

Detección de anomalías en trayectorias de vuelo utilizando autoencoders y segmentación del espacio aéreo basada en regiones de Voronoi

Detection of flight trajectory anomalies using autoencoders and Voronoi-based airspace segmentation

MSc. José David Ortega Pabón¹, PhD. Jimmy Anderson Flórez Zuluaga²
MSc. Mónica Patricia Hernández Lordui³

¹ Universidad Pontificia Bolivariana, Escuela de ingenierías, Doctorado en ingeniería,, Medellín, Antioquia, Colombia.

² Institución Universitaria de Envigado, Facultad de ingeniería, Grupo de Investigación Tecnologías Emergentes Sostenibles e Inteligentes - GITESI, Envigado, Antioquia, Colombia.

³ University of Massachusetts Amherst, Manning College of Information & Computer Sciences, Master of Science in Computer Science, Amherst, Massachusetts, EEUU.

Correspondencia: jose.ortega@fac.mil.co

Recibido: 30 septiembre 2024. **Revisado:** 26 noviembre 2024. **Aceptado:** 17 diciembre 2024. **Publicado:** 01 enero 2025.

Cómo citar: J. D. Ortega Pabón, J. A. Flórez Zuluaga, y M. P. Hernández Lordui, «Detección de anomalías en trayectorias de vuelo utilizando autoencoders y segmentación del espacio aéreo basada en regiones de Voronoi», RCTA, vol. 1, n.º 45, pp. 82–90, ene. 2025.
Recuperado de <https://ojs.unipamplona.edu.co/index.php/rcta/article/view/3496>

Esta obra está bajo una licencia internacional
Creative Commons Atribución-NoComercial 4.0.



Resumen: Dado el creciente tráfico aéreo mundial, este artículo compara dos enfoques de autoencoders para la detección de anomalías en trayectorias aéreas, empleando el algoritmo DBSCAN como referencia inicial. El primer modelo utiliza características continuas normalizadas (latitud, longitud, velocidad y rumbo), mientras que el segundo incorpora una segmentación discreta del espacio aéreo mediante regiones de Voronoi, además de las variables cinemáticas. Los resultados indican una precisión para la detección de anomalías en promedio del 96% en el autoencoder continuo y del 97% en el modelo basado en Voronoi, con este último mostrando una mayor capacidad para identificar trayectorias normales. El análisis cualitativo demostró que los autoencoders, al incluir variables adicionales, capturan anomalías más complejas que DBSCAN. La integración de Voronoi mejoró la explicabilidad del modelo, facilitando la interpretación de las anomalías en su contexto geográfico.

Palabras clave: detección de anomalías, autoencoder, machine learning, aprendizaje no supervisado, regiones de voronoi.

Abstract: Given the increasing global air traffic, this article compares two autoencoder approaches for anomaly detection in flight trajectories, using the DBSCAN algorithm as an initial reference. The first model utilizes normalized continuous features (latitude, longitude, speed, and heading), while the second incorporates a discrete segmentation of the airspace through Voronoi regions, alongside kinematic variables. The results indicate on average 96% accuracy for the continuous autoencoder and 97% for the Voronoi-based model, with the latter showing a greater ability to identify normal trajectories. Qualitative analysis revealed that autoencoders, by including additional variables, capture more

complex anomalies than DBSCAN. The integration of Voronoi regions improved the model's explainability, facilitating the interpretation of anomalies within their geographic context.

Keywords: anomaly detection, autoencoder, machine learning, unsupervised learning, voronoi regions.

1. INTRODUCCIÓN

El constante aumento en las operaciones aéreas a nivel global, como se observa en los datos recolectados por Flightradar24 (ver Fig. 1), impone una carga creciente sobre los sistemas de control del tráfico aéreo, los cuales deben garantizar la seguridad operacional y gestionar eficientemente el espacio aéreo. A medida que el volumen de vuelos sigue incrementándose, la implementación de sistemas automatizados que asistan en la toma de decisiones se vuelve crucial para mantener los niveles de seguridad y eficiencia.

