

INTEGRACIÓN DE ALGORITMOS DE INTELIGENCIA ARTIFICIAL EN FUNCIÓN DEL PRONOSTICO DE COMSUMO DE COMBUSTIBLE EN AERONAVES ERJ 145 DE UNA AEROLINEA COLOMBIANA

C. Lozano^a, P. Melo^a, J. Bermúdez^a, S. González^a y S. Fuentes^a
^aFacultad de Ingeniería Aeronáutica – Escuela de Aviación del Ejército
Aeropuerto Internacional Eldorado, puerta 6 – Bogotá D.C., Colombia
Email: juanbermudezgonzalez@cedoc.edu.co

RESUMEN

Los costos operativos de vuelos comerciales están estrechamente vinculados a los precios de producción del combustible Jet A1. Con el transcurso del tiempo, se ha observado un incremento en su precio, desencadenando un efecto dominó en el costo del billete aéreo para el consumidor final. Esta investigación se centró en desarrollar un algoritmo de pronóstico del consumo de combustible específico para el modelo de aeronave ERJ 145, basándose en bitácoras recopiladas durante 2018 y 2019. Para la construcción del algoritmo, se implementó un código en Python, aprovechando las capacidades del framework Sci-kit Learn. Se aplicaron técnicas de "problema inverso" y "ingeniería de características" para optimizar y focalizar el tratamiento de los datos. Los resultados se asociaron con factores de mayor impacto en el ciclo de consumo. La eficacia del algoritmo propuesto se evaluó utilizando métricas como el Error Absoluto Medio (MAE), el Error Cuadrático Medio (MSE) y la Raíz del Error Cuadrático Medio (RMSE). Las métricas indicaron una capacidad de predicción eficiente en el consumo de combustible para vuelos comerciales.

Palabras clave: Machine learning, pronóstico de combustible, métricas de evaluación, problema inverso, algoritmos de predicción

INTRODUCCIÓN

El sector aeronáutico en Colombia ha experimentado un notable crecimiento en la última década. Entre 2011 y 2019, la actividad aérea en el país creció aproximadamente un 5% [1]. Sin embargo, la pandemia global de COVID-19 causó una drástica reducción en la industria, con una caída cercana al 73%. A pesar de este revés, a partir de 2021, la aviación comercial colombiana retomó su ritmo y ha mantenido un margen de crecimiento similar [2]. Este patrón de crecimiento amerita un estudio detallado por parte de operadores aeronáuticos tanto colombianos como internacionales, con el objetivo de pronosticar tendencias y diseñar estrategias de acción a corto, mediano y largo plazo.

Las aeronaves de aviación comercial modernas, equipadas con sistemas de propulsión a reacción, emplean predominantemente el combustible JET A-1, un hidrocarburo esencial para su funcionamiento [3]. Según estudios recientes [4], el costo del combustible para aviación ha experimentado un aumento sustancial, con un crecimiento aproximado del 250% en intervalos de cuatro años. Dada esta dinámica de precios y la constante búsqueda de eficiencia por parte de los operadores aéreos, es imperativo desarrollar planes de acción que optimicen el consumo de combustible, minimizando, por ejemplo, vuelos no rentables o de baja ocupación.

La tarea de optimizar el consumo de combustible puede conceptualizarse como un "problema inverso". Este concepto describe la relación entre un sistema bajo estudio y los datos observados en un contexto específico [5]. En relación con el pronóstico del consumo de combustible de la aeronave ERJ-145, se ha identificado una necesidad clara de abordar este problema desde la perspectiva del problema inverso, creando un puente entre los datos disponibles y el comportamiento del sistema. La **Figura 1** ilustra el esquema propuesto para desarrollar un algoritmo de inteligencia artificial que aborde esta tarea.

