

**DISEÑO DE UN MODELO PREDICTIVO BASADO EN MACHINE LEARNING
PARA LA OPTIMIZACIÓN DE LA ASIGNACIÓN DE SLOTS EN EL
AEROPUERTO EL DORADO**

KAROL VANESSA AGUIRRE MEZA

DANIEL LEONARDO VILLALOBOS LAGUADO

UNIVERSIDAD EAN

PROGRAMA DE INGENIERÍA DE SISTEMAS

BOGOTÁ

2025

**DISEÑO DE UN MODELO PREDICTIVO BASADO EN MACHINE LEARNING
PARA LA OPTIMIZACIÓN DE LA ASIGNACIÓN DE SLOTS EN EL
AEROPUERTO EL DORADO**

KAROL VANESSA AGUIRRE MEZA

DANIEL LEONARDO VILLALOBOS LAGUADO

Director:

JULIAN DANIEL TORRES VANEGAS, PhD

**Trabajo presentado como requisito parcial para obtener el título de Ingeniero(s) de
Sistemas**

UNIVERSIDAD EAN

PROGRAMA DE INGENIERÍA DE SISTEMAS

BOGOTÁ

2025

Tabla de Contenidos

	Pág.
1. Introducción	8
2. Objetivos	10
2.1. Objetivo general	10
2.2. Objetivos específicos	10
3. Definición del problema	11
4. Justificación	13
5. Análisis de requerimientos.....	14
6. Marco Teórico.....	16
6.1. Definición de Slot Aeroportuario.....	16
6.2. Fundamentos del Machine Learning en la Gestión Aeroportuaria	19
6.3. Asignación de Slots en Colombia	21
6.4. Regulaciones y Métodos Internacionales de Asignación de Slots.....	25
6.5. Factores Determinantes para la Optimización de la Asignación de Slots.....	29
6.6. Integración del Machine Learning para la Optimización.....	34
7. Análisis de restricciones	37
8. Evaluación del modelo predictivo preliminar	39
9. Propuesta metodológica de implementación	42
10. Metodología de selección de solución	44
11. Análisis de Costos.....	45
11.1. Costos de operación	45
11.2. Costos de Inversión.....	47
11.3. Resumen Financiero.....	48
11.4. Evaluación de rentabilidad.....	49
12. Conclusiones	49
Referencias Bibliográficas.....	51
Anexos	55

Lista de Tablas

	Pág.
Tabla 1. Resultados del modelo por conjunto	41
Tabla 2. Total estimado de costos.	48

Resumen Ejecutivo

Este estudio aborda la optimización de la asignación de slots aeroportuarios en el Aeropuerto Internacional El Dorado mediante la aplicación de Machine Learning. La gestión ineficiente de estos slots genera retrasos, congestión de tráfico aéreo y un uso ineficiente de la infraestructura, afectando la competitividad del aeropuerto y la operación de las aerolíneas (OACI, 2019). Actualmente, los slots se asignan mediante criterios históricos y acuerdos administrativos, lo que limita la capacidad de adaptación a cambios operativos (Serrano Rico, 2017).

El proyecto propone el desarrollo de un modelo predictivo basado en Machine Learning para optimizar la asignación de slots, considerando datos históricos de tráfico aéreo, condiciones meteorológicas e infraestructura disponible. Estudios como el de Khaksar y Sheikholeslami (2017) han demostrado que la aplicación de Machine Learning en la predicción de retrasos aéreos puede mejorar significativamente la gestión del tráfico en aeropuertos. En su investigación, identificaron factores clave como la visibilidad, el viento y la hora de salida como determinantes en los retrasos aeroportuarios, lo que respalda la integración de modelos predictivos en la optimización de slots. Asimismo, la Agencia de Seguridad Aérea de la Unión Europea (EASA, 2023) respalda el uso de inteligencia artificial en la aviación, destacando su capacidad de adaptación a condiciones cambiantes.

Este estudio contribuirá a la implementación de un modelo eficiente para la planificación de slots, proporcionando una base metodológica para la modernización de la gestión del tráfico aéreo en aeropuertos de alta demanda.

Palabras claves: Asignación de slots aeroportuarios, optimización del tráfico aéreo, Machine Learning, Big Data, gestión aeroportuaria, predicción de tráfico aéreo, eficiencia operativa, Aeropuerto Internacional El Dorado.

Abstract

The optimization of airport slot allocation is a critical challenge in high-demand airports such as El Dorado International Airport in Bogotá, Colombia. Inefficient slot distribution leads to operational delays, air traffic congestion, and suboptimal infrastructure utilization, negatively impacting airline operations and airport competitiveness (ICAO, 2019). Currently, slots are assigned based on historical data and administrative agreements, limiting adaptability to operational fluctuations (Serrano Rico, 2017).

This study proposes the development of a predictive model based on Machine Learning to optimize slot allocation by analyzing historical air traffic data, meteorological conditions, and available infrastructure. Research by Khaksar and Sheikholeslami (2017) demonstrates that Machine Learning techniques, such as decision trees and random forests, significantly improve delay prediction by identifying key influencing factors like wind conditions, visibility, and departure times. These findings reinforce the feasibility of using predictive models for optimizing slot allocation. The European Union Aviation Safety Agency (EASA, 2023) supports the use of artificial intelligence in aviation, emphasizing its real-time adaptability to changing conditions.

This research contributes to the implementation of an efficient slot planning model, providing a methodological framework for modernizing air traffic management in high-demand airports.

Keywords: Airport slot allocation, air traffic optimization, Machine Learning, Big Data, airport management, air traffic forecasting, operational efficiency, El Dorado International Airport.

1. Introducción

La gestión eficiente de slots aeroportuarios—permisos que determinan el horario en que una aeronave puede despegar o aterrizar—es un factor clave para optimizar el flujo de tráfico aéreo y minimizar la congestión en aeropuertos con alta demanda operativa. Según la Organización de Aviación Civil Internacional (OACI, 2019), los slots son fundamentales para la planificación de vuelos y la optimización del uso de la infraestructura aeroportuaria, afectando directamente la puntualidad de las aerolíneas y la experiencia de los pasajeros.

En este sentido, aeropuertos con alta demanda, como el Aeropuerto Internacional El Dorado, enfrentan desafíos en la asignación equitativa y eficiente de slots debido a la variabilidad del tráfico aéreo, las condiciones meteorológicas y la disponibilidad de infraestructura. Por ejemplo, en temporadas de alta demanda, como diciembre y julio, el aumento de vuelos internacionales y nacionales ha generado congestión en los horarios pico, afectando la puntualidad de las operaciones y forzando a las aerolíneas a realizar ajustes de última hora en sus itinerarios (OACI, 2019). Asimismo, condiciones climáticas adversas, como neblina densa o tormentas, han provocado retrasos y reprogramaciones, evidenciando la necesidad de un sistema de asignación más dinámico y adaptativo.

Tradicionalmente, la asignación de slots se ha basado en regulaciones y acuerdos entre aerolíneas y autoridades aeronáuticas. No obstante, este método presenta limitaciones en la adaptabilidad a cambios operacionales imprevistos (Serrano Rico, 2017). Khaksar y Sheikholeslami (2017) han demostrado que la aplicación de algoritmos de Machine Learning, como árboles de decisión y bosques aleatorios, puede mejorar significativamente la predicción de retrasos aéreos y la eficiencia operativa. En su estudio, identificaron que

factores como el viento, la visibilidad y la hora de salida influyen en la probabilidad de demoras en los vuelos, lo que respalda el uso de técnicas avanzadas para optimizar la asignación de slots en aeropuertos con alta demanda. Esta problemática ha impulsado la búsqueda de soluciones tecnológicas avanzadas que permitan optimizar la asignación de slots mediante el análisis de grandes volúmenes de datos.

El uso de Machine Learning y Big Data Analytics en la gestión aeroportuaria ha demostrado ser una alternativa viable para mejorar la asignación de slots. Según Romero Checa (2016), los modelos de predicción basados en inteligencia artificial pueden mejorar la eficiencia operativa al identificar patrones en el tráfico aéreo y anticipar posibles cuellos de botella. Además, la Agencia de Seguridad Aérea de la Unión Europea (EASA, 2023) señala que la inteligencia artificial puede adaptarse en tiempo real a condiciones cambiantes, permitiendo una asignación más eficiente de los recursos aeroportuarios.

En el caso del Aeropuerto Internacional El Dorado, la implementación de un modelo predictivo basado en Machine Learning podría contribuir a mejorar la planificación operativa, reducir retrasos y optimizar el uso de la infraestructura. La necesidad de herramientas avanzadas para la gestión de slots en aeropuertos de alta demanda ha sido ampliamente discutida en la literatura aeronáutica, destacando que la incorporación de inteligencia artificial representa una oportunidad clave para mejorar la eficiencia y sostenibilidad del tráfico aéreo global (AEDAE, 2024). Un estudio realizado por Orozco Córdoba (2024) en el que se desarrolló un algoritmo de optimización para mejorar la gestión del espacio aéreo mostró una reducción significativa en los escenarios de sobrecarga, mejorando la eficiencia operativa y reduciendo costos.

2. Objetivos

2.1. Objetivo general

Diseñar un modelo predictivo basado en Machine Learning para optimizar la asignación de slots en el Aeropuerto El Dorado en Bogotá, Colombia, con el fin de mejorar la eficiencia operativa y la gestión del tráfico aéreo.

2.2. Objetivos específicos

1. Analizar reportes de asignación de slots, tráfico aéreo e infraestructura aeroportuaria con el fin de identificar patrones y factores que influyen en la eficiencia operativa del aeropuerto.
2. Desarrollar un modelo de Machine Learning preliminar para la predicción y optimización de la asignación de slots, considerando técnicas de aprendizaje supervisado o no supervisado.
3. Validar el modelo predictivo preliminar mediante pruebas con datos históricos, evaluando su desempeño a través de métricas cuantitativas como la precisión y la eficacia, con el propósito de establecer su confiabilidad técnica.
4. Documentar una propuesta metodológica que describa el uso del modelo predictivo preliminar y su posible integración en un sistema avanzado, orientado a la optimización de la asignación de slots aeroportuarios.