En este contexto, la detección de desviaciones en las características típicas de trayectorias de aeronaves, conocidas como anomalías, pueden comprometer la seguridad de las operaciones aéreas. Las anomalías pueden surgir por diversas causas, como condiciones meteorológicas adversas [1], [2], fallos técnicos o errores humanos. Ayudando también a reducir el impacto medioambiental, al reconocer desviaciones que podrían incrementar el consumo de combustible y las emisiones de gases contaminantes [3].




Fig. 1. Vuelos a nivel mundial 2020 – 2024, datos de Flightradar24.

Fuente: Elaboración propia.

Además, la identificación temprana de anomalías puede optimizar los costos logísticos asociados a la operación aérea. Prever desvíos o retrasos permite ajustar la gestión en tierra, como la asignación de puertas de embarque, el personal de operaciones y la distribución de recursos, lo que mejora la eficiencia operativa y reduce costos [3].

En términos generales, una anomalía se define como cualquier desviación significativa respecto a un patrón esperado. Desde una perspectiva estadística, las anomalías pueden interpretarse como cambios en la distribución de probabilidad dentro de los datos [4]. Aunque, esta desviación de lo “normal” también depende del contexto, es decir debido a la incidencia de factores externos como fenómenos meteorológicos, congestión de tráfico en temporadas altas, etc. Además, la baja frecuencia de eventos anómalos en los datos históricos supone otro reto. No obstante, la adopción de algoritmos de machine learning han mejorado la capacidad de detectar anomalías en tiempo real en diferentes industrias y sectores [5], [6].

En la aviación, una anomalía puede referirse a desviaciones en la trayectoria de vuelo, la velocidad, la altitud o el rumbo de una aeronave, entre otros datos disponibles. Diversos estudios han abordado esta temática mediante el uso de técnicas como autoencoders [7], [8], [9], [10], [11], redes generativas antagónicas (GANs) [8], Maquinas de soporte vectorial [3] y algoritmos no supervisados como K-means [12], DBSCAN [13] e Isolation Forest [7], aplicados a distintas fases del vuelo: despegue, crucero y aterrizaje.

El uso de modelos de machine learning facilita un enfoque de seguridad proactivo, anticipándose a problemas críticos. Esto contrasta con los enfoques reactivos tradicionales, donde las medidas correctivas se implementan solo después de que ha ocurrido un incidente. La anticipación de riesgos mejora tanto la seguridad como la eficiencia de las operaciones aéreas.

Este artículo propone una comparación y evaluación de dos enfoques basados en autoencoders, con el objetivo de mejorar la precisión en la detección de anomalías en la fase de crucero de rutas aéreas. El primer enfoque trabaja con características continuas, como la latitud, longitud, velocidad y rumbo. El segundo enfoque utiliza una representación discreta del espacio aéreo mediante regiones de Voronoi [14], junto con las características continuas de velocidad y rumbo. La

hipótesis principal de este artículo es que, al comparar ambos modelos cuantitativa y cualitativamente, el uso de las regiones discretas de Voronoi proporcionará una representación más compacta y eficiente del espacio aéreo, lo que permitirá detectar anomalías con una precisión comparable o incluso superior.

Además, el enfoque basado en regiones de Voronoi aporta una mayor explicabilidad al modelo, ya que permite analizar el comportamiento esperado dentro de cada región específica y cómo difieren las anomalías detectadas. Este enfoque permite una interpretación local de las desviaciones, lo que facilita la identificación y comprensión de los patrones anómalos, mejorando la capacidad de toma de decisiones de los operadores al proporcionar una visualización clara y precisa de dónde y cómo ocurren potenciales anomalías en el espacio aéreo.

El resto del artículo está organizado de la siguiente forma: en la sección 2, se describen las fases metodológicas utilizadas para el desarrollo de la investigación, incluyendo los algoritmos empleados y los datos de entrada. En la sección 3, se presentan los resultados obtenidos, donde se comparan los enfoques de detección de anomalías basados en autoencoders. Finalmente, en la sección 4, se exponen las conclusiones y se proponen futuras líneas de investigación relacionadas con la mejora de los modelos.