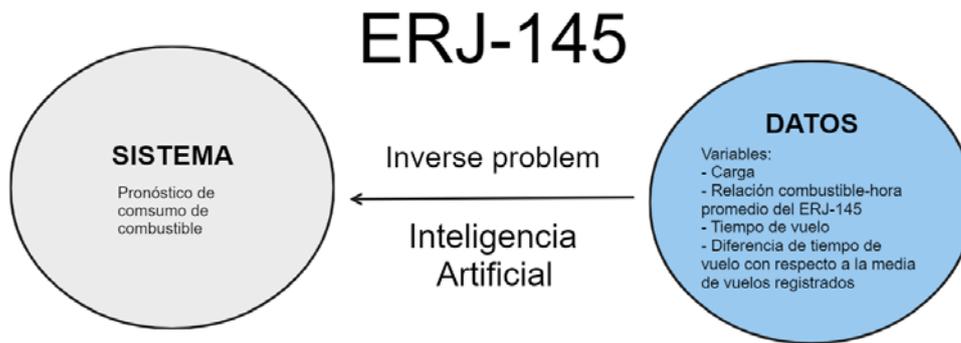


Figura 1. Diagrama solución pronóstico de consumo de combustible

La gestión de las variables independientes — tales como cantidad de carga, relación combustible-hora, tiempo de vuelo y diferencia de tiempo de vuelo promedio — se llevó a cabo mediante la técnica de ingeniería de características (en inglés, "feature engineering"). Este enfoque permite la normalización y transformación de la base de datos, ajustando los valores reales pero conservando las relaciones (ya sean directas o indirectas) entre ellos. Esto, a su vez, facilita una mayor precisión en el algoritmo de pronóstico de consumo de combustible al asegurar una correlación más robusta entre las variables [6]. La inteligencia artificial (IA) es un campo dentro de las ciencias de la computación que busca desarrollar modelos de pronóstico de información inspirados en la estructura y funcionamiento de las neuronas biológicas del ser humano. Estos modelos, conocidos como redes neuronales, toman datos a través de "entradas" (análogas a las dendritas), asignan pesos a estos datos (similar a las sinapsis), procesan la información mediante funciones de activación (equivalentes al núcleo neuronal) y generan una salida (similar al axón). Este enfoque permite que los algoritmos de IA sean versátiles y eficientes en su capacidad de aprendizaje, aplicables a diversos dominios como la generación de contenido, reconocimiento de objetos, visión por computadora, clasificación de datos, entre otros [7]. En la **Figura 2**, se presenta una representación esquemática del paradigma típicamente empleado en algoritmos de inteligencia artificial.

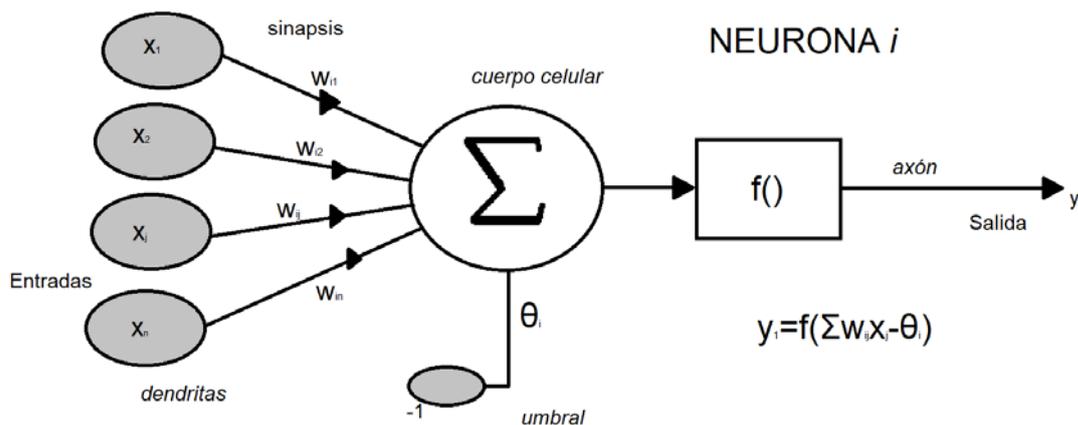


Figura 2. Ejemplo de red neuronal

Dentro de los diversos modelos de inteligencia artificial disponibles, el algoritmo "Random Forest" (Bosque Aleatorio) fue seleccionado como el más adecuado para la investigación en cuestión. Este modelo es capaz de generar un pronóstico del consumo de combustible basándose en factores externos relacionados. Su operación se fundamenta en la construcción de múltiples árboles de decisión a partir de subconjuntos del conjunto de datos de entrenamiento. A diferencia de la percepción común, Random Forest no se basa en el paradigma de redes neuronales, sino en una agregación de decisiones de múltiples árboles. Al obtener los resultados de cada árbol, se aplica un mecanismo de "votación suave" (soft voting) si la variable objetivo es categórica. En caso de que la variable sea numérica, se calcula un

promedio de los resultados de todos los árboles [8]. Este enfoque de combinar las predicciones de múltiples árboles proporciona al modelo una robustez y precisión superior en comparación con otros algoritmos de inteligencia artificial. En la Figura 3, se ofrece una representación visual del proceso llevado a cabo por el algoritmo Random Forest al procesar un conjunto de datos de entrenamiento.

