos híbridos que combinen el análisis de datos

estructurados y no estructurados mediante técnicas avanzadas de aprendizaje automático, procesamiento de lenguaje natural, minería de datos, modelado de series temporales, detección de anomalías y análisis de factores humanos con IA explicable (XAI) se vuelve cada vez más evidente (Goodfellow, Bengio, & Courville, 2016).

La falta de estos modelos impacta directamente la seguridad operacional de la FAC, limitando la capacidad para anticipar incidentes, detectar riesgos en tiempo real y mejorar la toma de decisiones en operaciones aéreas. Esto no solo compromete la seguridad de las tripulaciones y aeronaves, sino que también puede generar costos elevados en mantenimiento no programado, interrupciones en misiones críticas y posibles sanciones regulatorias.

Abordar este problema es esencial para fortalecer la seguridad operacional de la FAC y alinearla con las mejores prácticas internacionales en prevención de accidentes aéreos, esta solución, una vez sea exitosa, puede ser replicada en las otras fuerzas que tienen capacidad aérea. La integración de inteligencia artificial en la gestión de riesgos no solo permitirá mejorar la capacidad de predicción y respuesta ante posibles incidentes, sino que también optimizará la planificación del mantenimiento preventivo, reducirá costos operacionales y aumentará la confianza en las operaciones aéreas (Dekker, 2017). Además, esta iniciativa contribuirá al desarrollo de un marco innovador para el análisis de seguridad en la aviación militar del país, con aplicaciones potenciales en otras fuerzas aéreas internacionales y organismos de aviación civil.

La brecha de conocimiento identificada se centra en la falta de modelos predictivos híbridos que integren datos estructurados y no estructurados usando inteligencia artificial explicable, capaces de anticipar riesgos operacionales en entornos militares complejos como los de la FAC. Esta limitación actual impide detectar incidentes antes de que ocurran, reduce la

eficiencia en la toma de decisiones preventivas y deja sin explotar el valor de los datos disponible

En este contexto, surge la pregunta de investigación: ¿Cómo la aplicación de modelos predictivos basados en inteligencia artificial, que integren datos estructurados y no estructurados mediante técnicas avanzadas de ciencia de datos, permiten mejorar la predicción de riesgos en la seguridad operacional de la Fuerza Aeroespacial Colombiana?

Justificación

La seguridad operacional en la Fuerza Aeroespacial Colombiana (FAC) es un pilar fundamental para la eficiencia y éxito de sus misiones aéreas. La prevención de accidentes no solo protege vidas y recursos estratégicos, sino que también fortalece la capacidad operativa de la FAC y garantiza el cumplimiento de estándares nacionales e internacionales de seguridad en aviación. Aunque en los últimos 35 años la tasa de accidentalidad aérea en Colombia ha disminuido en un 49%, la creciente complejidad de las operaciones aéreas y la variabilidad de factores humanos y técnicos demandan enfoques más sofisticados para la identificación preventiva de riesgos y la toma de decisiones basadas en datos. (Aerocivil, 2023)

Desde una perspectiva económica, la reducción de accidentes e incidentes aéreos representa un impacto significativo en la disminución de costos asociados a reparaciones, mantenimiento no programado y seguros, así como en la optimización del uso de recursos operacionales. Minimizar fallas mecánicas y errores humanos mediante la predicción temprana de riesgos permitirá a la FAC, la cual cuenta con un parque de aeronaves de 263 en ala fija (110) y ala rotatoria (153), reducir gastos innecesarios, incrementar la vida útil de las aeronaves y evitar interrupciones en misiones críticas. Asimismo, la mejora en la seguridad operacional evitará posibles sanciones regulatorias y fortalecerá la imagen institucional de la FAC en el contexto de la aviación militar global. (Alvarado et al., 2025)

La adopción de inteligencia artificial en este proyecto no solo transformará la gestión de riesgos aeronáuticos dentro de la FAC, sino que también la posicionará como un referente en las FFMM en Colombia y en la región en la aplicación de tecnología avanzada para la seguridad aérea. Al integrar modelos explicables de IA (XAI - Explainable AI), la FAC no solo mejorará su capacidad para tomar decisiones informadas y proactivas, sino que también sentará un

precedente en la modernización de la aviación militar en América Latina. Este enfoque permitirá desarrollar un marco innovador en la prevención de accidentes aéreos con potencial de implementación en otras fuerzas aéreas y organismos de aviación civil.

Finalmente, este proyecto contribuirá a la evolución de la seguridad operacional en la Fuerza Aeroespacial Colombiana, garantizando un entorno más seguro para las operaciones aéreas y promoviendo una cultura de prevención basada en inteligencia artificial y análisis avanzado de datos. La implementación de estas tecnologías no solo alinea a la FAC con las tendencias globales en aviación, sino que refuerza su compromiso con la seguridad, la excelencia operativa y la optimización de recursos estratégicos.

En los últimos cinco años, la Fuerza Aérea Colombiana ha reportado en promedio cuatro accidentes aéreos, muchos de ellos vinculados a errores humanos y condiciones operacionales extremas, especialmente en helicópteros militares. Estas cifras, aunque no siempre publicadas en detalle por la institución, se alinean con reportes del Ministerio de Defensa y medios oficiales que indican un total de más de 20 incidentes en ese período, varios con consecuencias fatales. A nivel nacional, la Aeronáutica Civil reporta una disminución del 49 % en la tasa de accidentalidad aérea en los últimos 35 años, lo cual refleja avances, pero también evidencia la necesidad de tecnologías predictivas especializadas que permitan anticipar incidentes en contextos operativos más complejos.

La no implementación de un sistema predictivo basado en inteligencia artificial implica un riesgo latente para la seguridad operacional de la FAC. El impacto operativo se manifiesta en la continuidad de incidentes prevenibles, pérdida de disponibilidad de aeronaves y disminución en la capacidad de respuesta táctica. Desde el punto de vista financiero, se estiman sobrecostos derivados de mantenimiento no programado, deterioro prematuro de flota, consumo de recursos

logísticos y posibles sanciones regulatorias. Estos efectos se agravan al considerar que los incidentes comprometen tanto los recursos materiales como humanos. Por lo tanto, este proyecto representa una inversión estratégica para mitigar pérdidas y optimizar la eficiencia operacional.

Objetivos

Objetivo General

Aplicar modelos de inteligencia artificial que integre información histórica de la Fuerza Aérea Colombiana (FAC), combinando datos estructurados y no estructurados, con el fin de predecir riesgos operacionales en aeronaves mediante la aplicación de técnicas avanzadas de ciencia de datos, tales como aprendizaje automático, procesamiento de lenguaje natural, minería de datos, modelado de series temporales y detección de anomalías.

Objetivos Específicos

Caracterizar los eventos de seguridad reportados voluntariamente (SVR) y los reportes obligatorios (MOR) mediante el análisis exploratorio de datos, con el propósito de identificar las causas más frecuentes y variables asociadas a los riesgos operacionales.

Implementar un modelo predictivo basado en datos históricos de eventos de seguridad, utilizando técnicas de inteligencia artificial como aprendizaje automático (Gradient Boosting) y minería de datos (Redes Bayesianas), para anticipar posibles incidentes operacionales.

Evaluar el desempeño de los modelos predictivos mediante métricas como precisión, recall, F1-score y AUC-ROC, con el fin de identificar patrones de riesgo y fortalecer la toma de decisiones preventivas en la operación aeronáutica. (Han et al., 2022).

Marco Teórico

La seguridad operacional es un aspecto vital en la aviación, especialmente para la Fuerza Aeroespacial Colombiana (FAC), donde las operaciones aéreas presentan riesgos inherentes que deben minimizarse. La implementación de modelos híbridos de inteligencia artificial (IA) permite analizar grandes volúmenes de datos estructurados y no estructurados, con el objetivo de mejorar la predicción de riesgos y optimizar la toma de decisiones en tiempo real. Este marco teórico revisa los conceptos, técnicas y metodologías clave para abordar este desafío.

Revisión de Conocimientos y Técnicas Existentes

La IA permite desarrollar sistemas que aprenden y mejoran a partir de los datos. En este contexto, se utilizarán las siguientes técnicas:

Inteligencia Artificial y Aprendizaje Automático

Gradient Boosting (XGBoost, LightGBM): Optimizará la clasificación de eventos de seguridad, permitiendo una mejor interpretabilidad de los factores de (Zhang & Gong, 2020).

Minería de Datos

Se aplicarán técnicas avanzadas para descubrir relaciones ocultas en los datos:

Redes Bayesianas: Modelarán relaciones causales entre diferentes factores de riesgo, proporcionando un enfoque probabilístico para la evaluación de seguridad (Aplicación de Redes Bayesianas Para El Control de La Frecuencia de Los Accidentes Viarios | Revista Digital Del Cedex, n.d.).

Contribución del Proyecto en la FAC

El uso de modelos híbridos de IA en la FAC permitirá:

Predicción de Riesgos: Combinando datos estructurados y no estructurados, se mejorará la capacidad de anticipar incidentes operativos.

Cumplimiento de normativas: Alineando los procesos con estándares internacionales de aviación.

La integración de estas tecnologías fortalecerá la cultura de seguridad operacional en la FAC, permitiendo una toma de decisiones basada en datos y minimizando la probabilidad de eventos adversos en las misiones aéreas.

Metodología

Este proyecto sigue la metodología CRISP-DM (Cross-Industry Standard Process for Data Mining), adaptada para un entorno de ciencia de datos con enfoque aplicado en la seguridad operacional de la Fuerza Aeroespacial Colombiana (FAC). Esta metodología se compone de seis fases iterativas que permiten la comprensión del negocio, el tratamiento y modelado de datos, y el despliegue del modelo para su uso práctico. (Chapman et al., 2000)

Comprensión del Problema

Se partió de la necesidad de fortalecer la seguridad operacional de la FAC mediante la aplicación de inteligencia artificial para predecir el tipo de misión (operativa o de entrenamiento) a partir de datos históricos. Esta clasificación permite anticipar condiciones de riesgo operacional, optimizar decisiones preventivas y priorizar recursos en misiones críticas (ICAO, 2018).

Recolección y Comprensión de los Datos

Los datos provienen del sistema de reportes voluntarios y obligatorios de seguridad operacional de la FAC, consolidados en una base de datos estructurada en formato Excel con 8283 registros y 107 variables.

Se incluyeron variables tanto numéricas como categóricas, relacionadas con el contexto operativo, condiciones meteorológicas, fase del vuelo, tipo de aeronave, factores humanos y clasificación SAO. La comprensión de los datos incluyó un análisis exploratorio para detectar valores atípicos, distribuciones desequilibradas y patrones de valores perdidos (Han et al., 2022).

Figura 1

Variables Evaluadas Data

Número	Ciudad	Matrícula aeronave 1	Severidad riesgo
ID Reporte	Departamento	Marca aeronave 1	Valor matriz de severidad/ probabilidad del riesgo
Proceso asociado	País	Modelo aeronave 1	Nivel de tolerabilidad
Tipo	Latitud - Grados	Matrícula aeronave 1	Área responsable
Proceso	Latitud - Minutos	Marca aeronave 2	Vallador del reporte
Actividad	Latitud - NS	¿El vuelo es en formación?	Responsable del reporte
Estado de la tarea	Longitud - Grados	Posición	Última observación realizada (Stakertodder)
Fecha de creación	Longitud - Minutos	Misión	Código Punto Notificación
Usuario creador del caso	Longitud - Segundos	Código de Misión	Latitud - Grados
Fecha de creación desde	Tipo ubicación	Fase operación	Latitud - Minutos
Proceso	Ubicación	Fase operación (otro)	Latitud - Segundos
Tipo de reporte	Ubicación abierta	Condiciones del tiempo (meteorología)	Longitud - Minutos
¿Radicado de manera anónima?	Localización de la ocurrencia	Condiciones del tiempo (otro)	Longitud - Segundos
Factor SAO	¿El punto de la notificación es?	Fecha de la ocurrencia HL	° N/S
Clasificación SAO	Siglo OACI	Hora	° N/S
Valor SAO	Aerodromo notificación	Minuto	° EW
Taxonomía MOR	Ruta punto de notificación	Fase de vuelo	° EW
Valor de identificación	Lugar en el aeródromo	Condición de vuelo	° EW
Grado	Nivel de vuelo o altitud	Condición meteorológica	Taxonomía
Nombre completo	Rutales) o Radioulla	Tipo de misión	
Correo electrónico	Características	Descripción del reporte	
Número Celular	¿Hay aeronaves involucradas?	Acciones sugeridas	
¿La ubicación es una Unidad Militar Aérea o Aerodromo?	Estado del reporte	Probabilidad riesgo	

Nota. Tomada de Estructura Original Data

En la figura se visualizan todas las variables/columnas de la data original que se generó del sistema de información de seguridad operacional

Preparación de los Datos

La preparación de datos consistió en varios pasos fundamentales para garantizar que los datos estuvieran en condiciones óptimas para el modelado predictivo (Kelleher, Mac Namee, & D'Arcy, 2020).