2. METODOLOGÍA

En esta sección, se describe la metodología empleada para la detección de anomalías en trayectorias aéreas mediante un enfoque comparativo de dos autoencoders. De acuerdo con la Fig. 2, el proceso metodológico comienza con el preprocesamiento de los datos de vuelo, seguido de la identificación de anomalías de referencia ("ground truth") utilizando el algoritmo DBSCAN, el cual clasifica las detecciones de las trayectorias como normales o anómalas, basándose exclusivamente en las características espaciales de latitud y longitud.

A partir de esta clasificación, los autoencoders son entrenados exclusivamente con las detecciones que han sido etiquetadas como normales por DBSCAN. Esto permite que los autoencoders aprendan el comportamiento típico de las trayectorias aéreas, para posteriormente identificar desviaciones significativas que podrían representar anomalías.

La metodología se divide en dos enfoques: el primero emplea características continuas normalizadas (latitud, longitud, velocidad y rumbo) para detectar anomalías, mientras que el segundo utiliza una representación discreta del espacio aéreo mediante regiones de Voronoi, además de la velocidad y rumbo normalizados. Ambas aproximaciones son evaluadas y comparadas en términos de precisión y capacidad de detección de anomalías, tanto cuantitativa como cualitativamente.




Fig. 2. Metodología para la detección de anomalías.
 Fuente: Elaboración propia.

2.1. Base de datos y preprocesamiento

La base de datos utilizada está conformada por 120 trayectorias de vuelos comerciales en la ruta Bogotá-San Andrés, que conecta el Aeropuerto Internacional El Dorado con el Aeropuerto Internacional Gustavo Rojas Pinilla. Estos datos, recuperados de Flightradar24, abarcan los meses de julio y agosto de 2024. Cada vuelo se representa mediante una trayectoria, que consiste en un conjunto de puntos registrados a lo largo del recorrido. Estos puntos, denominados detecciones,

capturan información sobre la posición de la aeronave (latitud y longitud) y su comportamiento cinemático (altitud, velocidad y rumbo).

La ruta Bogotá-San Andrés es una de las más largas en Colombia, con una duración promedio de 90 minutos, lo que implica mayores riesgos en caso de desviaciones o anomalías, ya que estas pueden aumentar el consumo de combustible y las emisiones, además de comprometer la seguridad operacional. El análisis se enfoca en la fase de crucero del vuelo, para tal fin, se filtraron las detecciones registradas por debajo de los 10.000 pies (ft) de altitud, dado que las fases de despegue y aterrizaje suelen introducir variaciones que no reflejan de manera precisa el comportamiento de la aeronave en altitud estable.

Para el desarrollo de la metodología propuesta, se seleccionaron las variables latitud y longitud para representar la posición de la aeronave, mientras que el rumbo y la velocidad se utilizaron como características cinemáticas. La altitud fue excluida del análisis debido a su elevada correlación con la velocidad, con un coeficiente de Pearson de 0.87, lo que sugiere que ambas variables transmiten información similar. Por ello, se determinó que la inclusión de la altitud sería redundante.

2.2. Anomalías de Referencia (Ground Truth) con DBSCAN

Para determinar el ground truth de anomalías en las trayectorias aéreas, que será utilizado como referencia para los algoritmos de autoencoders en las etapas posteriores, se empleó el algoritmo DBSCAN (Density-Based Spatial Clustering of Applications with Noise) [15], utilizando la implementación disponible en la librería scikit-learn. Este algoritmo agrupa puntos cercanos en función de su densidad espacial y clasifica como anomalías aquellos que están dispersos o aislados de los grupos principales. DBSCAN se aplicó a las coordenadas de latitud y longitud para identificar desviaciones geográficas en las trayectorias de vuelo.

En la Fig. 3, se presenta una visualización de los resultados obtenidos con DBSCAN. Los puntos verdes corresponden a detecciones clasificadas como normales, mientras que los puntos rojos representan las anomalías detectadas. Además, estas anomalías servirán como referencia para evaluar los modelos propuestos en las siguientes etapas.




Fig. 3. Detecciones normales y anomalías en trayectorias aéreas identificadas por DBSCAN.

Fuente: Elaboración propia.

