



# MÁSTER UNIVERSITARIO EN INGENIERÍA DE TELECOMUNICACIONES

TRABAJO FIN DE MÁSTER

## Detección de Protocolos de Comunicación en Drones Comerciales

Autor: Raúl González Gómez

Director: Javier Matanza Domingo

Madrid

Declaro, bajo mi responsabilidad, que el Proyecto presentado con el título  
Detección de Protocolos de Comunicación en Drones Comerciales  
en la ETS de Ingeniería - ICAI de la Universidad Pontificia Comillas en el  
curso académico 2023/2024 es de mi autoría, original e inédito y  
no ha sido presentado con anterioridad a otros efectos.

El Proyecto no es plagio de otro, ni total ni parcialmente y la información que ha sido  
tomada de otros documentos está debidamente referenciada.

Fdo.: Raúl González                      Fecha: 31/05/2024

Autorizada la entrega del proyecto

**EL DIRECTOR DEL PROYECTO**

Fdo.: Javier Matanza Domingo                      Fecha: 15/06/2024



## **AUTORIZACIÓN PARA LA DIGITALIZACIÓN, DEPÓSITO Y DIVULGACIÓN EN RED DE PROYECTOS FIN DE GRADO, FIN DE MÁSTER, TESIS O MEMORIAS DE BACHILLERATO**

### ***1º. Declaración de la autoría y acreditación de la misma.***

El autor D. Raúl González Gómez

DECLARA ser el titular de los derechos de propiedad intelectual de la obra: Detección de Protocolos de Comunicación en Drones Comerciales, que ésta es una obra original, y que ostenta la condición de autor en el sentido que otorga la Ley de Propiedad Intelectual.

### ***2º. Objeto y fines de la cesión.***

Con el fin de dar la máxima difusión a la obra citada a través del Repositorio institucional de la Universidad, el autor **CEDE** a la Universidad Pontificia Comillas, de forma gratuita y no exclusiva, por el máximo plazo legal y con ámbito universal, los derechos de digitalización, de archivo, de reproducción, de distribución y de comunicación pública, incluido el derecho de puesta a disposición electrónica, tal y como se describen en la Ley de Propiedad Intelectual. El derecho de transformación se cede a los únicos efectos de lo dispuesto en la letra a) del apartado siguiente.

### ***3º. Condiciones de la cesión y acceso***

Sin perjuicio de la titularidad de la obra, que sigue correspondiendo a su autor, la cesión de derechos contemplada en esta licencia habilita para:

- a) Transformarla con el fin de adaptarla a cualquier tecnología que permita incorporarla a internet y hacerla accesible; incorporar metadatos para realizar el registro de la obra e incorporar “marcas de agua” o cualquier otro sistema de seguridad o de protección.
- b) Reproducir la en un soporte digital para su incorporación a una base de datos electrónica, incluyendo el derecho de reproducir y almacenar la obra en servidores, a los efectos de garantizar su seguridad, conservación y preservar el formato.
- c) Comunicarla, por defecto, a través de un archivo institucional abierto, accesible de modo libre y gratuito a través de internet.
- d) Cualquier otra forma de acceso (restringido, embargado, cerrado) deberá solicitarse expresamente y obedecer a causas justificadas.
- e) Asignar por defecto a estos trabajos una licencia Creative Commons.
- f) Asignar por defecto a estos trabajos un HANDLE (URL *persistente*).

### ***4º. Derechos del autor.***

El autor, en tanto que titular de una obra tiene derecho a:

- a) Que la Universidad identifique claramente su nombre como autor de la misma
- b) Comunicar y dar publicidad a la obra en la versión que ceda y en otras posteriores a través de cualquier medio.
- c) Solicitar la retirada de la obra del repositorio por causa justificada.
- d) Recibir notificación fehaciente de cualquier reclamación que puedan formular terceras personas en relación con la obra y, en particular, de reclamaciones relativas a los derechos de propiedad intelectual sobre ella.

### ***5º. Deberes del autor.***

El autor se compromete a:

- a) Garantizar que el compromiso que adquiere mediante el presente escrito no infringe ningún derecho de terceros, ya sean de propiedad industrial, intelectual o cualquier otro.
- b) Garantizar que el contenido de las obras no atenta contra los derechos al honor, a la intimidad y a la imagen de terceros.
- c) Asumir toda reclamación o responsabilidad, incluyendo las indemnizaciones por daños, que pudieran ejercitarse contra la Universidad por terceros que vieran infringidos sus derechos e intereses a causa de la cesión.

- d) Asumir la responsabilidad en el caso de que las instituciones fueran condenadas por infracción de derechos derivada de las obras objeto de la cesión.

**6º. Fines y funcionamiento del Repositorio Institucional.**

La obra se pondrá a disposición de los usuarios para que hagan de ella un uso justo y respetuoso con los derechos del autor, según lo permitido por la legislación aplicable, y con fines de estudio, investigación, o cualquier otro fin lícito. Con dicha finalidad, la Universidad asume los siguientes deberes y se reserva las siguientes facultades:

- La Universidad informará a los usuarios del archivo sobre los usos permitidos, y no garantiza ni asume responsabilidad alguna por otras formas en que los usuarios hagan un uso posterior de las obras no conforme con la legislación vigente. El uso posterior, más allá de la copia privada, requerirá que se cite la fuente y se reconozca la autoría, que no se obtenga beneficio comercial, y que no se realicen obras derivadas.
- La Universidad no revisará el contenido de las obras, que en todo caso permanecerá bajo la responsabilidad exclusiva del autor y no estará obligada a ejercitar acciones legales en nombre del autor en el supuesto de infracciones a derechos de propiedad intelectual derivados del depósito y archivo de las obras. El autor renuncia a cualquier reclamación frente a la Universidad por las formas no ajustadas a la legislación vigente en que los usuarios hagan uso de las obras.
- La Universidad adoptará las medidas necesarias para la preservación de la obra en un futuro.
- La Universidad se reserva la facultad de retirar la obra, previa notificación al autor, en supuestos suficientemente justificados, o en caso de reclamaciones de terceros.

Madrid, a 25 de mayo de 2024

**ACEPTA**



Fdo Raúl González Gómez

Motivos para solicitar el acceso restringido, cerrado o embargado del trabajo en el Repositorio Institucional:



# MÁSTER UNIVERSITARIO EN INGENIERÍA DE TELECOMUNICACIONES

TRABAJO FIN DE MÁSTER

## Detección de Protocolos de Comunicación en Drones Comerciales

Autor: Raúl González Gómez

Director: Javier Matanza Domingo

Madrid

# Agradecimientos

Me gustaría agradecer especialmente al departamento de innovación de la empresa TRC por su apoyo durante todas las fases del proyecto.

También quiero agradecer a Javier Matanza Domingo por haber sido un gran director de trabajo, sin su inestimable ayuda el resultado satisfactorio no habría sido posible.

Por último, a mis padres, por brindarme la oportunidad de poder estudiar mi pasión, la ingeniería de telecomunicaciones.





# **DETECCIÓN DE PROTOCOLOS DE COMUNICACIÓN EN DRONES COMERCIALES**

**Autor: González Gómez, Raúl**

Director: Matanza Domingo, Javier

Entidad Colaboradora: Grupo TRC Informática

## **RESUMEN DEL PROYECTO**

En este trabajo se ha desarrollado un sistema de detección de drones comerciales mediante el uso de diversas técnicas avanzadas. Entre estas técnicas se incluyen el desarrollo de algoritmos personalizados específicamente diseñados para identificar y rastrear drones, así como el entrenamiento de modelos de inteligencia artificial utilizando la transferencia de conocimiento.

La personalización de algoritmos permite adaptar el sistema a las características específicas de los drones comerciales, mejorando la precisión y eficiencia en su detección. Estos algoritmos se basan en parámetros y patrones únicos de vuelo, señales de control y firmas electrónicas que distinguen a los drones de otros objetos voladores.

El entrenamiento de modelos de inteligencia artificial mediante la transferencia de conocimiento implica utilizar modelos pre-entrenados en grandes conjuntos de datos relacionados, aplicándolos a la detección de drones. Esta técnica aprovecha el aprendizaje previo y adapta el modelo a nuevas tareas específicas con menor necesidad de datos adicionales. Los modelos se afinan para reconocer las características distintivas de los drones comerciales, mejorando la capacidad del sistema para detectar y clasificar correctamente estos dispositivos en tiempo real.

Además, el sistema integra múltiples fuentes de datos, incluyendo sensores ópticos, acústicos y de radiofrecuencia, para mejorar la precisión y robustez de la detección. La combinación de estos diferentes métodos permite una detección más confiable y reduce la posibilidad de falsos positivos y negativos.

La implementación de este sistema no solo tiene aplicaciones en la seguridad y vigilancia de espacios restringidos, sino que también puede ser utilizado en la gestión del tráfico aéreo urbano y en la protección de infraestructuras críticas. A medida que el uso de drones comerciales continúa creciendo, este sistema avanzado de detección contribuirá

significativamente a la mitigación de riesgos asociados y al desarrollo de regulaciones eficaces para su operación segura y sostenible.

**Palabras clave:** Dron, UAS, DSP, Defensa, guerra

## **1. Introducción**

El trabajo de fin de máster se centra en el desarrollo de un sistema avanzado para la detección de drones, con el objetivo de identificar con precisión la presencia de estos en áreas específicas.

En España, se han definido zonas de exclusión para proteger infraestructuras estratégicas, donde los drones tienen prohibido volar. Además, ENAIRE (Enaire, 2024) publica regularmente nuevas zonas donde temporalmente no se pueden realizar vuelos de drones por diversos motivos. Es crucial controlar qué aeronaves entran en estos espacios regulados y determinar cuáles tienen derecho de vuelo.

El proyecto se centra exclusivamente en drones comerciales, accesibles al público y operados por personal con escasa formación. La reciente escalada de conflictos ha mostrado que los drones no tripulados de bajo coste representan una amenaza considerable tanto para la población civil como para el personal militar, pudiendo ser usados para inteligencia o ataques directos.

El uso asimétrico de drones por actores no estatales y grupos rebeldes complica la capacidad de las fuerzas convencionales para prevenir o defenderse de ataques, alterando el equilibrio de poder en el campo de batalla. La relevancia de este proyecto radica en su aplicación práctica para la seguridad y vigilancia, así como en su contribución a la gestión del espacio aéreo urbano. A medida que los drones proliferan, el control efectivo del espacio aéreo es cada vez más crítico.

Este trabajo representa una contribución técnica significativa, abordando una necesidad social y regulatoria creciente, y busca equilibrar los beneficios de los drones con la mitigación de los riesgos asociados a su operación. La investigación contribuirá a la seguridad y regulación del espacio aéreo, garantizando una integración segura y sostenible de los drones en la vida cotidiana.

## **2. Definición del proyecto**

El proyecto de fin de máster consiste en el desarrollo de un sistema avanzado para la detección de drones, con el propósito de identificar con precisión la presencia de drones comerciales en áreas específicas. La detección se deberá realizar por medio de la recepción de señales capturadas con una radio definida por software.

El sistema desarrollado deberá de ser capaz de discernir si las señales provenientes del entorno se tratan de un dron o por contrario son señales aleatorias correspondientes a otros sistemas de comunicación.

Además, dentro de los objetivos, se incluye que el procesado realizado deberá ser el mínimo ya que se pretende reducir lo máximo posible el hardware empleado, así como las especificaciones de este.

Se van a detectar drones de dos marcas y protocolos concretos, por un lado, se va a detectar el protocolo Ocusync, desarrollado por DJI, e incorporado en la gran mayoría de los dispositivos desarrollados por la marca, salvo en contadas excepciones, y drones que empleen el protocolo SkyLink de la marca Autel.

Se han escogido estos dos protocolos y marcas por la alta penetración y volumen de mercado que presentan. Además, al ser unos drones tan populares son los que más comúnmente van a presentar una amenaza para la seguridad, por lo tanto, se maximiza el valor aportado con esta solución.

En el caso de la detección por medio de redes neuronales, se va a intentar que el modelo sea capaz de generalizar lo máximo posible y detecte drones del máximo número de protocolos y marcas, para ello se va a nutrir al modelo de un amplio conjunto de entrenamiento, realizado exprofeso.


## **3. Descripción del modelo/sistema/herramienta**

Los tres métodos de detección deberán de funcionar en paralelo, de forma que, si la señal de entrada corresponde a un dron de la marca DJI, el sistema de detección de drones de protocolo SkyLink de la marca Autel no deberá de mostrar un positivo.

Por otro lado, la detección por medio de redes neuronales es posible que sí presente positivos de forma simultánea a cualquiera de los otros dos métodos, pero no es objetivo de

este trabajo el decidir la actuación en base a las **detecciones**, únicamente se va a informar a sistemas de más alto nivel la presencia de aeronaves hostiles en la zona.

Tanto los drones de la marca Autel (Autel, s.f.) como DJI (DJI, s.f.) hacen uso de la modulación digital OFDM (Wikipedia, 2023). Esta modulación es muy sensible a variaciones de frecuencia, por ello, se tiene que realizar un procesado previo de sincronización frecuencial que permite una mayor tasa de detección.



*Ilustración 1 Flujo corrección en frecuencia*

En el caso de DJI este proceso de corrección en frecuencia se tiene que realizar también tras adaptar la frecuencia de muestreo de la señal de entrada, puesto que si no se respetara la ortogonalidad de las portadoras de datos se podría ver alterada.

Para la detección de drones empleando el protocolo Ocusync, se emplean una serie de trazas conocidas formadas por secuencias de Zadoff Chu (Wikipedia, 2023) como datos en las portadoras OFDM.

Por su parte, la detección de SkyLink, se realiza por medio de la búsqueda de un preámbulo común a todas las señales enviadas por este protocolo.

Ambas detecciones se consiguen por medio de la correlación de una señal buscada con la señal de entrada, tanto en el dominio temporal como en el de la frecuencia en el caso de SkyLink, Se ha tenido que realizar un algoritmo de discernimiento para diferenciar los resultados de las correlaciones correspondientes a detecciones de las salidas correspondientes a señales aleatorias.

En el caso de la red neuronal, se ha probado con varios modelos pre-entrenados, entre los que se encuentran:

- VGG
- MobileNet
- Resnet50

Se han escogido estos modelos por su reconocida eficacia y su amplio uso en la comunidad científica y tecnológica. Estos modelos son altamente valorados debido a su probada precisión y robustez en una variedad de aplicaciones, lo que los convierte en una elección ideal para la transferencia de conocimiento. Al haber sido extensamente probados y evaluados, estos modelos han demostrado ser de los mejores en su clase, ofreciendo un rendimiento superior en tareas de detección y clasificación.

La elección de estos modelos permite aprovechar su arquitectura optimizada y su capacidad para generalizar bien en diferentes contextos, facilitando la adaptación a la tarea específica de detección de drones comerciales. Además, el uso de estos modelos preentrenados reduce significativamente el tiempo y los recursos necesarios para entrenar desde cero, ya que pueden aprender de los patrones y características previamente adquiridos.

En concreto, la robustez y la alta precisión de estos modelos en la identificación de objetos en imágenes complejas son fundamentales para el éxito del sistema de detección de drones. Su capacidad para manejar grandes volúmenes de datos y su eficiencia en el procesamiento

de información en tiempo real son cruciales para una detección rápida y precisa, especialmente en escenarios dinámicos y de alta complejidad.

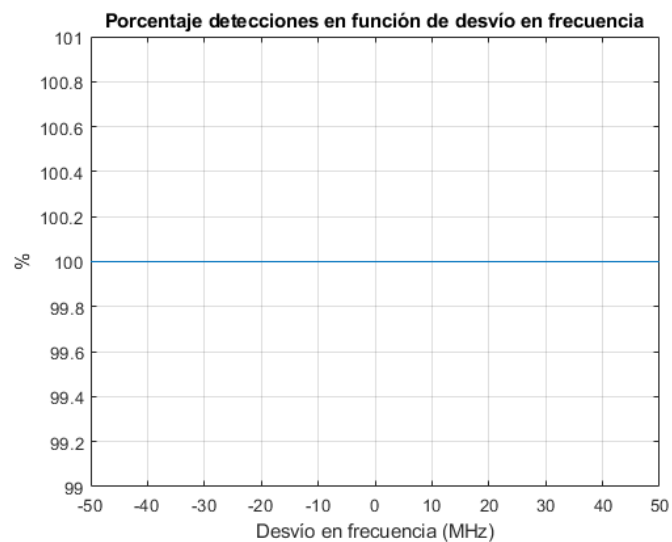
#### 4. Resultados

Para evaluar los algoritmos propuestos, se han realizado numerosas pruebas y experimentos para poder validar el rendimiento de estos, y conocer las limitaciones y requisitos de señal que estos tienen.

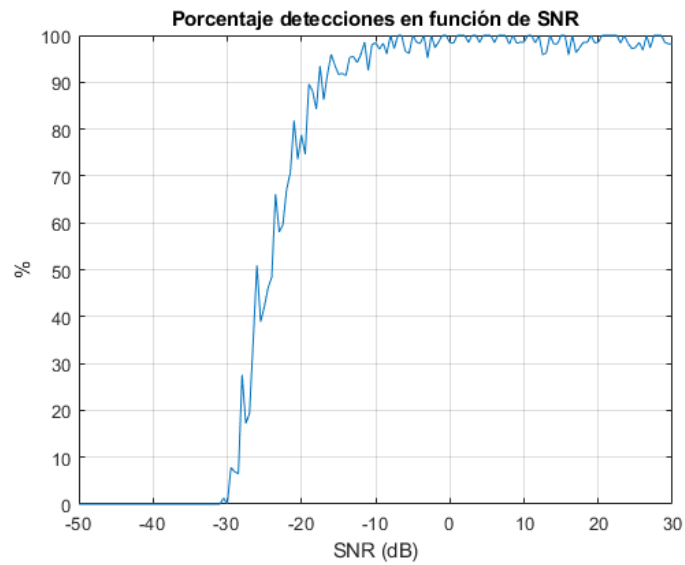
Por ello se han probado todos los algoritmos desarrollados:

- Detección Ocusync

Para este tipo de detección es muy importante la resiliencia del sistema con respecto a la relación señal a ruido y el desplazamiento en frecuencia, por lo tanto, se han realizado diversas simulaciones para probar las capacidades del sistema.