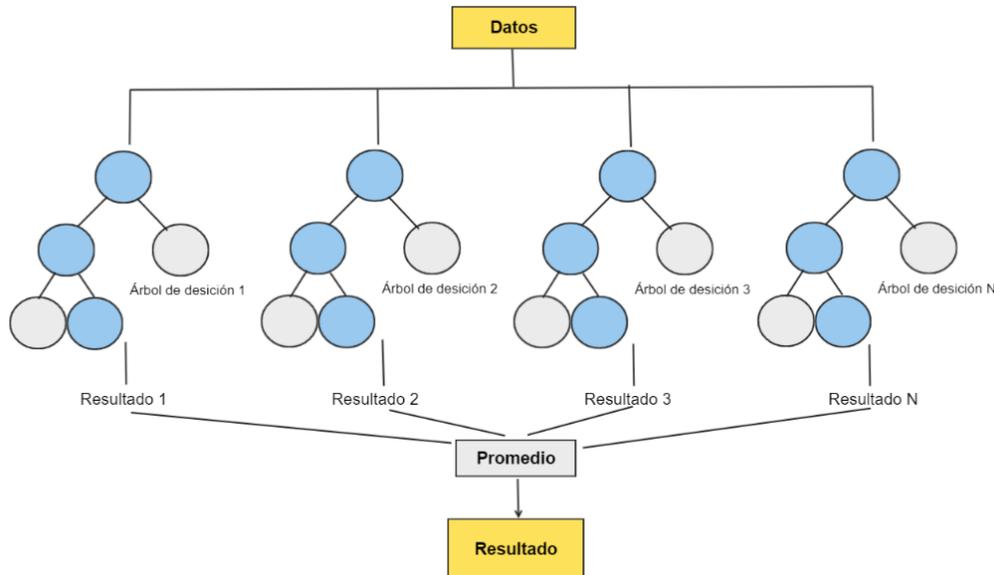


Figura 3. Paradigma de modelo *Random Forest*

Al finalizar la creación del modelo, fue necesario tener una evaluación de este. Las métricas de evaluación de un algoritmo cuantitativo son: MAE (mean absolute error), MSE (mean squared error) y RMSE (root mean squared error). Estas métricas son permiten obtener el estado de precisión de un modelo de predicción. MAE adquiere la diferencia entre el resultado esperado y el resultado obtenido, realiza una adición y aplica el cociente entre la cantidad de la muestra, el resultado se presenta en las mismas unidades utilizadas en los datos de entrenamiento por lo cual permite un mejor análisis; el MSE y RMSE son paralelos, el primero corresponde a la diferencia cuadrática de los valores esperados y reales, realizando la adición de estas sustracciones y el cociente con el valor de cantidad de la muestra, a su vez el RMSE toma el valor obtenido en el MSE y realiza un proceso de radicación cuadrática, lo que permite volver a las unidades de medidas iniciales, las ventajas del uso de la métrica RMSE es la penalización de los errores más grandes o con mayor valor [9]. Un análisis en conjunto con estas tres métricas permitirá la evaluación del desempeño de un modelo de predicción, cuyos valores cercanos a 0 indican perfección. En la **Tabla 1** es posible evidenciar las fórmulas de las métricas utilizadas y una síntesis de su uso en modelos de predicción.

Tabla 1. Métricas de evaluación

Métrica	Fórmula	Unidades	Ventaja	Desventaja
MAE	$\frac{1}{n} \sum_{i=1}^n y_1 - \hat{y}_i $ (1)	Misma de los datos.	Mejor comprensión, uso comercial.	No penaliza errores grandes.
MSE	$\frac{1}{n} \sum_{i=1}^n (y_1 - \hat{y}_i)^2$ (2)	Misma de los datos al cuadrado.	Penalización de errores grandes.	No maneja las mismas unidades que los datos.