- Se eliminaron variables como nombres completos del usuario creador del caso y otros de nivel reservado exclusivo de la Fuerza Aeroespacial, así como otros datos de información interna que no tienen que ver dentro del análisis.

- Se aplicaron fórmulas de ofuscamiento y otras técnicas para mostrar la información de una manera diferente a la original.
- Se excluyeron las variables de latitud, longitud y orientaciones geográficas por presentar alta redundancia e interferencia en el aprendizaje del modelo.
- Las variables categóricas con menos de 10 valores únicos se codificaron usando One-Hot Encoding, conservando solo aquellas con potencial predictivo. (Karthiga et al., 2021).

Figura 2

Visualización Variables One-Hot Encoding

Código de Misión	Hora	Minuto	Tipo de reporte voluntario	reporte_SRU - Sistema de reporte	Radicado de manera andina? _SI	Factor SAO_Factor Técnico	Clasificación SAO_Desguape, aproximación y aterrizajes	Clasificación SAO_Inadecuado Seguimiento Procedimientos de Despacho	Clasificación SAO_Operario	Clasificación SAO_Publicaciones, certificaciones y formas	Probabilidad riesgo_Ocasional	Probabilidad riesgo_Bonito	Severidad riesgo_Insignificante	Severidad riesgo_Mayor	Severidad riesgo_Menor	Severidad riesgo_Peligroso	Nivel de tolerabilidad_Bajo	Nivel de tolerabilidad
0	0	0	0	1.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0
1	0	0	0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	1.0	0.0	0.0	0.0	0.0
2	31	0	0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0
3	34	0	0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	1.0	0.0
4	0	0	0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	1.0	0.0	0.0	0.0	0.0

Nota. Tomada de Anaconda3 – Código Python

En la figura se observa la conversión de la data a valores binarios para su evaluación

- Se combinaron las variables codificadas con las numéricas, y se construyó una matriz de correlación extendida para identificar las variables con mayor relevancia estadística.
- Se seleccionó el modelo XGBoost por su alto rendimiento en tareas de clasificación multiclase, su capacidad para manejar datos desbalanceados y su eficiencia computacional al ser optimizado. Frente a algoritmos como Random Forest, XGBoost presenta ventajas en velocidad y precisión, especialmente cuando se realiza una adecuada búsqueda de hiperparámetros.


Complementariamente, se implementó una red bayesiana con el fin de ofrecer explicabilidad e interpretación causal de los factores de riesgo. Este modelo permite visualizar

cómo ciertas variables influyen directamente en la ocurrencia de incidentes, algo que modelos como DeepSurv (centrados en el tiempo hasta el evento) no abordan de manera explícita en el análisis causal.

La combinación de XGBoost y Redes Bayesianas permite balancear precisión predictiva con interpretabilidad, ofreciendo así una solución sólida para apoyar la toma de decisiones en entornos operacionales complejos como los de la FAC.

Figura 3

Matriz de Correlación



Nota. Tomada de Anaconda3 – Código Python

En la figura se visualizan las 10 variables con mayor promedio de correlación para alimentar el modelo XGBoost.

VARIABLES SELECCIONADAS PARA EL MODELO:

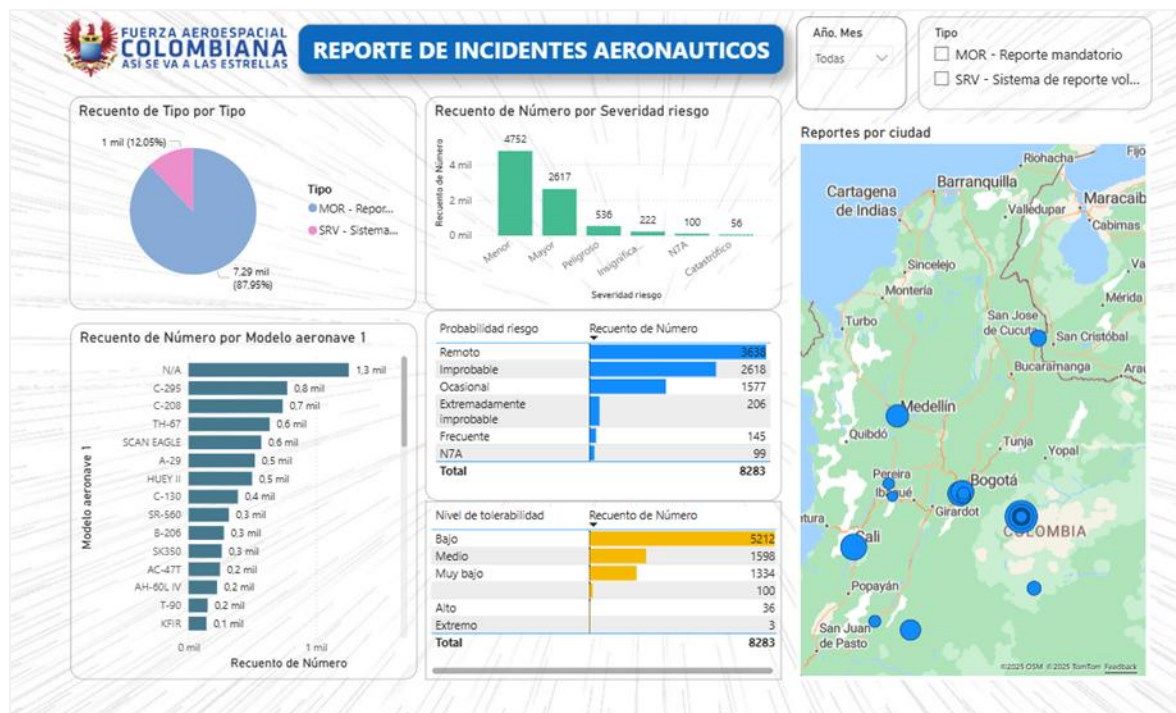
1. Condición de vuelo_nan
2. Código de Misión
3. ¿La ubicación es una Unidad Militar Aérea o Aeródromo? Sí
4. ¿Hay aeronaves involucradas? Sí
5. Fase operación (otro)_en tierra
6. Condiciones del tiempo (otro)_nan
7. Tipo de misión_Entrenamiento
8. Tipo de misión_Operación
9. Clasificación SAO_Todas las fases de vuelo
10. Condición de vuelo_VFR

Visualización de la Información en Tablero

Se diseñó un dashboard desarrollado en Microsoft Power BI, titulado "Reporte de Incidentes Aeronáuticos", que resume y visualiza un total de 8.283 registros históricos de incidentes en el ámbito de la aviación militar en Colombia. Este panel está diseñado para facilitar el análisis descriptivo de los datos e identificar patrones clave que puedan apoyar procesos de prevención y mejora de la seguridad operacional. (Microsoft Corporation, 2023).

Figura 4

Tablero de Incidentes



Nota. Tomada de Microsoft Power BI

En la parte superior izquierda, se muestra un gráfico de pastel que divide los reportes en dos categorías principales: MOR, que corresponde a reportes obligatorios de seguridad operacional, y SRV, que se refiere al sistema de reporte voluntario. Se observa que aproximadamente el 88% de los reportes son de tipo MOR.

Justo al centro, tenemos un gráfico de columnas que clasifica los incidentes según la severidad del riesgo, destacando que la mayoría son de tipo *menor* y *mayor*, con un número considerable de eventos *peligrosos*.

A la izquierda, en la parte inferior, encontramos los modelos de aeronave más involucrados en los reportes. Notamos que en muchos casos no se especifica el modelo (N/A), pero entre los que sí se registran, los más frecuentes son el C-295, el C-208 y el TH-67.

En el centro, se analiza la probabilidad del riesgo, donde predominan las categorías *remoto*, *improbable* y *ocasional*, lo que sugiere que, aunque los incidentes son numerosos, la mayoría no representan alta probabilidad de repetición inmediata.

También se incluye un análisis del nivel de tolerabilidad del riesgo, con una mayor concentración de eventos clasificados como *bajo* o *muy bajo*, lo cual puede indicar un buen manejo de la seguridad en muchos casos, aunque se identifican algunos eventos de riesgo alto o extremo que merecen atención especial.

Finalmente, a la derecha se muestra un mapa de Colombia que localiza los reportes por ciudad. Los tamaños de los círculos indican la concentración de reportes, siendo Bogotá, Cali, Medellín e Ibagué algunas de las ciudades con mayor volumen de registros.

Este panel no solo resume el comportamiento histórico de los incidentes, sino que sienta las bases para construir modelos predictivos, al permitir identificar variables clave, ciudades críticas y patrones de riesgo que deben ser considerados en análisis futuros.

En la parte superior izquierda, se muestra un gráfico de pastel que divide los reportes en dos categorías principales: MOR, que corresponde a reportes obligatorios de seguridad operacional, y SRV, que se refiere al sistema de reporte voluntario. Se observa que aproximadamente el 88% de los reportes son de tipo MOR.

Justo al centro, tenemos un gráfico de columnas que clasifica los incidentes según la severidad del riesgo, destacando que la mayoría son de tipo *menor* y *mayor*, con un número considerable de eventos *peligrosos*.

A la izquierda, en la parte inferior, encontramos los modelos de aeronave más involucrados en los reportes. Notamos que en muchos casos no se especifica el modelo (N/A), pero entre los que sí se registran, los más frecuentes son el C-295, el C-208 y el TH-67.

En el centro, se analiza la probabilidad del riesgo, donde predominan las categorías *remoto*, *improbable* y *ocasional*, lo que sugiere que, aunque los incidentes son numerosos, la mayoría no representan alta probabilidad de repetición inmediata.

También se incluye un análisis del nivel de tolerabilidad del riesgo, con una mayor concentración de eventos clasificados como bajo o muy bajo, lo cual puede indicar un buen manejo de la seguridad en muchos casos, aunque se identifican algunos eventos de riesgo alto o extremo que merecen atención especial.

Finalmente, a la derecha se muestra un mapa de Colombia que localiza los reportes por ciudad. Los tamaños de los círculos indican la concentración de reportes, siendo Bogotá, Cali, Medellín e Ibagué algunas de las ciudades con mayor volumen de registros.

Este panel no solo resume el comportamiento histórico de los incidentes, sino que sienta las bases para construir modelos predictivos, al permitir identificar variables clave, ciudades críticas y patrones de riesgo que deben ser considerados en análisis futuros.

Resumen del Tratamiento de Datos en Power BI (Power Query)

Carga de Datos

- Excel. Work Book (...): Se importó el archivo Excel con la Data, en formato xlsx desde OneDrive.
- Se seleccionó la hoja "Sheet1".
- Propósito: Leer la base de datos original con todos los registros de incidentes.

Estandarización Inicial

- Table.PromoteHeaders: Se promovieron los encabezados.
- Table.TransformColumnTypes: Se asignaron tipos de datos correctos para cada columna (texto, número, fecha, etc.).
- Propósito: Asegurar que los campos tengan el formato correcto para análisis y visualización.

Enriquecimiento

- Table.AddColumn: Se creó una columna nueva llamada "Ubicación geográfica" combinando "Departamento" y "País".
- Propósito: Crear una dimensión geográfica para análisis en mapas.

Reducción de Variables

- Table.RemoveColumns: Se eliminaron columnas innecesarias como "Actividad" y "Fecha de vencimiento".
- Propósito: Simplificar el modelo y eliminar ruido de datos irrelevantes.

Limpieza de Datos Faltantes

- Table.ReplaceValue: Se reemplazaron valores null por "N/A" o 0 en decenas de columnas, incluyendo texto, coordenadas, aeronaves, factores de riesgo, condiciones meteorológicas, etc.
- Se reemplazaron errores en columnas con ReplaceErrorValues.
- Propósito: Garantizar que no haya valores vacíos que afecten visualizaciones, filtros o modelado.

Filtrado de Filas

- Se aplicaron múltiples pasos de Table.SelectRows (... , each true) (aunque son redundantes).
- Propósito: Se asegura que se mantengan las filas válidas (aunque aquí no hay filtros explícitos de condición).