El algoritmo fue configurado con los siguientes parámetros:

- ϵ (epsilon): Se fijó un valor de 0.083 grados, que corresponde aproximadamente a 5 millas náuticas, como el radio máximo dentro del cual dos puntos se consideran vecinos. Este parámetro controla la distancia a partir de la cual las detecciones pueden pertenecer al mismo grupo.
- min_samples: Se estableció en 10, lo que significa que al menos 10 puntos deben estar dentro del radio ϵ para que un punto forme parte de un grupo o cluster. Para que una detección no sea clasificada como anomalía, debe pertenecer a un grupo, independientemente de cuál sea. Si un punto no cumple con este criterio, se clasifica como ruido o anomalía.

2.3. Normalización de los datos

Previo al entrenamiento de los autoencoders, se llevó a cabo un proceso de normalización utilizando la normalización estándar Z, implementada en scikit-learn. Este paso es fundamental porque variables como latitud, longitud, rumbo y velocidad presentan escalas distintas, lo que podría introducir sesgos en el modelo, favoreciendo aquellas características con rangos más amplios. Al normalizar los datos, todas las características se ajustan a una escala uniforme, permitiendo que el modelo trate todas las variables de manera equilibrada.

La normalización ajusta cada característica para que tenga una media de 0 y una desviación estándar de 1, lo que se logra mediante la ecuación (1).

$$x_{normalizada} = \frac{x - \mu}{\sigma} \quad (1)$$

Donde x es el valor original de la característica, μ es la media de esa característica, y σ es la desviación estándar.

2.4. Asociación de las detecciones con regiones de Voronoi

Para segmentar el espacio aéreo en el análisis de trayectorias aéreas, se utilizaron los diagramas de Voronoi, siguiendo la metodología descrita en [14], que permite una discretización espacial al dividir el espacio en regiones basadas en puntos geodésicos significativos, denominados también como generadores.

En el caso de la ruta Bogotá-San Andrés, se generaron regiones de Voronoi utilizando el algoritmo dispuesto en el sistema de información geográfica QGIS, tomando como referencia los puntos significativos de las rutas ATS superiores en Colombia [16]. Este proceso segmenta el espacio aéreo en un conjunto de polígonos no superpuestos.

Como se puede apreciar en la Fig. 4, en las zonas de mayor congestión, como el centro del país alrededor del Aeropuerto El Dorado, se observa una mayor densidad de regiones, lo que refleja la complejidad de la gestión del tráfico en estas áreas.

Cada detección registrada durante el vuelo se asocia a una región de Voronoi específica mediante una operación de contención. Este proceso añade un nuevo atributo categórico a los datos de las trayectorias, denominado zona Voronoi.

El atributo zona Voronoi permite agrupar las detecciones de múltiples trayectorias, reduciendo la complejidad espacial continua y facilitando el análisis de patrones de vuelo. De este modo, la variabilidad en las trayectorias se acota dentro de un conjunto finito de regiones, lo que simplifica la identificación de patrones anómalos o desviaciones significativas.

En la Fig. 4, se muestra un ejemplo de cómo se generan las regiones de Voronoi utilizando los puntos significativos de las rutas superiores en Colombia.




Fig. 4. Regiones de Voronoi generadas con las rutas superiores en Colombia. **Fuente:** Elaboración propia.

2.5. Codificación de las regiones de Voronoi

Una vez que cada detección fue asociada a su correspondiente región de Voronoi, se realizó la codificación de estas regiones categóricas mediante la técnica de One-Hot Encoding, implementada con scikit-learn. Dado que los autoencoders no admiten variables categóricas de manera directa, es necesario transformar las regiones de Voronoi en un formato binario que el modelo pueda procesar. Esta codificación convierte cada región en una columna donde los valores son 0 o 1, indicando si una detección pertenece o no a una región específica.

Antes de realizar la codificación, se identificaron las regiones de Voronoi más representativas para la ruta Bogotá - San Andrés. Para este propósito, se estableció un umbral mínimo de 10 trayectorias por región, de forma que solo aquellas que superaran este umbral fueran consideradas significativas. En la Fig. 5 se muestra la distribución de trayectorias por región. Las regiones que no alcanzaron este umbral se excluyeron de la codificación, lo que garantiza que las detecciones dentro de dichas zonas no influyan en el entrenamiento del autoencoder.