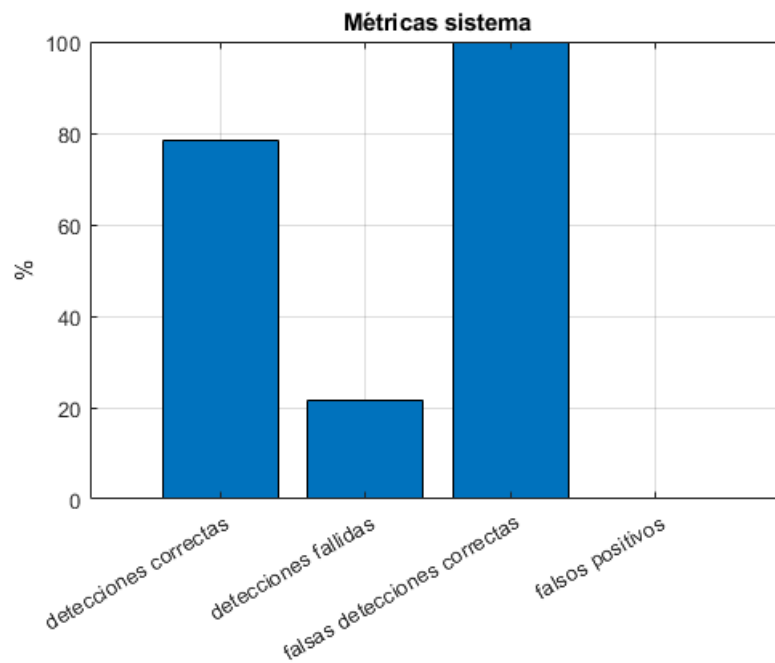


*Ilustración 2 Precisión vs frecuencia*



*Ilustración 3 Porcentaje detecciones vs SNR*

En la gráfica se puede observar el ratio de falsas detecciones y de detecciones fallidas que tiene el sistema en entornos altamente ruidosos.



*Ilustración 4 Métrica falsos positivos Ocusync*

- Detección Autel

Como en el caso anterior es necesario conocer cómo reacciona ante entornos ruidosos y con la señal desplazada en frecuencia.

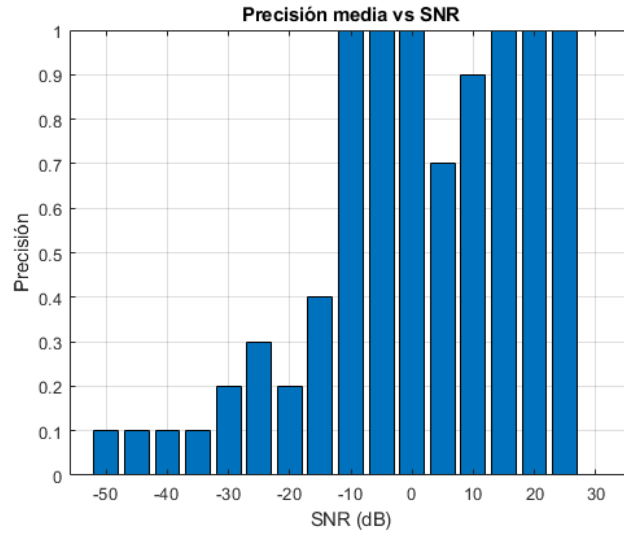


Ilustración 5 Resultados prueba detección en frecuencia SkyLink

En el caso de la detección en el dominio del tiempo se ha probado cual es el rango de desviación de frecuencia máxima de error que se puede permitir.

No es un rango amplio, pero al tener un algoritmo de corrección de frecuencia que tiene un error dentro del margen detectable, no es un problema.

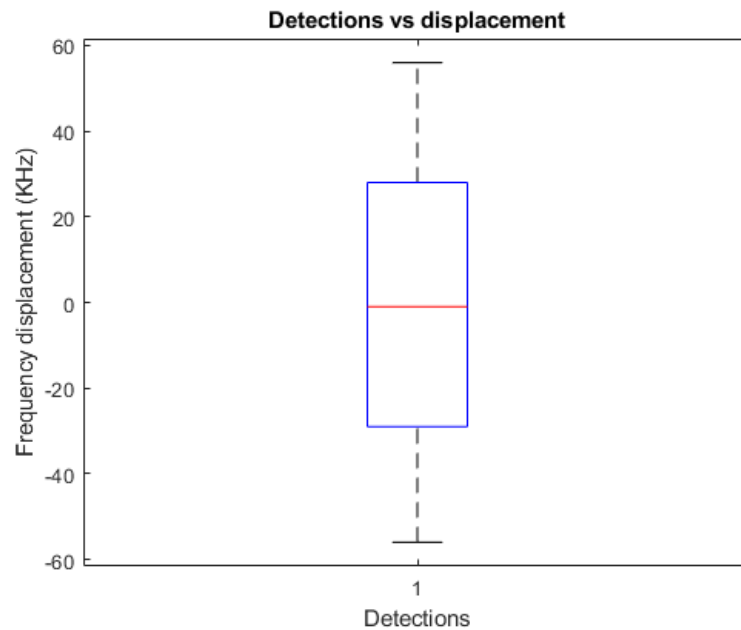


Ilustración 6 Rango detecciones posibles Autel SkyLink



En el caso de la detección en el dominio de la frecuencia, el desplazamiento en frecuencia no es relevante, por lo que solo se ha probado cual es la precisión del algoritmo ante situaciones con altos niveles de ruido




Ilustración 7 Precisión detecciones SkyLink

- Detección con DeepLearning

Para la detección por medio de un modelo de inteligencia artificial, se han probado modelos base sobre los que se han aplicado aprendizaje por transferencia, para comparar los modelos se han evaluado las curvas de precisión y error en el entrenamiento en el conjunto de validación y en el de entrenamiento.





Ilustración 8 Curva entrenamiento MobileNet



*Ilustración 9 Curva entrenamiento ResNet*



*Ilustración 10 Curva entrenamiento VGG*

Se ha optado por implementar la solución que hace uso del modelo con MobileNet como base.

Además, se han realizado pruebas en entornos reales para validar el funcionamiento del sistema en su totalidad. Dicha prueba real ha revelado que el sistema es capaz de detectar drones hasta una distancia máxima de

Se ha de tener en cuenta que la distancia máxima de detección es directamente dependiente del hardware empleado en la cadena de recepción de radiofrecuencia, entre las que se incluyen antenas, amplificadores y radios definidas por software. Por ello una mejora en este aspecto del proyecto tendría consecuencias de incremento de la distancia de forma directa.

## 5. Conclusiones

Como conclusión, se puede derivar que el desarrollo de un sistema de detección anti-drones ha demostrado ser una tarea desafiante pero alcanzable. El sistema ha logrado detectar drones satisfactoriamente, cumpliendo con los objetivos planteados, demostrando su eficacia en diversas condiciones ambientales y operativas. La integración de tecnologías avanzadas como radares, cámaras ópticas e infrarrojas, y técnicas de procesamiento de señales ha sido crucial para el éxito del sistema, permitiendo una detección precisa y oportuna. Los algoritmos de procesamiento de imágenes y señales, incluyendo aprendizaje automático e inteligencia artificial, han sido efectivos en la clasificación y diferenciación de drones, reduciendo falsos positivos y aumentando la precisión.

El sistema ha sido diseñado con un enfoque modular, facilitando su escalabilidad y adaptación a diferentes entornos y necesidades, desde la seguridad en aeropuertos hasta la protección de infraestructuras críticas. Las pruebas realizadas en diferentes escenarios han demostrado su robustez y capacidad para mantener un alto nivel de detección en condiciones adversas.

A pesar del éxito alcanzado, se han identificado áreas de mejora, como aumentar la autonomía del sistema y su capacidad para operar en entornos altamente congestionados. Se sugiere explorar nuevas tecnologías emergentes para complementar y mejorar las capacidades actuales del sistema. Las posibles mejoras a corto plazo incluyen desarrollar inteligencia artificial multicategoría para clasificar marcas y tipos de drones, buscar mejores modelos de transfer learning para mejorar la generalización y reducir el tiempo de inferencia, generar sintéticamente el preámbulo de los drones Autel usando el protocolo SkyLink, y ampliar el número de protocolos detectados.

## 6. Referencias

- Autel. (s.f.). *Autel-Home*. Obtenido de <https://www.autel.com/es/>
- Bender, C. (2022). *DJI drone IDs are not encrypted*. The University of Tulsa.
- DJI. (s.f.). *DJI-Aeroscope*. (DJI) Obtenido de <https://www.dji.com/es/aeroscope>
- DJI. (s.f.). *DJI-Official Website*. Obtenido de <https://www.dji.com/es>
- Enaire. (2024). *Enaire*. Obtenido de <https://www.enaire.es/home>
- Enebral, A. R. (5 de Octubre de 2023). *elconfidencialdigital.com*. Obtenido de <https://www.elconfidencialdigital.com/articulo/defensa/ejercito-aire-incorpora-sistema-que-captura-drones-derribarlos/20231004171006646942.html>
- FAA. (2020). *Standard Specification for Remote ID and Tracking*. ASTM.
- Haruna Abdu, M. H. (2017). A Survey on Waste Detection and Classification using Deep Learning. *ResearchGate*.
- Hugo Andrade Carrera , Soraya Sinche Maita , & Pablo Hidalgo Lascano . (12 de Noviembre de 2020). RITI Journal, Vol. 9, 17 (Especial 2021) e-ISSN: 2387-0893 © RITI. CC BY-NC Taller Andino de Comunicaciones Inalámbricas y sus Aplicaciones 111 Modelo para detectar el uso correcto de mascarillas en tiempo real utilizando redes neuronales con.
- Indra. (s.f.). Obtenido de <https://www.indracompany.com/es/anti-drone-system>
- Maad Shatnawi, N. A. (2022). Deep Learning Approach for Masked Face Identification. *International Journal of Advanced Computer Science and Applications*.
- Mohammad F. Al-Sa'd, Abdulla Al-Ali, Tamer Khattab, & Aiman Erbad. (2019). RF-based drone detection and identification using deep learning approaches: An initiative towards a large open source drone database. *sciencedirect*.
- proto17. (2022). *dji\_droneid*. Obtenido de [https://github.com/proto17/dji\\_droneid](https://github.com/proto17/dji_droneid)

RUB-SysSec. (2023). *DroneSecurity*. Obtenido de <https://github.com/RUB-SysSec/DroneSecurity>

Target Tecnologia. (s.f.). *Target Tecnologia*. Obtenido de [https://www.target-tecnologia.es/categoria\\_producto/sistemas-anti-dron/](https://www.target-tecnologia.es/categoria_producto/sistemas-anti-dron/)

Wikipedia. (27 de Septiembre de 2023). *Multiplexación por división de frecuencias ortogonales*. Obtenido de [https://es.wikipedia.org/wiki/Multiplexaci%C3%B3n\\_por\\_divisi%C3%B3n\\_de\\_frecuencias\\_ortogonales#:~:text=OFDM%20es%20un%20esquema%20de,y%20patentado%20cuatro%20a%C3%B1os%20despu%C3%A9s](https://es.wikipedia.org/wiki/Multiplexaci%C3%B3n_por_divisi%C3%B3n_de_frecuencias_ortogonales#:~:text=OFDM%20es%20un%20esquema%20de,y%20patentado%20cuatro%20a%C3%B1os%20despu%C3%A9s).

Wikipedia. (11 de Septiembre de 2023). *Zadoff–Chu sequence*. Obtenido de [https://en.wikipedia.org/wiki/Zadoff%E2%80%93Chu\\_sequence](https://en.wikipedia.org/wiki/Zadoff%E2%80%93Chu_sequence)

Wikipedia. (s.f.). *Aprendizaje profundo*. Obtenido de [https://es.wikipedia.org/wiki/Aprendizaje\\_profundo](https://es.wikipedia.org/wiki/Aprendizaje_profundo)

Wikipedia. (s.f.). *Espectro ensanchado por salto de frecuencia*. Obtenido de [https://es.wikipedia.org/wiki/Espectro\\_ensanchado\\_por\\_salto\\_de\\_frecuencia](https://es.wikipedia.org/wiki/Espectro_ensanchado_por_salto_de_frecuencia)

Wikipedia. (s.f.). *Software defined radio*. Obtenido de [https://en.wikipedia.org/wiki/Software-defined\\_radio](https://en.wikipedia.org/wiki/Software-defined_radio)

Wikipedia. (s.f.). *Transformada rápida de Fourier*. Obtenido de [https://es.wikipedia.org/wiki/Transformada\\_r%C3%A1pida\\_de\\_Fourier#Algoritmos](https://es.wikipedia.org/wiki/Transformada_r%C3%A1pida_de_Fourier#Algoritmos)

Xianjing Han, G. L. (2021). Echocardiographic Features of Patients with Coronary Heart Disease and Angina Pectoris under Deep Learning Algorithms. *ResearchGate*, pág. 8.

# **TÍTULO DEL TFM (EN INGLÉS)**

**Autor: González Gómez, Raúl**

Director: Matanza Domingo, Javier

Entidad Colaboradora: Grupo TRC Informática

## **ABSTRACT**

In this work, a system for detecting commercial drones has been developed using various advanced techniques. These techniques include the development of custom algorithms specifically designed to identify and track drones, as well as the training of artificial intelligence models using knowledge transfer.

The customization of algorithms allows the system to adapt to the specific characteristics of commercial drones, improving the accuracy and efficiency of their detection. These algorithms are based on unique flight parameters and patterns, control signals, and electronic signatures that distinguish drones from other flying objects.

Training artificial intelligence models through knowledge transfer involves using pre-trained models on large, related datasets and applying them to drone detection. This technique leverages prior learning and adapts the model to new specific tasks with less need for additional data. The models are fine-tuned to recognize the distinctive features of commercial drones, enhancing the system's ability to detect and classify these devices correctly in real-time.

Additionally, the system integrates multiple data sources, including optical, acoustic, and radiofrequency sensors, to improve the accuracy and robustness of detection. Combining these different methods enables more reliable detection and reduces the possibility of false positives and negatives.

The implementation of this system has applications not only in the security and surveillance of restricted areas but also in the management of urban air traffic and the protection of critical infrastructure. As the use of commercial drones continues to grow, this advanced detection system will significantly contribute to mitigating associated risks and developing effective regulations for their safe and sustainable operation.

. **Keywords:** Drone, UAS, DSP, Defence, War

## **1. Introduction**

The master's thesis focuses on the development of an advanced system for drone detection, aiming to accurately identify the presence of these devices in specific areas.

In Spain, exclusion zones have been defined to protect strategic infrastructures where drones are prohibited from flying. Additionally, ENAIRE (Enaire, 2024) regularly publishes new zones where drone flights are temporarily banned for several reasons. It is crucial to monitor which aircraft enter these regulated spaces and determine which ones have the right to fly.

The project exclusively targets commercial drones that are accessible to the public and operated by individuals with minimal training. The recent escalation of conflicts has shown that low-cost unmanned drones pose a considerable threat to both the civilian population and military personnel, as they can be used for intelligence gathering or direct attacks.

The asymmetric use of drones by non-state actors and rebel groups complicates the ability of conventional forces to prevent or defend against attacks, altering the balance of power on the battlefield. The relevance of this project lies in its practical application for security and surveillance, as well as its contribution to the management of urban airspace. As drones proliferate, effective airspace control becomes increasingly critical.

This work represents a significant technical contribution, addressing a growing social and regulatory need, and seeks to balance the benefits of drones with the mitigation of risks associated with their operation. The research will contribute to airspace security and regulation, ensuring a safe and sustainable integration of drones into everyday life.

## **2. Project definition**

The master's thesis involves the development of an advanced system for drone detection, aimed at accurately identifying the presence of commercial drones in specific areas. The detection will be performed by capturing signals using software-defined radio (SDR). The developed system must be capable of discerning whether the signals from the environment are from a drone or are random signals from other communication systems. Additionally, one of the objectives is to ensure that the processing required is minimal, aiming to reduce the hardware used and its specifications as much as possible. The system will detect drones


from two specific brands and protocols: on the one hand, it will detect the Ocusync protocol, developed by DJI and incorporated into the majority of their devices, with few exceptions, and drones that use the SkyLink protocol from the Autel brand. These two protocols and brands have been chosen due to their high market penetration and volume. Additionally, since these drones are so popular, they are the ones most likely to pose a security threat, thereby maximizing the value provided by this solution. In the case of detection using neural networks, the goal is to enable the model to generalize as much as possible and detect drones from the maximum number of protocols and brands. To achieve this, the model will be trained with a comprehensive dataset created specifically for this purpose.

### **3. System definition**

The three detection methods must operate in parallel. For instance, if the input signal corresponds to a DJI drone, the SkyLink protocol drone detection system by Autel should not indicate a positive. On the other hand, neural network detection might simultaneously show positives along with either of the other two methods, but it is not the objective of this work to determine actions based on the detections. The system will only report the presence of hostile aircraft in the area to higher-level systems.

Both Autel (Autel, s.f.) and DJI (DJI, s.f.) drones use OFDM (Wikipedia, 2023) digital modulation. This modulation is extremely sensitive to frequency variations; therefore, a preliminary process of frequency synchronization is necessary to achieve a higher detection rate.





*Figure 1 Frequency correction workflow.*

In the case of DJI, this frequency correction process must also be conducted after adapting the sampling frequency of the input signal. If the orthogonality of the data carriers is not maintained, it could be affected.

For drone detection using the Ocusync protocol, known traces formed by Zadoff-Chu (Wikipedia, 2023) sequences are used as data in the OFDM carriers. In the case of SkyLink detection, it is performed by searching for a preamble common to all signals sent by this protocol.

Both detections are achieved by correlating a target signal with the input signal, in both the time domain and the frequency domain for SkyLink. Therefore, an algorithm has also been

developed to differentiate the correlation results corresponding to detections from those corresponding to random signals.

Regarding the neural network, several pre-trained models have been evaluated, including:

- VGG
- MobileNet
- Resnet50

These models were chosen for their recognized efficacy and wide use in the scientific and technological community. They are highly valued due to their proven accuracy and robustness in a variety of applications, making them an ideal choice for knowledge transfer. Having been extensively tested and evaluated, these models have demonstrated to be among the best in their class, offering superior performance in detection and classification tasks.

The selection of these models allows us to leverage their optimized architecture and ability to generalize well in different contexts, facilitating adaptation to the specific task of commercial drone detection. Additionally, using these pre-trained models significantly reduces the time and resources needed for training from scratch, as they can learn from previously acquired patterns and features.

Specifically, the robustness and high accuracy of these models in identifying objects in complex images are fundamental to the success of the drone detection system. Their ability to manage large volumes of data and their efficiency in processing information in real-time are crucial for rapid and accurate detection, especially in dynamic and extraordinarily complex scenarios.

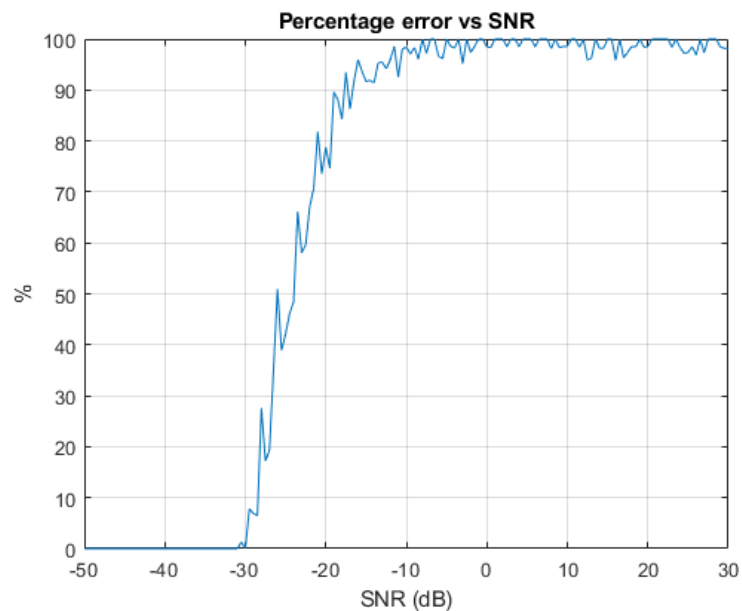
#### 4. Results

To evaluate the proposed algorithms, numerous tests and experiments have been conducted to validate their performance and understand their limitations and signal requirements.