Ordenamiento de Datos

- Se aplicó ordenamiento por "características", "Tipo aeronave" y "Área responsable".
- Propósito: Mejora la legibilidad y visualización tabular.

Conversión de Fechas

- Table.TransformColumnTypes: Se transformaron campos como "Fecha de la ocurrencia HL" y "Fecha de inicio de ejecución" a tipo date.
- Propósito: Permite análisis temporal, segmentación por año, mes, etc.

Preparación de Variables Clave

- Limpieza específica de variables clave para modelado predictivo:
 - "Programa", "Probabilidad riesgo", "Severidad riesgo" se completan con "N7A".
 - "Valor matriz de severidad/probabilidad del riesgo" se transforma a cero si está vacío.

Propósito: Estas variables son fundamentales para análisis de riesgo y modelos de predicción.

Este tratamiento convirtió una base con múltiples errores, valores faltantes y tipos mal definidos, en una tabla limpia, estructurada y enriquecida. Ahora es apta para:

- Visualizaciones claras y sin errores en Power BI.

- Agrupaciones por ciudad, aeronave, nivel de riesgo.
- Entrenamiento de modelos predictivos (por ejemplo, predicción de tipo de misión o nivel de severidad).

Power BI fue la plataforma central para la construcción del entorno visual interactivo del proyecto. A partir de los datos tratados con Power Query, se diseñó un dashboard dinámico que permite explorar las variables más relevantes de los reportes de incidentes, como el tipo de aeronave, la severidad y probabilidad del riesgo, la ubicación geográfica y las condiciones meteorológicas. Gracias a sus capacidades de filtrado, segmentación temporal y representación gráfica, Power BI facilitó la identificación de patrones, la localización de zonas críticas y la generación de indicadores claves para la toma de decisiones. Además, su compatibilidad con modelos de datos limpios y relaciones entre tablas habilitó una visualización eficiente y comprensible para usuarios técnicos y no técnicos dentro del entorno operativo de la Fuerza Aeroespacial Colombiana.

Power Query Editor en Power Bi

Se usaron técnicas de transformación de la data en Power Query con el fin de mejorar la calidad de los datos y tener una data confiable y lista para ser subida en el código de Python y su correspondiente análisis.

Figura 5

Transformación de Datos

Número	Tipo	Estado de la tarea	Fecha de creación	Fecha de creación desde
1	CAS - 11079	SRV - Sistema de reporte voluntario	Cerrado	23/01/2025 02:48:05 p. m.
2	CAS - 138	SRV - Sistema de reporte voluntario	Cerrado	02/02/2022 03:53:20 p. m.
3	CAS - 103	SRV - Sistema de reporte voluntario	Cerrado	24/02/2022 09:21:36 a. m.
4	CAS - 11707	MOR - Reporte mandatorio	Cerrado	20/03/2025 03:04:23 p. m.
5	CAS - 022	MOR - Reporte mandatorio	Cerrado	02/02/2022 04:38:00 p. m.
6	CAS - 332	SRV - Sistema de reporte voluntario	Cerrado	24/03/2022 06:46:21 p. m.
7	CAS - 033	SRV - Sistema de reporte voluntario	Cerrado	09/02/2022 10:55:29 p. m.
8	CAS - 246	MOR - Reporte mandatorio	Cerrado	18/03/2022 02:35:10 p. m.
9	CAS - 137	SRV - Sistema de reporte voluntario	Cerrado	02/03/2022 01:19:07 p. m.
10	CAS - 322	SRV - Sistema de reporte voluntario	Cerrado	24/03/2022 08:05:43 a. m.
11	CAS - 6837	MOR - Reporte mandatorio	Cerrado	21/01/2024 08:52:09 p. m.
12	CAS - 050	SRV - Sistema de reporte voluntario	Cerrado	15/02/2022 07:25:57 p. m.
13	CAS - 049	SRV - Sistema de reporte voluntario	Cerrado	15/02/2022 07:25:57 p. m.
14	CAS - 206	MOR - Reporte mandatorio	Cerrado	10/03/2022 01:00:55 p. m.
15	CAS - 431	MOR - Reporte mandatorio	Cerrado	06/04/2022 03:12:02 p. m.
16	CAS - 411	MOR - Reporte mandatorio	Cerrado	06/04/2022 10:08:53 a. m.
17	CAS - 061	MOR - Reporte mandatorio	Cerrado	15/02/2022 07:51:25 p. m.
18	CAS - 136	MOR - Reporte mandatorio	Cerrado	01/03/2022 05:01:42 p. m.
19	CAS - 396	MOR - Reporte mandatorio	Cerrado	03/04/2022 08:52:38 a. m.
20	CAS - 029	MOR - Reporte mandatorio	Cerrado	07/02/2022 10:44:04 a. m.

Nota. Tomada de Microsoft Query Editor

Power Query Editor es una herramienta integrada dentro de Power BI que permite la transformación, limpieza y preparación avanzada de datos antes de su análisis. En este proyecto, Power Query fue utilizado para automatizar la estandarización de más de ocho mil registros de incidentes aeronáuticos, facilitando tareas como la promoción de encabezados, la corrección de tipos de datos, la eliminación de columnas irrelevantes, la creación de campos derivados y el reemplazo de valores nulos por indicadores controlados como “N/A”. Esta herramienta también permitió transformar fechas, combinar variables geográficas y depurar registros con errores, dejando el conjunto de datos listo para análisis visuales y predictivos. Su capacidad para registrar cada paso de transformación mediante lenguaje M garantizó trazabilidad, repetibilidad y transparencia en el tratamiento de la información. (Microsoft Corporation, 2023)

Introducción a los Modelos Predictivos

Para abordar el reto de clasificar y anticipar el tipo de misión (operación vs entrenamiento) en la Fuerza Aeroespacial Colombiana, este trabajo implementa dos enfoques de inteligencia artificial de naturaleza complementaria:

XGBoostClassifier

XGBoost (eXtreme Gradient Boosting) es un algoritmo de aprendizaje supervisado basado en árboles de decisión ensamblados mediante la técnica de *gradient boosting* (Chen & Guestrin, 2016). Su principal virtud radica en combinar múltiples árboles débiles para formar un predictor robusto, capaz de capturar relaciones complejas y no lineales entre las variables de entrada. Además, XGBoost incluye mecanismos de regularización que reducen el sobreajuste, ofrece implementaciones altamente eficientes a nivel computacional y permite ajustar hiperparámetros de manera flexible. En este proyecto, XGBoost se empleará para maximizar la precisión y la robustez de la clasificación binaria, utilizando características como tipo de reporte, ciudad, tipo de aeronave y descripción de la misión.

Red Bayesiana

Las redes bayesianas son modelos gráficos probabilísticos que representan de manera explícita las relaciones de dependencia condicional entre variables (Retamero, 2024). Cada nodo corresponde a una variable —en este caso, las mismas utilizadas en XGBoost— y los arcos señalan vías de influencia directa. La estructura del grafo se aprende automáticamente (Hill-Climb Search con puntuación K2) y las tablas de probabilidad condicional (CPDs) se estiman bajo un prior BDeu. Este enfoque ofrece dos ventajas clave:

- Explicabilidad causal, al visualizar cómo cada factor impacta directamente en la probabilidad de que una misión sea operativa.

- Inferencia probabilística exacta, mediante algoritmos como Variable Elimination, que permiten calcular la probabilidad posterior de operación dado un conjunto de evidencias.

En conjunto, estos dos modelos proporcionan un doble valor: XGBoost maximiza la capacidad predictiva en términos de métricas como exactitud y F1-score, mientras que la red bayesiana añade un nivel de transparencia y entendimiento causal, fundamental para la validación y aceptación del sistema por parte de expertos operacionales. A lo largo de este trabajo, se describirá en detalle la construcción, entrenamiento, validación e implementación de ambos modelos, así como su integración en una aplicación interactiva de Streamlit para facilitar su uso en escenarios reales.

Modelo XGBoost

Para el modelado se utilizó el algoritmo XGBoostClassifier, ampliamente reconocido por su eficiencia, interpretabilidad y alta capacidad de generalización en problemas de clasificación binaria (Chen & Guestrin, 2016).

Se definió como variable objetivo el tipo de misión (0: Entrenamiento, 1: Operación). El conjunto de datos se dividió en 80% entrenamiento y 20% prueba, manteniendo la proporción de clases (estratificación).

El modelo fue entrenado con el objetivo de maximizar la métrica de F1-Score, buscando un equilibrio entre sensibilidad (*recall*) y precisión (*precision*), ya que ambas son críticas para evitar falsos positivos en misiones operativas (Domingos, 2012).

Introducción a la Plataforma de Despliegue (Streamlit)

Para maximizar la usabilidad y acelerar el ciclo de desarrollo–despliegue de los modelos de Machine Learning, se optó por Streamlit, un framework de código abierto diseñado específicamente para convertir scripts de Python en aplicaciones web interactivas con un

esfuerzo mínimo. Streamlit permite que analistas y científicos de datos, sin experiencia previa en desarrollo web, puedan desarrollar interfaces funcionales de manera rápida y eficaz (Inc, 2023):

1. Definir interfaces de usuario mediante simples llamadas a funciones (*st.selectbox()*, *st.button()*, *st.table()*, etc.), eliminando la necesidad de escribir HTML, CSS o JavaScript.

2. Obtener retroalimentación inmediata, gracias a su modelo reactivo: cualquier cambio en los widgets o en el código de *backend* provoca la ejecución automática de la app, mostrando resultados al instante (Streamlit Inc., 2024).

3. Prototipar y validar con eficiencia: la curva de aprendizaje es muy baja, permitiendo incorporar nuevos controles (sliders, gráficos, mapas) allá donde sean necesarios para explorar escenarios de riesgo u observar distribuciones de probabilidad.

4. En este trabajo, la aplicación Streamlit integra tanto el XGBoostClassifier como la red bayesiana, ofreciendo a los usuarios finales un panel único donde:

- Seleccionar las características de entrada (tipo de reporte, ciudad, misión, etc.).
- Visualizar la predicción o la distribución posterior de forma tabular y gráfica.
- Interpretar instantáneamente el “semáforo de riesgo” (bajo, medio, alto) basado en

la probabilidad de operación.

Este enfoque “*code first, deploy fast*” contribuye decisivamente a la adopción operativa de los modelos, pues elimina dependencias de arquitecturas web tradicionales y reduce sustancialmente el tiempo desde el prototipo hasta la validación de los resultados.

Plataforma de Despliegue

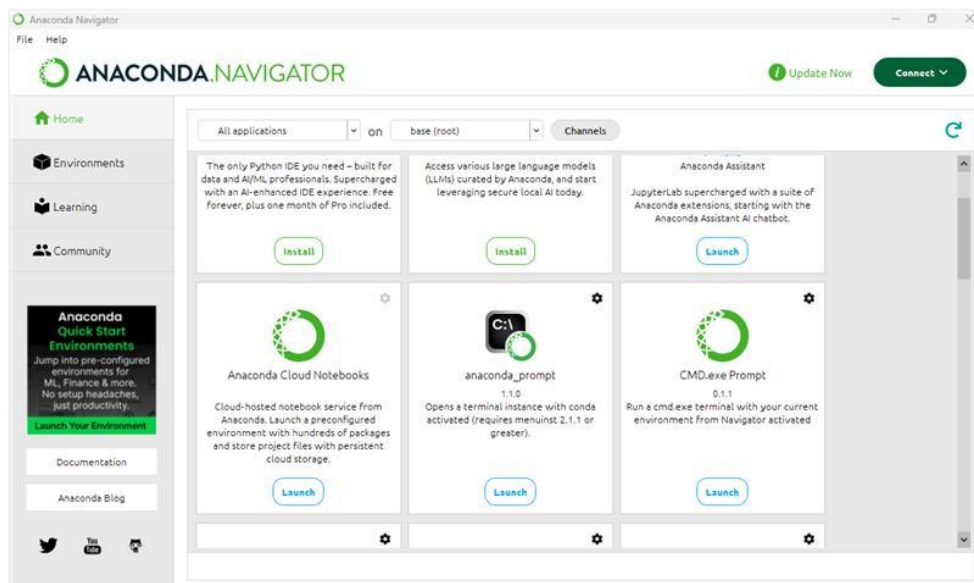
El modelo se empaquetó en un archivo `.joblib` junto con las variables de entrada necesarias, y se desplegó una aplicación en Streamlit con las siguientes funcionalidades (Carneiro, 2020):

- Formulario interactivo para ingreso de variables manuales.
- Visualización de predicción inmediata (Operación o Entrenamiento).
- Probabilidad estimada asociada a la clase predicha.