Fig. 5. Trayectorias por región de Voronoi para la ruta Bogotá - San Andrés. **Fuente:** Elaboración propia.

Durante el proceso de predicción, cualquier región de Voronoi no conocida en el conjunto de entrenamiento se codifica como un vector de ceros. Este enfoque asegura que las regiones de menor relevancia o aquellas fuera del conjunto de entrenamiento no interfieran en el comportamiento del modelo, manteniendo una representación categórica adecuada del espacio aéreo segmentado.

2.6. Detección de anomalías con autoencoders

Para la detección de anomalías en trayectorias aéreas, se entrenaron dos autoencoders con distintas configuraciones de entrada. El primero utiliza las características continuas normalizadas (latitud, longitud, velocidad y rumbo). El segundo incorpora una representación discreta del espacio aéreo mediante regiones de Voronoi, codificadas con One-Hot Encoding, además de las características cinemáticas velocidad y rumbo, normalizadas. Ambos modelos fueron implementados utilizando la librería Keras, con un optimizador Adam y la función de pérdida de error cuadrático medio (MSE), definida en la ecuación (2).

$$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2 \quad (2)$$

Donde x_i es el valor original, $\hat{x}_i$ es el valor reconstruido, y n es el número de características. El objetivo de los autoencoders es minimizar el error de reconstrucción, lo que les permite aprender los patrones normales de las trayectorias, y con base en esto detectar anomalías.

Ambos autoencoders fueron entrenados durante 100 épocas con un tamaño de batch de 32. Las capas ocultas de ambos modelos usan la función de activación ReLU, y en la capa de salida una función de activación lineal.

La arquitectura de ambos autoencoders se detalla en la tabla 1.

Tabla 1: Arquitectura autoencoders

Capa	Autoencoder continuo	Autoencoder Voronoi
Entrada	4	11
Codificadora 1	16	64
Codificadora 2	8	32
Cuello de botella	4	8
Decodificadora 1	8	32
Decodificadora 2	16	64
Salida	4	11

Fuente: elaboración propia.

En la Fig. 6, se presenta un comparativo de los errores de reconstrucción entre ambos autoencoders.

Los resultados muestran que el autoencoder continuo presenta una mayor dispersión en los errores de reconstrucción, alcanzando valores de hasta 0.38. Esto sugiere que el modelo continuo es más sensible a variaciones en las trayectorias o anomalías en los datos, lo que indica una mayor dificultad para reconstruir con precisión ciertos puntos.




Fig. 6. Comparativo errores de reconstrucción.
Fuente: Elaboración propia.

Por otro lado, el autoencoder basado en regiones de Voronoi (autoencoder Voronoi) muestra una dispersión más reducida en los errores de reconstrucción, alcanzando un máximo de 0.25. Esto sugiere que el modelo Voronoi ofrece mayor consistencia en sus predicciones. La diferencia en el comportamiento de ambos modelos podría atribuirse a la segmentación discreta del espacio aéreo en el enfoque Voronoi, lo que simplifica la representación de las trayectorias. Además, este modelo incluye un mayor número de parámetros de entrada, al incorporar 9 regiones de Voronoi junto con las características de velocidad y rumbo. Esta mayor complejidad se refleja en el número incrementado de neuronas en las capas codificadoras y decodificadoras, lo que le permite reconstruir las trayectorias con mayor precisión y capturar patrones.

3. RESULTADOS

Para evaluar y comparar los resultados obtenidos por ambos autoencoders (continuo y Voronoi), se realizó un análisis cuantitativo y cualitativo. Se establecieron diferentes umbrales de reconstrucción para cada modelo, basados en el análisis de los errores de reconstrucción (Fig. 6). Para el autoencoder continuo, se fijó un umbral de 0.02, mientras que para el autoencoder Voronoi, el umbral fue de 0.014. Estos umbrales determinan cuándo una detección es clasificada como anómala o normal.