RMSE	$\sqrt{\frac{1}{n} \sum_{i=1}^n (y_1 - \hat{y}_i)^2}$ (3)	Misma de los datos.	Penalización de errores grandes, unidades iguales que los datos.	Posible sesgo a errores grandes poco frecuentes.
-------------	--------------------------------------------------------------	---------------------	------------------------------------------------------------------	--------------------------------------------------

METODOLOGÍA

El enfoque CRISP-DM sirvió como piedra angular en la metodología adoptada para este estudio, estructurada en cuatro etapas principales, como se puede observar en la **Figura 4**. Este proceso comienza con un análisis exploratorio de datos, donde se examina minuciosamente el conjunto de datos para identificar sus principales características y detectar patrones inherentes. A continuación, se procede a la caracterización de los datos, lo que permite entender y priorizar las variables más relevantes para el estudio. Posteriormente, se desarrolla el algoritmo de inteligencia artificial, empleando técnicas de aprendizaje automático para modelar matemáticamente el fenómeno en cuestión. La última etapa involucra la aplicación de métricas de evaluación al algoritmo de predicción del consumo de combustible, con el objetivo de medir su precisión, robustez y aplicabilidad en distintos contextos. Este enfoque metodológico asegura un análisis de datos sistemático y riguroso, alineado con los estándares científicos contemporáneos [10].

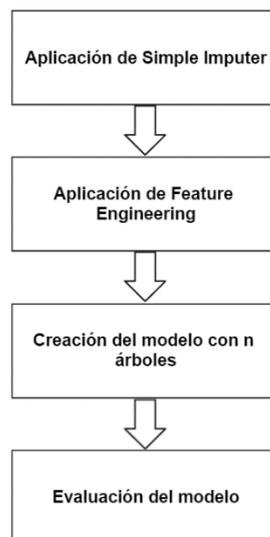


Figura 4. Diagrama de flujo creación del algoritmo

Siguiendo el paradigma CRISP-DM, el análisis exploratorio de datos resultó esencial, especialmente cuando se abordó la problemática de valores faltantes en el conjunto de datos. Estos vacíos en la información requerían una solución, por lo que se optó por aplicar la técnica de imputación "Simple Imputer", disponible en el paquete Sci-kit Learn de Python. Esta herramienta facilita la sustitución de valores ausentes o nulos en el conjunto de datos utilizando varios métodos, como la moda, mediana o media. Dada la distribución normal de los datos, se eligió el método de la media para la imputación. El procedimiento adoptado se ilustra en la **Figura 5**, que muestra un fragmento del algoritmo implementado.

Cristian Lozano, Pedro Melo, Juan Bermúdez, Sara González, Samuel Fuentes

```

1 from sklearn.impute import SimpleImputer
2 columnas_numericas = x.select_dtypes(include='number').columns
3 imputer = SimpleImputer(strategy='median')
4 for columna in columnas_numericas:
5     imputer.fit(x[[columna]])
6     x[columna] = imputer.transform(x[[columna]])

```

Figura 5. Aplicación de la técnica *Simple Imputer*

Prosiguiendo con la metodología adoptada, se emplearon diversas técnicas de ingeniería de características para escalar los datos, buscando optimizar el rendimiento del modelo según las métricas de evaluación. El lenguaje de programación Python, mediante el módulo Sci-kit Learn, facilita la implementación de múltiples técnicas de escalado, entre las que se encuentran: StandardScaler, MinMaxScaler, QuantileTransformer, MaxAbsScaler, PowerTransformer y RobustScaler. La **Figura 6** ilustra estas transformaciones, mostrando cómo, a pesar del cambio en la escala de los datos, se conservan las relaciones inherentes entre ellos. En dicha figura, los valores en color rojo representan la cantidad de carga; en verde, la relación combustible-hora promedio del ERJ-145; en amarillo, la diferencia entre el tiempo de vuelo promedio y el tiempo de vuelo real; y en azul, el tiempo de vuelo real.