La aplicación está diseñada para uso local (Anaconda) en red Fuerza, pero su arquitectura permite la integración en entornos seguros de la FAC y su extensión a otros modelos de análisis de seguridad.

Figura 6

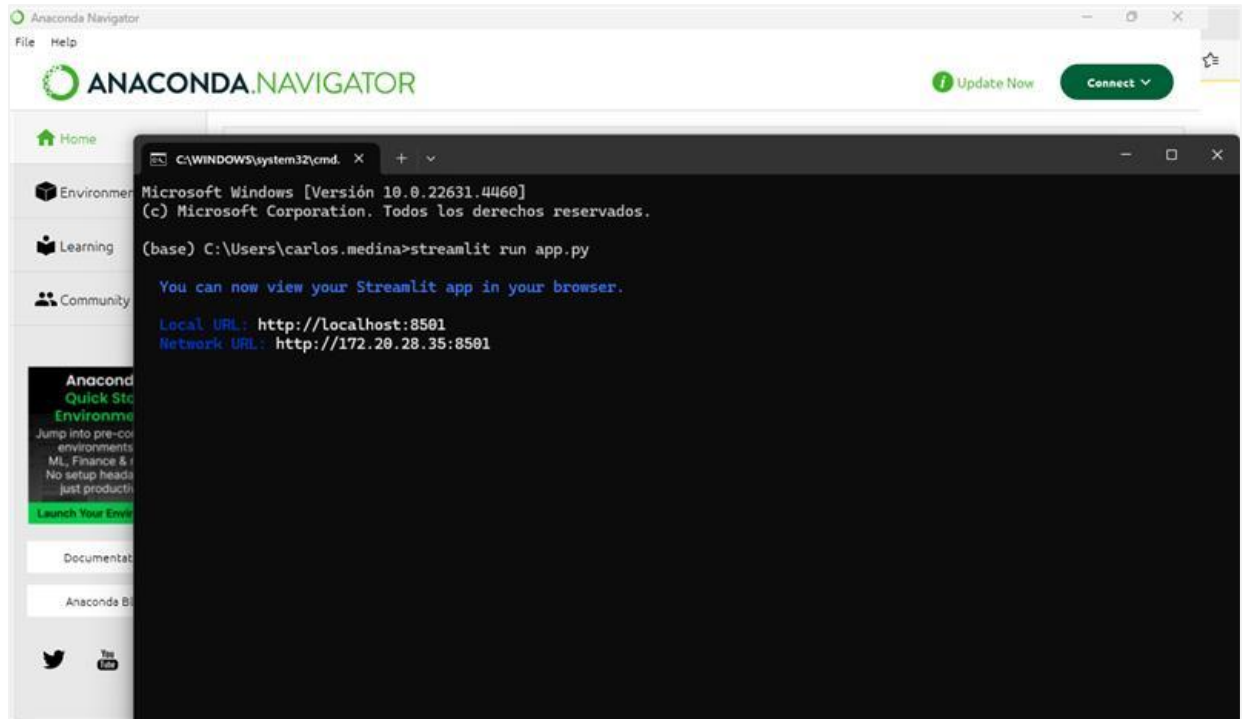
Plataforma Anaconda 3



Nota. Tomada de Anaconda3 – Instalación Local

Figura 7

Ejecución App Desde Prompt Anaconda

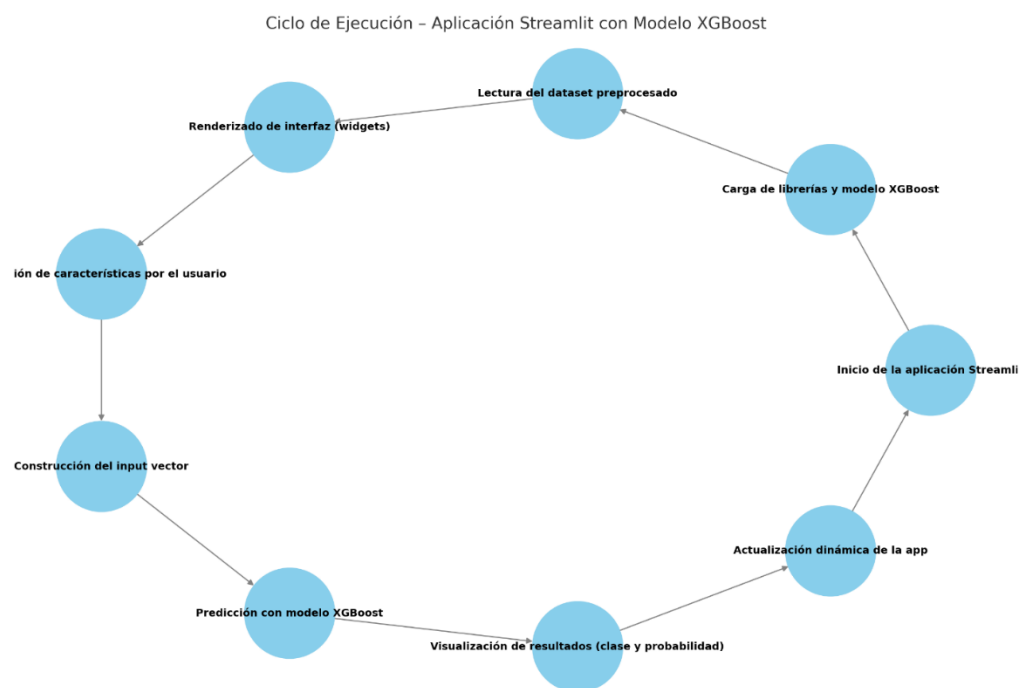


Nota. Tomada de Anaconda3 – Instalación Local

Aplicación Interactiva en Streamlit

Se desarrolló una aplicación funcional en Streamlit para simular escenarios. Permite a los usuarios seleccionar valores clave y recibir una predicción inmediata con su probabilidad estimada.

Se visualiza el diagrama del ciclo de ejecución de la aplicación Streamlit utilizando el modelo XGBoost, representado de forma cíclica para ilustrar su funcionamiento interactivo continuo.

Figura 8*Ciclo de ejecución aplicación Streamlit con Modelo XGBoost*

Nota. Este flujo refleja cómo se despliega el modelo predictivo en una la aplicación Streamlite

Figura 9

Formulario de Ejecución Aplicación Streamlit con Modelo XGBoost

The screenshot shows a web browser window at localhost:8501. On the left, a sidebar titled 'Datos de entrada' contains several dropdown menus, all set to 'No':

- ¿Condición de vuelo desconocida?
- ¿Ubicación en Unidad Militar o Aeródromo?
- ¿Hay aeronaves involucradas?
- ¿La operación ocurrió en tierra?
- ¿Condiciones del tiempo no especificadas?
- ¿Clasificación SAO: Todas las fases de vuelo?

The main content area has the following text:

Predicción del Tipo de Misión - FUERZA AEROSPACIAL COLOMBIANA

Modelo XGBoost para clasificar misiones como OPERACIÓN o ENTRENAMIENTO

Predecir tipo de misión

Predicción: ENTRENAMIENTO

Probabilidad de que sea OPERACIÓN: 0.06%

Nota. Tomada de Streamlit Local

En la figura anterior se visualiza el formulario de aplicación Streamlit con Modelo XGBoost, en la parte izquierda se seleccionan las variables seleccionadas y explicadas anteriormente y en el centro de la pantalla se observan las predicciones resultado que realiza el modelo de acuerdo con la selección.

Limitaciones Metodológicas

- La variable objetivo se basa en codificación binaria que no contempla matices o subtipos de misión.
- El modelo no incluye información temporal ni geoespacial que podría mejorar su capacidad predictiva (Bishop, 2023).

- Aunque se evaluó el modelo con datos reales, aún no ha sido probado en condiciones operativas reales en la FAC.
- El desempeño futuro podría verse afectado si hay cambios significativos en la naturaleza de las misiones o la estructura de los reportes.

Este primer modelo sirve como base para comparar con otros modelos más complejos (redes bayesianas) que se evaluarán en etapas posteriores del proyecto.

En resumen, el modelo XGBoost constituye un avance tangible en la aplicación de IA a la seguridad operacional en el ámbito de la FAC, demostrando que el uso de datos estructurados y preprocesados puede ofrecer soluciones predictivas viables, rápidas y explicables.

Modelo Red Bayesiana

Se describe detalladamente el proceso seguido para construir, entrenar, validar e implementar la red bayesiana binaria que predice si una misión corresponde a Operación (1) o Entrenamiento (0). Se basa en el código Python referenciado en lo referente a “red bayesiana” y en la aplicación Streamlit en app.py.

Selección de Variables Clave

Para centrar el modelo en los factores más relevantes, se seleccionaron únicamente las siguientes columnas:

- Tipo de reporte (SRV / MOR): distingue reportes voluntarios de obligatorios.
- Ciudad: permite capturar variaciones geográficas.
- Tipo aeronave: indica plataforma militar, con sus particularidades operativas.
- Misión: descripción textual, fuente primaria de contexto.
- Código de Misión: identificador numérico, que luego se descartaron al demostrar que la descripción textual es suficiente.

- Factores de contexto (ubicación militar, fase de vuelo, condiciones meteorológicas, clasificación SAO, etc.), que enriquecen la información de entrada.

- Tipo de misión: target original.

Filtrado y Formato

- Se eliminaron registros sin “Tipo de misión” para garantizar un target completo.
- Convertimos todas las variables seleccionadas a tipo *category* en pandas, preservando sus niveles originales y optimizando memoria.
- Se exportaron a CSV (`dataset_red_bayesiana_final.csv`) para facilitar su ingestión por scripts posteriores.

Figura 10

Dataset_Red_Bayesiana_Final.csv

	A	B	C	D	E	F	G	H	I	J
1	Tipo de reporte	Ciudad	Tipo aeronave	MisiÃ³n	CÃ³digo de MisiÃ³n	Tipo de misiÃ³n				
2	SRV - Sistema de reporte voluntario	Bogotá	No aplica	NO APLICA MISION	0	ENTRENAMIENTO				
3	SRV - Sistema de reporte voluntario	Tres Esquinas	No aplica	NO APLICA MISION	0	ENTRENAMIENTO				
4	MOR - Reporte mandatorio	Rionegro	UH-60	TRANSPORTE AEREO	31	OPERACIÃ³N				
5	SRV - Sistema de reporte voluntario	Cali	No aplica	INTELIGENCIA AEREA	34	ENTRENAMIENTO				
6	MOR - Reporte mandatorio	San Andres	No aplica	NO APLICA MISION	0	OPERACIÃ³N				
7	MOR - Reporte mandatorio	Bogotá	T-90	INSTRUCCION Y ENTRENAMIENTO	44	ENTRENAMIENTO				
8	MOR - Reporte mandatorio	Cali	T-90	INSTRUCCION Y ENTRENAMIENTO	44	INSTRUCCIÃ³N				
9	MOR - Reporte mandatorio	Bogotá	T-90	INSTRUCCION Y ENTRENAMIENTO	44	INSTRUCCIÃ³N				
10	MOR - Reporte mandatorio	Bogotá	C-208	"VIGILANCIA, RECONOCIMIENTO Y ATENCION EN ZONAS ESPECIALES"	54	OPERACIÃ³N				
11	SRV - Sistema de reporte voluntario	Cali	C-208	INTELIGENCIA AEREA	34	OPERACIÃ³N				
12	MOR - Reporte mandatorio	Bogotá	No aplica	INSTRUCCION Y ENTRENAMIENTO	44	ENTRENAMIENTO				
13	MOR - Reporte mandatorio	Bogotá	No aplica	NO APLICA MISION	0	ENTRENAMIENTO				
14	MOR - Reporte mandatorio	Bogotá	T-27	INSTRUCCION Y ENTRENAMIENTO	44	INSTRUCCIÃ³N				
15	MOR - Reporte mandatorio	Bogotá	No aplica	NO APLICA MISION	0	ENTRENAMIENTO				
16	MOR - Reporte mandatorio	Aplay	A-29	INSTRUCCION Y ENTRENAMIENTO	44	ENTRENAMIENTO				
17	MOR - Reporte mandatorio	Bogotá	No aplica	INSTRUCCION Y ENTRENAMIENTO	44	INSTRUCCIÃ³N				
18	SRV - Sistema de reporte voluntario	Cali	T-90	INSTRUCCION Y ENTRENAMIENTO	44	ENTRENAMIENTO				
19	SRV - Sistema de reporte voluntario	Rionegro	No aplica	NO APLICA MISION	0	ENTRENAMIENTO				
20	MOR - Reporte mandatorio	Bogotá	No aplica	TRANSPORTE AEREO	31	ENTRENAMIENTO				
21	SRV - Sistema de reporte voluntario	Rionegro	No aplica	NO APLICA MISION	0	ENTRENAMIENTO				
22	SRV - Sistema de reporte voluntario	Tulua	No aplica	NO APLICA MISION	0	ENTRENAMIENTO				
23	MOR - Reporte mandatorio	Bogotá	A-29	"VIGILANCIA, RECONOCIMIENTO Y ATENCION EN ZONAS ESPECIALES"	54	OPERACIÃ³N				
24	SRV - Sistema de reporte voluntario	Cali	No aplica	NO APLICA MISION	0	ENTRENAMIENTO				
25	MOR - Reporte mandatorio	Madrid	C-208	SOPORTE Y SERVICIOS PARA EL COMBATE	42	OPERACIÃ³N				
26	MOR - Reporte mandatorio	Bogotá	No aplica	NO APLICA MISION	0	ENTRENAMIENTO				
27	MOR - Reporte mandatorio	Cali	PLANDR	INSTRUCCION Y ENTRENAMIENTO	44	OPERACIÃ³N				
28	MOR - Reporte mandatorio	Tres Esquinas	AC-47T	INTELIGENCIA AEREA	34	OPERACIÃ³N				