En el análisis cuantitativo, se examinaron las métricas de precisión, recall y F1-score, comparando las predicciones de los autoencoders con las etiquetas generadas por DBSCAN. Por otra parte, el análisis cualitativo evaluó cómo cada enfoque segmenta y clasifica las detecciones.

En términos cuantitativos, ambos autoencoders mostraron una alta eficacia en la detección de anomalías en comparación con las etiquetas de referencia generadas por DBSCAN, como se muestra en la tabla 2. El autoencoder basado en características continuas (latitud, longitud, velocidad y rumbo) alcanzó una precisión en promedio del 96% en la detección de anomalías, mientras que el autoencoder basado en regiones de Voronoi logró una precisión ligeramente superior en promedio del 97%. Sin embargo, las diferencias en la identificación de trayectorias normales fueron significativas: el autoencoder continuo obtuvo una precisión de 8%, frente al 21% del modelo basado en Voronoi.

Tabla 2: Evaluación cuantitativa autoencoders

Métrica	Autoencoder continuo	Autoencoder Voronoi
Precisión (normal)	8%	21%
Precisión (anomalía)	96%	97%
Recall (normal)	11%	32%
Recall (anomalía)	94%	95%
F1-score (normal)	9%	25%
F1-score (anomalía)	95%	96%
Macro avg	0.53	0.63

Fuente: elaboración propia.

El recall, que mide la capacidad del modelo para detectar correctamente las anomalías, fue similar para ambos enfoques, con valores cercanos al 95% para el autoencoder Voronoi y el continuo. Sin embargo, el F1-score y el macro promedio (promedio entre ambas clases: normal y anomalía) reflejan una ventaja del modelo basado en Voronoi, que presentó un macro promedio de 0.63 frente a 0.53 del autoencoder continuo. Este resultado indica que el autoencoder Voronoi no solo es más eficiente en la detección de anomalías, sino que también es más preciso en la identificación de trayectorias normales, lo que es relevante para reducir falsos positivos.

Dado que DBSCAN se basó exclusivamente en latitud y longitud para la detección de anomalías, mientras que los autoencoders consideran características adicionales, como velocidad y rumbo. Las métricas cuantitativas podrían verse afectadas por la capacidad de los autoencoders para detectar patrones relevantes que DBSCAN no logró identificar. Esto refuerza la necesidad de

complementar el análisis cuantitativo con un análisis cualitativo, para evaluar los casos en los que los modelos capturan desviaciones significativas no detectadas por DBSCAN.

El análisis cualitativo reveló diferencias importantes en el comportamiento de los dos autoencoders. En la Fig. 7, se observa que el autoencoder continuo clasifica como normales detecciones que están distantes de los corredores aéreos esperados, mientras que el enfoque basado en Voronoi muestra un mayor control en la clasificación, asociando las detecciones con las regiones representativas para la ruta (Fig. 8). Para ambos casos Los puntos verdes corresponden a detecciones clasificadas como normales y los puntos rojos corresponden a anomalías. Esto sugiere que el autoencoder continuo es más sensible a pequeñas variaciones en las trayectorias, lo que puede llevar a clasificaciones incorrectas y a una mayor tasa de falsos positivos.




Fig. 7. Detecciones anómalas y normales identificados por el autoencoder continuo.

Fuente: Elaboración propia.




Fig. 8. Detecciones anómalas y normales identificados por el autoencoder Voronoi.

Fuente: Elaboración propia.

Una característica relevante del Autoencoder Voronoi es su capacidad de ofrecer una mayor explicabilidad en los resultados. Al estar alineado con la segmentación del espacio aéreo mediante regiones de Voronoi, permite interpretar con mayor claridad dónde se localizan las anomalías en relación con el espacio geográfico, facilitando así el análisis y la comprensión de los patrones de vuelo. Como se aprecia en la visualización de las trayectorias por región de Voronoi (Fig. 9), el modelo ofrece una representación intuitiva de la distribución de las anomalías a lo largo del espacio aéreo, lo que proporciona una valiosa herramienta para el análisis cualitativo de los resultados.