All developed algorithms have been evaluated:

- Ocusync Detection

For this type of detection, the system's resilience to the signal-to-noise ratio and frequency shift is crucial. Therefore, various simulations have been conducted to evaluate the system's capabilities.



*Figure 2 Detection ratio compared with SNR.*

The graph below shows the ratio of false detections and missed detections in highly noisy environments.

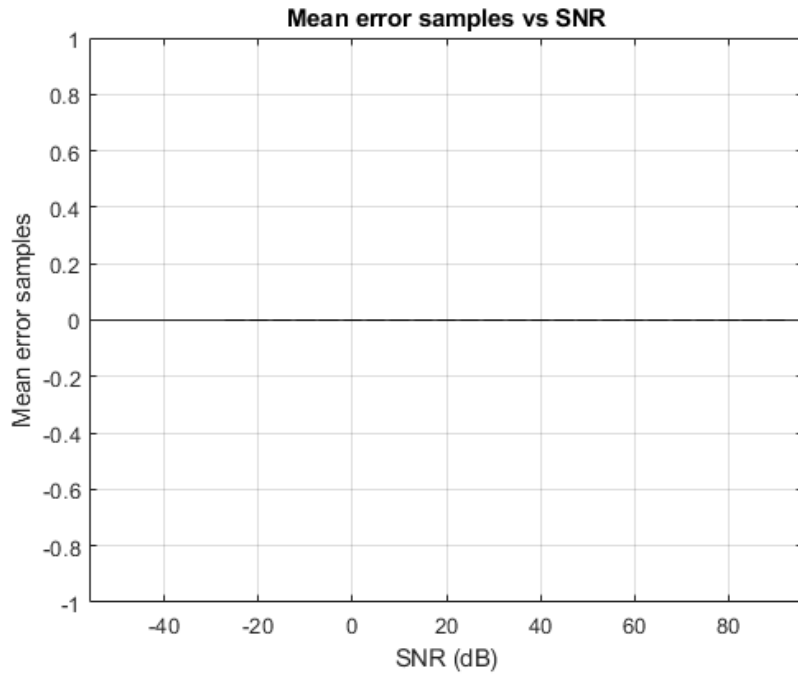


Figure 3 Detection percentage vs frequency.

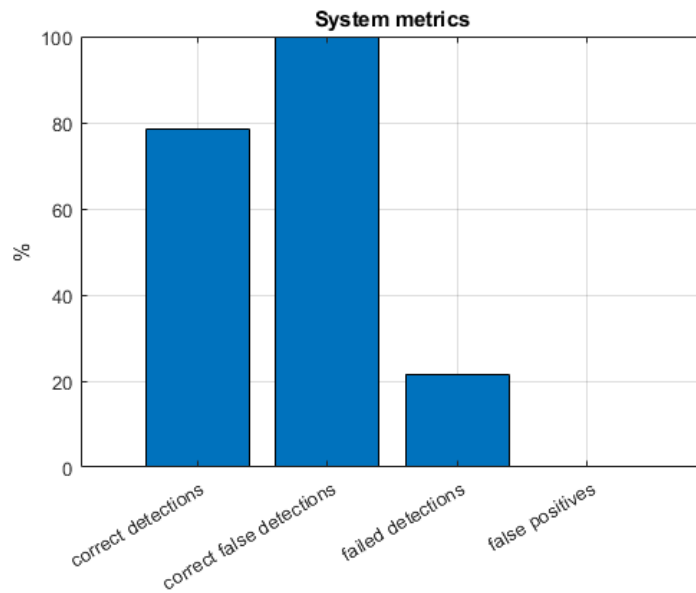


Figure 4 Ocusync false detection rate metrics.

- Autel Detection

As in the previous case, it is necessary to understand how it reacts to noisy environments and frequency-shifted signals.

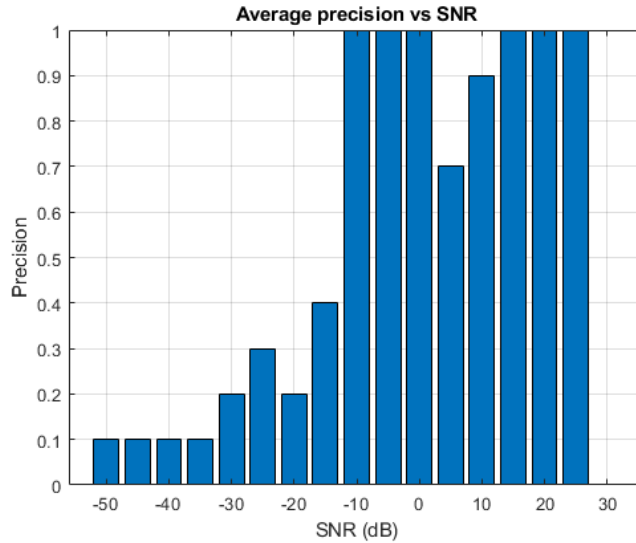


Figure 5 Frequency Detection Results for SkyLink

In the case of time-domain detection, tests have been conducted to determine the maximum allowable frequency deviation error range. Although it is not a wide range, the frequency correction algorithm keeps the error within the detectable margin, so it is not a problem.




Figure 6 Possible Detection Range for Autel SkyLink

In the case of frequency-domain detection, frequency shift is not relevant, so the tests have only focused on the algorithm's accuracy in high-noise situations.

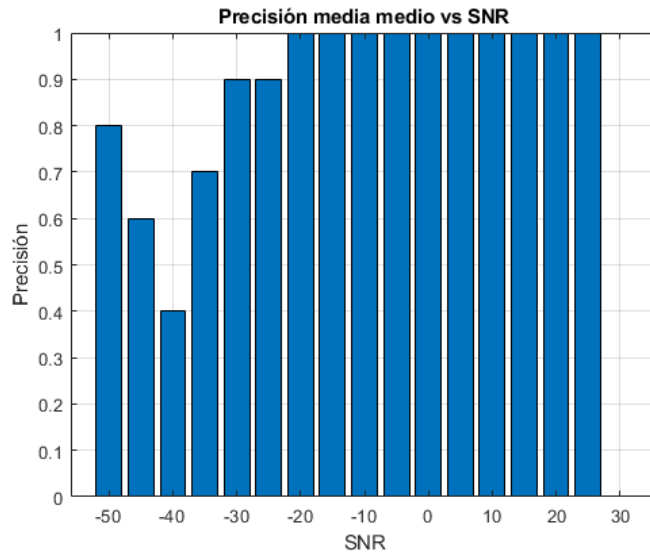


Figure 7 SkyLink precision vs SNR.

- Deep Learning Detection

For detection using an artificial intelligence model, base models have been evaluated with transfer learning applied. To compare the models, precision, and error curves during training on the validation set and training set have been evaluated.





Figure 8 MobileNet Training Curve



*Figure 9 ResNet Training Curve*



*Figure 10 VGG Training Curve*

The solution using the MobileNet model as the base has been chosen for implementation.

Additionally, tests in real-world environments have been conducted to validate the system's overall functionality. These real-world tests have revealed that the system can detect drones up to a maximum distance of X.

It should be noted that the maximum detection distance is directly dependent on the hardware used in the radio frequency reception chain, including antennas, amplifiers, and

software-defined radios. Therefore, improvements in this aspect of the project would directly result in an increased detection distance.

## **5. Conclusions**

As a conclusion, it can be derived that the development of an anti-drone detection system has proven to be a challenging but achievable task. The system has successfully detected drones, meeting the set objectives and demonstrating its effectiveness in various environmental and operational conditions. The integration of advanced technologies such as radars, optical and infrared cameras, and signal processing techniques has been crucial to the system's success, enabling precise and timely detection. Image and signal processing algorithms, including machine learning and artificial intelligence, have been effective in classifying and differentiating drones, reducing false positives, and increasing accuracy.

The system has been designed with a modular approach, facilitating its scalability and adaptation to different environments and needs, from airport security to the protection of critical infrastructures. Tests conducted in various scenarios have demonstrated its robustness and ability to maintain an elevated level of detection in adverse conditions.

Despite the success achieved, areas for improvement have been identified, such as increasing the system's autonomy and its ability to operate in highly congested environments. It is suggested to explore new emerging technologies to complement and enhance the current capabilities of the system. Potential short-term improvements include developing multi-category artificial intelligence to classify brands and types of drones, seeking better transfer learning models to improve generalization and reduce inference time, synthetically generating the preamble of Autel drones using the SkyLink protocol, and expanding the number of detected protocols.



## 6. Bibliography

Autel. (s.f.). *Autel-Home*. Obtenido de <https://www.autel.com/es/>

Bender, C. (2022). *DJI drone IDs are not encrypted*. The University of Tulsa.

DJI. (s.f.). *DJI-Aeroscope*. (DJI) Obtenido de <https://www.dji.com/es/aeroscope>

DJI. (s.f.). *DJI-Official Website*. Obtenido de <https://www.dji.com/es>

Enaire. (2024). *Enaire*. Obtenido de <https://www.enaire.es/home>

Enebral, A. R. (5 de Octubre de 2023). *elconfidencialdigital.com*. Obtenido de <https://www.elconfidencialdigital.com/articulo/defensa/ejercito-aire-incorpora-sistema-que-captura-drones-derribarlos/20231004171006646942.html>

FAA. (2020). *Standard Specification for Remote ID and Tracking*. ASTM.

Haruna Abdu, M. H. (2017). A Survey on Waste Detection and Classification using Deep Learning. *ResearchGate*.

Hugo Andrade Carrera , Soraya Sinche Maita , & Pablo Hidalgo Lascano . (12 de Noviembre de 2020). RITI Journal, Vol. 9, 17 (Especial 2021) e-ISSN: 2387-0893 © RITI. CC BY-NC Taller Andino de Comunicaciones Inalámbricas y sus Aplicaciones 111 Modelo para detectar el uso correcto de mascarillas en tiempo real utilizando redes neuronales con.

Indra. (s.f.). Obtenido de <https://www.indracompany.com/es/anti-drone-system>

Maad Shatnawi, N. A. (2022). Deep Learning Approach for Masked Face Identification. *International Journal of Advanced Computer Science and Applications*.

Mohammad F. Al-Sa'd, Abdulla Al-Ali, Tamer Khattab, & Aiman Erbad. (2019). RF-based drone detection and identification using deep learning approaches: An initiative towards a large open source drone database. *sciencedirect*.

proto17. (2022). *dji\_droneid*. Obtenido de [https://github.com/proto17/dji\\_droneid](https://github.com/proto17/dji_droneid)

RUB-SysSec. (2023). *DroneSecurity*. Obtenido de <https://github.com/RUB-SysSec/DroneSecurity>

Target Tecnologia. (s.f.). *Target Tecnologia*. Obtenido de [https://www.target-tecnologia.es/categoria\\_producto/sistemas-anti-dron/](https://www.target-tecnologia.es/categoria_producto/sistemas-anti-dron/)

Wikipedia. (27 de Septiembre de 2023). *Multiplexación por división de frecuencias ortogonales*. Obtenido de [https://es.wikipedia.org/wiki/Multiplexaci%C3%B3n\\_por\\_divisi%C3%B3n\\_de\\_frecuencias\\_ortogonales#:~:text=OFDM%20es%20un%20esquema%20de,y%20patentado%20cuatro%20a%C3%B1os%20despu%C3%A9s](https://es.wikipedia.org/wiki/Multiplexaci%C3%B3n_por_divisi%C3%B3n_de_frecuencias_ortogonales#:~:text=OFDM%20es%20un%20esquema%20de,y%20patentado%20cuatro%20a%C3%B1os%20despu%C3%A9s).

Wikipedia. (11 de Septiembre de 2023). *Zadoff–Chu sequence*. Obtenido de [https://en.wikipedia.org/wiki/Zadoff%E2%80%93Chu\\_sequence](https://en.wikipedia.org/wiki/Zadoff%E2%80%93Chu_sequence)

Wikipedia. (s.f.). *Aprendizaje profundo*. Obtenido de [https://es.wikipedia.org/wiki/Aprendizaje\\_profundo](https://es.wikipedia.org/wiki/Aprendizaje_profundo)

Wikipedia. (s.f.). *Espectro ensanchado por salto de frecuencia*. Obtenido de [https://es.wikipedia.org/wiki/Espectro\\_ensanchado\\_por\\_salto\\_de\\_frecuencia](https://es.wikipedia.org/wiki/Espectro_ensanchado_por_salto_de_frecuencia)

Wikipedia. (s.f.). *Software defined radio*. Obtenido de [https://en.wikipedia.org/wiki/Software-defined\\_radio](https://en.wikipedia.org/wiki/Software-defined_radio)

Wikipedia. (s.f.). *Transformada rápida de Fourier*. Obtenido de [https://es.wikipedia.org/wiki/Transformada\\_r%C3%A1pida\\_de\\_Fourier#Algoritmos](https://es.wikipedia.org/wiki/Transformada_r%C3%A1pida_de_Fourier#Algoritmos)

Xianjing Han, G. L. (2021). Echocardiographic Features of Patients with Coronary Heart Disease and Angina Pectoris under Deep Learning Algorithms. *ResearchGate*, pág. 8.

## *Índice de la memoria*

<b>Capítulo 1. Introducción .....</b>	<b>7</b>
<b>Capítulo 2. Estado de la Cuestión .....</b>	<b>9</b>
2.1 Sistemas desarrollados con anterioridad .....	9
2.2 Clasificación.....	10
<b>Capítulo 3. Definición del Trabajo .....</b>	<b>14</b>
3.1 Justificación.....	14
3.1.1 Ausencia de soluciones abiertas.....	14
3.1.2 Ausencia de soluciones nacionales.....	14
3.1.3 Solución de bajos recursos.....	15
3.2 Objetivos .....	15
3.2.1 Objetivos técnicos.....	16
3.2.2 Objetivos didácticos .....	16
3.3 Metodología.....	17
3.4 Planificación y Estimación Económica .....	17
<b>Capítulo 4. Detección protocolo Ocusync.....</b>	<b>21</b>
4.1 Descripción protocolo .....	21
4.2 Estructura trama .....	23
4.2.1 Parámetros señal.....	23
4.2.2 Secuencia Zadoff Chu.....	25
4.3 Captura señales.....	27
4.3.1 Corrección en frecuencia .....	28
4.3.2 Cambio frecuencia de muestreo .....	32
4.4 Detección.....	36
4.4.1 Discernimiento correlaciones.....	39
4.5 Evaluación sistema.....	43
4.5.1 Prueba falsos positivos.....	43
4.5.2 Prueba corrección desviación frecuencia .....	45
4.5.3 Conclusiones.....	48
<b>Capítulo 5. Detección drones Autel .....</b>	<b>49</b>

5.1	Análisis protocolo.....	49
5.2	Detección protocolo .....	54
5.2.1	<i>Detección en frecuencia</i> .....	54
5.2.2	<i>Detección en dominio temporal</i> .....	66
5.2.3	<i>Ventajas y desventajas</i> .....	71
5.3	Implementación.....	72
<b>Capítulo 6. Detección drones DeepLearning.....</b>		<b>74</b>
6.1	Transfer learning .....	75
6.2	Modelos empleados.....	76
6.2.1	<i>ResNet</i> .....	76
6.2.2	<i>VGG</i> .....	77
6.2.3	<i>MobileNet</i> .....	78
6.3	Conjunto de datos.....	78
6.3.1	<i>Preprocesado</i> .....	79
6.1	Entrenamiento modelos.....	80
6.1.1	<i>Herramientas empleadas</i> .....	82
6.2	Resultados .....	82
6.2.1	<i>Entrenamiento MobileNet</i> .....	83
6.2.2	<i>Entrenamiento ResNet</i> .....	86
6.2.3	<i>Entrenamiento VGG</i> .....	88
6.3	Modelo escogido .....	91
<b>Capítulo 7. Pruebas reales.....</b>		<b>93</b>
<b>Capítulo 8. Conclusiones y Trabajos Futuros.....</b>		<b>95</b>
<b>Capítulo 9. Bibliografía.....</b>		<b>97</b>
<b>ANEXO A 100</b>		
<b>Anexo B 103</b>		

## *Índice de figuras*

Ilustración 1 Flujo corrección en frecuencia .....	12
Ilustración 2 Precisión vs frecuencia .....	14
Ilustración 3 Porcentaje detecciones vs SNR .....	15
Ilustración 4 Métrica falsos positivos Ocusync .....	15
Ilustración 5 Resultados prueba detección en frecuencia SkyLink .....	16
Ilustración 6 Rango detecciones posibles Autel SkyLink .....	16
Ilustración 7 Precisión detecciones SkyLink .....	17
Ilustración 8 Curva entrenamiento MobileNet .....	17
Ilustración 9 Curva entrenamiento ResNet .....	18
Ilustración 10 Curva entrenamiento VGG .....	18
Ilustración 11 Diagrama Gantt de planificación .....	19
Ilustración 12 Estructura trama V3 .....	23
Ilustración 13 Estructura trama V2 .....	23
Ilustración 14 Fase secuencias Zadoff Chu .....	26
Ilustración 15 Amplitud secuencias Zadoff Chu .....	26
Ilustración 16 Diagrama flujo captura señales .....	28
Ilustración 17 Espectrograma señal entrada .....	29
Ilustración 18 Diagrama flujo corrección desvío frecuencia .....	31
Ilustración 19 Respuesta en frecuencia filtro reconstrucción .....	33
Ilustración 20 Espectro sin diezmar .....	34
Ilustración 21 Espectro diezclado .....	34
Ilustración 22 Espectrograma tras última corrección y diezclado .....	35
Ilustración 23 Correlación con símbolo 4 .....	37
Ilustración 24 Correlación símbolo 6 .....	37
Ilustración 25 Resultado correlación con señal aleatoria .....	38
Ilustración 26 Ampliación correlación símbolo 4 .....	40