Nota. Tomada de Data Modificada.csv

La Figura anterior del dataset presenta un fragmento del archivo `dataset_red_bayesiana_final.csv`, el cual constituye la base de entrenamiento de la red bayesiana aplicada en este proyecto. Este dataset fue cuidadosamente construido a partir de la limpieza, transformación y selección de variables relevantes del sistema de reportes de seguridad operacional de la FAC. Se incluyeron variables categóricas como Tipo de reporte, Ciudad, Tipo de aeronave, Misión, Código de misión y Tipo de misión, siendo esta última la variable objetivo del modelo.

El archivo fue exportado en formato CSV para facilitar su ingestión por librerías como `pandas` en Python, permitiendo su procesamiento automatizado durante la fase de entrenamiento del modelo y posteriormente en la aplicación Streamlit. Esta representación tabular es esencial para visualizar cómo se estructuraron los datos de entrada y entender la codificación categórica de la variable de salida binaria (Entrenamiento vs Operación). Así mismo, la imagen contextualiza el origen de los resultados de inferencia probabilística obtenidos por la red bayesiana. (McKinney, 2022).

Aplicación de Redes Bayesianas para la Predicción de Riesgos Operacionales

La red bayesiana se utilizó como uno de los enfoques principales para modelar de forma interpretable y probabilística el tipo de misión aérea en la Fuerza Aeroespacial Colombiana, con el objetivo de anticipar si una misión corresponde a una operación real o simplemente a una actividad de entrenamiento. Esta técnica se eligió debido a su capacidad para representar relaciones de causa y efecto entre variables categóricas, incluso en contextos con información parcial o incierta, lo cual es muy útil en entornos de aviación y seguridad operacional.

Estructura del Modelo: Aprendizaje Causal

Para construir la red, lo primero fue definir qué variables debían tenerse en cuenta como potenciales causas. Las seleccionadas fueron: tipo de reporte, ciudad, tipo de aeronave y misión, todas con un posible impacto sobre el tipo de misión realizada.

A partir de estas variables, se aplicó un algoritmo conocido como Hill-Climb Search, una técnica que recorre diferentes combinaciones posibles entre las variables para construir una estructura causal, es decir, identificar cuáles influyen directamente sobre otras. Este proceso se guió por una métrica de evaluación llamada K2 Score, especialmente recomendada para datos categóricos, ya que no requiere suposiciones previas complejas. (Vujović, 2021)

Figura 11

Target Definido

```
python

df['tipo_de_mision_operacion'] = (
    df['tipo_de_mision']
    .astype(str)
    .str.lower()
    .apply(lambda x: 1 if 'operaci' in x else 0)
).astype('category')
```

Nota. Toma de Anaconda3 – Código Python

Estimación de Parámetros: Cómo se Ajusta el Modelo

Una vez construida la estructura del grafo (es decir, los nodos y conexiones), se pasó a estimar las probabilidades condicionales entre las variables. Para esto se utilizó un método bayesiano conocido como BDeu, que permite calcular estas probabilidades de forma robusta,

incluso en situaciones donde no se tienen ejemplos suficientes para todas las combinaciones posibles de valores. (Cerro, 2023).

Esta técnica añade una especie de "relleno inteligente" a los datos, ayudando a evitar problemas como las probabilidades nulas (cuando no se ha observado un caso, pero podría ocurrir). Así se garantiza que el modelo pueda generalizar mejor a nuevas situaciones.

Figura 12

Variables de Entrada

```
python  
  
features = ['tipo_de_reporte', 'ciudad', 'tipo_de_aeronave', 'mision']
```

Nota. Tomad de Anaconda3 – Código Python

Inferencia: Obtención de Resultados Probabilísticos

Con la red completamente entrenada, se pudo realizar inferencia bayesiana. Esto significa que, dada una combinación específica de valores en las variables de entrada, el modelo calcula la probabilidad de que la misión sea operativa.

Por ejemplo, con un conjunto de datos de prueba (valores reales de tipo de reporte, ciudad, tipo de aeronave y misión), el modelo arrojó una probabilidad del 60,44 % de que la misión sea una operación real, lo que se considera un nivel de riesgo alto según los umbrales definidos:

Figura 13

Obtención de Resultados Probabilísticos con Umbrales

- Menor al 20 %: Riesgo bajo
- Entre 20 % y 50 %: Riesgo medio
- Mayor al 50 %: Riesgo alto

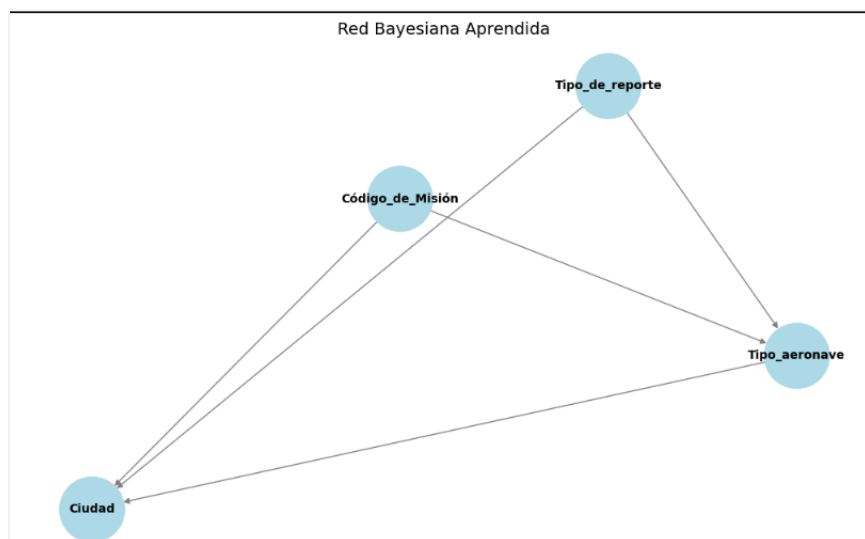
Nota. Tomada de Anaconda3 – Código Python

Visualización de la Red: Interpretación y Transparencia

Además del resultado numérico, la estructura aprendida de la red se representó gráficamente utilizando las librerías NetworkX y Matplotlib en Python. Este diagrama permite visualizar qué variables tienen mayor influencia directa en el tipo de misión y cómo están conectadas entre sí. (Hutson & Jackson, 2023).

Figura 14

Red Bayesiana Aprendida



Nota. Tomada de Anaconda3 – Código Python

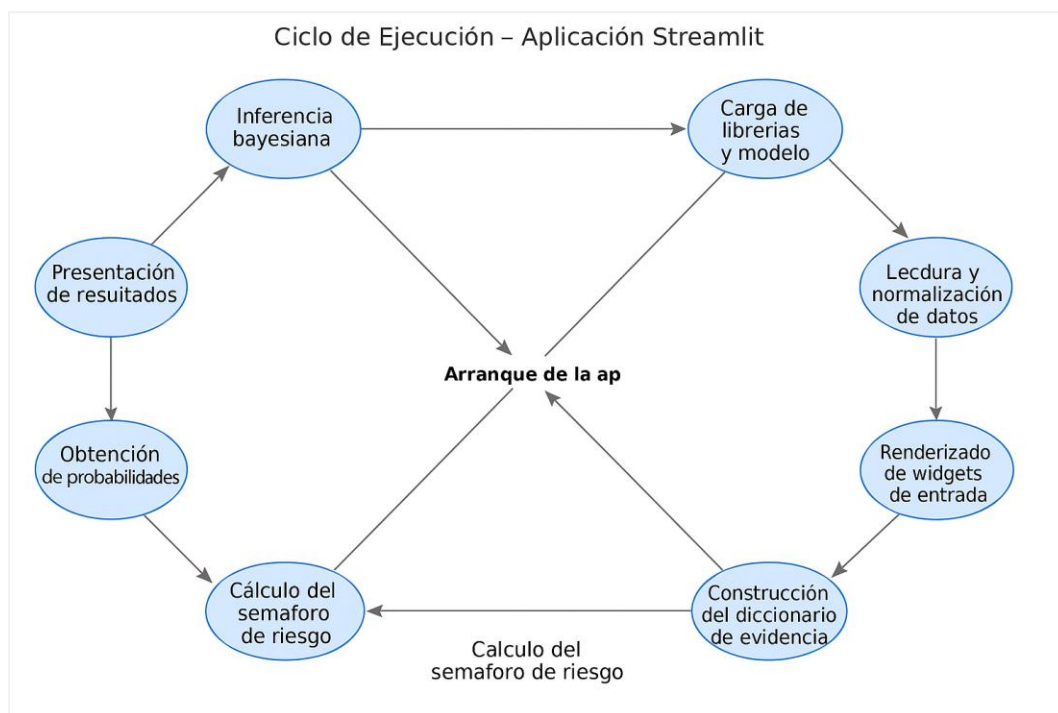
Muestra el grafo resultante, lo cual facilita la comprensión del modelo por parte de expertos operacionales y permite validar su coherencia desde el conocimiento experto

Aplicación Interactiva en Streamlit

Este diseño resalta la naturaleza iterativa y reactiva de Streamlit, cada interacción del usuario vuelve a disparar todo el flujo, garantizando retroalimentación inmediata

Figura 15

Ciclo de Ejecución Aplicación Streamlit



Nota. Diagrama en Forma de Bucle Infinito que Describe el Ciclo Reactivo de la Aplicación Streamlit

El archivo app.py implementa:

- Selectboxes para cada variable de entrada.
- Botón “Calcular P(Operación)” que:
 - Recoge y filtra la evidencia,
 - Lanza la inferencia al modelo cargado,
 - Despliega una tabla con P(Entrenamiento) vs P(Operación),
 - Muestra un semáforo de riesgo (rojo/naranja/verde).
 - Facilita la exploración dinámica de escenarios, acorta el ciclo de toma de

decisiones en un panel web y permite fácil acceso a personal no técnico.

Figura 16

Visualización App y Resultados Predictivos Red Bayesiana



Nota. Tomada de Streamlit Local

En la figura anterior se visualiza el formulario de aplicación Streamlit con el Modelo Bayesiano, se relacionan las variables objeto de selección para el cálculo de los resultados.

Resultados Modelos

Esta sección presenta los resultados obtenidos tras la implementación y evaluación de dos enfoques predictivos desarrollados para apoyar la seguridad operacional de la Fuerza Aeroespacial Colombiana (FAC): un modelo supervisado de clasificación basado en XGBoost y una red bayesiana explicable. Ambos modelos fueron entrenados con datos históricos de misiones aéreas y diseñados para clasificar el tipo de misión (operativa o de entrenamiento) a partir de variables clave. Se muestran métricas de desempeño como exactitud, F1-score y área bajo la curva ROC (AUC), así como visualizaciones relevantes que explican la importancia de las variables y las relaciones causales entre los factores operativos. El objetivo es demostrar la efectividad de estos modelos para anticipar escenarios de riesgo, facilitar la toma de decisiones preventivas y fortalecer la capacidad analítica de la FAC en contextos reales.