Fig. 9. Datos anómalos y normales identificados por el autoencoder Voronoi para la región BUTAL.

Fuente: Elaboración propia.

4. CONCLUSIONES

Este artículo presenta una comparación entre dos enfoques de autoencoders para la detección de anomalías en trayectorias aéreas. La metodología utiliza el algoritmo no supervisado DBSCAN para generar una referencia inicial de anomalías, que luego es empleada en el entrenamiento de los autoencoders. Estos modelos difieren en los datos de entrada: uno se entrena con características continuas normalizadas (latitud, longitud, velocidad y rumbo), mientras que el otro incorpora una representación discreta del espacio aéreo mediante regiones de Voronoi, junto con las variables cinemáticas de velocidad y rumbo.

Ambos autoencoders mostraron un alto desempeño en la detección de anomalías, con una precisión en promedio del 96% en el autoencoder continuo y del 97% en el autoencoder Voronoi. Sin embargo, se observaron diferencias significativas al evaluar la capacidad para identificar trayectorias normales basadas en las etiquetas generadas por DBSCAN. Mientras que el autoencoder continuo obtuvo una precisión del 8%, el modelo Voronoi alcanzó un 21%.

Al complementar los resultados cuantitativos con un análisis cualitativo, como se observa en las Fig. 7 y Fig. 8, se puede inferir que, aunque DBSCAN se basa en distancias geográficas, los autoencoders detectan anomalías más complejas al incluir variables cinemáticas. Esto permite clasificar las detecciones no solo por proximidad, sino también por el comportamiento de la aeronave en el espacio aéreo. Esta observación resalta la importancia de incorporar evaluaciones de expertos, que validen los resultados más allá de las métricas cuantitativas, un desafío común en la evaluación de modelos no supervisados, de acuerdo con autores como [13].

La representatividad de los datos es crítica para entrenar autoencoders, que dependen de datos normales para identificar anomalías. En futuros trabajos, se sugiere un enfoque semi-supervisado para construir el ground truth, donde la intervención de expertos mejore la selección de datos normales y aumente la efectividad de los modelos.

Un aspecto clave de este trabajo es la redefinición de características mediante las regiones de Voronoi, que segmentan el espacio aéreo de manera contextualizada con las operaciones. Esta segmentación permite una representación más intuitiva de las trayectorias y un análisis más detallado de las anomalías, ofreciendo una mayor claridad en la relación entre anomalías y ubicación espacial, por ejemplo, como se presenta en Fig. 9.

Finalmente, el uso de autoencoders en la detección de anomalías en trayectorias aéreas apoya un enfoque de seguridad proactivo. La capacidad de identificar patrones anómalos antes de que se conviertan en incidentes contribuye no solo a mejorar la seguridad operacional, sino también a optimizar la eficiencia en la gestión del espacio aéreo.

REFERENCIAS

- [1] R. H. Cáceres León, "Meteorología aplicada a la seguridad de las operaciones aéreas," *Ciencia y Poder Aéreo*, Jun. 2017, doi: <https://doi.org/10.18667/9789585996113>.
- [2] J. Ortega, J. Florez, S. Lorduy, G. Jimenez, and O. Quintero, "Improve decision-making process in Air Command and Control Systems with meteorological data fusion," in *2021 International Conference on Decision Aid Sciences and Application (DASA)*, IEEE, Dec. 2021, pp. 636–642. doi: 10.1109/DASA53625.2021.9682330.