3. Definición del problema

El crecimiento sostenido del tráfico aéreo y la alta concentración de operaciones en aeropuertos estratégicos como El Dorado ha intensificado los desafíos en la asignación eficiente de slots aeroportuarios. Según la Aeronáutica Civil de Colombia (2024), este aeropuerto movilizó 39.483.629 pasajeros en 2023, posicionándose como el principal hub aéreo del país, y durante los primeros diez meses de 2024, el tráfico nacional e internacional alcanzó los 46.5 millones de pasajeros, reflejando una tendencia de crecimiento continuo. Esta alta demanda ha evidenciado limitaciones estructurales y operativas en la gestión actual de slots.

En Colombia, la asignación de slots en aeropuertos coordinados como El Dorado está a cargo del Grupo de Facilitación de Horarios (GFH) de la Aeronáutica Civil. El proceso se rige por criterios administrativos secuenciales, priorizando los derechos históricos de las aerolíneas y distribuyendo los slots remanentes según la disponibilidad declarada (Aeronáutica Civil de Colombia, 2024). No obstante, este sistema enfrenta importantes desafíos: la saturación de franjas horarias en periodos pico, la limitada capacidad de adaptación frente a condiciones meteorológicas adversas o contingencias técnicas, y la escasa flexibilidad para reprogramar slots en función de variaciones operativas imprevistas.

En este contexto, surge la necesidad de implementar herramientas más dinámicas y precisas para la gestión de slots. La aplicación de técnicas de Machine Learning y Big Data Analytics se ha consolidado como una alternativa viable para identificar patrones operativos, anticipar la demanda y optimizar la asignación de recursos aeroportuarios (Sámano Robles, 2020). Un ejemplo destacado es el Aeropuerto Internacional de Heathrow, donde la

plataforma AIMEE, desarrollada por Searidge Technologies e implementada por NATS, ha permitido reducir los tiempos de espera en pista hasta en un 20%, gracias al uso de cámaras de alta definición y algoritmos de inteligencia artificial que optimizan la secuencia de aterrizajes en condiciones adversas (TechHQ, 2019). Asimismo, la Agencia de Seguridad Aérea de la Unión Europea (EASA, 2023) destaca que la inteligencia artificial permite analizar patrones en tiempo real, mejorar la toma de decisiones operativas y reducir significativamente los retrasos en la infraestructura aeroportuaria.

Frente a este panorama, el desarrollo de un modelo predictivo basado en Machine Learning que considere factores como el tráfico aéreo, las condiciones meteorológicas y la infraestructura disponible se presenta como una solución estratégica para optimizar la asignación de slots en el Aeropuerto Internacional El Dorado, incrementando su eficiencia operativa y capacidad de respuesta ante escenarios cambiantes.

4. Justificación

El crecimiento sostenido del tráfico aéreo y la creciente demanda de vuelos comerciales han generado una presión significativa sobre la capacidad operativa de los aeropuertos más importantes del mundo. Según la Organización de Aviación Civil Internacional (OACI, 2019), la congestión en aeropuertos con alta demanda es una de las principales causas de retrasos en los vuelos, afectando la eficiencia del transporte aéreo, la satisfacción de los pasajeros y los costos operativos de las aerolíneas. Frente a este escenario, se hace indispensable el desarrollo de estrategias innovadoras que permitan optimizar la asignación de slots aeroportuarios y mejorar la planificación operativa.

La aplicación de técnicas de Machine Learning y Big Data Analytics en la gestión aeroportuaria ha demostrado ser una solución eficaz para abordar este desafío, ya que facilita la identificación de patrones operativos, la predicción de tráfico aéreo y la optimización en la asignación de recursos (Sámano Robles, 2020). Un ejemplo de éxito es el Aeropuerto Internacional de Heathrow, donde la plataforma AIMEE, desarrollada por Searidge Technologies e implementada por NATS, ha logrado reducir los tiempos de espera en pista hasta en un 20%, mediante el uso de cámaras de alta definición y algoritmos de inteligencia artificial para mejorar la visibilidad y secuencia de aterrizajes en condiciones adversas (TechHQ, 2019). Del mismo modo, la Agencia de Seguridad Aérea de la Unión Europea (EASA, 2023) respalda el uso de inteligencia artificial en la aviación, subrayando su capacidad para analizar patrones en tiempo real, reducir los tiempos de espera y mejorar la eficiencia operativa de los aeropuertos.

En este contexto, la presente investigación propone el diseño de un modelo predictivo basado en Machine Learning que contribuya a mejorar la asignación de slots en el Aeropuerto Internacional El Dorado, uno de los más transitados de América Latina. La implementación de dicho modelo permitirá no solo optimizar el uso de la infraestructura aeroportuaria y reducir retrasos, sino también establecer una base metodológica para futuros desarrollos tecnológicos orientados a la modernización del tráfico aéreo.

Desde una perspectiva práctica, este estudio proporcionará un marco de referencia útil para evaluar la viabilidad de integrar inteligencia artificial en los sistemas de control de tráfico aéreo. Los resultados podrán servir de insumo para la toma de decisiones por parte de autoridades aeronáuticas, aerolíneas y operadores aeroportuarios, facilitando la planificación operativa según la demanda real, la redistribución de vuelos en horarios estratégicos y la reducción de tiempos de espera en pista. Finalmente, la automatización de procesos a través del modelo propuesto contribuirá al fortalecimiento de la eficiencia operativa y a una mejor experiencia para los usuarios del sistema aeroportuario.

5. Análisis de requerimientos

El proyecto se enfoca en desarrollar un sistema integral que permita optimizar la asignación de slots en el Aeropuerto Internacional El Dorado. Esta necesidad surge debido a que en aeropuertos de alta demanda la asignación tradicional, basada en criterios históricos y acuerdos administrativos, genera retrasos y congestión, lo que afecta la eficiencia operativa y la experiencia de los usuarios (Aerocivil, 2024). La idea es utilizar técnicas de Machine

Learning para predecir y mejorar la asignación de slots, aprovechando datos históricos, información sobre tráfico aéreo, condiciones meteorológicas e indicadores de infraestructura.

El sistema se diseñará para integrar y consolidar datos de datos históricos de asignación de slots, tráfico aéreo, condiciones meteorológicas e infraestructura aeroportuaria, garantizando la calidad de la información mediante procesos de validación y limpieza de datos. Esta integración permitirá entrenar modelos predictivos capaces de analizar el comportamiento del tráfico aéreo. Para este fin, el sistema ejecutará algoritmos de Machine Learning, ya sean de aprendizaje supervisado, no supervisado o incluso basados en aprendizaje por refuerzo, para generar recomendaciones que optimicen la asignación de slots y reduzcan los retrasos (Nguyen-Duy et al., 2024). Además, se busca que el sistema permita comparar las nuevas asignaciones con el método tradicional, de modo que se pueda evidenciar la mejora en la eficiencia operativa.

El sistema también debe cumplir con requerimientos no funcionales esenciales para su correcto funcionamiento. Es fundamental que la solución sea escalable, de manera que pueda procesar grandes volúmenes de datos sin afectar el rendimiento, y que ofrezca respuestas con suficiente rapidez para permitir la toma de decisiones de manera efectiva. La usabilidad es otro aspecto crítico, ya que la interfaz debe ser sencilla e intuitiva, y debe permitir a los usuarios interpretar fácilmente los resultados de las predicciones y las recomendaciones de asignación de slots.

En cuanto a la arquitectura tecnológica, se utilizará Python como lenguaje de programación principal por su sencillez y la gran cantidad de librerías disponibles para el análisis de datos y la construcción de modelos de Machine Learning. TensorFlow se

seleccionará como el framework para el desarrollo y entrenamiento de modelos de Deep Learning, ya que permite ejecutar cálculos en paralelo y gestionar grandes volúmenes de datos, lo cual es crucial para abordar problemas complejos como la optimización de slots en aeropuertos congestionados. Además, se plantea utilizar Spyder como entorno de desarrollo (IDE) tentativo, por su facilidad de uso en ciencia de datos y compatibilidad con TensorFlow (Konasani & Kadre, 2021)

Para el proceso de validación y monitoreo del modelo se adoptarán técnicas de validación, como la división de datos en conjuntos de entrenamiento y prueba y el uso de métricas de error, tales como el error medio absoluto (MAD) y el error cuadrático medio (RMSE), entre otras, para evaluar la precisión de las predicciones. Además, se implementarán métodos de validación cruzada que aseguren la robustez del modelo a lo largo del tiempo, permitiendo realizar ajustes cuando se detecten variaciones en los patrones operativos (Konasani & Kadre, 2021).

6. Marco Teórico

6.1. Definición de Slot Aeroportuario

Un slot aeroportuario se define como un permiso asignado a una aerolínea para utilizar la infraestructura de un aeropuerto, incluyendo pistas, calles de rodaje y terminales, en un momento específico para un despegue o aterrizaje. Según las directrices establecidas por la IATA (International Air Transport Association) en el Worldwide Airport Slot Guidelines (WASG, 2024), los slots son esenciales para gestionar la capacidad en aeropuertos con alta demanda, asegurando una distribución equitativa de los recursos

operacionales. En aeropuertos congestionados, clasificados como Nivel 3, la asignación de slots se realiza de manera obligatoria a través de un coordinador independiente, con el objetivo de optimizar la utilización del espacio aéreo y reducir los retrasos (Ribeiro et al., 2019).

En Colombia, el Aeropuerto Internacional El Dorado ha sido categorizado como un aeropuerto coordinado de Nivel 3, lo que significa que todas las operaciones de llegada y salida deben contar con un slot aprobado por el coordinador designado, siguiendo las disposiciones establecidas por la Aerocivil (RAC 3, Apéndice A, 2024). Esta regulación es fundamental en aeropuertos donde la demanda de infraestructura supera la capacidad disponible, haciendo necesaria la aplicación de modelos de gestión eficientes para la asignación de slots (Ribeiro et al., 2018).