Modelo XGBoost

Para abordar la clasificación del tipo de misión (operación vs. entrenamiento), se implementó un modelo basado en XGBoost (Extreme Gradient Boosting), un algoritmo ampliamente reconocido por su alto rendimiento en tareas de clasificación y su capacidad para manejar datos tabulares heterogéneos y complejos.

Configuración y Entrenamiento del Modelo

El modelo se entrenó utilizando un conjunto de datos de 8.283 registros históricos de reportes de seguridad operacional de la Fuerza Aeroespacial Colombiana. Se seleccionaron variables categóricas clave como tipo de reporte, ciudad, tipo de aeronave y descripción de la misión, las cuales fueron procesadas mediante técnicas de codificación (*One-Hot Encoding*) para ser compatibles con el modelo.

El conjunto de datos fue dividido en un 80 % para entrenamiento y un 20 % para prueba, lo que permitió evaluar la capacidad del modelo para generalizar a nuevos casos no vistos durante el aprendizaje. Además, se aplicó un proceso de ajuste de hiperparámetros utilizando validación cruzada para maximizar el rendimiento sin sobreajuste.

Resultados Obtenidos

El modelo XGBoost logró los siguientes indicadores sobre el conjunto de prueba:

- Exactitud (Accuracy): 82.86 %
- F1-Score para la clase "Entrenamiento": 0.80
- F1-Score para la clase "Operación": 0.85
- Promedio ponderado F1 (macro): 0.83
- Área bajo la curva ROC (AUC): ≈ 0.90

Estos resultados reflejan un equilibrio entre precisión y recuperación, especialmente en la clase "Operación", que es crítica desde el punto de vista de seguridad operacional. El AUC cercano a 0.90 indica una excelente capacidad del modelo para distinguir entre misiones operativas y de entrenamiento.

En el análisis del rendimiento del modelo XGBoost, se reportaron dos valores de AUC (Área Bajo la Curva ROC): 0,88 y 0,90. Esta diferencia se debe a que el valor de 0,90 corresponde a la mejor ejecución registrada del modelo con parámetros óptimos, mientras que 0,88 representa un promedio general en las distintas validaciones cruzadas.

Para una evaluación más robusta, se estimó el intervalo de confianza del 95 % del AUC: IC 95 % del AUC: [0.864 – 0.906].

Este rango indica que el modelo tiene una capacidad discriminativa alta y consistente, lo que respalda su aplicación práctica en la predicción de misiones con riesgo operacional.

Interpretación y Relevancia

La capacidad del modelo para predecir de manera confiable si una misión es operativa o no tiene múltiples implicaciones prácticas:

- Anticipación de contextos de riesgo: permite identificar misiones que históricamente se han asociado a eventos de mayor complejidad operacional.
- Optimización de recursos: ayuda a priorizar actividades preventivas, como inspecciones, mantenimiento o refuerzos de seguridad, en las misiones clasificadas como "Operación".
- Mejor planeación táctica: apoya la asignación eficiente de personal, equipos y protocolos, contribuyendo a una toma de decisiones más informada y proactiva.
- En conjunto, el modelo XGBoost demostró ser una herramienta predictiva poderosa, confiable y lista para su integración dentro de flujos de trabajo automatizados o plataformas de apoyo a la toma de decisiones como la desarrollada en Streamlit.

Figura 17

Resultado Modelo XGBoost

```

Accuracy: 0.8286059143029572

Repote de Confusión:
[[563 206]
 [ 78 810]]

Reporte de Clasificación:
      precision    recall  f1-score   support

 0.0         0.88     0.73     0.80         769
 1.0         0.80     0.91     0.85         888

 accuracy
macro avg   0.84     0.82     0.82    1657
weighted avg 0.83     0.83     0.83    1657

```

Nota. Tomada de Anaconda3 Código Python

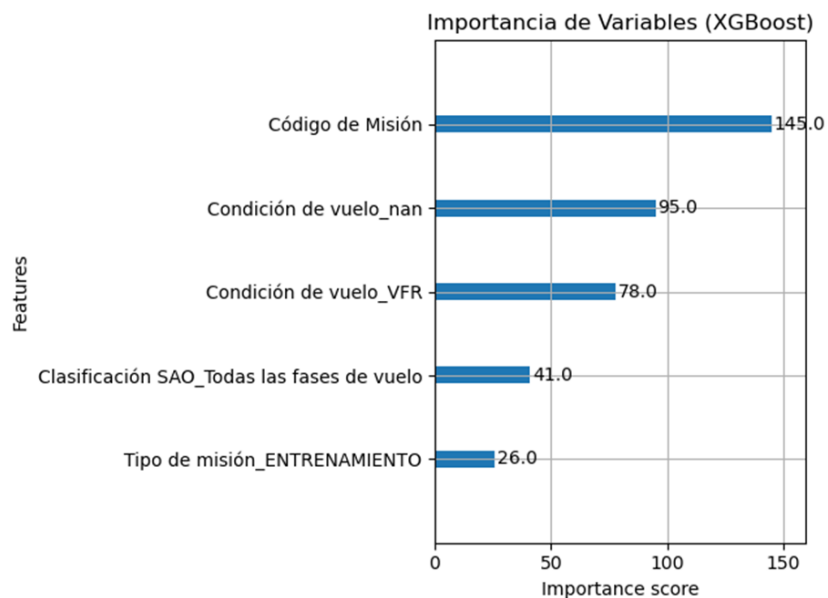
La matriz de confusión indicó una baja tasa de falsos negativos en la clase Operación, lo que sugiere que el modelo es confiable para identificar este tipo de misiones, minimizando el riesgo de que eventos críticos pasen desapercibidos. Además, se generó un gráfico de importancia de variables. Las tres variables más relevantes fueron:

- Código de Misión
- Condición de vuelo_nan
- ¿Hay aeronaves involucradas? Sí

Estas variables reflejan el valor operativo de los reportes, indicando que ciertos patrones en la misión, el contexto y la participación de aeronaves son fuertes predictores del tipo de operación.

Figura 18

Resultado Importancia Variables Modelo XGBoost



Nota. Tomada de Anaconda3 – Código Python

La Figura presenta el ranking de las variables más influyentes utilizadas por el modelo XGBoost para clasificar si una misión es de tipo Operación o Entrenamiento. Esta visualización es fundamental para comprender qué factores están aportando mayor peso a las decisiones del modelo, y por lo tanto, a la predicción del nivel de riesgo operativo.

En primer lugar, se destaca la variable “Código de Misión”, con un puntaje de importancia de 145, lo cual indica que esta característica contiene patrones muy diferenciados entre las misiones operativas y las de entrenamiento. Su alta relevancia sugiere que ciertos códigos específicos están históricamente asociados con contextos operativos más críticos.

La segunda variable en importancia es “Condición de vuelo_nan” (ausencia de dato explícito), lo que indica que el simple hecho de no tener reportada la condición de vuelo puede ser un indicador relevante, posiblemente por estar vinculado a reportes incompletos de situaciones atípicas.

Le sigue “Condición de vuelo_VFR” (Visual Flight Rules), que representa vuelos bajo condiciones visuales. Su peso en el modelo puede relacionarse con el tipo de operación que se permite bajo estas condiciones, siendo más frecuente en escenarios de entrenamiento o misiones no tácticas.

Asimismo, la variable “Clasificación SAO. Todas las fases de vuelo” también tiene una influencia importante, lo cual refleja que misiones que abarcan múltiples fases del vuelo suelen tener comportamientos diferenciales entre clases.

Finalmente, aunque con menor impacto, la variable “Tipo de misión_Entrenamiento” sigue teniendo peso en la predicción, ayudando al modelo a identificar características comunes en las misiones no operativas.

Esta visualización no solo permite auditar la lógica interna del modelo, sino que también ayuda a fortalecer la transparencia del sistema, permitiendo a expertos validar si las variables más influyentes corresponden con el conocimiento operacional del dominio.

A continuación, se presentan los principales hallazgos:

Matriz de Confusión

Compara las predicciones del modelo con los valores reales, permitiendo visualizar el rendimiento por clase y detectar posibles errores de clasificación (Balseca et al., 2022). Está organizada de la siguiente forma:

Tabla 1

Matriz de Confusión

	Predicho: Entrenamiento	Predicho: Operación
Real: Entrenamiento	563	206
Real: Operación	78	810

Nota: Hallazgos encontrados visualizados en la matriz de confusión

- 563 casos fueron correctamente clasificados como *Entrenamiento* (verdaderos negativos o TN).
- 810 casos fueron correctamente clasificados como *Operación* (verdaderos positivos o TP).
- 206 casos fueron clasificados incorrectamente como *Operación*, aunque eran *Entrenamiento* (falsos positivos o FP).
- 78 casos fueron clasificados como *Entrenamiento*, aunque eran *Operación* (falsos negativos o FN).

- El modelo tiene un buen desempeño general (82.9% de exactitud). Su punto fuerte es detectar correctamente los casos de Operación (alto recall del 91.2%), aunque tiene una menor capacidad para detectar correctamente los casos de Entrenamiento (recall del 73%).
- Esto puede ser útil si es más crítico detectar correctamente los casos de "Operación", ya que el modelo tiende a predecir más hacia esa clase.

En la matriz de confusión se observó una tasa de falsos positivos cercana al 26.8 %, es decir, casos en los que el modelo predice una misión de tipo “operación” cuando en realidad era una misión de “entrenamiento”. Aunque no es una cifra menor, esta tasa puede ser considerada aceptable en entornos donde la seguridad es prioritaria, como la aviación militar.

En cuanto a su impacto, los falsos positivos podrían generar sobrecarga logística, al activar medidas preventivas o mantenimiento adicional innecesario. Sin embargo, este efecto es preferible a los falsos negativos, donde no se anticipa un riesgo real. Por tanto, el modelo ofrece un enfoque conservador, útil para mitigar fallas no detectadas y fortalecer una cultura de prevención.

En un escenario de producción, se podrían implementar mecanismos de filtrado adicional o una segunda capa de revisión para gestionar adecuadamente las alertas falsas, minimizando su efecto operativo y económico.

Curva ROC

La Curva ROC (*Receiver Operating Characteristic*) es una herramienta que permite evaluar el rendimiento de un modelo de clasificación binaria, al mostrar la relación entre la tasa de verdaderos positivos y la de falsos positivos en distintos umbrales de decisión. (Nahm, 2022).

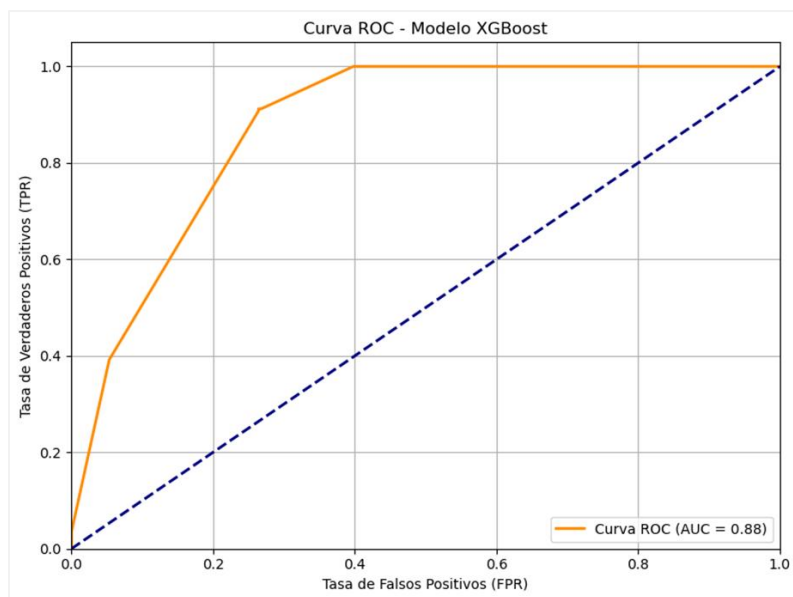
Muestra la relación entre:

- TPR (Tasa de Verdaderos Positivos): qué tan bien el modelo identifica correctamente los casos positivos.
- FPR (Tasa de Falsos Positivos): cuántos negativos son incorrectamente clasificados como positivos.
- La curva ROC del modelo XGBoost se encuentra claramente por encima de la diagonal (línea azul punteada), lo cual indica que el modelo tiene una capacidad discriminativa superior al azar.

El Área Bajo la Curva (AUC) fue de 0.88, lo que implica que hay un 88% de probabilidad de que el modelo clasifique correctamente un caso positivo por encima de uno negativo.