Ilustración 27	Correlación con parámetros incluidos .....	41
Ilustración 28	Diagrama flujo algoritmo detección .....	42
Ilustración 29	Ratios de detecciones Ocusync .....	45
Ilustración 30	Porcentaje detecciones en función de la SNR .....	47
Ilustración 31	Error cometido en función de frecuencia .....	48
Ilustración 32	Espectrograma señal Autel con preámbulo .....	50
Ilustración 33	Ampliación preámbulo .....	51
Ilustración 34	Espectro preámbulo .....	52
Ilustración 35	Espectrograma ampliado preámbulo con chirp .....	53
Ilustración 36	Convolución imagen con filtro predefinido .....	57
Ilustración 37	Ejemplo resultado detección en frecuencia Autel SkyLink .....	59
Ilustración 38	Comparación tiempo correlación vs convolución .....	60
Ilustración 39	Tiempo ejecución medio con GPU.....	61
Ilustración 40	Comparación tiempo ejecución CPU vs GPU.....	61
Ilustración 41	Diagrama flujo detección Autel.....	64
Ilustración 42	Resultados prueba detección en frecuencia SkyLink .....	65
Ilustración 43	Correlación temporal Autel SkyLink sin desplazamiento en frecuencia .....	67
Ilustración 44	Correlación temporal Autel SkyLink con desplazamiento en frecuencia .....	68
Ilustración 45	Diagrama flujo corrección en frecuencia Autel.....	69
Ilustración 46	Diagrama caja detecciones temporales Autel SkyLink .....	71
Ilustración 47	Estructura típica red neuronal convolucional (obtenida de (Hugo Andrade Carrera , Soraya Sinche Maita , & Pablo Hidalgo Lascano , 2020)).....	75
Ilustración 48	Descripción transferlearning (elaboración propia).....	76
Ilustración 49	Arquitectura ResNet (obtenida de (Haruna Abdu, 2017)).....	77
Ilustración 50	Arquitectura VGG (obtenida de (Xianjing Han, 2021) ).....	77
Ilustración 51	Arquitectura MobileNet (obtenido de (Maad Shatnawi, 2022)) .....	78
Ilustración 52	Distribución clases conjunto datos .....	79
Ilustración 53	Espectrograma dron ejemplo.....	80
Ilustración 54	Precisión entrenamiento vs validación MobileNet.....	85
Ilustración 55	Error entrenamiento vs validación MobileNet .....	85

Ilustración 56 Precisión entrenamiento vs validación ResNet .....	88
Ilustración 57 Error entrenamiento vs validación ResNet.....	88
Ilustración 58 Precisión entrenamiento vs validación VGG .....	90
Ilustración 59 Error entrenamiento vs validación VGG.....	90
Ilustración 60 Localización prueba reales .....	93

## *Índice de tablas*

Tabla 1 Componentes necesarios .....	20
Tabla 2 Frecuencias Ocusync .....	23
Tabla 3 Parámetros señales Ocusync.....	24
Tabla 4 Parámetros algoritmo detección Ocusync .....	40
Tabla 5 Parámetros simulación falsos positivos.....	44
Tabla 6 Parámetros simulación corrección desviación frecuencia.....	46
Tabla 7 Parámetros extraídos Autel SkyLink.....	53
Tabla 8 Parámetros espectrograma detección Autel SkyLink.....	56
Tabla 9 Parámetros detección Autel SkyLink .....	63
Tabla 10 Parámetros algoritmo temporal Autel SkyLink.....	70
Tabla 11 Parámetros espectrograma Deep Learning .....	80
Tabla 12 Espacio búsqueda Optuna .....	81
Tabla 13 Parámetros MobileNet.....	84
Tabla 14 Parámetros ResNet .....	87
Tabla 15 Parámetros VGG .....	89



## Capítulo 1. INTRODUCCIÓN

En la era actual, caracterizada por avances tecnológicos rápidos y constantes, los drones han emergido como herramientas versátiles con una amplia gama de aplicaciones. Desde la fotografía y la entrega de paquetes hasta la vigilancia y la agricultura, los drones están remodelando innumerables industrias y aspectos de la vida cotidiana. Sin embargo, esta creciente omnipresencia de los drones también presenta desafíos significativos, especialmente en términos de seguridad, privacidad y regulación del espacio aéreo. Por lo tanto, la detección eficaz de drones se ha convertido en una prioridad para numerosas entidades y organizaciones tanto públicas como privadas.

Tal es la necesidad de proteger las infraestructuras que en España se han definido zonas de exclusión, que por su importancia estratégica o por seguridad operativa los vehículos aéreos no tripulados tienen prohibido volar. Además, ENAIRE (Enaire, 2024) publica regularmente nuevas zonas en el AIP por las que temporalmente no se pueden realizar vuelos de drones por diversos motivos. Es imperativo conocer que aeronaves entran en los diferentes espacios regulados y controlar cuáles de estas aeronaves tienen derecho de vuelo y cuáles no.

Este trabajo de fin de máster aborda esta necesidad, centrando la atención en el desarrollo de un sistema avanzado para la detección de drones. El objetivo principal de este trabajo fin de máster es diseñar un sistema que pueda identificar con precisión la presencia de drones en un área específica.

En este desarrollo se va a centrar la atención exclusivamente en drones comerciales, es decir, drones que se venden en la actualidad al público y que pueden ser operados por personal civil con escasa formación.

Como se ha podido observar en la reciente escalada de conflictos, los drones no tripulados de bajo coste suponen una gran amenaza para tanto la población civil como para el

personal militar destinado en un entorno. Estos drones se pueden dedicar tanto a la obtención de inteligencia sobre el terreno, como al ataque directo por medio de explosivos adheridos a este.

La naturaleza asimétrica del uso de drones también plantea desafíos para las fuerzas convencionales, ya que pueden ser utilizados por actores no estatales y grupos rebeldes con recursos limitados, pero con un impacto significativo. Esto podría cambiar el equilibrio de poder en el campo de batalla y complicar la capacidad de las fuerzas militares convencionales para prevenir o defenderse de ataques.

La relevancia de este proyecto radica no solo en su aplicación práctica para la seguridad y la vigilancia, sino también en su contribución al campo emergente de la gestión del espacio aéreo urbano. A medida que los drones continúan proliferando, el control efectivo del espacio aéreo se vuelve cada vez más crítico. Este trabajo, por lo tanto, no solo representa una contribución técnica significativa, sino que también aborda una necesidad social y regulatoria creciente.

Este proyecto representa un paso adelante en la búsqueda de un equilibrio entre el aprovechamiento de los beneficios que los drones ofrecen y la mitigación de los riesgos asociados a su operación. A través de esta investigación, se espera contribuir significativamente a la seguridad y regulación del espacio aéreo, garantizando que la integración de los drones en nuestra vida cotidiana sea segura y sostenible.

## Capítulo 2. ESTADO DE LA CUESTIÓN

Desde la aparición de los primeros vehículos aéreos no tripulados surgen numerosas iniciativas destinadas a la detección y neutralización de drones, la gran mayoría de estas prioriza la neutralización de los objetivos frente a la detección de estos, ya que la detección se realizaba directamente por inspección visual. También surgieron proyectos destinados a la detección de drones mediante el uso de inteligencias artificiales, por medio del análisis de la imagen de cámaras observando el exterior, como analizando el espectro de la señal recibida.

### *2.1 SISTEMAS DESARROLLADOS CON ANTERIORIDAD*

En la actualidad existen sistemas de detección de drones comerciales, desarrollados por empresas privadas, los más conocidos a nivel nacional son:

- “Aeroscope” (DJI, s.f.) de la empresa DJI. La detección se realiza únicamente funciona para drones de su marca Además el sistema Aeroscope representa un gran problema de seguridad ya que es el propio fabricante el que reporta los drones dentro de una zona, esto hace que todos los sistemas de seguridad dependan de un únicamente fabricante, haciendo posible que este no reporte ciertos drones de forma intencionada, con el finde traspasar las zonas de seguridad establecidas.
- “EnforceAir2” desarrollado por la empresa israelí Ra’anana, y adquirido para el Ejército del Aire y del Espacio por parte de la empresa Target Tecnología (Target Tecnología, s.f.). La empresa desarrolladora no especifica que tipo de drones detecta ni que tecnología emplea para la detección.
- El sistema “Crow” de Indra (Indra, s.f.). Este sistema está destinado únicamente al Ejército del Aire y del Espacio, para la detección de drones se apoya principalmente en el sistema Aeroscope mencionado anteriormente

## **2.2 CLASIFICACIÓN**

Los sistemas de detección de UAS desarrollados hasta la fecha, se pueden clasificar en función de numerosos parámetros.

Dependiendo de la portabilidad del sistema, se pueden clasificar en:

- Fijos: Ubicados en puntos estratégicos para cobertura amplia, como azoteas de edificios, formando un "paraguas" de protección.
- Portátiles: Más flexibles, utilizados en eventos o para acompañar comitivas de personalidades, aunque con menor rango de acción.

En lo referido a la forma de detección de los drones, los sistemas se clasifican en:

- Pasivos: Son sistemas que no emiten ningún tipo de señal, detectan la presencia de objetivos por medio del análisis de señales recibidas en tiempo real. Para poder realizar detecciones es necesario conocer con exactitud las características de la señal empleada por el dron. En caso de no conocerse se pueden aplicar algoritmos de inteligencia artificial, pero en ese caso la precisión decae de forma significativa, y el proceso de obtención de datos para entrenar los modelos es largo y costoso.
- Activos: Se tratan de radares parametrizados para la detección de objetivos de pequeño tamaño. Este tipo de sistemas tiene un alto número de falsos positivos, ya que un dron de pequeño tamaño tiene una sección radar muy similar a la de un ave. Se necesitan algoritmos especializados para poder discernir si la detección se trata de un ave o de un vehículo aéreo no tripulado en base a su patrón de comportamiento y velocidad. Este método de detección es el más costoso y el menos efectivo, ya que el precio de los componentes es muy elevado, y cada vez que es sistema es desplegado, se tiene que realizar una calibración minuciosa para reducir lo máximo posible la probabilidad de falsa alarma.

También existen esfuerzos para poder realizar la detección de objetivos por medio de técnicas de Deep learning o aprendizaje profundo.

En función del tipo de dato de entrada que empleen para realizar el discernimiento de si el dato se trata de una UA o de otro elemento, los sistemas se clasifican en:

- Reconocimiento de imágenes: realizan la detección por medio del análisis de imágenes obtenidas del entorno, en las cuales buscan elementos que tengan siluetas similares a las de UAS comerciales. En el caso de que la imagen de entrada presente un elemento dentro de un margen de confianza, este se clasifica como enemigo.
- Análisis de patrones de señal: la detección de los objetivos es realizada procesando secuencias de señales recibidas por medio de un receptor de RF, generalmente radios definidas por software. La detección se puede realizar procesando la señal en el dominio temporal o en el dominio de la frecuencia. Este último es el más empleado ya que la señal capturada por la SDR (Wikipedia, s.f.) se trata de datos IQ, muy pesados para ser cargados en GPU o en CPU, por lo que el tiempo de inferencia es muy elevado.

Estas técnicas cuentan con el inconveniente de necesitar grandes conjuntos de datos clasificados correctamente. Es por ello por lo que no se han producido grandes avances en este enfoque, a pesar de que existen iniciativas que pretenden formar repositorios comunes para el almacenamiento de la información (Mohammad F. Al-Sa'd, Abdulla Al-Ali, Tamer Khatlab, & Aiman Erbad, 2019).

En la actualidad se están realizando cambios legislativos para que los pilotos de UAS puedan reportar de forma cooperativa la posición e intenciones de su aeronave, por lo tanto, otra clasificación de los sistemas de detección sería:

- No cooperativos: en este grupo se englobarían todos los sistemas descritos hasta ahora. En este método el piloto del dron no quiere que se conozca el vuelo de su aeronave, siendo una amenaza seria para la seguridad de la ciudadanía. La mayoría de los sistemas de detección asumen que usuario del dron detectado es hostil, por lo que todos los sistemas tienden a la detección no cooperativa. Esta detección es más complicada, puesto que no se conoce de antemano la forma de onda empleada ni el protocolo.
- Cooperativos: Hasta la fecha solo existe un protocolo de reporte de posición e intenciones desarrollado para UAS en exclusividad, este protocolo es el “RemoteID”, definido por la FAA (FAA, 2020). En este protocolo se definen varios métodos y tecnologías para el reporte de los drones, con la intención de que su implementación sea lo más económica y sencilla posible. Desde septiembre del año 2023, es de obligado montar este sistema de identificación en los drones que vuelen sobre territorio europeo, la realidad es que ningún fabricante de drones ha implementado este protocolo hasta el momento de escritura de este trabajo. Esta norma, permite la detección de UAS tanto por medio de tecnología wifi en la banda de 2.4GHz como por medio de tecnología de bluetooth. Ningún sistema de los conocidos y descritos en este trabajo emplea este protocolo para realizar la detección de drones, por ello la detección de drones cooperativa se puede decir que es prácticamente residual.

En lo referido a trabajos públicos mencionados anteriormente, la documentación es escasa, apenas hay artículos que traten la materia, la mayoría de la información incorporada relacionada con el funcionamiento del protocolo Ocusync se ha extraído del siguiente artículo de una universidad de Tulsa (Bender, 2022) y del repositorio público de GitHub (proto17, 2022), a pesar de que la información era en cierta manera errónea o desactualizada.

Ambos dos han sido de gran utilidad para este trabajo, pero la información que contenían no era exacta o estaba desactualizada, por lo tanto, únicamente han servido de base para realizar la posterior investigación.

Todo el trabajo se ha tenido que realizar basándose en estudios propios, y conclusiones extraídas del análisis de las señales capturadas de pruebas reales por medio de radios definidas por software, todo el hardware del proyecto se encuentra descrito en detalle en el apartado *Planificación y Estimación Económica*.

En este trabajo, la detección de los objetivos se realiza por medio del análisis de las señales emitidas por el dron, así como del espectro de las señales recibidas en el detector. Es decir, se trataría de un sistema pasivo, fijo y basado en el procesado digital de señales, junto con un apartado basado en inteligencia artificial.

## **Capítulo 3. DEFINICIÓN DEL TRABAJO**

### ***3.1 JUSTIFICACIÓN***

#### **3.1.1 AUSENCIA DE SOLUCIONES ABIERTAS**

A pesar de la existencia de sistemas de detección previos, ninguno de ellos es capaz de integrar todos los métodos y tecnologías existentes. Este trabajo al ser capaz de integrar diferentes métodos de detección permite ampliar el número de drones detectables, así como obtener mayor precisión, puesto que en ocasiones un objetivo puede ser detectado por varios métodos de forma simultánea.

Además, todos los trabajos anteriores de detección de drones son de código cerrado, lo que hace que las entidades y corporaciones no puedan emplearlos por su alto coste económico.

#### **3.1.2 AUSENCIA DE SOLUCIONES NACIONALES**

Todos los sistemas de detección de drones del mercado son soluciones realizadas por empresas radicadas fuera del territorio nacional, en algunos de los casos incluso fuera de la Unión Europea. Esto supone un gran problema a nivel estratégico puesto que la información de la posición de drones en espacio aéreo es información de alto valor operativo.

Además, la empresa fabricante del sistema podría controlar que tipo de drones son detectados y cuales no, provocando que ciertos drones pasaran desapercibidos para el sistema, suponiendo un gran riesgo para la seguridad.

El sistema más común es el sistema “Aeroscope” (DJI, s.f.), desarrollado por la empresa china DJI (DJI, s.f.). Al depender de una empresa radicada en China, su funcionamiento depende de las relaciones diplomáticas del país que lo utilice, de forma que, si estas llegaran a su fin, la empresa DJI podría dejar de reportar ciertos drones estratégicos en territorio nacional a petición del gobierno chino.



Este sistema pretende de dotar de independencia y soberanía a la empresa o estado que lo utilice, ya que no requiere de conexión a internet para funcionar, ni para reportar los objetivos detectados. Esto representa una gran ventaja con respecto a los sistemas anteriores, ya que la mayoría necesitaba de conexión para poder indicar la presencia de un objetivo. Esto radica en que los otros métodos de detección de drones no son portables

### **3.1.3 SOLUCIÓN DE BAJOS RECURSOS**

Este sistema no requiere de hardware especializado para poder realizar el procesamiento de la señal, si no que se puede ejecutar en ordenadores de bajo costo con bajos recursos. No requiere de FPGAS ni de procesadores especializados de procesamiento digital de señales.

## **3.2 OBJETIVOS**

El objetivo principal de este trabajo es desarrollar un sistema para la detección de drones utilizando tres enfoques específicos: la identificación de drones que utilizan el protocolo Ocusync, la detección de drones de la marca Autel, y la clasificación mediante modelos de aprendizaje profundo de imágenes de espectrogramas para determinar la presencia de drones.

Este sistema multifacético busca ofrecer una solución robusta, eficaz y de cómputo ligero para la monitorización y gestión del espacio aéreo entorno a la posición de despliegue, aprovechando las capacidades avanzadas del procesamiento de señales y la inteligencia artificial. El propósito es establecer un método confiable y eficiente que permita identificar rápidamente distintos tipos de drones en diversas condiciones operativas, contribuyendo así a la seguridad y regulación del uso de estos dispositivos en el espacio aéreo.

A modo de resumen, los objetivos se pueden dividir en dos grupos:

### **3.2.1 OBJETIVOS TÉCNICOS**

- Desarrollo de un sistema multifacético para la detección de drones:
  - Implementación de métodos para la identificación de drones que utilizan el protocolo Ocusync.
  - Integración de técnicas específicas para la detección de drones de la marca Autel.
  - Desarrollo de modelos de aprendizaje profundo para la clasificación de imágenes de espectrogramas, enfocados en determinar la presencia de drones.
- Optimización del rendimiento del sistema:
  - Creación de un sistema de cómputo ligero que no requiera grandes recursos informáticos, asegurando así su viabilidad en diferentes entornos de despliegue.
  - Utilización de algoritmos avanzados de procesamiento de señales y técnicas de inteligencia artificial para maximizar la eficacia y la rapidez de la detección.
- Adaptabilidad y robustez del sistema:
  - Asegurar que el sistema sea capaz de operar bajo diversas condiciones ambientales y operativas.
  - Implementación de pruebas rigurosas para validar la confiabilidad del sistema en diferentes escenarios de uso.

### **3.2.2 OBJETIVOS DIDÁCTICOS**

- Formación en técnicas avanzadas de inteligencia artificial y procesamiento de señales:

- Desarrollando e implementando modelos de aprendizaje profundo y técnicas de procesamiento de señales aplicadas a problemas de detección en tiempo real.
- Ampliar conocimientos sobre programación en MATLAB y todas sus funcionalidades.
- Desarrollo de habilidades prácticas en la implementación de sistemas de monitorización:

### ***3.3 METODOLOGÍA***

El desarrollo del proyecto de detección de drones se ha estructurado utilizando la metodología de trabajo en cascada, un enfoque sistemático y secuencial que ha permitido una gestión efectiva del proyecto al estar destinado a un entorno empresarial. Este enfoque ha sido crucial para asegurar que cada fase del proyecto se completara antes de pasar a la siguiente, facilitando la planificación y la coordinación entre los diferentes equipos involucrados.

### ***3.4 PLANIFICACIÓN Y ESTIMACIÓN ECONÓMICA***


Para realizar la planificación del proyecto, se han listado todas las tareas necesarias para poder llegar al objetivo final, las cuales son:

- **Recopilación de Documentación:** Esta fase inicial implica la recogida y análisis de información técnica sobre los drones, sus frecuencias de operación, el protocolo Ocusync y la tecnología de Autel, así como las regulaciones actuales en el espacio aéreo para drones.
- **Captura de Señales:** En este hito, se establecen los mecanismos para capturar las señales emitidas por los drones usando el protocolo Ocusync y por los drones de la marca Autel.
- **Análisis de Señales:** Se procesan las señales capturadas para identificar las características distintivas y parámetros clave que serán utilizados para la detección.