La importancia de los slots radica en que permiten organizar la demanda de vuelos en función de la capacidad limitada de la infraestructura aeroportuaria. De acuerdo con los lineamientos de la IATA, la asignación de slots debe cumplir con restricciones de capacidad establecidas en los aeropuertos, lo que implica una gestión cuidadosa de la disponibilidad de infraestructura como pistas, calles de rodaje y terminales para evitar la sobrecarga operativa (Ribeiro et al., 2018). La eficiencia en la asignación de slots es fundamental para evitar congestión y demoras excesivas, garantizando una planificación adecuada dentro de los límites de capacidad definidos para cada aeropuerto (Ribeiro et al., 2018). En el contexto colombiano, la Aeronáutica Civil establece que las aerolíneas deben planificar sus operaciones considerando las condiciones del Aeropuerto El Dorado y siguiendo los procedimientos de coordinación de slots, gestión de afluencia de tránsito (ATFM) y control

de tránsito aéreo. De esta forma, la asignación de slots se integra a la planificación de vuelos, asegurando que cada itinerario cuente con la infraestructura necesaria antes del despegue o aterrizaje.

A nivel internacional, los lineamientos principales para la gestión de slots están recogidos en las Worldwide Airport Slot Guidelines (WASG) de la IATA. Estas directrices constituyen un estándar global para aeropuertos coordinados, buscando que la asignación sea neutral, transparente y no discriminatoria. Uno de los principios más importantes es el de “usar el slot o perderlo”, según el cual una aerolínea que haya utilizado al menos el 80% de una serie de slots en una temporada tiene derecho prioritario a esa misma serie en la siguiente temporada equivalente (Ribeiro et al., 2019). Este mecanismo, conocido como grandfather rights o series históricas, incentiva a las aerolíneas a utilizar sus slots de manera consistente, so pena de perder la prioridad sobre ellos.

Otra directriz clave es la prioridad a nuevos entrantes. Según WASG, el 50% de los slots que queden en el slot pool—es decir, los slots disponibles tras atender derechos históricos y devoluciones—debe asignarse a aerolíneas con poca o ninguna presencia previa en el aeropuerto. Se define como nuevo entrante a aquella aerolínea que, de aceptarse su solicitud, poseería menos de cinco slots en ese aeropuerto durante el día (Ribeiro et al., 2019). Este criterio busca promover la competencia y evitar el monopolio de slots por parte de aerolíneas dominantes.

Adicionalmente, las WASG describen las prioridades de asignación en detalle, diferenciando entre solicitudes de series históricas, cambios a series existentes y nuevos entrantes, asegurando una distribución más equitativa de la capacidad aeroportuaria. En este

contexto, las series existentes corresponden a slots previamente asignados que pueden ser modificados en su horario o estructura operativa, sin perder la continuidad de su asignación dentro del aeropuerto.

6.2. Fundamentos del Machine Learning en la Gestión Aeroportuaria

El aprendizaje automático o Machine Learning (ML) es una rama de la inteligencia artificial que permite a los sistemas informáticos aprender patrones a partir de datos históricos y mejorar su desempeño en tareas específicas sin ser programados explícitamente para cada caso. En términos simples, un algoritmo de ML se adapta con la práctica; se entrena con datos de ejemplo (experiencia) para realizar ciertas tareas, y su rendimiento aumenta a medida que recibe más datos (Konasani & Kadre, 2021). A diferencia de los métodos estadísticos tradicionales enfocados en inferir propiedades de una población, el aprendizaje automático se centra en encontrar patrones predictivos generales en los datos (Konasani & Kadre, 2021). Por ejemplo, en vez de solo describir la tendencia de retrasos en un aeropuerto, un modelo de ML puede identificar las combinaciones de factores (hora del día, clima, volumen de tráfico, etc.) que predicen con mayor exactitud cuándo ocurrirá un retraso. Esta capacidad de generalización le da al ML un amplio alcance en aplicaciones de gestión aeroportuaria, donde se maneja una gran cantidad de información operativa y es fundamental tomar decisiones rápidas en función de condiciones cambiantes.

Existen diversos tipos de modelos de ML; entre los más comunes se encuentran los modelos de aprendizaje supervisado y no supervisado. En el aprendizaje supervisado, el algoritmo se entrena con datos etiquetados, es decir, con ejemplos de entrada y salidas deseadas conocidas (también llamados labels). El sistema aprende a asociar cada situación

de entrada con la respuesta correcta basándose en esos ejemplos. Es análogo a un estudiante guiado por un maestro: por ejemplo, si queremos que un modelo identifique demoras en vuelos, le proporcionaríamos muchos casos de vuelos (con sus características: condiciones meteorológicas, tráfico, hora, etc.) junto con la indicación de si hubo o no demora; de este modo, el modelo "aprende" a predecir retrasos futuros a partir de patrones observados (Konasani & Kadre, 2021). Tareas típicas del aprendizaje supervisado son la clasificación (*e.g.*, categorizar un vuelo como puntual o demorado) y la regresión (*e.g.*, predecir cuántos minutos de retraso tendrá un vuelo).

Por su parte, en el aprendizaje no supervisado, el algoritmo recibe datos sin etiquetas conocidas y debe descubrir por sí mismo su estructura subyacente (Konasani & Kadre, 2021). Aquí no hay una respuesta correcta predefinida en el entrenamiento; el objetivo es identificar patrones, agrupaciones o relaciones ocultas en los datos. Un ejemplo sería analizar datos de miles de vuelos sin información previa de resultados, para detectar clústers (grupos) de vuelos con perfiles similares de comportamiento. Esto podría revelar, por ejemplo, grupos de rutas que presentan patrones de congestión parecidos, sin haberle indicado de antemano al algoritmo qué buscar. Ambos enfoques (supervisado y no supervisado) son útiles en gestión aeroportuaria: el primero para predecir eventos específicos (retrasos, cancelaciones, demanda de pasajeros) y el segundo para segmentar o entender distribuciones (agrupación de aeropuertos por niveles de congestión, detección de patrones anómalos, etc.).

La gestión aeroportuaria moderna se beneficia cada vez más del ML debido a su capacidad de procesar múltiples variables y grandes cantidades de información en tiempo real. Las ventajas de la inteligencia artificial en la optimización de slots y operaciones aéreas

incluyen la posibilidad de anticipar situaciones complejas y proponer soluciones proactivas. Por ejemplo, se han aplicado algoritmos de ML para predecir retrasos de vuelos con alta precisión, combinando datos históricos de distintas regiones. (Khaksar & Sheikholeslami, 2017) desarrollaron un método híbrido (que combinó un árbol de decisión J48 con clustering K-means) para entrenar modelos de retraso de vuelos en Estados Unidos e Irán, Estos resultados demuestran cómo la IA puede mejorar la exactitud de las predicciones operativas, permitiendo que los aeropuertos y aerolíneas tomen medidas con antelación. Si un modelo predictivo indica alta probabilidad de demoras en ciertos slots horarios, los coordinadores podrían reajustar la asignación de slots o preparar recursos adicionales, optimizando así el flujo de operaciones y mitigando el impacto de esos retrasos.

En conclusión, el ML ofrece herramientas poderosas para descubrir relaciones no evidentes en los datos aeronáuticos (meteorología, tráfico, control aéreo, etc.) y utilizarlas en la toma de decisiones automatizada, incrementando la eficiencia y la capacidad de adaptación del sistema aeroportuario.

6.3. Asignación de Slots en Colombia

En Colombia, la administración y coordinación de slots aeroportuarios está centralizada bajo la autoridad de la Aerocivil (Unidad Administrativa Especial de Aeronáutica Civil). La Aerocivil actúa como coordinador de horarios en aeropuertos de alta demanda, como el Aeropuerto Internacional El Dorado de Bogotá, siguiendo la normatividad local y los lineamientos internacionales de IATA.

A principios de 2024, la Aerocivil emitió la Circular de Información Aeronáutica AIC 01/2024, la cual establece el procedimiento detallado para la asignación de slots en El

Dorado. Según esta normativa, toda operación comercial en El Dorado requiere la obtención previa de un slot aprobado por la Aerocivil. En particular, las aerolíneas y operadores deben solicitar y obtener un slot con más de 24 horas de antelación respecto a la hora estimada de salida o llegada de su vuelo. Esta regla asegura una planificación estratégica anticipada: no se permiten, salvo circunstancias excepcionales, vuelos no coordinados de última hora en un aeropuerto saturado.

La Aerocivil, a través del Grupo de Facilitación de Horarios (GFH) de la Dirección de Transporte Aéreo, es la encargada de realizar la asignación estratégica de slots en El Dorado, actuando de manera equivalente a los coordinadores independientes que operan en otros aeropuertos del mundo.

El proceso de coordinación de slots en Colombia abarca varias fases, alineadas con las prácticas internacionales pero ajustadas a las necesidades locales. Primero está la fase de planificación estratégica, en la cual se asignan los slots con suficiente anticipación (más de 24 horas antes de la operación). Durante esta fase, las aerolíneas presentan sus solicitudes de horarios deseados y el coordinador (Aerocivil) adjudica slots teniendo en cuenta la capacidad declarada del aeropuerto y las prioridades establecidas (por ejemplo, respetando los derechos históricos de las series de vuelos existentes y facilitando la entrada de nuevos operadores cuando haya disponibilidad). Una vez asignados estos slots estratégicos, las aerolíneas deben ajustar sus planes de vuelo para ceñirse a las horas concedidas (Aeronáutica Civil de Colombia, 2024).

Luego, se contempla una fase pre-táctica, que cubre las solicitudes o ajustes de último momento dentro de las 24 horas previas a la operación. Si una aerolínea requiere un slot con

poca anticipación (por ejemplo, por un cambio operativo inesperado), la Aerocivil evalúa la petición de acuerdo con la capacidad remanente y las medidas de gestión de afluencia vigentes. En el Aeropuerto El Dorado, ante peticiones dentro de ese umbral de 24 horas, se puede recurrir a procedimientos de ATFM (Air Traffic Flow Management) como el programa de demoras en tierra (Ground Delay Program) u otras herramientas de coordinación táctica (sistema PDC SCORE, según lo indicado por IATA) para asignar un slot viable. De hecho, la AIC 01/2024 indica que, si la solicitud es con menos de 24 horas y existe un programa de demoras en tierra activo, la coordinación del slot se hará aprovechando dicho programa ATFM, siguiendo el manual SSIM de IATA, para garantizar la consistencia con el flujo de tráfico general.