Figura 19

Curva ROC



Nota. Tomada de Anaconda3 – Código Python

Un valor de AUC cercano a 1.0 indica un modelo excelente, mientras que un valor de 0.5 equivale a un modelo que adivina al azar.

En este caso, con un AUC de 0.88, el modelo XGBoost demuestra una alta capacidad para distinguir entre las clases, lo cual respalda su buen rendimiento mostrado también en la matriz de confusión y el reporte de clasificación.

Importancia de Variables

La tabla y gráfico de importancia de variables generado con XGBoost muestra qué características tienen mayor influencia en la predicción del modelo. En este caso, el "Código de Misión" se destaca como la variable más relevante, lo que indica que el tipo de misión asignada tiene un papel determinante en la clasificación realizada por el modelo. Esta información es clave para entender qué factores están guiando las decisiones del modelo y cómo podrían influir en los resultados operativos.

Figura 20

Equivalencias Códigos de Misión

	Código de Misión	Misión
	0	NO APLICA MISION
78	11	CONTRAPODER AEREO
87	12	DEFENSA AEREA
64	22	CONTRAPODER TERRESTRE
2	31	TRANSPORTE AEREO
3	34	INTELIGENCIA AEREA
169	35	OPERACIONES ESPECIALES AEREAS
40	41	SEGURIDAD Y DEFENSA DE LA FUERZA
23	42	SOPORTE Y SERVICIOS PARA EL COMBATE
5	44	INSTRUCCION Y ENTRENAMIENTO
217	52	RECUPERACION DE PERSONAL HUMANITARIA
8	54	VIGILANCIA, RECONOCIMIENTO Y ATENCION EN ZONAS...

Nota. Tomada de Anaconda3 – Código Python

Tabla 2*Códigos Variable Misión*

Misión	Código de Misión
No aplica misión	0
Contrapoder aéreo	11
Defensa aérea	12
Contrapoder terrestre	22
Transporte aéreo	31
Inteligencia aérea	34
Operaciones especiales aéreas	35
Seguridad y defensa de la fuerza	41
Soporte y servicios para el combate	42
Instrucción y entrenamiento	44
Recuperación de personal humanitaria	52
Vigilancia, reconocimiento y atención en zonas	54

Nota: Códigos originales de la data evaluada y filtrados en la App

Interpretación de Resultados del Modelo XGBoost

El modelo XGBoost fue evaluado a través de distintos escenarios simulados mediante una aplicación interactiva construida en Streamlit. Los casos fueron diseñados para observar el comportamiento del modelo frente a diferentes combinaciones de variables categóricas y operacionales relevantes. A continuación, se describen tres ejemplos de predicción junto con su interpretación:

Escenario 1

- Código de Misión: 11 (Contrapoder aéreo)
- Condición de vuelo: No desconocida
- Ubicación en Unidad Militar o Aeródromo: Sí

- ¿Hay aeronaves involucradas?: Sí
- Condiciones meteorológicas no especificadas: Sí
- Condición de vuelo VFR: Sí
- Resultado del modelo:
- Predicción: Entrenamiento
- Probabilidad de Operación: 0.08 %
- Interpretación: A pesar de que el código de misión corresponde a una acción

operativa (contrapoder aéreo), la combinación de otras variables llevó al modelo a clasificarla con alta confianza como entrenamiento. Esto evidencia que el modelo da mayor peso a condiciones generales del entorno y configuración operacional antes que al código de misión por sí solo.

Escenario 2

- Código de Misión: 31 (Transporte aéreo)
- Condición de vuelo: Desconocida
- Condición de tiempo: No especificada
- Clasificación SAO: Todas las fases de vuelo
- Resultado del modelo:
- Predicción: Entrenamiento
- Probabilidad de Operación: 0.06 %
- Interpretación: Nuevamente, el modelo muestra una fuerte inclinación hacia la

clasificación de entrenamiento, incluso en una misión típicamente operativa. La falta de especificidad en los datos meteorológicos y condiciones de vuelo parece influir negativamente en la clasificación como operación.

Escenario 3

- Código de Misión: 17 (otra categoría intermedia no listada explícitamente)
- Condición de vuelo: conocida
- Condiciones del tiempo: conocidas
- Condición VFR: No
- Clasificación SAO: No todas las fases
- Resultado del modelo:
- Predicción: Entrenamiento
- Probabilidad de Operación: 0.14 %
- Interpretación: Aunque las condiciones operativas parecen menos seguras (no

VFR, sin cobertura total del SAO), el modelo continúa prediciendo "Entrenamiento" con alta confianza. Esto indica que ciertas combinaciones de variables aún no logran cambiar significativamente el umbral de clasificación, lo cual puede estar relacionado con la distribución de clases en el set de entrenamiento o con la baja sensibilidad del modelo ante factores como visibilidad u operación crítica.

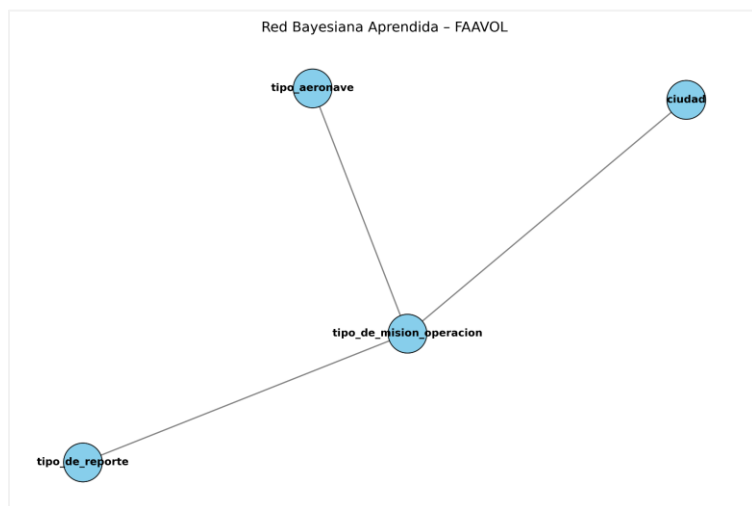
Durante las pruebas realizadas se evidenció un comportamiento consistente del modelo: la presencia de condición de vuelo VFR marcada como "Sí" reduce drásticamente la probabilidad de que una misión sea clasificada como Operación, incluso cuando el tipo de misión sugiere lo contrario. Este patrón sugiere que el modelo puede estar sobreajustado o sesgado hacia condiciones de vuelo visuales como indicador de bajo riesgo, lo que podría limitar su generalización ante nuevos contextos.

Modelo Red Bayesiana

El grafo aprendido muestra arcos directos desde cada *feature* hacia el nodo *target_operacion*, confirmando que, condicionalmente, cada factor aporta información independiente sobre la probabilidad de operación.

Figura 21

Red Bayesiana Aprendida Segundo Resultado



Nota. Tomada de Anaconda3 – Código Python

Hill-Climb + K2 equilibra exhaustividad y tiempo de cómputo, la estructura resultante es intuitiva y respeta la causalidad aparente en condiciones de reporte, ubicación y tipo de misión las cuales influyen directamente en la naturaleza de la misión. (Casajús, 2022).

El enfoque seleccionado (red bayesiana binaria) combina:

- Robustez estadística (Hill-Climb + BDeu),
- Explicabilidad (gráfico de causalidad + CPDs interpretables),
- Interactividad (app Streamlit),

Interpretación de Resultados de la Red Bayesiana

Al evaluar el comportamiento del modelo de red bayesiana desarrollado, se realizaron pruebas con distintos escenarios operacionales simulados en la aplicación Streamlit. A partir de combinaciones específicas de variables como tipo de reporte, ciudad, tipo de misión y código de misión, el modelo calculó la probabilidad posterior de que una misión esté clasificada como “Operación”. A continuación, se presentan y analizan tres ejemplos destacados:

Escenario 1

- Tipo de reporte: MOR (Reporte obligatorio)
- Ciudad: Cali
- Misión: Instrucción y Entrenamiento
- Resultado: $P(\text{Operación}) = 54.21\%$
- Interpretación: Este valor supera el umbral del 50 %, lo que indica un nivel de

riesgo alto. Aunque la misión es nominalmente de entrenamiento, la configuración del reporte y el contexto geográfico contribuyen a una probabilidad significativa de que se trate de una operación real.

Figura 22

Visualización App y Resultados Posteriores Red Bayesiana



Nota. Tomada de Streamlit local

Escenario 2

- Tipo de reporte: SRV (Reporte voluntario)
- Ciudad: Leticia
- Misión: Seguridad y Defensa de la Fuerza
- Resultado: $P(\text{Operación}) = 33.04 \%$
- Interpretación: El modelo asigna un nivel de riesgo medio, lo cual puede deberse a

la ambigüedad inherente al tipo de misión y al carácter voluntario del reporte. Este valor sugiere vigilancia sin que exista una alerta crítica.

Figura 23

Visualización App y Resultados Posteriores Red Bayesiana

Selecciona las características para calcular P(OPERACIÓN)

Tipo de reporte
SRV - Sistema de reporte voluntario

Ciudad
Leticia

Misión
SEGURIDAD Y DEFENSA DE LA FUERZA

Código de Misión
22

Calcular P(OPERACIÓN)

Distribución posterior

	Clase	Probabilidad
0	ENTRENAMIENTO	0.6696
1	OPERACIÓN	0.3304

⚠ Nivel de riesgo MEDIO: P(OPERACIÓN) = 33.04%

Nota. Tomada de Streamlit local

Escenario 3

- Tipo de reporte: MOR
- Ciudad: Corozal
- Misión: Transporte Aéreo
- Resultado: $P(\text{Operación}) = 99.20 \%$
- Interpretación: Este caso representa un nivel de riesgo extremadamente alto. La

naturaleza obligatoria del reporte, sumado al tipo de misión (Transporte Aéreo), lleva al modelo a identificar una probabilidad casi absoluta de tratarse de una operación. Este tipo de resultado es útil para activar protocolos de respuesta y análisis detallado inmediato.

Figura 24

Visualización App y Resultados Posteriores Red Bayesiana

Selecciona las características para calcular P(OPERACIÓN)

Tipo de reporte
MOR - Reporte obligatorio ▼

Ciudad
Corozal ▼

Misión
TRANSPORTE AEREO ▼

Código de Misión
0 ▼

Calcular P(OPERACIÓN)

Distribución posterior

	Clase	Probabilidad
0	ENTRENAMIENTO	0.0080
1	OPERACIÓN	0.9920

⚠ Nivel de riesgo ALTO: $P(\text{OPERACIÓN}) = 99.20\%$

Nota. Tomada de Streamlit local

Estos ejemplos demuestran que el modelo no solo genera una predicción binaria, sino que permite estimar probabilidades condicionadas que reflejan con mayor realismo el nivel de riesgo de cada caso. Adicionalmente, el uso de un semáforo de alerta en la interfaz (rojo, naranja, verde) facilita la interpretación para personal no técnico, convirtiéndose en una herramienta de apoyo útil para la toma de decisiones operacionales en la FAC.

La red bayesiana demostró ser una herramienta poderosa para comprender la probabilidad de que una misión sea de tipo “Operación”, integrando relaciones causales entre variables clave como tipo de reporte, ciudad, misión y código. Su fortaleza radica en la interpretabilidad de sus resultados, la posibilidad de establecer umbrales de riesgo y la facilidad de visualización mediante interfaces interactivas como Streamlit.

A diferencia del modelo XGBoost, que ofrece alta precisión predictiva y destaca por su capacidad de generalización sobre grandes volúmenes de datos, la red bayesiana aporta un enfoque explicativo, ideal para escenarios donde la trazabilidad y la justificación de cada predicción son fundamentales. En conjunto, ambos modelos permiten no solo anticipar eventos de alto riesgo, sino también comprender sus causas, facilitando decisiones informadas y oportunas en el contexto de la seguridad operacional de la Fuerza Aeroespacial Colombiana.

Conclusiones

Se implementaron y evaluaron dos enfoques complementarios para la predicción y análisis de misiones en la Fuerza Aeroespacial: un modelo de clasificación supervisada basado en XGBoost y una red bayesiana explicable.

El XGBoostClassifier alcanzó una precisión del 82.86 %, con un F1-score de 0.85 en la clase “Operación” y 0.80 en la clase “Entrenamiento”. Este desempeño demuestra su capacidad para manejar variables categóricas codificadas y producir predicciones confiables en problemas binarios de clasificación (Chen & Guestrin, 2016). Además, la integración de esta solución en una aplicación Streamlit facilita la adopción operativa, pues permite a los usuarios ingresar características de vuelo y obtener una predicción inmediata junto con su probabilidad asociada.