- Desarrollo del Algoritmo Ocusync: Creación de un algoritmo específico para la detección de drones que utilizan el protocolo Ocusync, incorporando las características identificadas en el análisis previo.
- Evaluación del Algoritmo Ocusync: Pruebas y ajustes del algoritmo Ocusync para validar su eficacia y eficiencia en diferentes escenarios.
- Extracción de Información Ocusync: Se perfecciona el proceso de extracción de información relevante de las señales de drones con Ocusync, optimizando la recopilación de datos para la clasificación.
- Desarrollo del Algoritmo Autel: Implementación de un algoritmo específico para la detección de drones de la marca Autel.
- Evaluación del Algoritmo Autel: Testeo del algoritmo Autel y calibración según los resultados obtenidos para garantizar precisión en la detección.
- Diseño del Modelo de Deep Learning: Diseño de un modelo de aprendizaje profundo que sea capaz de clasificar las imágenes de los espectrogramas y determinar la presencia de drones.
- Evaluación del Modelo de Deep Learning: Se lleva a cabo una evaluación completa del modelo de aprendizaje profundo, ajustando y afinando su desempeño.
- Documentación de Resultados: Compilación de todos los datos, análisis, y resultados del proyecto en un formato sistemático para futura referencia y validación.
- Memoria Final: Redacción de la memoria final del TFM, que incluirá una descripción detallada de la metodología, los procesos y los resultados del proyecto.

Más tarde se ha realizado un diagrama de Gantt con todas las tareas ordenadas en orden cronológico, y se ha seguido durante todo el desarrollo del proyecto.

Dicho diagrama se muestra a continuación:



*Ilustración 11 Diagrama Gantt de planificación*

Como podrá advertirse, la tarea de “captura de señales” tiene una duración muy elevada, desde la finalización de la tarea de recopilación de documentación hasta el final del proyecto. Esto es porque durante todo el desarrollo del proyecto se fueron adquiriendo nuevos UAS con diferentes protocolos, haciendo que fuera necesario capturar las señales que estos emiten para poder realizar el modelo de DeepLearning final, y para evaluar el desempeño de los algoritmos anteriormente desarrollados.

En lo referido a la estimación económica del proyecto, se van a enumerar todos los componentes imprescindibles necesarios para poder llevar a cabo la detección de drones por medio de los algoritmos descritos. Es posible que se añadan nuevos componentes, o que estos se tengan que ampliar para poder abarcar objetivos más amplios, por lo tanto, esto debe tomarse como una estimación económica de base.

<b>Componente</b>	<b>Cantidad</b>	<b>Precio</b>
Ordenador Aeon BOXER-6645-ADS	2	1.000€
SPECTRAN® V6 PLUS 2000XA-6	2	10.000€
Rohde & Schwarz R&SHE400LP	4	2.260€

*Tabla 1 Componentes necesarios*

## Capítulo 4. DETECCIÓN PROTOCOLO OCUSYNC

### 4.1 DESCRIPCIÓN PROTOCOLO

Ocusync es un protocolo de transmisión de datos avanzado desarrollado por DJI, diseñado específicamente para sus drones. Este protocolo permite la transmisión de video en alta definición y datos de telemetría entre el dron y el controlador a distancias considerables, mejorando significativamente la estabilidad y la calidad de la conexión comparado con tecnologías anteriores.

Ocusync se destaca por su capacidad de cambiar automáticamente entre frecuencias de transmisión para optimizar la señal y reducir la interferencia, lo que resulta esencial para operaciones de vuelo en áreas con alto tráfico de señales. Además, facilita características avanzadas como la transmisión de video a múltiples dispositivos simultáneamente y soporta la integración con accesorios adicionales, como gafas FPV, aumentando así la versatilidad y las aplicaciones prácticas de los drones DJI.

La comunicación es bidireccional, entre el dron y el mando de control. Dentro de dicha comunicación, se envían tres tipos de mensajes:

- Mensajes de control desde el mando de operaciones, destinados a controlar la posición velocidad e inclinación del dispositivo.
- Mensajes de video, enviados desde el dron para poder mostrarlo en el dispositivo móvil conectado al mando.
- Mensajes broadcast de información, denominados “droneID”, enviadas de forma periódica. Estas tramas son cruciales ya que contienen información detallada sobre la posición actual del dron, datos de telemetría esenciales para el seguimiento y control, así como información sobre el piloto que está operando el dron.

Este trabajo se va a centrar en la detección de dichos paquetes “droneID” enviados en forma de broadcast.

Los drones que emplean esta tecnología en este estudio son el Mavic Mini 2 y el Mavic 3, ambos conocidos por su rendimiento y fiabilidad.

El protocolo envía de forma periódica las tramas "droneID". Estas tramas son cruciales ya que contienen información detallada sobre la posición actual del dron, datos de telemetría esenciales para el seguimiento y control, así como información sobre el piloto que está operando el dron. La transmisión de estas tramas droneID es fundamental para mantener la seguridad y la gestión eficaz del espacio aéreo, especialmente en entornos donde múltiples drones pueden estar operando simultáneamente.

El protocolo Ocusync hace uso de tramas OFDM (Wikipedia, 2023) (Orthogonal Frequency-Division Multiplexing) para la transmisión eficiente y robusta de los datos, las tramas OFDM se envían en diferentes bandas dependiendo del tipo de trama que se pretenda transmitir. En el caso de las tramas de droneID, las frecuencias a las que se envían son conocidas previamente. Estas frecuencias son proporcionadas por estudios y artículos anteriores relacionados (proto17, 2022)

Las frecuencias son:

<b>Banda 2.4 GHz</b>	<b>Banda 5.8 GHz</b>
2399.5 MHz	5741.5 MHz
2414.5 MHz	5756.5 MHz
2429.5 MHz	5771.5 MHz
2444.5 MHz	5786.5 MHz
2459.5 MHz	5801.5 MHz
	5816.5 MHz



5831.5 MHz

*Tabla 2 Frecuencias Ocusync*

Independientemente de la banda de comunicaciones que se fuerce al dron en la aplicación de control, las tramas correspondientes a mensajes droneID, siempre se van a enviar en estas frecuencias, incluso cuando esta comunicación se produce a la vez que otras, o incluso si se solapa con las tramas de vídeo.

## 4.2 ESTRUCTURA TRAMA

La estructura de los paquetes de droneID enviados como el propio protocolo Ocusync son propietarios de la empresa DJI y de código cerrado. Para poder obtener la estructura de la trama se ha tenido que recurrir a artículos como (RUB-SysSec, 2023) así como al análisis de las señales interceptadas con drones en vuelo.

### 4.2.1 PARÁMETROS SEÑAL

Un paquete de droneID está compuesto por 8 o 9 símbolos OFDM, dependiendo de la versión del protocolo. En el caso de que se trate de Ocusync versión 2, el paquete tiene 9 símbolos, pero en el caso de que sea de versión 3, la más nueva, se tienen 3 símbolos.

Cada símbolo OFDM viene precedido de un prefijo cíclico. En el caso del primer símbolo y del último este prefijo cíclico es de 80 muestras, mientras que, en los demás casos, este es de 72 muestras.

PC 80 muestras	Símbolo 1	PC 72 muestras	Símbolo 2	PC 72 muestras	Símbolo 3	PC 72 muestras	Símbolo 4	PC 72 muestras	Símbolo 5	PC 72 muestras	Símbolo 6	PC 72 muestras	Símbolo 7	PC 80 muestras	Símbolo 8
-------------------	-----------	-------------------	-----------	-------------------	-----------	-------------------	-----------	-------------------	-----------	-------------------	-----------	-------------------	-----------	-------------------	-----------

*Ilustración 12 Estructura trama V3*

PC 80 muestras	Símbolo 1	PC 72 muestras	Símbolo 2	PC 72 muestras	Símbolo 3	PC 72 muestras	Símbolo 4	PC 72 muestras	Símbolo 5	PC 72 muestras	Símbolo 6	PC 72 muestras	Símbolo 7	PC 72 muestras	Símbolo 8	PC 80 muestras	Símbolo 9
-------------------	-----------	-------------------	-----------	-------------------	-----------	-------------------	-----------	-------------------	-----------	-------------------	-----------	-------------------	-----------	-------------------	-----------	-------------------	-----------

*Ilustración 13 Estructura trama V2*

La señal completa tiene 1024 portadoras de datos, pero no se envía información en todas las portadoras para poder respetar un ancho de banda de guarda. Por cada símbolo enviado, se tienen 600 portadoras de datos, cada una de las cuales tiene la información modulada con una modulación QPSK.

Si se analiza la señal con una frecuencia de muestreo de 15.36 MHz, como es el caso en este trabajo la separación entre portadoras es de 15 KHz, y el ancho de banda total de la señal OFDM es de 15.36 MHz, mientras que el ancho de banda de los datos es de 9.16 MHz. Además, la duración completa de la trama en el caso de la versión 3 es de 57 ms y en el caso de la versión 2 es de 64 ms

Parámetro	Versión 2	Versión 3
Separaciones portadoras	15KHz	15KHz
Duración	63 ms	57 ms
Ancho de banda total	15.36 MHz	15.36 MHz
Ancho de banda datos	9.16 MHz	9.16 MHz
Frecuencia muestreo	15.36 MHz	15.36 MHz

*Tabla 3 Parámetros señales Ocusync*

No todos los símbolos transmiten información de la posición del dron, si no que, como no se cuenta con pilotos en las portadoras, el fabricante ha introducido dos secuencias conocidas por el receptor en los símbolos 4 y 6 de la secuencia. Estos símbolos se respetan independientemente de la versión del protocolo. Estas secuencias conocidas se tratan se secuencias de Zadoff Chu, y es por medio de estas secuencias como se va a realizar la detección de los drones.

### 4.2.2 SECUENCIA ZADOFF CHU

La secuencia de Zadoff-Chu (ZC) (Wikipedia, 2023) , también conocida como secuencia de Chu o secuencia de Frank-Zadoff-Chu (FZC), es una secuencia matemática de valores complejos que, cuando se aplica a una señal, da lugar a una nueva señal de amplitud constante. La señal resultante se trata de una señal modulada por una variación continua de fase y con amplitud constante.

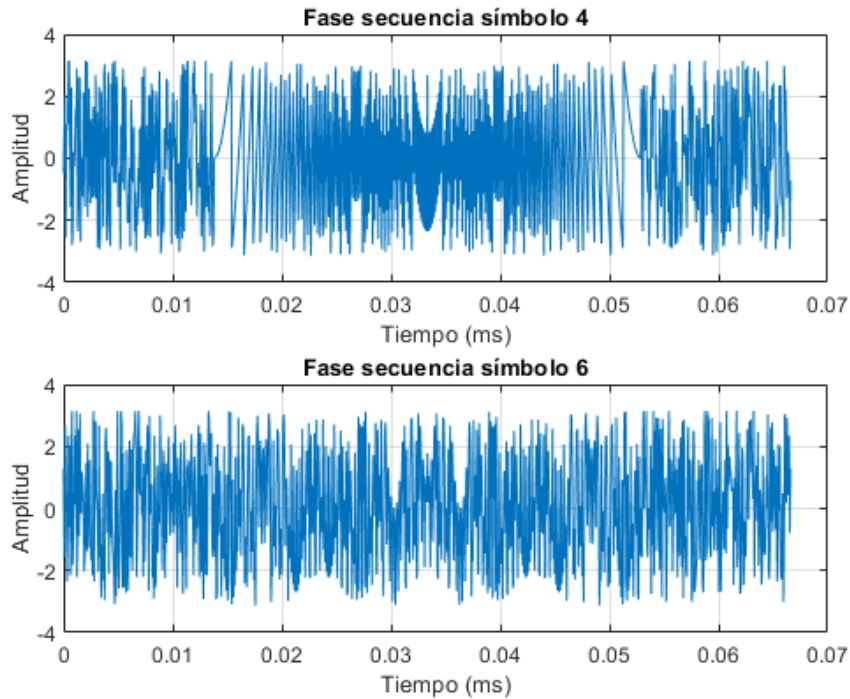
La fórmula para obtener una secuencia de Zadoff Chu es la siguiente:

$$x_u(n) = \exp\left(\frac{-j * \pi * raiz * n}{N}\right) \forall n \in Z$$

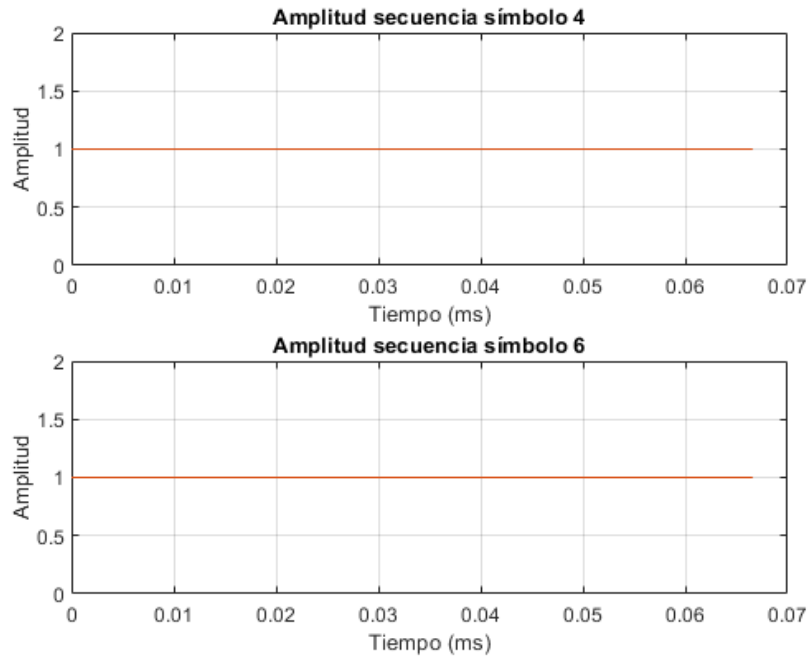
*Ecuación 1 Fórmula generación secuencia Zadoff Chu*

Como se puede observar en la fórmula anterior, la generación de la secuencia requiere de un valor inicial para poder obtener toda la secuencia, dicho valor se denomina “raíz”. En el caso de los mensajes de “droneID”, el símbolo cuatro está formado por una secuencia de raíz 600, mientras que la secuencia del símbolo 6 está formada por la raíz 147

A continuación, se muestra como es dicha señal en el dominio del tiempo tanto en amplitud como en fase:



*Ilustración 14 Fase secuencias Zadoff Chu*



*Ilustración 15 Amplitud secuencias Zadoff Chu*

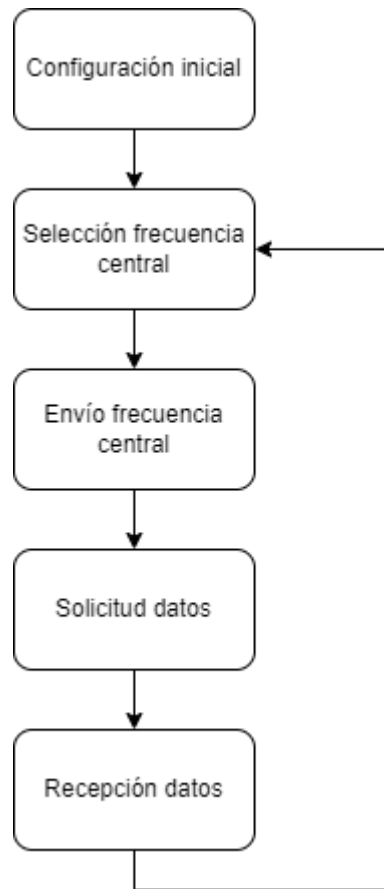
Estas señales tienen la ventaja de que cuando se autocorrelan con versiones desplazadas de sí mismas presentan una autocorrelación nula. Es esta propiedad lo que permite que se puedan detectar los drones, ya que el receptor conoce previamente dicha secuencia, por lo tanto, al realizar correlaciones de la señal de entrada con la señal conocida, se pueden obtener si en la señal recibida existe una señal de droneID, así como la posición de los símbolos 4 y 6.

Es a partir de estas posiciones como se podría llegar a demodular la información contenida en las portadoras.

### ***4.3 CAPTURA SEÑALES***

Para poder realizar la detección de los mensajes de droneID en tiempo real, primero se tiene que realizar la captura de señales del entorno. Para ello se va a emplear una SDR (software defined radio) sintonizada en tiempo real a las frecuencias conocidas.

El diagrama de flujo del proceso de captura de las señales es el siguiente:

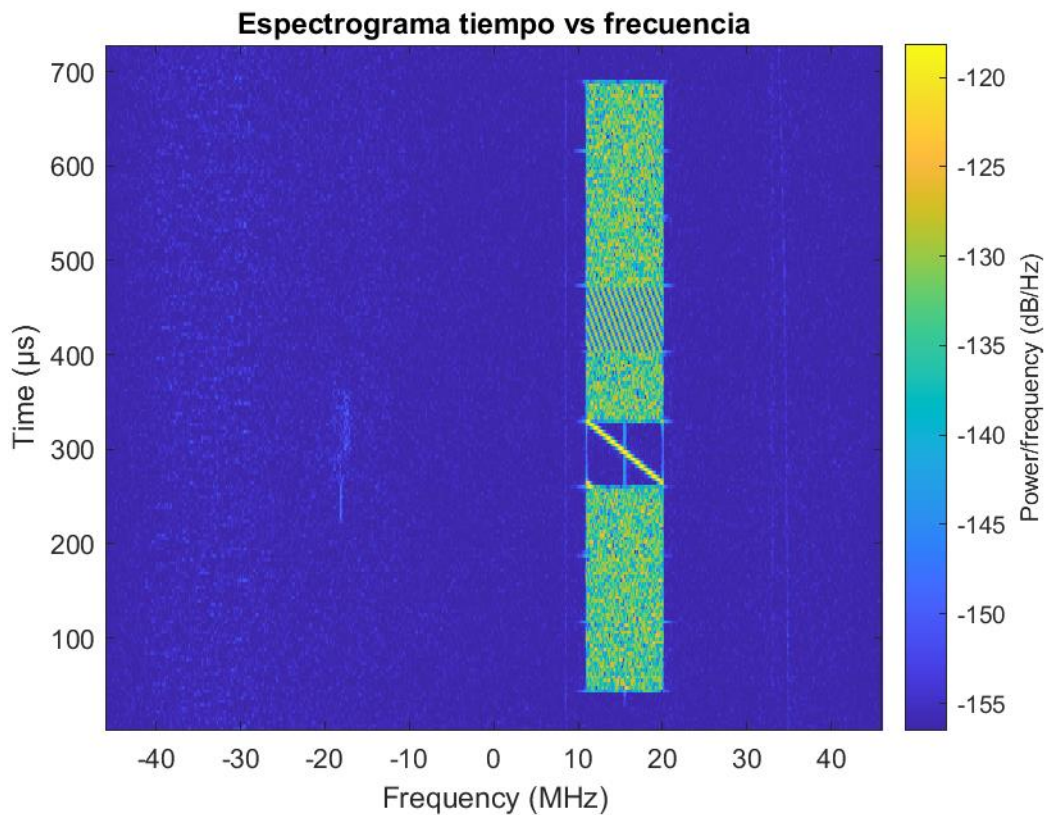


*Ilustración 16 Diagrama flujo captura señales*

Se han obtenido señales en bloques de 10 ms con una frecuencia de muestreo de 92.16 MHz, esto hace que sea necesario realizar una adaptación de la frecuencia de muestreo una vez se ha capturado la señal

#### **4.3.1 CORRECCIÓN EN FRECUENCIA**

Derivado del hecho de que este proyecto se ha realizado en un entorno laboral, y que el sistema solo cuenta con una cadena de recepción, en ocasiones no se ha podido sintonizar la frecuencia central de la SDR a la deseada, por ello, se ha realizado una rutina, que, aprovechando el espectro de la señal, centra entorno a frecuencia central cero la señal de 10 ms.