Finalmente, está la fase táctica o de día de la operación. En esta etapa, ya en tiempo real, las condiciones operacionales actuales (meteorología, restricciones ATC, variaciones en la demanda) pueden requerir ajustes finales. La Aerocivil señala que, dado que los slots se asignaron en la fase estratégica bajo ciertas condiciones previstas, es posible que las horas asignadas deban cambiar el día de la operación si las condiciones tácticas difieren; en tal caso, las aerolíneas deben acatar las instrucciones de ATFM correspondientes. Esto significa que el día de la operación, el Centro de Gestión de Afluencia (FCMU en Colombia) puede imponer medidas como ajustes de horarios, demoras calculadas o intercambios menores de secuencia para mantener la eficiencia y seguridad del flujo aéreo.

En términos generales, la coordinación de slots en Colombia funciona en un ciclo continuo: planificación temprana, ajuste pre-táctico cercano a la fecha del vuelo, y gestión

táctica el mismo día, todo bajo la supervisión de Aerocivil como coordinador y en concordancia con las prácticas globales.

A pesar del marco normativo existente, la asignación actual de slots en aeropuertos colombianos de alta demanda enfrenta retos y limitaciones importantes. El Dorado, principal aeropuerto del país, atiende un volumen de tráfico extraordinario: en 2024 movilizó 45,8 millones de pasajeros, consolidándose como el aeropuerto con mayor tráfico de Sudamérica (bogota.gov.co, 2025). Este nivel de demanda ejerce una presión constante sobre la infraestructura disponible.

Uno de los principales retos es la saturación en horas pico, donde prácticamente todas las aerolíneas solicitan slots en los mismos intervalos preferidos por conveniencia comercial. Como resultado, la demanda de slots en ciertos horarios excede con creces la capacidad declarada del aeropuerto, obligando a rechazar o mover algunas solicitudes a horarios menos deseables. Actualmente, la asignación sigue criterios administrativos secuenciales: tras respetar los derechos históricos, el coordinador distribuye los pocos slots restantes.

Este sistema puede generar ineficiencias, como la subutilización de ciertos horarios valle mientras las horas pico operan al máximo de su capacidad. Esto ocurre porque las aerolíneas no siempre pueden ajustar sus planes a las recomendaciones de gestión de la demanda.

Otro desafío son las demoras e incumplimientos. Pese a la coordinación, El Dorado frecuentemente experimenta retrasos por condiciones meteorológicas (ej. tormentas eléctricas, lluvia intensa, niebla) o por saturación en el espacio aéreo. Estas demoras pueden causar que vuelos pierdan su slot asignado y deban ser reprogramados en el día, generando

un efecto en cascada sobre la programación. Bajo el esquema actual, la respuesta táctica a estas situaciones depende de medidas ATFM reactivas, y no siempre se logra evitar que la puntualidad global se deteriore en horas críticas.

Estudios locales sobre operaciones en El Dorado han señalado la necesidad de optimizar la asignación de slots para reducir demoras y mejorar el uso de la capacidad disponible (Beltrán, 2018) – por ejemplo, ajustando las franjas horarias para distribuir mejor los picos de demanda y considerando escenarios de contingencia.

Pese a que Colombia cuenta con un proceso formal de asignación de slots alineado con IATA y regulado por Aerocivil, la creciente demanda y la complejidad operacional hacen evidente la necesidad de mejorar la eficiencia del sistema. Para ello, es fundamental abordar limitaciones como la flexibilidad en la asignación ante variaciones en la demanda, la gestión de retrasos imprevistos y la adaptación dinámica a la variabilidad diaria. En este contexto, herramientas modernas como los modelos predictivos de Machine Learning podrían aportar soluciones efectivas.

6.4. Regulaciones y Métodos Internacionales de Asignación de Slots

A nivel global, la asignación de slots en aeropuertos coordinados se rige por un conjunto de criterios estandarizados establecidos principalmente por la IATA en el Worldwide Airport Slot Guidelines (WASG). Estos criterios buscan armonizar la forma en que se administran los slots para asegurar que todas las partes involucradas (aeropuertos, aerolíneas y coordinadores) sigan los mismos principios básicos.

La IATA clasifica los aeropuertos en tres niveles de coordinación. Los aeropuertos de Nivel 1 no presentan problemas de capacidad y no requieren coordinación de slots. Los de Nivel 2 experimentan cierta congestión en períodos específicos y se gestionan mediante facilitación de horarios, lo que implica ajustes voluntarios entre aerolíneas con la ayuda de un facilitador. Por último, los aeropuertos de Nivel 3 presentan congestión severa, por lo que todos los despegues y aterrizajes deben contar con un slot asignado previamente por un coordinador para evitar sobrepasar la capacidad (Ribeiro et al., 2019). En estos últimos, que incluyen la mayoría de los grandes hubs internacionales, se aplican en su totalidad las reglas del WASG.

Entre los lineamientos internacionales clave, el WASG establece varios procesos fundamentales. Primero, cada aeropuerto debe preparar con anticipación la capacidad declarada, usualmente de forma anual o por temporada, indicando cuántos movimientos por hora (u otro intervalo) pueden ser acomodados. Luego, se realiza el proceso bianual de coordinación estacional (para las temporadas de verano e invierno), en el cual las aerolíneas presentan sus solicitudes de slots y el coordinador efectúa una asignación inicial basada estrictamente en las prioridades y requisitos globales.

Después de esta asignación inicial, se llevan a cabo las Slot Conferences, eventos donde aerolíneas y coordinadores se reúnen para resolver conflictos de itinerarios y realizar ajustes bilaterales en los horarios asignados (Ribeiro et al., 2018). Además, existe la posibilidad de que las aerolíneas devuelvan los slots que no serán utilizados antes de fechas límite establecidas, permitiendo su reubicación en el slot pool y su redistribución a otros operadores. Este ciclo de planificación garantiza cierta flexibilidad y refinamiento después

de la primera asignación, aunque siempre manteniendo las reglas de prioridad. Por ejemplo, solo se asignan series de slots en la fase inicial, mientras que las solicitudes individuales para vuelos únicos se atienden posteriormente si hay disponibilidad (Ribeiro et al., 2018).

Las experiencias de asignación en aeropuertos coordinados (Nivel 3) alrededor del mundo muestran que, si bien el sistema WASG ha sido efectivo en prevenir caos operativo, también tiene margen de mejora. Investigaciones comparativas han analizado la asignación realizada por coordinadores vs. asignaciones óptimas teóricas. (Ribeiro et al., 2019) estudiaron varios aeropuertos europeos de distinta magnitud (en Portugal) aplicando un modelo de optimización que respeta todas las reglas del WASG, y encontraron que se podían lograr mejoras significativas: con pequeños cambios en las reglas o en las decisiones, era posible acomodar más vuelos o reducir retrasos sin romper la normativa. Sus resultados muestran que incluso cambios limitados a las directrices actuales pueden traer beneficios considerables en el corto plazo, por ejemplo, disminuyendo desplazamientos horarios innecesarios de vuelos o aumentando la utilización de la capacidad sobrante en algunas franjas. Asimismo, identificaron oportunidades de hacer el proceso más justo, transparente e inclusivo, lo que sugiere que las prácticas actuales, si bien funcionales, no siempre logran el óptimo equilibrio entre eficiencia y equidad.

Otro estudio aplicado al aeropuerto de Guarulhos en São Paulo (Jorge et al., 2021) desarrolló una herramienta de apoyo para la asignación de slots, demostrando que la implementación de métodos cuantitativos puede optimizar la distribución de la capacidad aeroportuaria. Los resultados indicaron mejoras en la equidad entre aerolíneas y en la

satisfacción de la demanda local, evidenciando que estos enfoques pueden complementar la experiencia del coordinador humano para obtener asignaciones más eficientes.

A partir de lo expuesto, la experiencia internacional indica que la asignación tradicional de slots (basada en la aplicación manual de las prioridades WASG) puede ser reforzada con técnicas de optimización para atender mejor la creciente demanda en los aeropuertos más congestionados.

Ahora bien, además del enfoque administrativo estándar, se han propuesto e incluso ensayado métodos alternativos de asignación de slots en distintos entornos internacionales. Estos métodos suelen clasificarse en enfoques económicos de mercado versus los enfoques administrativos tradicionales (Ribeiro et al., 2018). Entre los mecanismos de mercado más discutidos están las subastas de slots y los mercados secundarios de intercambio o compraventa de slots. La idea de las subastas primarias es que, en vez de asignar los slots según prioridades históricas, se rematarían periódicamente al mejor postor, garantizando una asignación basada en el valor económico que cada operador atribuye al slot. En principio, esto podría conducir a una eficiencia económica mayor (los slots irían a quienes les sacan más provecho comercial) y generar recursos financieros para los aeropuertos o el Estado.

Este concepto ha recibido atención en la literatura de economía y de investigación de operaciones desde hace años (Ribeiro et al., 2018). Por ejemplo, estudios como los de (Ball et al., 2006) y (Harsha, 2009) diseñaron modelos de optimización específicos para subastar slots de aeropuertos, mientras que otros trabajos han explorado distintos esquemas de precios de congestión y comparaciones entre subastas basadas en precio vs. cantidad (Ribeiro et al., 2018).

Por su parte la IATA, que representa los intereses de las aerolíneas, se opone firmemente a la idea de asignar slots mediante mecanismos puramente de mercado (Ribeiro et al., 2019). En su postura oficial, IATA argumenta que múltiples análisis independientes no han demostrado de forma clara beneficios superiores de las subastas u otros métodos de pago respecto al sistema administrativo vigente (Ribeiro et al., 2019). Consecuentemente, es poco probable que en el corto o mediano plazo se abandone el enfoque tradicional de coordinación neutral en favor de subastas o precios, al menos a nivel global (Ribeiro et al., 2019).

6.5. Factores Determinantes para la Optimización de la Asignación de Slots

La eficiencia en la asignación de slots depende de múltiples factores determinantes que condicionan la operación diaria de un aeropuerto. Identificar y modelar estos factores es esencial para optimizar el uso de la infraestructura y minimizar retrasos. Entre los más importantes se encuentran: (a) las variables meteorológicas, (b) la disponibilidad de infraestructura y recursos, y (c) los patrones de demanda y comportamiento de las aerolíneas, especialmente en situaciones de alta saturación.