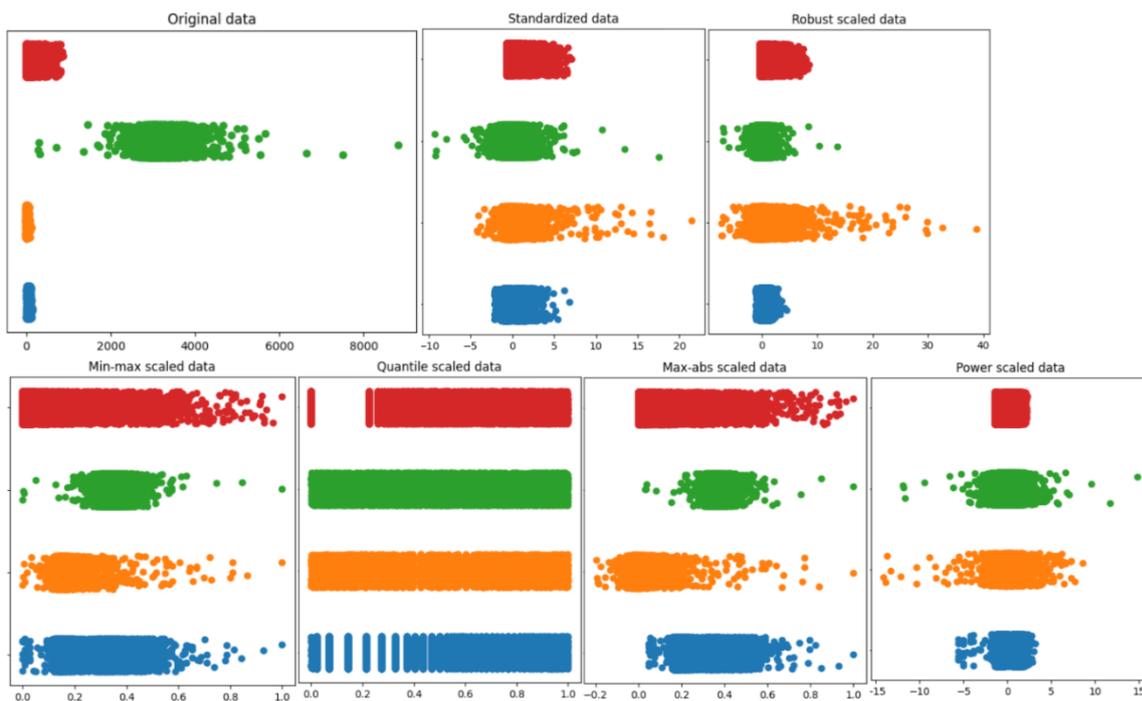


Figura 6. Técnicas aplicadas a los datos

Para el procesamiento de los datos utilizando el algoritmo de Random Forest, se empleó la clase RandomForestRegressor de Python. Sin embargo, antes de entrenar el modelo, fue esencial dividir el conjunto de datos en dos subconjuntos: entrenamiento y prueba. Esta división es crucial para prevenir el fenómeno conocido como "overfitting" o sobreajuste. Para este estudio, el 80% de los datos se destinó para entrenamiento y el 20% restante para pruebas. El sobreajuste ocurre cuando un modelo de machine learning se ajusta demasiado bien a los datos de entrenamiento, aprendiendo sus detalles específicos y ruido, en lugar de generalizar a partir de las tendencias subyacentes. Como resultado, aunque el modelo puede tener un rendimiento excelente en el conjunto de entrenamiento, su capacidad para hacer

Cristian Lozano, Pedro Melo, Juan Bermúdez, Sara González, Samuel Fuentes

predicciones precisas en datos no vistos (como el conjunto de prueba) se ve comprometida [11]. En la **Figura 7**, se muestra un fragmento del algoritmo donde se lleva a cabo la división de los datos y la configuración del modelo de Random Forest. Específicamente, se destaca la configuración de `n_estimators`, que determina el número de árboles de decisión en el bosque.

```

1 from sklearn.model_selection import train_test_split
2 X_train, X_test, y_train, y_test = train_test_split(x,y,test_size=0.20, random_state=0)
3 from sklearn.ensemble import RandomForestRegressor
4 rf_reg=RandomForestRegressor(random_state=42, n_estimators=500)
5 regressor=rf_reg.fit(X_train,y_train)
6 y_pred=regressor.predict(X_test)