- [3] J. Mendling, C. Di Ciccio, H. van der Aa, C. Cabanillas, and J. Prescher, "Detecting flight trajectory anomalies and predicting diversions in freight transportation," *Decis Support Syst*, 2016, doi: 10.1016/j.dss.2016.05.004.
- [4] M. Ahmed, A. Naser Mahmood, and J. Hu, "A survey of network anomaly detection techniques," *Journal of Network and Computer Applications*, vol. 60, pp. 19–31, Jan. 2016, doi: 10.1016/j.jnca.2015.11.016.
- [5] R. A. Ariyaluran Habeeb, F. Nasaruddin, A. Gani, I. A. Targio Hashem, E. Ahmed, and M. Imran, "Real-time big data processing for anomaly detection: A Survey," *Int J Inf Manage*, vol. 45, no. February, pp. 289–307, Apr. 2019, doi: 10.1016/j.ijinfomgt.2018.08.006.
- [6] M. E. Villa-Pérez, M. Á. Álvarez-Carmona, O. Loyola-González, M. A. Medina-Pérez, J. C. Velazco-Rossell, and K.-K. R. Choo, "Semi-supervised anomaly detection algorithms: A comparative summary and future research directions," *Knowl Based Syst*, vol. 218, p. 106878, Apr. 2021, doi: 10.1016/j.knosys.2021.106878.
- [7] L. Coelho e Silva and M. C. R. Murça, "A data analytics framework for anomaly detection in flight operations," *J Air Transp Manag*, vol. 110, Jul. 2023, doi: 10.1016/j.jairtraman.2023.102409.
- [8] M. Aksoy, O. Ozdemir, G. Guner, B. Baspinar, and E. Koyuncu, "Flight trajectory pattern generalization and abnormal flight detection with generative adversarial network," in *AIAA Scitech 2021 Forum*, American Institute of Aeronautics and Astronautics Inc, AIAA, 2021, pp. 1–11. doi: 10.2514/6.2021-0775.
- [9] X. Olive and L. Basora, "Detection and identification of significant events in historical aircraft trajectory data," *Transp Res Part C Emerg Technol*, vol. 119, Oct. 2020, doi: 10.1016/j.trc.2020.102737.
- [10] M. Memarzadeh, B. Matthews, and T. Templin, "Multiclass Anomaly Detection in Flight Data Using Semi-Supervised Explainable Deep Learning Model," *Journal of Aerospace Information Systems*, vol. 19, no. 2, pp. 83–97, Feb. 2022, doi: 10.2514/1.I010959.
- [11] A. Chevrot, A. Vernotte, and B. Legeard, "CAE: Contextual auto-encoder for multivariate time-series anomaly detection in air transportation," *Comput Secur*, vol. 116, May 2022, doi: 10.1016/j.cose.2022.102652.
- [12] M. Y. Pusadan, J. L. Buliali, and R. V. Hari Ginardi, "Cluster Phenomenon to Determine Anomaly Detection of Flight Route," *Procedia Comput Sci*, vol. 161, pp. 516–526, 2019, doi: 10.1016/j.procs.2019.11.151.
- [13] S. J. Corrado, T. G. Puranik, O. P. Fischer, and D. N. Mavris, "A clustering-based quantitative analysis of the interdependent relationship between spatial and energy anomalies in ADS-B trajectory data," *Transp Res Part C Emerg Technol*, vol. 131, Oct. 2021, doi: 10.1016/j.trc.2021.103331.
- [14] Jose Ortega, Jimmy Florez, Mónica Hernández, and Jhon Escobar, "Trajectory Validation for Decision Making in Air Traffic Management Using Voronoi Diagram," *Journal of Artificial Intelligence and Soft Computing Research*, vol. 12, no. 4, 2022, [Online]. Available: [https://www.webology.org/data-cms/articles/20230215105345pmWEBOL-OGY%2019%20\(6\)%20-%20164.pdf](https://www.webology.org/data-cms/articles/20230215105345pmWEBOL-OGY%2019%20(6)%20-%20164.pdf)
- [15] M. Ester, H.-P. Kriegel, J. Sander, and X. Xu, "A density-based algorithm for discovering clusters in large spatial databases with noise," in *Proceedings of the Second International Conference on Knowledge Discovery and Data Mining*, in KDD'96. AAAI Press, 1996, pp. 226–231.
- [16] Unidad Administrativa Especial de la Aeronáutica civil (organization), "ENR 3.2 RUTAS ATS SUPERIORES ENR 3.2 UPPER ATS ROUTES," Aug. 2024, Accessed: Sep. 20, 2024. [Online]. Available: https://www.aerocivil.gov.co/servicios-a-la-navegacion/servicio-de-informacion-aeronautica-ais/Documents/AIP%20AMDT%2065_23/ENR/ENR%203.2.pdf