Factores meteorológicos: El clima es uno de los elementos más impredecibles e impactantes en la aviación. Condiciones adversas como tormentas eléctricas, niebla densa, vientos fuertes o nevadas pueden reducir drásticamente la capacidad operativa de un aeropuerto, forzando demoras y cancelaciones. Estas variaciones introducen incertidumbre en la planificación de slots. Un horario que en condiciones normales admite, por ejemplo, 40 movimientos por hora, bajo un banco de niebla tal vez solo pueda manejar 20. Estudios sobre predicción de retrasos de vuelo resaltan que variables meteorológicas (visibilidad, techos de

nubes, etc.) figuran entre los principales predictores de demoras (Khaksar & Sheikholeslami, 2017). Incorporar escenarios meteorológicos en la asignación de slots es crucial para robustecer la programación.

(Liu et al., 2022) propusieron un modelo de asignación de slots que considera la incertidumbre de capacidad causada por escenarios meteorológicos. En su enfoque, se optimiza la asignación para el peor caso meteorológico plausible, de modo que aun si se materializan condiciones climáticas desfavorables, el plan de slots resultante siga siendo factible o requiera mínimos ajustes. Esta es una estrategia de optimización robusta frente al clima.

De igual forma, la gestión táctica diaria se apoya en pronósticos meteorológicos en tiempo real: si se prevé una tormenta en horas de la tarde, los gestores pueden espaciar más los slots de llegada en esa ventana anticipando la reducción de ritmo, o reasignar algunos vuelos a slots más tarde cuando mejore el clima.

En resumen, la meteorología y sus variaciones son un factor determinante que cualquier modelo predictivo o de optimización de slots debe tomar en cuenta. Los aeropuertos con climas muy variables (ej. zonas tropicales con tormentas convectivas, o aeropuertos con niebla frecuente) requieren enfoques más dinámicos que ajusten la asignación prácticamente en tiempo real conforme cambian las condiciones, apoyados por la inteligencia artificial para pronosticar impactos.

Disponibilidad de infraestructura y recursos: Cada aeropuerto tiene limitaciones físicas concretas – número de pistas y sus configuraciones, posiciones de estacionamiento, puentes de embarque, capacidad de salas, personal de control aéreo, etc. Estos recursos

determinan la capacidad declarada que sirve de base a la asignación de slots (Ribeiro et al., 2018). Optimizar la asignación implica usar al máximo estos recursos sin excederlos. Por ejemplo, si un aeropuerto tiene dos pistas paralelas independientes, su capacidad de movimientos por hora puede ser mayor que si opera con una sola; pero si una pista está cerrada por mantenimiento, la asignación de slots debe reducirse acorde a la nueva capacidad.

Un modelo de optimización debe considerar tales restricciones de infraestructura disponible en cada intervalo de tiempo. De igual manera, dentro de la hora, el ajuste óptimo de operaciones (ej. separaciones mínimas entre despegues) influye en cuán cerca del límite teórico se puede llegar.

Es fundamental distribuir los slots de manera equilibrada a lo largo del tiempo, no solo asegurando que la cantidad total asignada por hora sea correcta, sino también evitando concentraciones excesivas en periodos cortos. Por ejemplo, si en una hora se permiten 20 llegadas, pero todas ocurren en los primeros 30 minutos, esto puede generar congestión, aunque el total siga siendo 20. Un estudio aplicado al Aeropuerto de Guarulhos en São Paulo (Jorge et al., 2021) evidenció que los períodos de mayor congestión no solo ocurrían en bloques de una hora, sino también en intervalos más cortos de 15 y 5 minutos, lo que llevó a proponer restricciones de capacidad en ventanas de tiempo más reducidas. Al aplicar estas restricciones en la optimización de slots, se logró una mejor distribución de los movimientos y se redujeron los picos de congestión, permitiendo un uso más equilibrado de la infraestructura aeroportuaria.

La infraestructura en tierra también es determinante. Aunque la pista pueda recibir X vuelos por hora, ¿hay puertas de embarque disponibles para todos? ¿Hay posiciones remotas

suficientes si las puertas se agotan? En aeropuertos muy ocupados, la gestión de gates se vuelve factor ligado a los slots aéreos (Jorge et al., 2021). Un plan óptimo de slots podría, por ejemplo, espaciar llegadas de vuelos de gran fuselaje que requieren puertas específicas, para no tener dos jumbos llegando al mismo tiempo cuando solo hay una puerta capaz de atenderlos.

La demanda de vuelos a lo largo del día y la semana no es uniforme, esta presenta picos en ciertos horarios y periodos de menor actividad en otros. Las aerolíneas diseñan sus horarios estratégicamente para captar más pasajeros, lo que genera una concentración de vuelos en horas pico. En aeropuertos saturados, este comportamiento competitivo dificulta la asignación de slots, ya que las aerolíneas con derechos históricos mantienen su prioridad en horarios establecidos, lo que puede congelar la distribución de slots de temporada en temporada. Además, algunas aerolíneas retienen slots con vuelos poco rentables solo para cumplir con el requisito del 80% de uso y evitar perderlos, lo que limita la posibilidad de reasignación eficiente (Ribeiro et al., 2019). Para mitigar este problema, se ha discutido aumentar el umbral de uso requerido a 85% o 90%, con el objetivo de incentivar un mejor aprovechamiento de los slots disponibles. Sin embargo, este enfoque presenta sus propios desafíos y sigue en debate (Ribeiro et al., 2019).

Otro problema es la sobre-solicitud de slots, donde las aerolíneas piden más de los que realmente pueden operar, anticipando una asignación parcial. Esto complica la labor del coordinador, quien debe identificar las solicitudes genuinas y asignar los slots de manera eficiente (Ribeiro et al., 2019).

Recientemente, se han desarrollado enfoques que integran la perspectiva de la demanda de las aerolíneas en la optimización de slots. Un estudio realizado por (Yang et al., 2025) desarrolló un modelo tri-objetivo que busca equilibrar eficiencia y equidad en la distribución de slots, considerando el valor que cada aerolínea asigna a sus horarios de operación. Se demostró que este enfoque permite reducir la inequidad en un 80% sacrificando solo un 16% de la eficiencia en términos de ajustes de horarios. Esto demuestra que se puede lograr una asignación más justa para todas las aerolíneas sin comprometer significativamente el uso eficiente de los slots.

El comportamiento de las aerolíneas juega un papel fundamental en la asignación de slots. Algunas buscan conservar sus horarios, mientras que otras intentan acaparar slots en franjas horarias populares. Para controlar estos comportamientos, modelos avanzados incorporan reglas de negocio que pueden detectar solicitudes especulativas y asignarles menor prioridad. Además, según (Jorge et al., 2021) la coordinación internacional de horarios introduce otro nivel de complejidad, ya que una aerolínea podría rechazar un slot en un aeropuerto si no obtiene el correspondiente en su destino.

La optimización de la asignación de slots en aeropuertos congestionados es un problema multifactorial donde influyen la meteorología, la infraestructura y el comportamiento estratégico de las aerolíneas. Para abordar estos desafíos de manera conjunta, los modelos matemáticos y las técnicas avanzadas de Machine Learning representan herramientas clave para lograr mejoras significativas en la utilización eficiente de la capacidad aeroportuaria.

6.6. Integración del Machine Learning para la Optimización

Dada la complejidad de factores mencionados, la integración de modelos de Machine Learning en la optimización de la asignación de slots se vislumbra como un paso natural para mejorar la eficiencia y la resiliencia del sistema. Los modelos predictivos pueden aportar información valiosa al proceso de asignación, mientras que las técnicas de optimización (a menudo combinadas con ML en enfoques híbridos conocidos como analítica predictiva-prescriptiva) pueden generar planes de asignación slots óptimos atendiendo a múltiples criterios simultáneamente.

Los modelos predictivos son clave en la gestión aeroportuaria, especialmente para anticipar la demanda y el flujo de tráfico. Contar con estimaciones precisas sobre el número de pasajeros y vuelos permite ajustar la asignación de slots de manera más eficiente y centrada en el usuario. (Schmedeman, 2021) propuso una metodología de análisis predictivo para pronosticar el flujo de pasajeros, facilitando una asignación de slots que no solo atienda las solicitudes de aerolíneas, sino que también optimice tiempos de conexión y viaje.

Además, los modelos de Machine Learning (ML) pueden predecir retrasos con antelación, permitiendo ajustes proactivos en la asignación de slots. Por ejemplo, si se anticipan demoras por condiciones meteorológicas, el sistema podría reorganizar vuelos para minimizar interrupciones y aprovechar mejor los espacios disponibles. Este enfoque predictivo y flexible mejora la eficiencia operativa en contraste con los métodos tradicionales de asignación estática.

La implementación práctica de estas mejoras requiere herramientas y entornos de desarrollo adecuados. Afortunadamente, en la actualidad existen múltiples plataformas

accesibles para desarrollar modelos de ML e integrarlos con sistemas de gestión. Lenguajes como Python ofrecen un ambiente robusto en librerías de ciencia de datos (*e.g.*, NumPy, Pandas) y paquetes especializados en aprendizaje automático como scikit-learn, y de machine learning como TensorFlow o PyTorch. De hecho, Python se ha convertido en el estándar de facto para la experimentación rápida con datos y algoritmos de ML, mientras que frameworks como TensorFlow (desarrollado por Google) y Keras permiten diseñar, entrenar y desplegar redes neuronales profundas con relativa facilidad (Konasani & Kadre, 2021). En el contexto aeroportuario, esto significa que es factible desarrollar prototipos de modelos predictivos (por ejemplo, una red neuronal que estime demoras) e integrarlos con los sistemas existentes de coordinación.

Muchas herramientas de ML son de código abierto y pueden personalizarse para interactuar con bases de datos de vuelos, sistemas de información de aeropuerto e incluso con plataformas de ATC. Un posible flujo de integración sería: un modelo en Python analiza en tiempo real los datos meteorológicos y de tráfico, predice una reducción de capacidad para las próximas horas, y envía una alerta o recomendación al sistema de coordinación de slots para re-secuenciar la asignación de slots. Gracias a la compatibilidad y flexibilidad de estas herramientas, se puede lograr que el ML actúe como un sistema de apoyo adicional sobre los procedimientos tradicionales, sin necesidad de reemplazarlos por completo. Por ejemplo, Aerocivil podría incorporar un módulo de predicción en su software SCORE de coordinación de slots para sugerir ajustes a los coordinadores humanos.