```

Figura 7. *Random Forest en Python*

Tras desarrollar el modelo de pronóstico de consumo de combustible empleando diversas técnicas de ingeniería de características, se procedió a su evaluación utilizando las métricas MAE, MSE y RMSE. La **Figura 8** muestra el fragmento del algoritmo encargado de llevar a cabo esta evaluación de los modelos generados.

```

1 from sklearn import metrics
2
3 print("MAE: " , metrics.mean_absolute_error(y_test,y_pred))
4 print("MSE: " , metrics.mean_squared_error(y_test,y_pred))
5 print("RMSE: " , np.sqrt(metrics.mean_squared_error(y_test,y_pred)))

```

Figura 8. *Metrics en Python*

RESULTADOS Y DISCUSIÓN

Tras evaluar cada uno de los modelos generados, se consolidaron los resultados y se presentaron en la **Tabla 2**. De acuerdo con los datos, la técnica de escalado "Power Scaled" demostró ser la más eficaz, registrando valores de MAE, MSE y RMSE de 5.5930, 2469.2870 y 49.6910, respectivamente. Estos resultados corroboran el cumplimiento de los objetivos establecidos para el pronóstico del consumo de combustible en vuelos comerciales operados por aeronaves ERJ-145 de una aerolínea colombiana.

Tabla 2. Resultados por técnicas

Feature Engineering	MAE	MSE	RMSE
Standard	21,9240	2549,3440	50,4910
Min-max scaled	5,6050	2456,4600	49,5620
Quantile scaled	5,9050	3005,8390	54,8250
Max-abs scaled	5,6230	2472,5740	49,7240
Power scaled	5,5930	2469,2870	49,6910
Robust scaled	5,5945	2473,3031	49,7323

Los valores de MAE y RMSE proporcionan una medida del error promedio en las predicciones. Si, por ejemplo, un ERJ-145 requiere cierta cantidad de combustible durante un ciclo de vuelo, las predicciones

de nuestro modelo, basadas en el MAE, indicarían una desviación típica de alrededor de 6 kg. Sin embargo, en el peor de los casos, representado por el RMSE, esta desviación podría llegar a aproximadamente 50 kg.

El método "Power Scaled" ha demostrado ser particularmente eficiente en este contexto. Esta técnica transforma los datos para que se ajusten a una distribución gaussiana, siendo especialmente útil para datos con heterocedasticidad, es decir, cuando la varianza no es constante a lo largo del conjunto de datos [12]. Este escalamiento fue crucial, dadas las diversas unidades de medida en las que se presentaban los datos: toneladas, kilogramos, kilogramos por hora y minutos. Esto permitió una mayor correlación entre las variables y aseguró una varianza lineal entre ellas.

No obstante, los resultados también sugieren que hay margen para errores de predicción significativos. Estos pueden ser atribuidos a diversos factores, lo que subraya la necesidad de un análisis más detallado. Para optimizar el modelo predictivo, es esencial un enfoque exhaustivo que abarque desde la adquisición y calidad de los datos hasta la evaluación del número de árboles de decisión en el algoritmo. Este proceso de análisis detallado es crucial para identificar y corregir anomalías.

Posibles estrategias de mejora incluyen: obtener datos de mayor calidad y en mayor cantidad, especialmente considerando que el intervalo de tiempo analizado fue solo de 2018-2019; evaluar y ajustar los hiperparámetros del modelo, como la cantidad de árboles de decisión; y explorar otros algoritmos de aprendizaje automático para el pronóstico del consumo de combustible.

CONCLUSIONES

La integración de modelos y algoritmos de Machine Learning para la predicción de variables ha generado un profundo impacto en varios ámbitos. Uno de los primeros beneficiados ha sido la planificación estratégica empresarial. Gracias a los modelos predictivos de inteligencia artificial, las empresas ahora pueden tomar decisiones más informadas en áreas como la asignación de turnos de personal, la gestión de activos aeronáuticos y la adquisición de combustible. Esto no solo evita compras innecesarias de combustible a corto plazo, sino que también permite a las aerolíneas anticipar sus necesidades a largo plazo.

El medio ambiente también ha recibido beneficios indirectos a partir de estos avances. Al optimizar el uso de combustible, se reduce la emisión de CO₂ a la atmósfera, contribuyendo a mitigar el cambio climático. Además, al implementar estos modelos predictivos, las aerolíneas pueden colaborar conjuntamente para minimizar gastos logísticos, materiales, económicos y ambientales en activos que no serán utilizados inmediatamente.