*Ilustración 17 Espectrograma señal entrada*

Los pasos seguidos son:

1. Cálculo del espectrograma de la señal por medio de la transformada de Fourier en tiempo discreto.
2. Una vez se ha calculado la transformada de Fourier de la señal recibida en su totalidad, se calcula la media de todo el espectro con el fin del obtener los índices que se encuentren por encima, esto permite que se realice una estimación del ancho de banda de la señal recibida, ya que todos los índices por encima de la media componen el espectro de la señal OFDM.
3. Con los índices por encima de la media, se calcula el ancho de banda estimado de la señal de entrada, en el caso de que el ancho de banda difiera dentro de un margen del 5% del ancho de banda esperado, la señal se descarta.

4. Una vez se conoce cuál es el ancho de banda de la señal recibida, se calcula el índice correspondiente a la mitad de dicho ancho banda, así como la frecuencia a la que corresponde dicho índice.
5. Una vez se conoce la frecuencia en la que se encuentra el índice medio del ancho de banda de la señal, se estima la desviación en frecuencia.
6. Por último, se corrige dicha desviación en frecuencia multiplicando en el dominio temporal la señal de entrada por una exponencial con la desviación en frecuencia con el signo cambiado.

$$y(n) = x(n) * \exp(2 * \pi * (-desviacion)/N * n) \forall n \in Z$$

*Ecuación 2 Corrección desviación frecuencia*

Donde:

- $y(n)$  es la señal de salida corregida.
- $x(n)$  es la señal de entrada sin corregir.
- $N$  es la longitud de la señal  $x(n)$ .
- Desviación es la desviación en frecuencia calculada con los pasos anteriores.





*Ilustración 18 Diagrama flujo corrección desvío frecuencia*


Esta corrección en frecuencia no es lo suficientemente acertada como para poder demodular la información de las portadoras, por lo tanto, se tendrían que realizar más pasos de corrección fina en frecuencia.

Esta corrección en frecuencia se tiene que realizar en dos ocasiones, la primera se realiza antes del cambio de la frecuencia de muestreo, y la siguiente anda más adaptar tasa de muestreo. Como se puede observar en las imágenes *Ilustración 20* e *Ilustración 21* el ensanchado del espectro, afecta a la precisión del método empleado.

La primera iteración sirve para realizar una corrección estimada y poder realizar el cambio de la frecuencia de muestreo sin filtrar componentes de la señal de entrada.

#### **4.3.2 CAMBIO FRECUENCIA DE MUESTREO**

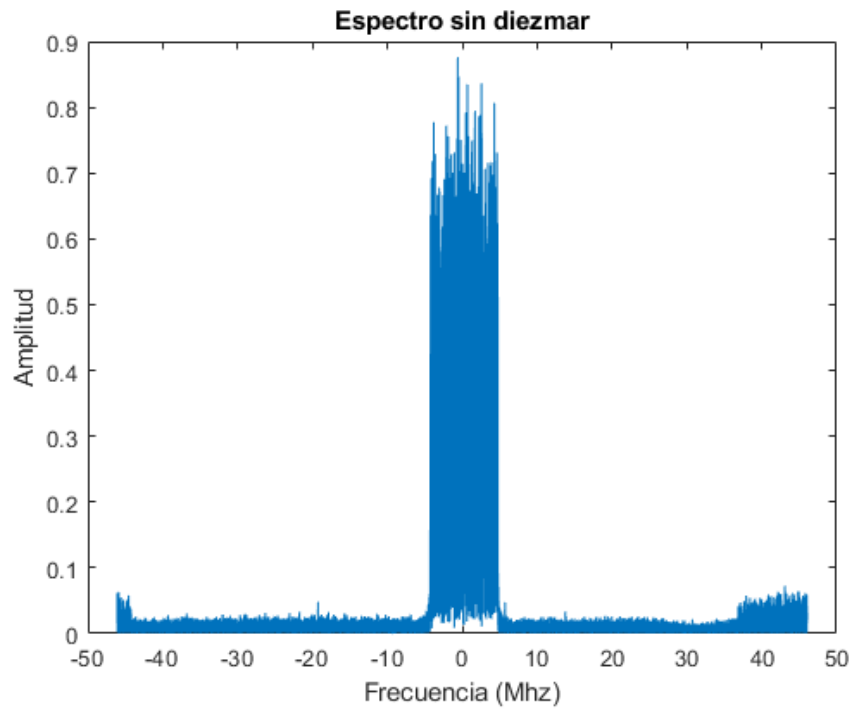
Para adaptar la tasa de muestreo a la deseada, 15.36 MHz, se ha filtrado cada bloque de 10 ms con un filtro de reconstrucción IIR de orden 8 cuya respuesta en frecuencia se muestra a continuación:



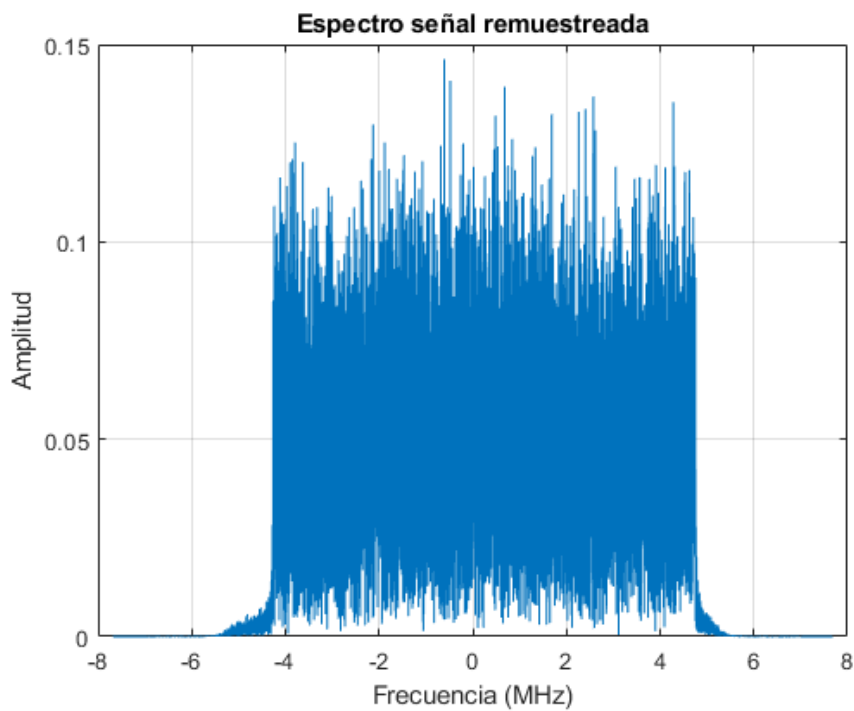
*Ilustración 19 Respuesta en frecuencia filtro reconstrucción*

Además, una vez que se ha filtrado la señal, se ha realizado un diezmado de la señal for un factor de 6.

De esta forma el espectro de la señal a la entrada se transforma de la siguiente manera fruto del diezmado:



*Ilustración 20 Espectro sin diezmar*



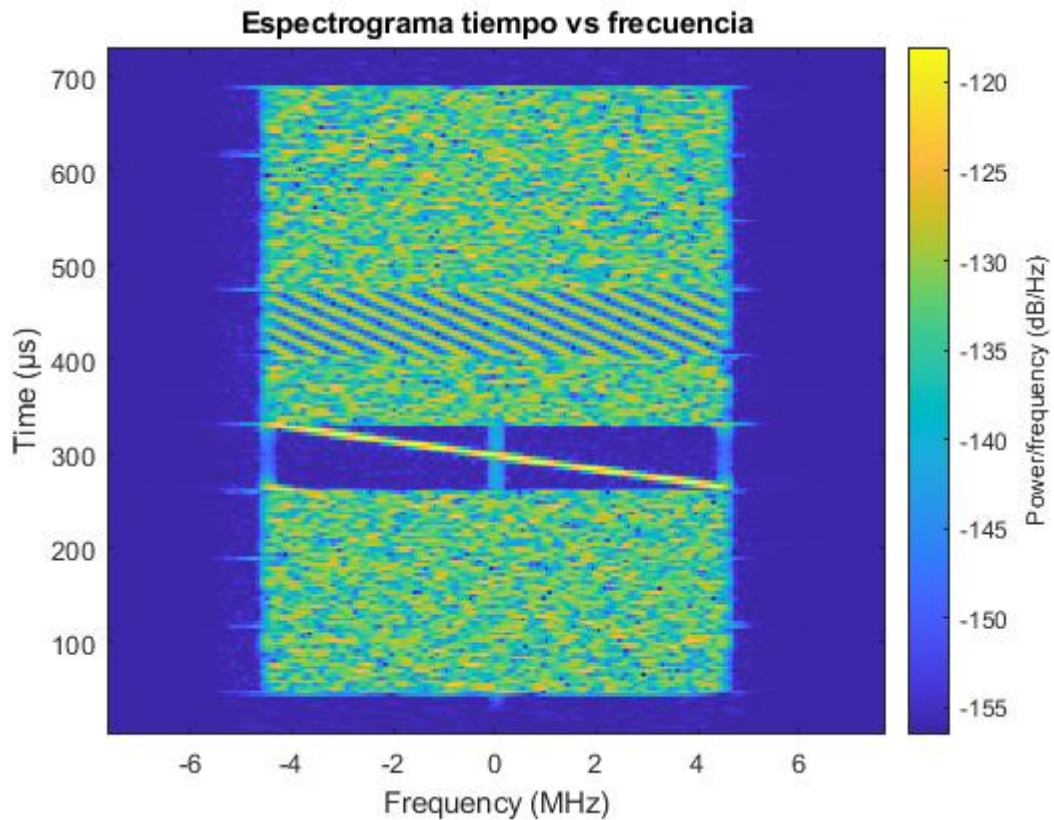
*Ilustración 21 Espectro diezgado*

De esta forma se obtiene una frecuencia de muestreo final de 15.36 MHz debido a que:

$$F_{S_{final}} = \frac{F_{S_{inicial}}}{M}$$

*Ecuación 3 Fórmula cambio tasa muestreo*

Con la frecuencia de muestreo ajustada y la señal centrada en frecuencia cero por segunda vez, se puede realizar la detección.



*Ilustración 22 Espectrograma tras última corrección y diezmado*

## 4.4 DETECCIÓN

Con los bloques de señal ya preparados para realizar la detección, se realiza la búsqueda de las secuencias de Zadoff Chu conocidas dentro de la señal total recibida.

Para realizar la búsqueda de las señales conocidas se ha implementado un correlador, el algoritmo recibe la señal remuestreada y corregida en frecuencia, y aplica una correlación con las secuencias de Zadoff Chu generadas previamente de forma sintética. En este proceso se descartan los desplazamientos negativos de la correlación para reducir la dimensionalidad del vector resultante.

$$R_{xy}(\tau) = \sum_{n=-\infty}^{\infty} x[n] \cdot y[n + \tau] \quad \forall \tau$$


*Ecuación 4 Fórmula correlación*

Este sistema de búsqueda de señales conocidas es equivalente a un filtro adaptado, ya que cuando la señal recibida no coincide en forma con la conocida, la salida del correlador sería nula o fondo de ruido, mientras que si es la señal conocida se tiene un pico claro temporal.

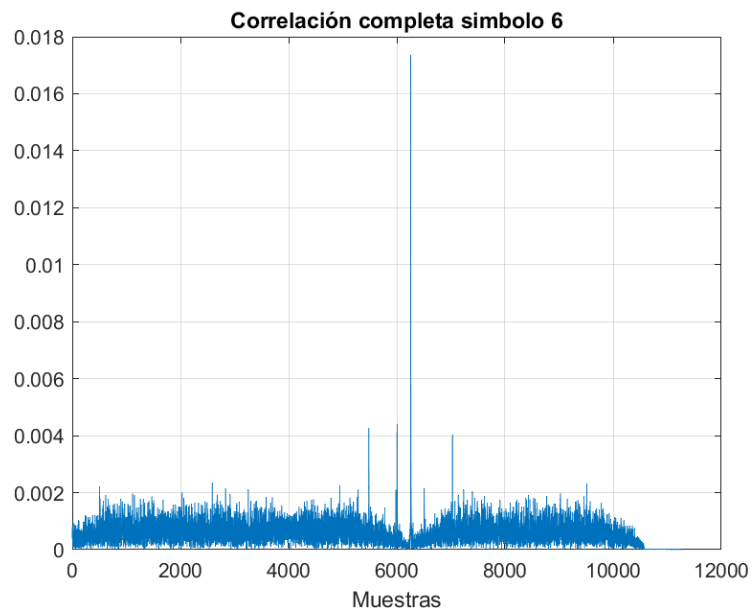
Este sistema presenta el inconveniente de que, si la señal de entrada es de una potencia suficiente, y de una duración reducida, la salida del correlador podría llegar a interpretarse como un pico temporal correspondiente a una detección.

Este error es recurrente, ya que los drones que se tratan de detectar trabajan en la banda de 2.4Ghz, en la cual también se encuentran las comunicaciones de protocolo WIFI. Este protocolo hace uso FHSS (espectro ensanchado por salto de frecuencia) (Wikipedia, s.f.), modulación que envía señales de corta duración, ancho de banda reducido y alta potencia, las cuales se pueden interpretar como falsos positivos.

Las salidas correspondientes a detecciones tienen la siguiente forma:

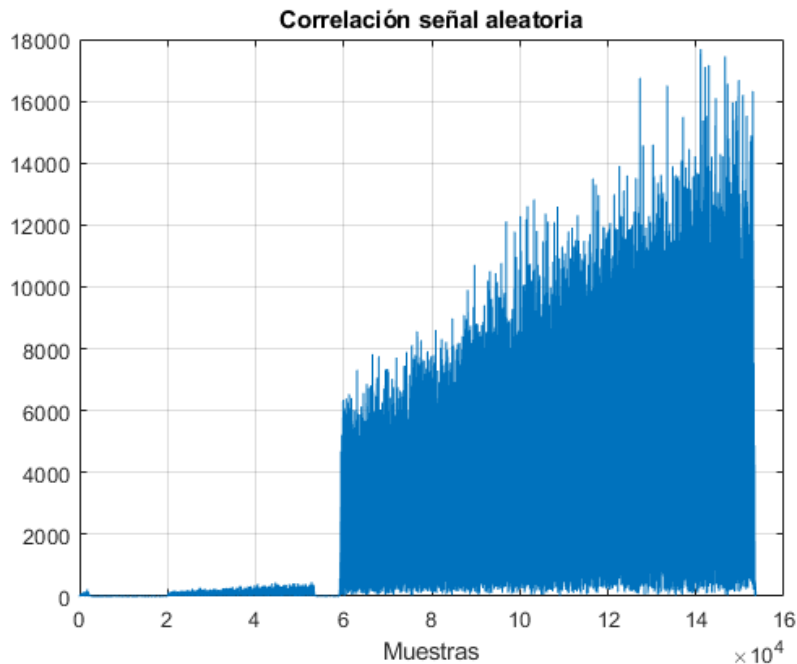


*Ilustración 23 Correlación con símbolo 4*



*Ilustración 24 Correlación símbolo 6*

Mientras que la salida del correlador cuando a la entrada se encontraban señales propias de otras comunicaciones:



*Ilustración 25 Resultado correlación con señal aleatoria*

Cabe resaltar de los resultados la diferencia de valor absoluto de los picos con respecto al resto de valores cercanos. Esto va a ser un factor determinante a la hora de determinar si se trata de una detección satisfactoria, el algoritmo se explica en **Discernimiento correlaciones**.

Por ello es necesario realizar una etapa de procesamiento posterior a la correlación, que recibiendo el vector de la salida del correlador, sea capaz de discernir entre secuencias correspondientes a un positivo, y señales relativas a otros protocolos de comunicación.

Este algoritmo se ha desarrollado de forma individual puesto que la literatura existente referente a la decisión a la salida de filtros adaptados requiere de secuencias temporales de señal interrelacionadas y con intervalos de tiempo muy reducidos entre sí.



Este algoritmo se ha denominado **algoritmo discernimiento**.

#### **4.4.1 DISCERNIMIENTO CORRELACIONES**

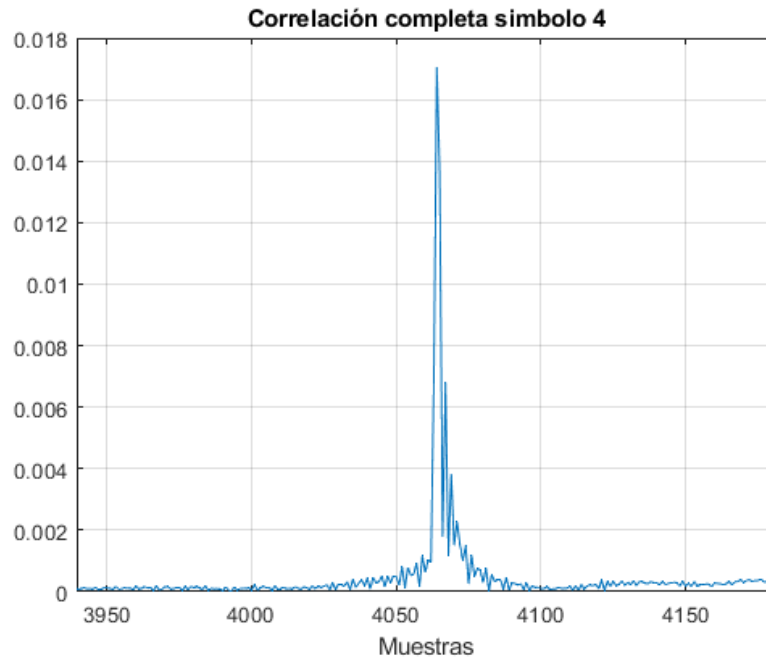
Para diferenciar de forma satisfactoria los vectores de detecciones con respecto a los que no, se ha desarrollado el siguiente algoritmo.