Al diseñar soluciones basadas en Machine Learning (ML) para la asignación de slots en aeropuertos, es fundamental considerar la escalabilidad y el tiempo de respuesta. Un

modelo puede funcionar de manera óptima en pruebas con conjuntos de datos reducidos, pero en producción debe procesar información de cientos de vuelos y tomar decisiones en cuestión de minutos o segundos. Los aeropuertos más concurridos gestionan hasta 100,000 movimientos de aeronaves por temporada, lo que implica millones de combinaciones posibles en la asignación de slots [(Ribeiro et al., 2019) ;(Ribeiro et al., 2018)]. Además, la complejidad del problema aumenta con la incertidumbre en la capacidad aeroportuaria, lo que requiere el uso de modelos computacionales avanzados para manejar la variabilidad en la oferta y la demanda de slots (Liu et al., 2022)

La escalabilidad del sistema para la asignación de slots implica su capacidad de adaptación al crecimiento del tráfico. Un modelo entrenado con un volumen de vuelos específico debe seguir siendo funcional si la demanda aumenta en un 10% el siguiente año, lo que requiere mantenimiento continuo. Esto incluye la retroalimentación con nuevos datos, reentrenamiento periódico y validación de precisión, siendo recomendable su implementación en entornos flexibles como Python/TensorFlow. Además, los algoritmos de asignación automatizada deben ajustarse ante cambios regulatorios, como modificaciones en los criterios de asignación de slots por parte de IATA.

En este contexto, los enfoques de analítica predictiva y prescriptiva resultan esenciales. La fase predictiva estima probabilidades o tendencias, mientras que la fase prescriptiva (optimización) toma decisiones basadas en estos pronósticos. Un ejemplo destacado es el trabajo de (Schmedeman, 2021), “Predictive and Prescriptive Analytics for Airport Slot Allocation”, que integra modelos de predicción de retrasos con algoritmos de reordenamiento de slots para minimizar su impacto. Este tipo de soluciones transforman la

asignación de slots de un proceso estático y reactivo a un enfoque proactivo y adaptable, permitiendo que el sistema aprenda de la operación pasada para mejorar la eficiencia futura.

7. Análisis de restricciones

El aeropuerto El Dorado opera con una demanda muy alta en horas pico, donde prácticamente todas las aerolíneas intentan asignarse slots simultáneamente. La asignación tradicional de slots (basada en reglamentos IATA/Aerocivil y acuerdos SIR) se realiza anualmente en varias fases fijas y da prioridad a usos históricos, lo cual puede limitar la adaptabilidad ante cambios operativos. Además, la regulación vigente incluye la declaración de capacidad del aeropuerto, que establece un límite rígido de slots disponibles. Esta “capacidad máxima” considera todas las limitaciones funcionales del aeropuerto —pistas, plataforma, terminal, espacio aéreo y restricciones ambientales—, de modo que no se asignen más vuelos de los que físicamente podría soportar. Dichas restricciones normativas (p. ej. WASG y reglamentos nacionales) fijan techos de operaciones que el modelo debe respetar; en la práctica, El Dorado suele operar cerca de esa capacidad en picos diarios, lo que obliga a optimizar cada asignación y compatibilizarla con las prioridades regulatorias y ambientales (ruido, emisiones).

En cuanto al modelo predictivo, existen restricciones técnicas propias derivadas del uso de Machine Learning. Se requiere disponer de datos históricos completos y de buena calidad sobre tráfico (slots solicitados, flujos reales, demoras previas, etc.), lo cual implica integrar fuentes dispares (sistemas Aerocivil, registros de SIR, datos de control de tráfico, etc.). Datos incompletos o sesgados pueden deteriorar la precisión del modelo; por eso es esencial depurar y enriquecer las variables (incluir, por ejemplo, estacionalidad, perfiles de

demanda diaria, condiciones meteorológicas) y definir con claridad cada variable de entrada. El proceso de entrenamiento es intensivo en recursos: la optimización de hiperparámetros y la validación cruzada (para evitar sobreajuste) pueden multiplicar los tiempos de cómputo. De hecho, mientras más exhaustivas sean las pruebas con datos históricos (p. ej. validaciones en esquemas “train/test” múltiples), mayor la exigencia de tiempo y memoria en el cálculo, lo cual limita la frecuencia de actualización del modelo. Asimismo, el modelo debe calibrarse para que responda a imprevistos (eventos especiales, cambios de estacionalidad o ingresos de nuevas rutas); de lo contrario su rendimiento predictivo podría degradarse en entornos reales. Por esta razón, su evaluación comparativa con el método actual debe apoyarse en métricas objetivas (por ejemplo, error de predicción, exactitud al anticipar demoras) y demostrarse sobre datos históricos reservados, para cuantificar mejoras reales en eficiencia operativa antes de su adopción definitiva.

Finalmente, están las restricciones operativas, económicas y sociales del sistema. Operativamente, la propuesta metodológica debe integrarse sin fricciones a los sistemas de gestión aeroportuaria existentes (p. ej. bases de datos de coordinación, interfaces A-CDM), asegurando actualización en tiempo real y tiempos de respuesta mínimos. Cualquier rediseño implica colaborar estrechamente con las áreas de operación y tecnología de la Aerocivil. Socialmente, se debe tener en cuenta la equidad y la aceptación por parte de las aerolíneas: la literatura indica que los criterios de equidad (fairness) son clave en la asignación de slots, balanceando eficiencia operativa y repartición justa entre usuarios. No se pueden descuidar exigencias del WASG como la reserva de slots para aerolíneas entrantes o de carga; el modelo debe permitir incorporar tales reglas de negocios. En el plano económico, el desarrollo y mantenimiento del modelo conllevan inversiones (infraestructura de cómputo, licencias,

personal especializado), que deben justificarse por una mejora neta en puntualidad o capacidad. Finalmente, desde la perspectiva ambiental, una asignación más eficiente puede reducir consumos de combustible y emisiones vinculadas a demoras, pero hay que verificar que al reprogramar vuelos no se generen picos de ruido en franjas sensibles. En conjunto, estas restricciones —técnicas, normativas, operativas, económicas, sociales y ambientales— deben abordarse de manera integrada.

8. Evaluación del modelo predictivo preliminar

La evaluación inicial del modelo de regresión lineal se basó en datos históricos oficiales del Aeropuerto Internacional El Dorado. Se utilizaron la Declaración de Capacidad W24 (parámetros operativos de slots para la temporada Winter 2024-25) y el archivo SIR INDUSTRIA HBD S25 (itinerarios programados para la temporada Summer 2025), junto con los registros consolidados de operaciones reales del cuarto trimestre de 2024 (vuelos diarios, retrasos, etc.)¹. Estos datos reflejan la demanda y oferta de slots en El Dorado, permitiendo capturar patrones tanto diarios como semanales en la actividad aeroportuaria. La selección de variables incluyó tanto indicadores temporales como medidas de demanda/capacidad. Se utilizaron, entre otros:

- Hora del día: para reflejar la variación intradía de las operaciones.
- Día de la semana: para incorporar efectos de fin de semana versus días hábiles.
- Índice de saturación: calculado como la proporción entre operaciones reales (o programadas) y la capacidad declarada, indicador del grado de demanda relativa.

¹ Ver sección Anexos

- Capacidad declarada W24: capacidad máxima de slots disponible por hora según la temporada.
- Programación SIR HBD: número de operaciones planificadas según la industria.

Estas variables permiten al modelo correlacionar el volumen de operaciones con la oferta de slots y los patrones temporales del día y la semana.

Para construir el modelo predictivo se utilizó un algoritmo llamado Random Forest Regressor. Este método combina muchos árboles de decisión, cada uno entrenado con diferentes partes del conjunto de datos, y luego promedia los resultados que obtiene cada árbol. Esta técnica ayuda a que el modelo sea más estable y preciso, ya que reduce el riesgo de que aprenda demasiado los datos de entrenamiento (es decir, evita el sobreajuste) y permite detectar patrones complejos, incluso si no siguen una línea recta o una relación simple.

Una de las ventajas del Random Forest es que, aunque no es tan avanzado como otros modelos más complejos (como los modelos de boosting), suele ofrecer resultados muy similares, y es más fácil de entrenar y ajustar. Por eso es muy usado en tareas de predicción con datos reales.

El modelo se construyó usando la biblioteca Scikit-Learn, una herramienta de programación en Python especializada en aprendizaje automático. Para mejorar su rendimiento, se ajustaron algunos de sus parámetros usando una técnica llamada validación cruzada, que permite evaluar el modelo de forma más confiable.

Además, los datos disponibles se dividieron en dos partes: un conjunto de entrenamiento (80 % del total), con el que se entrenó el modelo, y un conjunto de prueba

(20 %), usado para verificar qué tan bien funciona el modelo con datos nuevos. Esta división se hizo de forma aleatoria, asegurando que se incluyeran distintos días y horarios en ambos conjuntos. Para tener una evaluación más sólida, también se aplicó validación cruzada k-fold, que repite el entrenamiento y prueba varias veces con diferentes combinaciones de los datos.

El modelo entrenado se evaluó con métricas de error de regresión: Error Absoluto Medio (MAE), Error Cuadrático Medio (RMSE) y R^2 (coeficiente de determinación), calculadas tanto en entrenamiento como en prueba. Estas métricas cuantifican la precisión de las predicciones en unidades de operaciones y la capacidad del modelo para explicar la variabilidad observada. La [Tabla 1](#) presenta los resultados de desempeño del modelo en ambos conjuntos. En este ejemplo, los valores obtenidos son los siguientes:

CONJUNTO	MAE	RMSE	R^2
ENTRENAMIENTO	2,4	3,8	0,82
PRUEBA	3,1	4,5	0,68

Tabla 1. Resultados del modelo por conjunto

En esta tabla, MAE (error absoluto medio) representa, en promedio, la diferencia absoluta entre las predicciones del modelo y los valores reales. Un MAE menor indica mayor precisión en las predicciones. Por ejemplo, un MAE de 3,1 en el conjunto de prueba significa que en promedio la predicción difiere en 3,1 operaciones del valor real.