Por otro lado, en Colombia, la adopción de tecnologías de vanguardia y modelos predictivos fortalece el ecosistema que integra industria, gobierno y academia. Fomentando el uso de estas herramientas se cataliza el interés en diversos sectores de la sociedad, generando oportunidades laborales, impulsando la investigación y potenciando la economía nacional.

Finalmente, la implementación de modelos predictivos de consumo de combustible a través de Machine Learning ha traído consigo beneficios tangibles para la aviación colombiana. Desde una planificación estratégica más eficiente y una reducción de costos operativos, hasta la protección del medio ambiente y el estímulo a la innovación tecnológica, esta convergencia entre aviación e inteligencia artificial señala un avance notable en el sector.

REFERENCIAS

1. Girón Girón, L. Á (2023). Estimación de demanda de transporte aéreo de pasajeros desde un enfoque de redes para aeropuertos tipo hub: caso Aeropuerto El Dorado Bogotá (tesis de maestría). Universidad Nacional de Colombia, Bogotá D.C., Colombia
2. Viñas, L. C., y Gómez, M. (2023). El impacto de la COVID-19 en la demanda turística internacional. *ININEE CIENCIA*, 1(1), 23-38.
3. Orellano Lasprilla, J. L. (2023). Análisis Fluido Dinámico Computacional de un mezclador estático para combustible de aviación JET A-1 y Biodiesel (tesis de maestría). Universidad ECCI, Bogotá D.C., Colombia.
4. Morrison, J., Bonnefoy, P., Hansman, R. J., y Sgouridis, S. (2011). Investigation of the impacts of effective fuel cost increase on the US Air Transportation Network and fleet. Investigation of the

- Impacts of Effective Fuel Cost Increase on the US Air Transportation Network and Fleet. <http://hdl.handle.net/1721.1/62860>
5. Gallet A., Rigby S., Tallman T. N., Kong X., Hajirasouliha I., Liew A., Liu D., Chen L., Hauptmann A. and Smyl D. (2022). Structural engineering from an inverse problems perspective Proc. R. Soc. A.4782021052620210526, <http://doi.org/10.1098/rspa.2021.0526>
 6. M. Panda, A. A. A. Mousa and A. E. Hassanien (2021), "Developing an Efficient Feature Engineering and Machine Learning Model for Detecting IoT-Botnet Cyber Attacks," en IEEE Access, vol. 9, pp. 91038-91052, 2021, doi: 10.1109/ACCESS.2021.3092054
 7. Márquez Díaz, Jairo. (2020). Inteligencia artificial y Big Data como soluciones frente a la COVID-19. Revista de Bioética y Derecho, (50), 315-331. Epub 23 de noviembre de 2020. Recuperado en 13 de julio de 2023, de http://scielo.isciii.es/scielo.php?script=sci_arttext&pid=S1886-58872020000300019&lng=es&tlng=es
 8. Espinosa-Zúñiga, Javier Jesús. (2020). Aplicación de algoritmos Random Forest y XGBoost en una base de solicitudes de tarjetas de crédito. Ingeniería, investigación y tecnología, 21(3), 00002. Epub 02 de diciembre de 2020. <https://doi.org/10.22201/ii.25940732e.2020.21.3.022>
 9. Hodson, T. O.: Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not, Geosci. Model Dev., 15, 5481–5487, <https://doi.org/10.5194/gmd-15-5481-2022>, 2022
 10. Schröer, C., Kruse, F., & Gómez, J. M. (2021). A systematic literature review on applying CRISP-DM process model. Procedia Computer Science, 181, 526–534. <https://doi.org/10.1016/J.PROCS.2021.01.199>
 11. Ying, X. (2019). An Overview of Overfitting and its Solutions. Journal of Physics: Conference Series, 1168, 022022. doi:10.1088/1742-6596/1168/2/022022
 12. Fabian Pedregosa, Gaël Varoquaux, Alexandre Gramfort, Vincent Michel, Bertrand Thirion, Olivier Grisel, Mathieu Blondel, Peter Prettenhofer, Ron Weiss, Vincent Dubourg, Jake Vanderplas, Alexandre Passos, David Cournapeau, Matthieu Brucher, Matthieu Perrot, Édouard Duchesnay; 12(85):2825–2830, 2011.