Como se puede observar nunca se toma el valor absoluto de la correlación como un elemento diferenciador, ya que este depende en gran medida de la potencia de entrada de la señal, y esta potencia tiene una relación directa con la distancia del objetivo, pérdidas en la cadena de recepción y elementos externos, factores no controlables, y por lo tanto impredecibles.

Uno de los factores que se valora a la hora de discernir es el valor del pico con respecto a la media de todo el vector. En el caso de que se trate de una detección satisfactoria, la mayoría del vector corresponde a fondo de ruido, mientras que una porción reducida es señal del dron. Con esta métrica se consiguen eliminar los vectores derivados de la correlación con ruido de fondo.

El criterio más importante que se ha tenido en cuenta es el valor del pico de correlación con respecto a sus valores aledaños. En el caso de que la detección sea positiva, la relación que existe entre el pico y los valores cercanos es muy alta, por lo tanto, esta métrica sirve para descartar los casos en los que se trata de un pico de potencia puntual dentro de una señal más larga.

Sin embargo, puede ocurrir que el pico no sea una delta de Dirac pura (observable en la *Ilustración 26*), si no que el pico presente cierta pendiente previa al pico, por ello es necesario descartar los valores más cercanos al pico de correlación, ya que estos pueden ser fruto de la correlación con la parte correspondiente al prefijo cíclico.



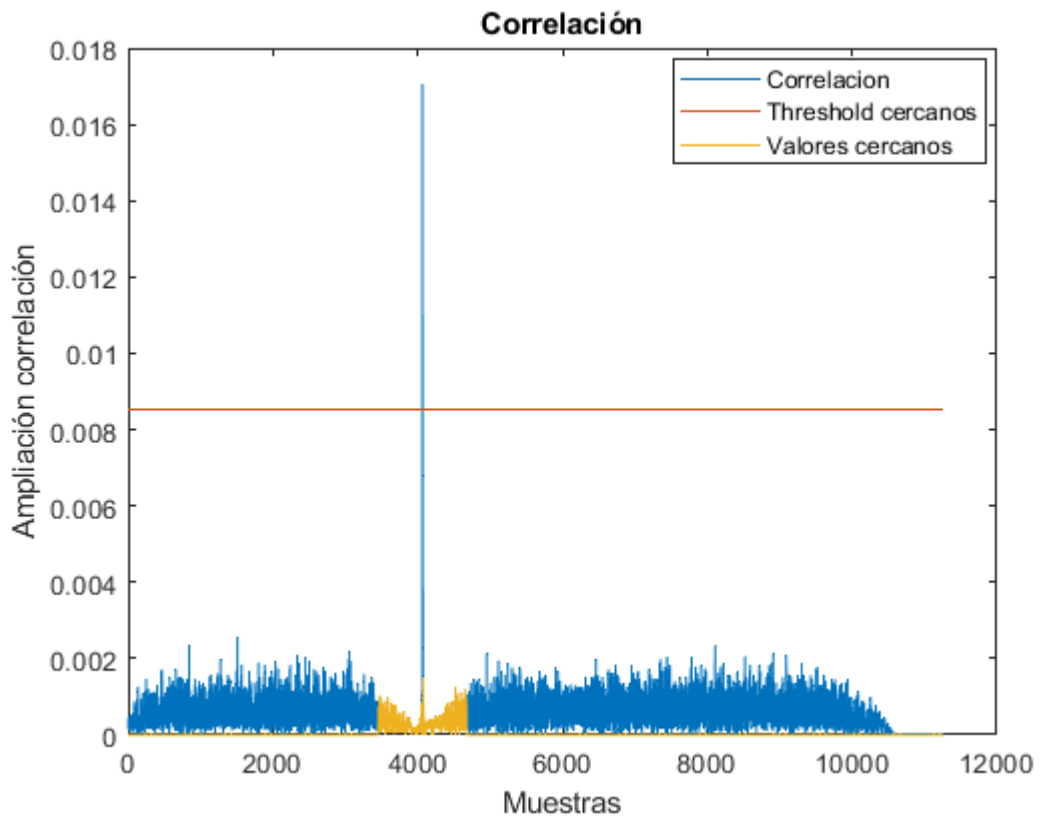
*Ilustración 26 Ampliación correlación símbolo 4*

En el caso de que el pico dividido por un factor siga siendo mayor que los valores cercanos a él, se trataría de una detección de dron empleando el protocolo Ocusync


Los parámetros que se han empleado para el algoritmo descrito anteriormente son:

<b>Parámetro</b>	<b>Valor</b>
Ratio media	10
Número de cercanos evaluados	550
Número aledaños descartados	10
Ratio cercanos	3

*Tabla 4 Parámetros algoritmo detección Ocusync*



*Ilustración 27 Correlación con parámetros incluidos*



*Ilustración 28 Diagrama flujo algoritmo detección*

## ***4.5 EVALUACIÓN SISTEMA***

A la hora de analizar que desempeño tiene el sistema a la hora de detectar drones, se han realizado dos pruebas, la primera de ellas consiste en introducir al sistema señales de dron con SNR variable entre 0 y 90, así como señales correspondientes a otro tipo de comunicaciones.

Por otro lado, se ha realizado otra prueba que evalúa la capacidad de corregir la desviación en frecuencia en diferentes condiciones de relación señal a ruido. Para esta prueba no se van a incluir señales externas aleatorias, ya que este caso queda cubierto por la simulación anterior.

Por último, se ha realizado un experimento calculando el error medio cometido a la hora de estimar el comienzo de la trama de mensaje de droneID. Esta prueba va a facilitar el camino a futuras ampliaciones del proyecto en las que se va a realizar la decodificación de la señal. Con los resultados obtenidos se va a poder tener una estimación de la SNR mínima para obtener la información de las portadoras de OFDM.

Estas simulaciones van a dar una visión del desempeño global del sistema en las diferentes situaciones que se puede encontrar en el entorno real una vez sea desplegado. Además, se van a conocer las limitaciones de este algoritmo, así como que métricas de falsos positivos y precisión esperar para las diferentes situaciones.

### **4.5.1 PRUEBA FALSOS POSITIVOS**

Como se ha explicado previamente, el objetivo de esta primera prueba es evaluar la capacidad del sistema de separar las detecciones de Ocusync frente a otras señales, incluso cuando las señales correspondientes a tramas de droneID presentar una SNR reducida.

Este experimento sirve para comprobar el ratio de falsos positivos que tiene el sistema, así como el porcentaje de señales reales que no son detectadas.

Se espera que el porcentaje de falsos positivos sea muy reducido, prácticamente nulo, y que el porcentaje señales reales no detectadas aumente a medida que la SNR disminuye.

#### **4.5.1.1 Parámetros**

En esta prueba se van a introducir 1000 señales con tramas correspondientes a drones de la marca DJI que emplean el protocolo Ocusync, con SNRs entre -50 y 50. Además se van a emplear señales aleatorias capturadas durante el desarrollo de este trabajo, que no corresponden a drones, o que corresponden a drones de otras marcas y protocolos.

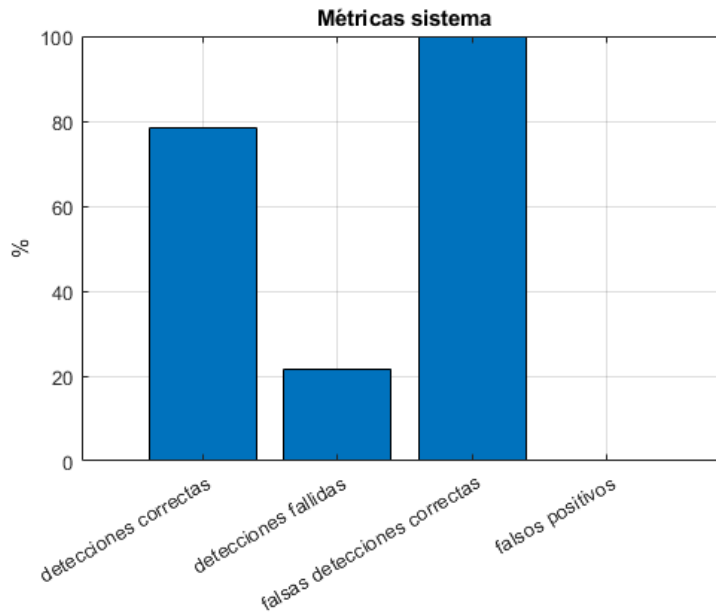
<b>Parámetro</b>	<b>Valor</b>
Número señales dron	1000
Número señales no dron	1185
SNR mínima	0
SNR máxima	90

*Tabla 5 Parámetros simulación falsos positivos*

#### **4.5.1.2 Resultados**

Tras realizar la simulación se ha obtenido la siguiente gráfica de precisión cuando la señal a la entrada es una señal con dron:

Esto indica que siempre que se realiza una detección de dron empleando este protocolo, la estimación del comienzo de la señal es perfecta, independientemente de la relación señal a ruido que se tenga presente.



*Ilustración 29 Ratios de detecciones Ocusync*

Además, en lo referente a los falsos positivos, el algoritmo implementado funciona prácticamente a la perfección, ninguna señal que no es dron es detectada como tal. Esto es gracias a la fuerte autocorrelación que presentan las secuencias de Zadoff Chu entre sí, y la correlación nula que tienen con señales aleatorias.

#### **4.5.2 PRUEBA CORRECCIÓN DESVIACIÓN FRECUENCIA**

Para comprobar el rendimiento del sistema propuesto es capaz de corregir la desviación en frecuencia independientemente de las diferentes condiciones que se pueden dar en el entorno en el que se va a desplegar el sistema, se ha realizado una simulación Monte Carlo en la cual se va a variar la SNR y la propia desviación en frecuencia.

En esta simulación se va a partir de 200 señales generadas sintéticamente, que contengan mensajes de droneID. A estas señales se les va a variar la longitud de forma aleatoria, añadiendo ceros delante y detrás de la trama de Ocusync, así como la SNR y la desviación en frecuencia, de esta forma se va a poder obtener una estimación de cómo se debería de comportar el sistema una vez que se despliegue.

Por cada señal de entrada, se van a realizar 50 desplazamientos en frecuencia y variaciones aleatorias de la SNR, así se consigue evaluar el sistema de una forma más completa.

Se espera que el sistema funcione de forma correcta independientemente de la desviación en frecuencia, pero que a medida que la SNR disminuye se va una decadencia en el rendimiento total de las detecciones.

#### **4.5.2.1 Parámetros**

Para ello los parámetros que se han variado son:

<b>Parámetro</b>	<b>Límite inferior</b>	<b>Límite superior</b>
SNR	-10	30
Desviación en frecuencia	-40 MHz	40 MHz


*Tabla 6 Parámetros simulación corrección desviación frecuencia*

#### **4.5.2.2 Resultados**

Para poder interpretar los resultados se ha elaborado una matriz de resultados, de forma que por cada desplazamiento en frecuencia y por cada SNR, se va a mostrar la precisión de detecciones del sistema.

Cuanto más detecciones se realicen en una SNR y desplazamiento en frecuencia determinados, mayor será el valor de precisión obtenido.






*Ilustración 30 Porcentaje detecciones en función de la SNR*

Como era de esperar, cuanto menor es la SNR de la señal de entrada, menor es la precisión que se obtiene en la detección.

A pesar de esta reducción, el sistema demuestra tener una alta precisión para casos en los que la señal tiene una SNR muy reducida, es por ello por lo que este algoritmo demuestra una gran resiliencia.

Por otro lado, al analizar el error cometido en función del desplazamiento en frecuencia de la señal de entrada, se obtiene la siguiente gráfica:



*Ilustración 31 Error cometido en función de frecuencia*

Por lo tanto, el sistema de corrección del desplazamiento en frecuencia funciona correctamente, y hace que este parámetro no sea determinante a la hora de realizar una detección.

### 4.5.3 CONCLUSIONES

Tras realizar las simulaciones, se concluye que el sistema desarrollado es correcto y funcional, es capaz de realizar detecciones de drones con una precisión y fiabilidad alta.

Como se ha podido observar, casi para cualquier desviación en frecuencia dentro del ancho de banda del receptor, el algoritmo ha sido capaz de realizar detecciones de forma satisfactoria.

La principal desventaja de este sistema es que, en la presencia de una señal de dron simultánea a otra señal, en ocasiones la corrección en frecuencia no es del todo correcta, y puede ocurrir que la estimación deje el espectro de la señal lejos del centro. Esto ha ocurrido en reducidas ocasiones por lo que no ha sido posible documentarlo.

## Capítulo 5. DETECCIÓN DRONES AUTEL

Como se ha explicado al comienzo del trabajo, uno de los objetivos a realizar era la detección de drones de la marca Autel. En su página web, el fabricante indica que existen al menos tres protocolos de comunicación empleados en sus productos

Este trabajo se ha centrado en detectar los drones correspondientes al protocolo puesto que es el que más interés estratégico tiene para defenderse de posibles amenazas.

A diferencia de los drones de la marca DJI no existe información pública sobre los diferentes tipos de mensajes que se envían entre el mando de control y el propio UAV, tampoco existe información sobre el tipo de modulación que se emplea para la comunicación.

Sin embargo, mediante el análisis de numerosas tramas capturadas de la comunicación, se han sacado numerosas conclusiones sobre el tipo de modulación empleada y sobre posibles métodos para realizar la detección del protocolo.

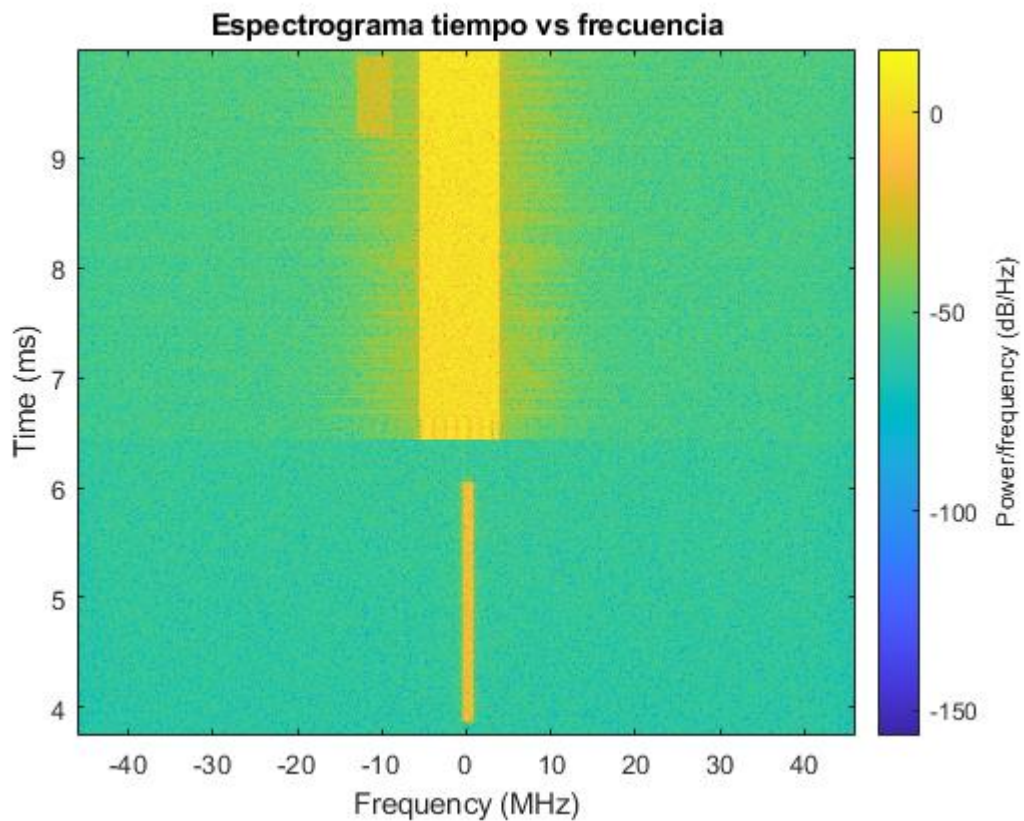
### *5.1 ANÁLISIS PROTOCOLO*

El primer paso realizado para la detección de drones Autel ha sido el análisis exhaustivo de la señal enviada de forma bidireccional entre el mando y el dron. Para ello se han empleado diferentes radios definidas por software para analizar en tiempo real el tipo de comunicación que se está empleando y la secuencia temporal de las comunicaciones.


De este análisis se ha concluido la siguiente información:

- La modulación empleada en la comunicación es OFDM. Como se puede observar en las imágenes de espectrograma y espectro adjuntas, el espectro es prácticamente idéntico al empleado por los drones DJI.

- Únicamente se envía información en una frecuencia. Tras numerosas pruebas en una cámara anecoica, se ha determinado que este protocolo únicamente emplea una banda para realizar la comunicación, en ningún caso se ha apreciado que aparecieran portadoras cercanas a la banda en uso o en otras frecuencias.
- La transmisión de imágenes forma la mayor parte de las comunicaciones. Al encender el mando sin conectar el dispositivo móvil para ver el stream de vídeo enviado por el dron, el ancho de banda de la señal empleada es el mismo, así como la frecuencia empleada, pero la frecuencia con la que envía símbolos OFDM se reduce de forma significativa.
- Antes de cada trama de vídeo se envía un segmento de señal a modo de preámbulo. Se entiende que este segmento es empleado como ecualizador por el receptor para poder decodificar correctamente la información de las portadoras.