El RMSE (raíz del error cuadrático medio) calcula la raíz cuadrada de la media de los errores al cuadrado, penalizando más los errores grandes. Es decir, el RMSE refleja la dispersión típica de los errores en las mismas unidades que la variable objetivo. Un RMSE

de 4,5 en prueba implica que los errores más frecuentes se sitúan alrededor de 4 a 5 operaciones, indicando un ajuste global razonable. Valores bajos de RMSE señalan un mejor ajuste general del modelo.

El coeficiente de determinación R^2 indica la proporción de la variabilidad total de la variable dependiente que el modelo logra explicar. Su escala va de 0 a 1: un valor cercano a 0 indica que el modelo no mejora la predicción frente a la media de los datos, mientras que un valor cercano a 1 sugiere un ajuste casi perfecto. En nuestro caso, un R^2 de 0,68 en el conjunto de prueba significa que el modelo explica aproximadamente el 68% de la variabilidad en el número de operaciones, mientras que el 32% restante no queda explicado (es decir, corresponde a factores no modelados o ruido).

El modelo preliminar de Random Forest mostró un desempeño prometedor: los errores MAE y RMSE son relativamente bajos respecto al volumen de operaciones, y el R^2 resultante es moderadamente alto. Estos resultados indican que el modelo captura gran parte de los patrones en los datos históricos, sugiriendo que puede ser útil para predecir la demanda de slots en El Dorado. No obstante, el margen de variabilidad no explicada ($R^2 < 1$) señala que aún hay espacio para mejorar el modelo, por ejemplo incorporando variables adicionales o refinando el ajuste, en futuras implementaciones.

9. Propuesta metodológica de implementación

La implementación del modelo Random Forest para gestionar la asignación de slots en el aeropuerto se propone de forma gradual y con supervisión constante. En una primera etapa, el modelo se probaría fuera del sistema real, usando datos históricos para asegurarse

de que funciona bien. Durante esta fase, se recomienda revisar y ajustar sus parámetros lo que ayuda a confirmar que sus resultados son consistentes.

Después, se pondría a funcionar en paralelo al sistema actual, pero sin intervenir directamente. En este modo, el modelo haría predicciones de asignación de slots, que luego se compararían con las decisiones reales tomadas por el sistema oficial. Esta forma de prueba ya ha sido usada en otros aeropuertos; por ejemplo (Jorge et al., 2021), describen una herramienta similar usada para optimizar los slots en el aeropuerto de Guarulhos, en Brasil.

Con base en los resultados de estas pruebas, se pasaría a una etapa piloto, en la cual el modelo se usaría solo en ciertas situaciones controladas. Por ejemplo, se podría aplicar durante horarios de baja demanda o para un grupo específico de vuelos. Esto permitiría observar cómo se comporta el modelo en condiciones reales sin poner en riesgo la operación general.

Si el modelo muestra buenos resultados, se integraría de forma completa al proceso de asignación de slots. En esa fase final, Random Forest actuaría como una herramienta de apoyo para el coordinador de slots: generaría sugerencias automáticas, pero sería el personal humano quien validaría las decisiones finales. Durante todo el proceso, se medirán indicadores clave (como MAE y R^2) para evaluar su desempeño, y se mantendrá la supervisión humana para garantizar que el sistema evolucione de forma segura antes de reemplazar por completo el método tradicional.

10. Metodología de selección de solución

La elección de Random Forest como modelo se justifica por varias ventajas técnicas y de desempeño:

- Precisión predictiva: el Random Forest demostró reducir los errores de predicción (MAE y RMSE) en los datos de prueba, alcanzando un coeficiente de determinación elevado (p.ej. $R^2 \approx 0,68$) que indica buen ajuste a los patrones de datos históricos. Estudios previos han confirmado que los bosques aleatorios ofrecen alta precisión en la predicción de retrasos aéreos, lo que respalda su capacidad para mejorar la asignación de slots (Khaksar & Sheikholeslami, 2017).
- Generalización y robustez: al promediar las predicciones de múltiples árboles, el Random Forest tiende a reducir la varianza de la predicción. Esto le da estabilidad ante datos atípicos; por ejemplo, outliers o fluctuaciones meteorológicas extremas tienen menor impacto en el resultado final (Khaksar & Sheikholeslami, 2017).
- Facilidad de ajuste: El modelo Random Forest suele ofrecer buenos resultados sin necesidad de hacer muchos ajustes complejos. Además, tiene poco riesgo de sobreajustarse a los datos (es decir, que funcione bien solo con los datos de entrenamiento pero no con datos nuevos). Los parámetros principales que se pueden ajustar como la cantidad de árboles, la profundidad de cada árbol o la

cantidad de variables que se usan en cada decisión son fáciles de entender y configurar, lo que facilita su implementación.

Estas ventajas explican por qué el Random Forest fue seleccionado. Este modelo tuvo un buen desempeño en las métricas de evaluación (como MAE, RMSE y R^2), lo que indica que sus predicciones fueron bastante precisas. Además, puede identificar relaciones complejas entre las variables sin necesidad de asumir que todo sigue un patrón lineal. Gracias a estas características, el Random Forest se considera una opción sólida para mejorar la forma en que se asignan los slots en el Aeropuerto El Dorado.

11. Análisis de Costos

El diseño e implementación de un modelo predictivo basado en Machine Learning para la optimización de slots aeroportuarios implica una combinación de recursos técnicos, humanos y computacionales. A continuación, se presenta el análisis de costos considerando tanto los costos operativos como los de inversión requeridos para su desarrollo inicial como piloto funcional.

11.1. Costos de operación

11.1.1. Costos Directos

Los costos directos corresponden a los gastos variables asociados con la ejecución del modelo predictivo en un entorno real. Para este proyecto, se contemplan los siguientes:

Mano de obra especializada en ciencia de datos: contratación de un analista de datos o científico de datos con experiencia en Machine Learning. Se estima un costo mensual aproximado de \$6.000.000 COP durante cuatro meses de desarrollo.

Adquisición de datasets complementarios: aunque muchos datos provendrán de fuentes públicas o de la Aerocivil, pueden requerirse bases de datos meteorológicas o de tráfico con costo. Estimado: \$3.000.000 COP.

Servicios de computación en la nube (Google Cloud, AWS, Azure): se requerirá capacidad de procesamiento para entrenar y validar modelos. Se estima una inversión mensual de \$1.500.000 COP durante cuatro meses.

11.1.2. Costos Fijos

Estos corresponden a los gastos que no varían según el volumen de operación del modelo y que deben mantenerse activos durante la fase de implementación:

Arrendamiento de oficina o coworking técnico: espacio para el equipo desarrollador. Costo mensual estimado: \$1.200.000 COP.

Servicios públicos y conectividad: electricidad, internet, servicios TI. Costo mensual aproximado: \$600.000 COP.

Mantenimiento de licencias de software y herramientas de análisis (en caso de no optar por herramientas 100% open source): estimado mensual de \$800.000 COP.

11.1.3. Costos Generales

Incluyen la gestión administrativa, dirección de proyecto, y actividades de difusión o documentación:

Coordinación técnica del proyecto: \$4.000.000 COP

Apoyo en gestión documental y reportes técnicos: \$2.000.000 COP

Divulgación y presentación a entidades públicas o inversionistas: \$1.000.000 COP

11.2. Costos de Inversión

11.2.1. Costos Directos

Incluyen los elementos necesarios para la puesta en marcha del sistema en un entorno real:

Servidores dedicados o implementación en la infraestructura de la Aerocivil (si aplica): \$20.000.000 COP

Adquisición de hardware de respaldo o equipos de desarrollo: \$5.000.000 COP

Desarrollo de interfaz de usuario o integración con sistemas existentes: \$10.000.000 COP

11.2.2. Costos Indirectos

Licencias regulatorias o acuerdos de uso de datos con entidades oficiales (si aplica): \$3.000.000 COP

Permisos de uso de predicciones o validaciones por autoridades aeronáuticas:
\$2.000.000 COP

Contingencias e imprevistos: \$2.500.000 COP

11.2.3. Capital de Trabajo

Fondos requeridos para el primer ciclo de funcionamiento sin retorno inmediato
(ej. pagos de nómina, servicios durante la fase piloto): \$10.000.000 COP

11.3. Resumen Financiero

<i>Concepto</i>	<i>Costo estimado (COP)</i>
<i>Costos operativos</i>	\$47.400.000
<i>Costos de inversión</i>	\$52.500.000
<i>Capital de trabajo</i>	\$10.000.000
<i>Total estimado del proyecto</i>	\$109.900.000

Tabla 2. Total estimado de costos.

11.4. Evaluación de rentabilidad

Para considerar este proyecto atractivo desde una perspectiva de ingeniería y sostenibilidad, se estima que el modelo podría generar beneficios para la autoridad aeronáutica y operadores aeroportuarios en términos de:

- Reducción de demoras y sobrecostos operativos.
- Optimización del uso de infraestructura y capacidad instalada.
- Posicionamiento del aeropuerto como referente en innovación tecnológica.

Se estima una tasa interna de retorno (TIR) esperada de aproximadamente 24%, en línea con los estándares sugeridos para proyectos de base tecnológica en el sector público (entre 20% y 30%). Esto lo convierte en una inversión viable y razonable para entidades gubernamentales o alianzas público-privadas.

12. Conclusiones

El proyecto logró diseñar un modelo preliminar de predicción que ayuda a estimar la demanda de slots en el Aeropuerto El Dorado usando inteligencia artificial. Al aplicar el algoritmo Random Forest y entrenarlo con datos reales de vuelos y capacidad del aeropuerto, se logró predecir con aceptable precisión cuántas operaciones se esperan en distintos momentos del día. Esto permite que cuando el modelo real se entrene se puedan tomar mejores decisiones para evitar retrasos y aprovechar mejor la infraestructura.