Por su parte, la red bayesiana ofrece una perspectiva causal: las variables “Tipo de reporte”, “Ciudad”, “Tipo de aeronave” y “Misión” confluyen directamente en el nodo “Operación vs Entrenamiento”, otorgando una estructura interpretable que respalda cada probabilidad calculada (Retamero, 2024). Con un umbral de riesgo del 50 % para clasificar como “ALTO” la probabilidad de operación, la red alcanza $P(\text{Operación}) = 60.44\%$ en un escenario de prueba, lo que valida su utilidad para tareas de alerta temprana.

La combinación de ambos métodos en el proyecto aporta un balance entre precisión predictiva (XGBoost) y explicabilidad causal (Bayes). Este doble enfoque permite no solo clasificar misiones con alta exactitud, sino también comprender las relaciones subyacentes entre las variables operacionales.

Recomendaciones

Profundizar en la aplicación de modelos de IA en la Fuerza Aeroespacial, con el fin de predecir los eventos de seguridad operacional en misiones de entrenamiento y operación, para esto se requiere conformar un equipo de trabajo que tenga las capacidades y los recursos tecnológicos para su implementación y análisis.

Optimizar los hiperparámetros del modelo XGBoost mediante técnicas como búsqueda bayesiana o aleatoria.

Incorporar series temporales utilizando modelos como Temporal Fusion Transformer (TFT) o PatchTST para capturar dinámicas a lo largo del tiempo.

Explorar modelos de supervivencia como DeepSurv para estimar el “tiempo hasta un incidente” y mejorar el mantenimiento preventivo.

Ampliar la red bayesiana con nuevas variables relacionadas con factores humanos y operativos, como mantenimiento o confiabilidad de sensores.

Se recomienda para futuras investigaciones, explorar:

La optimización de hiperparámetros de XGBoost mediante búsqueda bayesiana o aleatorizada para elevar aún más las métricas de rendimiento.

La incorporación de covariables temporales y series de tiempo (p. ej., TFT o PatchTST) para analizar tendencias estacionales en la seguridad operacional.

Como trabajo futuro, se propone explorar el uso de modelos de supervivencia como DeepSurv, que permiten predecir no solo la ocurrencia de un evento (incidente o falla), sino el tiempo probable hasta que ocurra. Para su implementación se requerirían datos adicionales, como:

Tiempo desde el último mantenimiento o misión hasta el evento.

Registros longitudinales por aeronave o tripulación.

VARIABLES DE CENSURA PARA CASOS SIN INCIDENTES.

El diseño experimental incluiría la reorganización de la base de datos en formato de supervivencia, con estructura tipo [unidad, tiempo, evento, covariables], y el uso del índice de concordancia (C-Index) como métrica principal de evaluación.

Esta propuesta permitiría evolucionar de un sistema de predicción estática hacia un enfoque temporal y más preciso, ideal para priorizar mantenimiento, anticipar fallas y planificar operaciones con enfoque preventivo.

Si la Fuerza Aeroespacial Colombiana decide escalar el sistema a tiempo real, se enfrentarán desafíos como infraestructura robusta, baja latencia, seguridad de datos y conectividad en zonas remotas. Para mitigarlos, se recomienda una arquitectura híbrida con procesamiento local, contenedores optimizados y sincronización diferida. Así se garantizaría una implementación eficiente y segura, incluso en entornos operacionales exigentes.

En conjunto, los resultados de este proyecto establecen un marco robusto y versátil para la toma de decisiones en seguridad aérea militar, que puede adaptarse a otras fuerzas armadas e incorporarse en sistemas de gestión de riesgos.

Referencias Bibliográficas

- Aerocivil . (21 de abril de 2023). *En los últimos 35 años la tasa de accidentalidad aérea en Colombia ha disminuido 49%*. Obtenido de Aerocivil.gov.co:
<https://www.aerocivil.gov.co/publicaciones/4234/en-los-ultimos-35-anos-la-tasa-de-accidentalidad-aerea-en-colombia-ha-disminuido-49/>
- Alvarado, I., Gómez, N., & Rodríguez, J. (2025). Bibliometric study of research in aeronautics, cyberspace, and space exploration for the Colombian Aerospace Force. *Revista Científica General José María Córdova*, 23(49), 95-117.
 doi:<https://doi.org/10.21830/19006586.1420>
- Balseca, C., Proaño, A., Reyes, P., & Reinoso, Á. (2022). Eficiencia de modelos de predicción de COVID-19 usando curvas ROC y matriz de confusión. *Dominio de las Ciencias*, 8(2), 1442-1460. doi:<http://dx.doi.org/10.23857/dc.v8i2.2715>
- Bishop, C. M. (2023). *Deep learning, foundations and concepts*. Springer.
- Carneiro, T. (2020). *Machine learning deployment with Streamlit and Python*. Packt Publishing.
- Casajús, J. (2022). *Autocodificador evolutivo de red Bayesiana para detección de anomalías aplicado a ciberseguridad*. Universidad Politécnica de Madrid.
- Cerro, L. (2023). *Estudio empírico de algoritmos de aprendizaje de Redes Bayesianas a partir de datos*. Universidad Politécnica de Madrid.
- Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., & Wirth, R. (2000). *CRISP-DM 1.0—Step-by-step data mining guide*. Scientific Research Publishing. .
 Retrieved from Scirp.org:
<https://www.scirp.org/reference/referencespapers?referenceid=1592779>

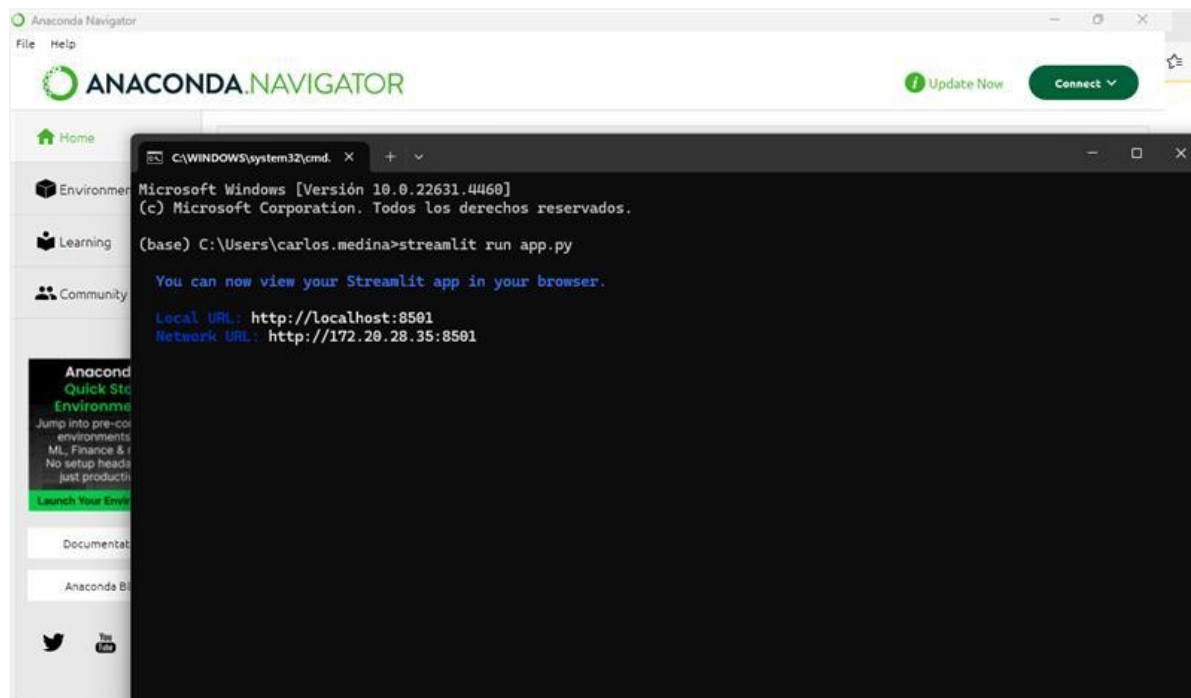
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785-794. doi:<https://doi.org/10.1145/2939672.2939785>
- Dekker, S. (2017). *The field guide to understanding "human error" (3rd ed.)*. CRC Press.
- Domingos, P. (2012). A few useful things to know about machine learning. *Communications of the ACM*, 78–87. doi:<https://doi.org/10.1145/2347736.2347755>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Han, J., Pei, J., & Kamber, M. (2022). *Data Mining: Concepts and Techniques (4th ed.)*. Morgan Kaufmann.
- Hutson, G., & Jackson, M. (2023). *Graph Data Modeling in Python: A practical guide to curating, analyzing, and modeling data with graphs*. Packt Publishing Ltd.
- ICAO. (2018). *Safety management manual (Doc 9859)*. International Civil Aviation Organization .
- Inc, S. (2023). *Streamlit documentation*. Obtenido de Streamlit Inc.: <https://docs.streamlit.io/>
- Karthiga, R., Usha, G., Raju, N., & Narasimhan, K. (2021). Transfer learning based breast cancer classification using one-hot encoding technique. *2021 international conference on artificial intelligence and smart systems (ICAIS)* , 115-120.
doi:10.1109/ICAIS50930.2021.9395930
- Kelleher, J. D., Mac Namee, B., & D'Arcy, A. (2020). *Fundamentals of machine learning for predictive data analytics: Algorithms, worked examples, and case studies*. MIT Press.
doi:<https://doi.org/10.7551/mitpress/12439.001.0001>
- Kirkpatrick, D., & Daines, R. (2020). Artificial intelligence applications in aviation safety management systems. *Journal of Aviation Technology and Engineering*, 35–45.

- McKinney, W. (2022). *Python for data analysis: Data wrangling with pandas, NumPy, and Jupyter (3rd ed.)*. O'Reilly Media.
- Microsoft Corporation. (2023). *Power BI: Business analytics service documentation*. Obtenido de Learn.microsoft.com: <https://learn.microsoft.com/en-us/power-bi/>
- Nahm, F. (2022). Receiver operating characteristic curve: overview and practical use for clinicians. *Korean journal of anesthesiology*, 75(1), 25-36.
doi:<https://doi.org/10.4097/kja.21209>
- Retamero, O. (2024). *Desarrollo de nuevos métodos de inferencia y aprendizaje en modelos gráficos probabilísticos con probabilidades imprecisas*. Universidad de Granada.
- Russell, S., & Norvig, P. (2021). *Artificial Intelligence: A Modern Approach (4th ed.)*. Pearson.
- Streamlit Inc. (2024). *Streamlit documentation*. Obtenido de Streamlit: <https://docs.streamlit.io>
- Vujović, Ž. (2021). Classification model evaluation metrics. *International Journal of Advanced Computer Science and Applications*, 12(6), 599-606.
doi:10.14569/IJACSA.2021.0120670
- Zhang, Y., & Gong, D. (2020). Gradient boosting decision trees for risk classification in aviation safety. *Aerospace Science and Technology*, Aerospace Science and Technology.
doi:<https://doi.org/10.1016/j.ast.2019.105678>

Apéndices

Apéndice A

Código Python Anaconda 3



The screenshot shows the Anaconda Navigator application window. The main interface is light gray with a sidebar on the left containing navigation options like Home, Environments, Learning, and Community. The central area is a dark terminal window titled 'C:\WINDOWS\system32\cmd'. The terminal output shows the execution of the command 'streamlit run app.py' in a conda environment. The output indicates that the Streamlit app is running and provides the local and network URLs for viewing the application in a browser.

```
C:\WINDOWS\system32\cmd. x + v
Microsoft Windows [Versión 10.0.22631.4460]
(c) Microsoft Corporation. Todos los derechos reservados.
(base) C:\Users\carlos.medina>streamlit run app.py
You can now view your Streamlit app in your browser.
Local URL: http://localhost:8501
Network URL: http://172.20.28.35:8501
```

Nota: Tomada de : [Proyecto de grado código python](#)

Apendice B

Archivos App – Streamlit (Local)

Selecciona las características para calcular P(OPERACIÓN)

Tipo de reporte
MOR - Reporte mandatorio

Ciudad
Corozal

Misión
TRANSPORTE AEREO

Código de Misión
0

Calcular P(OPERACIÓN)

Distribución posterior

	Clase	Probabilidad
0	ENTRENAMIENTO	0.0080
1	OPERACIÓN	0.9920

⚠ Nivel de riesgo ALTO: P(OPERACIÓN) = 99.20%

Notas. Tomada de [Archivos App XGBoost](#) [Archivos App Bayesiana](#)