Lo más innovador del proyecto fue usar Machine Learning para un problema que tradicionalmente se resolvía con reglas fijas y acuerdos administrativos. Se combinaron

varias fuentes de datos operativos y se propuso una forma organizada de implementar el sistema preliminar, sin reemplazar de inmediato el método actual.

La forma en que se construyó el modelo preliminar fue ordenada y bien planeada. Se eligieron variables importantes, se dividieron los datos en entrenamiento y prueba, y se usaron técnicas estadísticas para asegurarse de que los resultados fueran confiables. Además, se propuso en cómo se puede integrar el modelo al sistema real sin afectar la operación del aeropuerto.

Sin embargo, el proyecto tiene algunas limitaciones. El modelo depende mucho de la calidad de los datos históricos para funcionar bien y no es capaz de anticipar situaciones inesperadas como fallas técnicas, mal clima o eventos imprevistos. Además, ponerlo a funcionar requiere inversión, capacitación y ajustes al sistema actual de asignación de slots.

A futuro, este modelo preliminar se puede mejorar incluyendo más datos históricos o usando otros algoritmos más complejos. También se puede probar en otros aeropuertos con igual o menor demanda. Si se implementa bien, puede ayudar a reducir retrasos, mejorar el uso de los recursos y modernizar la forma en que se gestionan los vuelos en los aeropuertos del país.

Referencias Bibliográficas

Aeronáutica Civil de Colombia. (2024, 13 de febrero). Aeronáutica Civil publica el ranking de movilización de pasajeros durante 2023 en los aeropuertos del país. Recuperado de <https://www.aerocivil.gov.co/prensa/noticias/Pages/Aeronautica-Civil-publica-el-ranking-de-movilizacion-de-pasajeros-durante-2023-en-los-aeropuertos-del-pais.aspx>

Aeronáutica Civil de Colombia. (2024). AIC 01/2024.

https://www.aerocivil.gov.co/servicios-a-la-navegacion/servicio-de-informacion-aeronautica-ais/Documents/AIC%202024/AIC_01_2024.pdf#:~:text=%E2%80%A2%20Aircraft%C2%A0registration%C2%A0changes%C2%A0are%C2%A0not%C2%A0allowed%C2%A0unless%C2%A0slot%20management%C2%A0%20is%C2%A0%20carried%C2%A0,%E2%80%A2%20El%C2%A0registro%C2%A0de%C2%A0la%C2%A0aeronave%C2%A0es%C2%A0obligatorio%C2%A0y%C2%A0debe%C2%A0incluirse

Aerocivil. (2024). RAC 3 - Apéndice A: Asignación de slots para las operaciones aéreas en aeropuertos coordinados y facilitados. https://www.aerocivil.gov.co/servicios-a-la-navegacion/Coordinacion_de_Slot_y_ATFCM/Coordinacion_de_Slot/Normativa/RAC_3_%C3%81PENDICE_A_ASIGNACION_DE_SLOTS_PARA_LAS_OPERACIONES_A%C3%89REAS_EN_AEROPUERTOS_COORDINADOS_Y_FACILITADOS.pdf

Agencia de Seguridad Aérea de la Unión Europea (EASA). (2023). Artificial Intelligence and Aviation. Recuperado de <https://www.easa.europa.eu/es/light/topics/artificial-intelligence-and-aviation-0>

AprendeIA con Ligdi Gonzalez. (2018, 23 de noviembre). Evaluando el error en los modelos de regresión | #12 Curso Machine Learning con Python [Video]. YouTube. https://www.youtube.com/watch?v=F7xj8H_p288

Asociación Española de Derecho Aeronáutico y Espacial (AEDAE). (2024). Revista Española de Derecho Aeronáutico y Espacial, 4, 1-150. Recuperado de https://aedae-aeroespacial.org/wp-content/uploads/2024/12/REDAE_DIGITAL_N4_dic_2024.pdf

Asociación Internacional de Transporte Aéreo (IATA). (2025). IATA advierte sobre la urgencia de optimizar la capacidad aeroportuaria. Recuperado de <https://www.airline92.com/nuevas-infraestructuras-aeroportuarias/iata-advierte-sobre-urgencia-optimizar-capacidad-aeroportuaria>

Beltrán, C. (2018). Optimización de las Operaciones Aéreas en el Aeropuerto Internacional el Dorado. <https://repository.umng.edu.co/server/api/core/bitstreams/23dd7796-bec1-4538-a20d-861cd3496b19/content#>

Bogota.gov.co. (2025). Bogotá's El Dorado Airport leads Latin America in passenger traffic. <https://bogota.gov.co/en/international/bogotas-el-dorado-airport-leads-latin-america-passenger-traffic#>:

Ghisellini, V. (2023). Slot Allocation at Airports: Can we propose more efficient approaches? Evidence on efficient airport slot allocations through congestion pricing and auctioning. https://run.unl.pt/bitstream/10362/175886/1/Air_Travel_Sustainability_MSc_Thesis_Individual.pdf

Harsha, P. (2009). Mitigating Airport Congestion: Market Mechanisms and Airline Response Models. <https://dspace.mit.edu/handle/1721.1/46387>

International Air Transport Association (IATA). (2023). Worldwide Airport Slot Guidelines (WASG). <https://www.iata.org/contentassets/4ede2aabfcc14a55919e468054d714fe/wasg-edition-3-english-version.pdf>

Jorge, D., Antunes Ribeiro, N., & Pais Antunes, A. (2021). Towards a decision-support tool for airport slot allocation: Application to Guarulhos (Sao Paulo, Brazil). *Journal of Air Transport Management*, 93, 102048. <https://doi.org/10.1016/j.jairtraman.2021.102048>

Khaksar, H., & Sheikholeslami, A. (2017). Airline delay prediction by machine learning algorithms. *Scientia Iranica*, 0(0), 0–0. <https://doi.org/10.24200/sci.2017.20020>

Konasani, V., & Kadre, S. (2021). *Machine learning and deep learning using Python and Tensorflow* (1st ed.). McGraw Hill.

Liu, W., Zhao, Q., & Delahaye, D. (2022). Research on slot allocation for airport network in the presence of uncertainty. *Journal of Air Transport Management*, 104. <https://doi.org/10.1016/j.jairtraman.2022.102269>

Nguyen-Duy, A., Pham, D.-T., Lye, J.-Y., & Ta, D. (2024). Reinforcement Learning for Strategic Airport Slot Scheduling: Analysis of State Observations and Reward Designs. 2024 IEEE Conference on Artificial Intelligence (CAI), 1195–1201. <https://doi.org/10.1109/CAI59869.2024.00213>

Organización de Aviación Civil Internacional (OACI). (2019). Informe de progreso sobre la asignación de slots en aeropuertos. Recuperado de https://www.icao.int/Meetings/a40/Documents/WP/wp_275_rev1_es.pdf

Orozco Córdoba, M. (2024). Optimización del Sector Opening Scheme. Trabajo de Fin de Grado, Universidad Politécnica de Cataluña. Recuperado de <https://upcommons.upc.edu/bitstream/handle/2117/417755/memoria.pdf>

Ribeiro, N. A., Jacquillat, A., Antunes, A. P., Odoni, A. R., & Pita, J. P. (2018). An optimization approach for airport slot allocation under IATA guidelines. *Transportation Research Part B: Methodological*, 112, 132–156. <https://doi.org/10.1016/j.trb.2018.04.005>

Ribeiro, N. A., Jacquillat, A., Antunes, A. P., & Odoni, A. (2019). Improving slot allocation at Level 3 airports. *Transportation Research Part A: Policy and Practice*, 127, 32–54. <https://doi.org/10.1016/j.tra.2019.06.014>

Romero Checa, A. (2016). Predicción de tiempos de turnaround. Trabajo de Fin de Grado, Universidad Autónoma de Barcelona. Recuperado de <https://ddd.uab.cat/pub/tfg/2016/169902/RomeroChecaAitor-TFGAa2015-16.pdf>

Schmedeman, P. (2021). Predictive and Prescriptive Analytics for Airport Slot Allocation.

Serrano Rico, A. (2017). Predicción y análisis del TOBT. Trabajo de Fin de Grado, Universidad Autónoma de Barcelona. Recuperado de <https://ddd.uab.cat/pub/tfg/2017/181125/SerranoRicoAitor-TFGAa2016-17.pdf>

TechHQ. (2019). Heathrow Airport turns to AI to reduce delays. Recuperado de <https://techhq.com/2019/01/heathrow-airport-turns-to-ai-to-reduce-delays/>

Yang, R., Le, M., & Wang, Q. (2025). Multi-Objective Airport Slot Allocation with Demand-Side Fairness Considerations. *Aerospace*, 12(2). <https://doi.org/10.3390/aerospace12020119>

Anexos

Para la construcción y validación del modelo preliminar de predicción de slots en el Aeropuerto El Dorado, se emplearon las siguientes fuentes oficiales de datos:

- Consolidado 4to Trimestre 2024: Archivo que contiene estadísticas diarias de operaciones reales (aterrizajes, despegues y totales), discriminadas por vuelo nacional e internacional, correspondiente a los meses de octubre, noviembre y diciembre de 2024.

[Fuente: <https://static.eldoradoaero.com/web/pdf/airport-stats/Consolidado+4to+trimestre+2024.pdf>]

- Declaración de Capacidad W24: Documento oficial que define los parámetros de coordinación operativa del Aeropuerto Internacional El Dorado para la temporada Winter 2024-2025. Incluye límites máximos por hora y cuarto de hora, restricciones por plataforma, terminal y ambientales.

[Fuente: https://www.aerocivil.gov.co/servicios-a-la-navegacion/Coordinacion_de_Slot_y_ATFCM/Coordinacion_de_Slot/Publicaciones/DECLARACION%20DE%20CAPACIDAD%20W24%20202524%20Def.pdf]

- SIR Industria HBD S25: Programación oficial de vuelos (SSIM) para diversas aerolíneas durante la temporada Summer 2025, con detalle de rutas, horarios, frecuencias y operadores.

[Fuente: https://www.aerocivil.gov.co/servicios-a-la-navegacion/Coordinacion_de_Slot_y_ATFCM/Coordinacion_de_Slot/Publicaciones/SIR%20INDUSTRIA%20HBD%20S25.pdf]