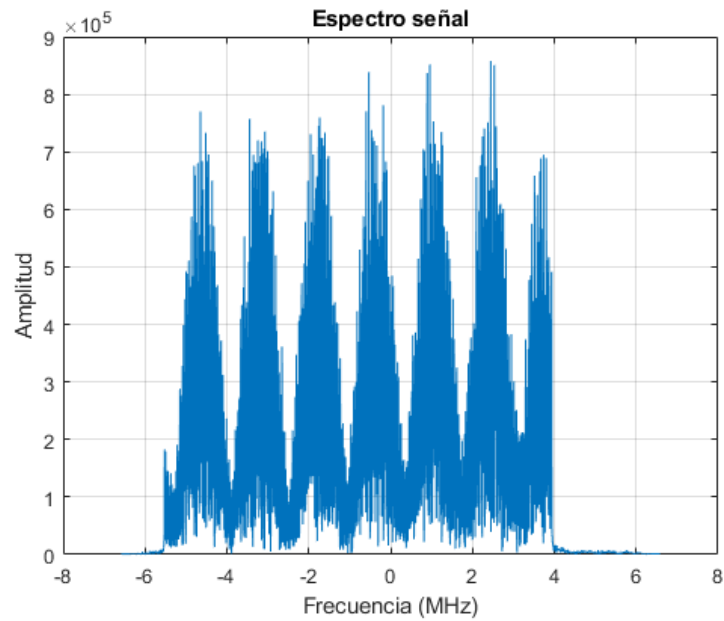
*Ilustración 32 Espectrograma señal Autel con preámbulo*



*Ilustración 33 Ampliación preámbulo*

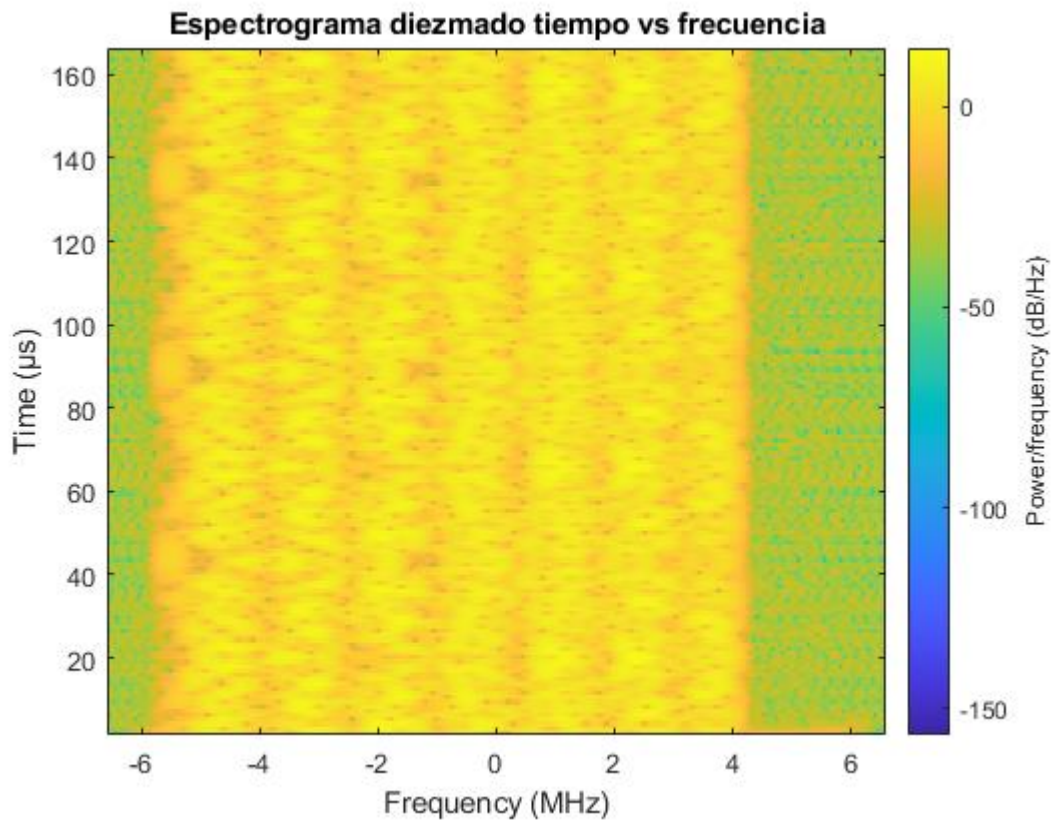
Es por medio de este preámbulo como se va a realizar la detección de este protocolo, ya que no existe otro protocolo de comunicaciones que haga uso de este preámbulo.

En este preámbulo se pueden apreciar 7 tonos diferentes, cada uno de estos tonos tiene un ancho de banda aproximado de 1MHz, por lo tanto, se presupone que cada uno de los tonos tiene que ir modulado con alguna modulación digital o variando la frecuencia a modo de chirp.



*Ilustración 34 Espectro preámbulo*

Si se amplía el espectrograma a únicamente la sección correspondiente al preámbulo se observa como cada uno de los tonos tiene una variación en frecuencia no lineal.



*Ilustración 35 Espectrograma ampliado preámbulo con chirp*

Se ha intentado replicar dicho preámbulo para poder generarlo de manera sintética y no depender de capturas externas susceptibles a error, pero no ha sido posible.

Las propiedades de las señales capturadas son:

<b>Parámetro</b>	<b>Valor</b>
Modulación	OFDM
Duración	10ms
Ancho de banda	9 MHz

*Tabla 7 Parámetros extraídos Autel SkyLink*

## **5.2 DETECCIÓN PROTOCOLO**

Como se ha explicado en el apartado anterior la detección de drones con protocolo “Autel SkyLink” se va a realizar por medio de la búsqueda de una señal conocida, en este caso un preámbulo.

Este método de detección es muy similar al empleado en el caso de los drones DJI ay que se va a seguir aprovechando la propiedad de la correlación entre señales. Sin embargo, a diferencia del caso anterior en el que se realizaba la correlación en el dominio del tiempo siempre, ahora se va a poder realizar la detección tanto en el dominio temporal como en el dominio de la frecuencia.

### **5.2.1 DETECCIÓN EN FRECUENCIA**

Este método de detección se basa en la búsqueda del preámbulo conocido dentro del espectrograma de la señal recibida. Este espectrograma se puede ver como una fotografía dentro de la que se busca un patrón concreto.

En este caso, no se trataría de una imagen, si no que ambas matrices serían la representación en valores complejos del espectrograma de sendas señales.

Una posible forma de encontrar ese patrón puede ser por medio de correlaciones del espectrograma recibido, con el espectrograma de la señal de referencia conocida. Este enfoque es el mismo que el empleado en la detección de Ocusync, simplemente aumentando una dimensión de los datos, antes se trataba únicamente con la dimensión temporal de la señal recibida, y ahora se trabaja con la dimensión temporal junto con la dimensión en frecuencia

Esta correlación en dos dimensiones tiene un coste un coste de computación muy elevado, generalmente, si no se realizan optimizaciones, la complejidad algorítmica de este procesado es de  $O(n^2 * m^2)$ , donde  $n$  y  $m$  son las dimensiones de las imágenes de entrada. En el mejor de los casos, si se realizaran optimizaciones como la de la correlación basada en la transformada de Fourier (Wikipedia, s.f.), la complejidad puede ser de:



$$O(n \cdot m \cdot \log(n) \cdot \log(m))$$

*Ecuación 5 Complejidad algorítmica transformada Fourier*

Para esta detección se han escogido los siguientes parámetros para realizar el espectrograma de las señales:

Parámetro	Valor
Ventana temporal	Haming
Tamaño FFT	2048
Porcentaje overlapping	75%
Tamaño ventana temporal	2048
Frecuencia muestreo	92.16 MHz

*Tabla 8 Parámetros espectrograma detección Autel SkyLink*

De estos parámetros se deriva que el tamaño de la matriz resultantes una vez se ha calculado el espectrograma es de: 2048x1797 (en el caso de la señal sea de 150 ms)


Es este enfoque lo que hace que este método de detección sea muy sencillo, pero es necesario realizar una optimización para poder ejecutarlo en tiempo real.

Este método tiene la ventaja de que, al realizarse un barrido por todo el espectrograma, se puede conocer es desplazamiento en frecuencia que tiene el flujo de datos que está enviando el dron al mando. Por lo tanto, si se deseara, se podría corregir dicha desviación variando la frecuencia central de la SDR receptora.

### **5.2.1.1 Optimización**

Durante muchos años en el sector del procesado de imágenes para aplicaciones de inteligencia artificial se ha discutido como poder encontrar patrones determinados dentro de una imagen. La solución a la que se llegó es realizar convoluciones de esa imagen recibida con filtros generados tras muchas iteraciones con algoritmos de optimización basados en el algoritmo de descenso del gradiente.

Por ello existen multitud de librerías y paquetes con algoritmos optimizados para poder realizar convoluciones de gran tamaño entre la imagen de entrada y un filtro en tiempos muy reducidos.



*Ilustración 36 Convolución imagen con filtro predefinido*

Existe una relación directa entre la convolución y la correlación, la fórmula de la correlación de dos señales discretas es:

$$R_x(m) = \sum_{n=0}^{N-1} x(n) \cdot x^*(n - m)$$

*Ecuación 6 Ecuación correlación discreta*

Mientras que la fórmula de la convolución en el dominio discreto es:

$$x[n] * y[n] = \sum_{k=-\infty}^{+\infty} x[n]y[n - k]$$

Si se realizan los siguientes cambios de variable

$$y(m - n) = x^*(n - m)$$

$$\tau = m - n$$

Entonces

$$y(\tau) = x^*(-\tau)$$

Por lo tanto, ahora la expresión anterior se puede expresar de la siguiente manera

$$R_x(m) = \sum_{n=0}^{N-1} x(n) \cdot y(m-n)$$


*Ecuación 7 Ecuación convolución con cambio de variables*

Es decir, una convolución

$$R_x = x(n) * x^*(n)$$


*Ecuación 8 Convolución final*

Esta relación entre la convolución y la correlación también se mantiene en señales de dos dimensiones, por lo tanto, se va a realizar la correlación del espectrograma de entrada con el espectrograma de la señal de referencia del preámbulo, por medio de una convolución, reduciendo el tiempo de cómputo de forma considerable.



*Ilustración 37 Ejemplo resultado detección en frecuencia Autel SkyLink*

A continuación, se adjunta una comparación del tiempo de correlación medio medido para un tamaño de matriz reducido.



*Ilustración 38 Comparación tiempo correlación vs convolución*


El incremento de rendimiento es notable, por ello en adelante en este proyecto, se va a realizar la operación de convolución para realizar la correlación de una señal

Además, gracias a que la convolución es una operación que se puede paralelizar, en tarjetas gráficas, ayudando a que el tiempo de cálculo de la operación se reduzca aún más. Por otro lado, el hecho de emplear matrices muy grandes en GPU puede hacer que el tiempo se incremente, ya que es necesario realizar una operación de copia de los datos a la memoria de la tarjeta gráfica desde la RAM del ordenador


Para confirmar que el tiempo de ejecución se reduce, se ha realizado una simulación con datos aleatorios de entrada, ejecutando la convolución tanto en CPU como en GPU.

#### **5.2.1.1.1 Prueba GPU vs CPU**

Se ha realizado un barrido de tamaños de matrices de entrada para asegurar que el tamaño con el que se va a trabajar es adecuado y que el tiempo de carga de la señal en GPU es lo suficientemente pequeño para justificar el uso de la tarjeta gráfica.



*Ilustración 39 Tiempo ejecución medio con GPU*



*Ilustración 40 Comparación tiempo ejecución CPU vs GPU*

De las gráficas se deriva que efectivamente, el hecho de emplear una tarjeta gráfica se justifica por el incremento sustancial de rendimiento.

Para el tamaño de matrices que se van a emplear el incremento de rendimiento es de un 40%

### ***5.2.1.2 Discernimiento correlaciones***

Al igual que en el apartado anterior en el que se detectada si un dron empleaba el protocolo Ocusync, se ha tenido que desarrollar e implementar un algoritmo para poder diferenciar las salidas del detector correspondientes a detecciones de drones empleando el protocolo Autel SkyLink.

El método de clasificación es muy similar al desarrollado en el apartado, se va a mirar el valor del pico de correlación con respecto a los valores más cercanos, así como respecto a la media de valores de toda la matriz.

Al realizar la comparación con el valor medio de todo el vector, se pueden eliminar los casos en los que la señal a la entrada sea solo ruido o señales aleatorias con un nivel de potencia reducido.

Como en el caso anterior, al realizar la comparación del pico con respecto a los valores más cercanos, se eliminan las posibles señales de corta duración y potencia elevada que puedan llegar al receptor. En este caso se tratan de las mismas señales FHSS que en el caso de Ocusync.



Los parámetros que se han escogido para este algoritmo son:

<b>Parámetro</b>	<b>Valor</b>
Ratio disparo	5
Valores cercanos analizados	100
Ratio cercanos	1.4
Índices cercanos descartados	10

*Tabla 9 Parámetros detección Autel SkyLink*

La única diferencia de este algoritmo con el de una dimensión, es que cuando se evalúan los valores cercanos, se hacen obteniéndolos en forma de cuadrado, es decir, si se evalúan 100 valores cercanos, esto se hace obteniendo una matriz de 100x100 valores.

Recepción vector correlación





Ilustración 41 Diagrama flujo detección Autel

Como se puede observar en *Ilustración 41 Diagrama flujo detección Autel*, el diagrama de flujo seguido es exactamente igual, salvando la diferencia de las dimensiones de los valores obtenidos y descartados.

### 5.2.1.3 Rendimiento

Para comprobar la resiliencia del sistema desarrollado, se ha realizado una simulación, en la cual se han introducido señales correspondientes a la enviada por drones en la comunicación con el mando, añadiéndolas ruido de fondo hasta valores en los que el ruido añadido superaba de forma sustancial el nivel de la señal, para observar la evolución de la precisión del algoritmo.



*Ilustración 42 Resultados prueba detección en frecuencia SkyLink*


En esta simulación, no se ha realizado desplazamiento en frecuencia de la señal de entrada, puesto que la señal es real, obtenida en un entorno no simulado, esta señal ya tiene implícito un desplazamiento en frecuencia no controlado por el receptor. Por lo tanto, para hacer la prueba lo más realista posible, se ha decidido no añadir más desplazamiento sintético.

Se puede apreciar como a medida que la relación señal a ruido disminuye, la precisión del algoritmo desarrollado se reduce de forma significativa. El hecho que para SNRs mayores que cero, la precisión sea siempre el 100% indica que el algoritmo es muy robusto ante ruido en el entorno, es un buen mecanismo para realizar detecciones.

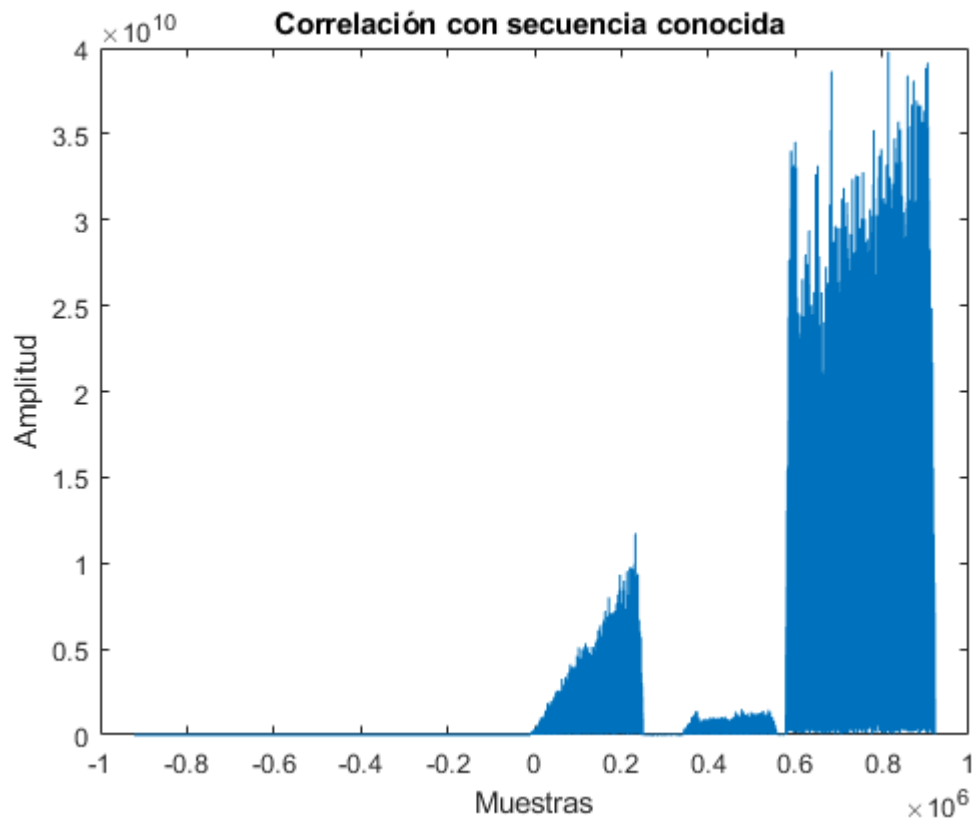
### **5.2.2 DETECCIÓN EN DOMINIO TEMPORAL**

Otra forma de detectar drones es por medio del análisis de la señal reciba en el dominio temporal, esta detección se realiza de forma análoga a la realizada en el apartado de *Detección protocolo Ocusync*. La única diferencia es que en vez de emplear la señal resultado de la secuencia de Zadoff Chu, se utiliza la señal correspondiente al preámbulo, en el dominio del tiempo.

Este algoritmo es muy sensible a la desviación en frecuencia de la señal de entrada, a continuación, se adjunta el resultado de una correlación de una señal centrada en frecuencia, junto con el resultado de la correlación de una señal desplazada 200 KHz.



*Ilustración 43 Correlación temporal Autel SkyLink sin desplazamiento en frecuencia*



*Ilustración 44 Correlación temporal Autel SkyLink con desplazamiento en frecuencia*

Para este algoritmo la corrección de la desviación en frecuencia es crítica, una desviación tan mínima, puede degenerar en una degradación importante del rendimiento de la detección. Tal que la detección del protocolo no se va a producir a pesar de encontrarse dentro de la señal recibida.

### ***5.2.2.1 Corrección desviación en frecuencia***

El mecanismo empleado para la corrección en frecuencia es exactamente igual al empleado en el apartado.

De hecho, el diagrama de flujo del algoritmo propuesto es el mismo, con la obvia de que la corrección en frecuencia se realiza únicamente en un paso, no se cambia la frecuencia de muestreo la señal, por lo tanto, el diagrama de flujo quedaría de la siguiente manera:



*Ilustración 45 Diagrama flujo corrección en frecuencia Autel*

Pero sólo se ejecutaría en una iteración.

#### **5.2.2.2 Discernimiento correlaciones**

En este caso el método para diferenciar si el resultado de la correlación es fruto de la presencia de un dron empleando el protocolo Autel SkyLink o si es fruto de otro tipo de señal, se ha empleado exactamente el mismo algoritmo descrito en *Discernimiento*

*correlaciones*, pero variando los parámetros introducidos al algoritmo para adaptarse a las nuevas condiciones del resultado.

Los parámetros variados son:

<b>Parámetro</b>	<b>Valor</b>
Ratio media	10
Número de cercanos evaluados	550
Número aledaños descartados	10
Ratio cercanos	3

*Tabla 10 Parámetros algoritmo temporal Autel SkyLink*

### **5.2.2.3 Rendimiento**

Como el método de corrección en frecuencia ya ha quedado validado con las simulaciones anteriores, se va a evaluar la capacidad de detección del algoritmo en el dominio temporal por medio del análisis de señales con diferentes desplazamientos en frecuencia.

De esta forma se va a cuantificar la resiliencia que tiene el algoritmo ante desplazamientos en frecuencia no deseados

Se va a partir del mismo conjunto de datos que en la prueba de detección en frecuencia, pero variando de forma aleatoria el desplazamiento en frecuencia de la señal de entrada.

Para mostrar los resultados, se va a realiza una representación de diagrama de caja, que representa los desplazamientos en frecuencia en los que se ha realizado una detección.





*Ilustración 46 Diagrama caja detecciones temporales Autel SkyLink*

Como era de esperar el mayor número de detecciones se produce cuando el desplazamiento es igual a cero. La gráfica está balanceada con respecto a cero, y no existe ningún valor fuera de los percentiles, indicando que el resultado obtenido es fiable.

Para que la señal sea detectada, se tiene que corregir la desviación en frecuencia con al menos un margen de 20KHz, ya que es el primer percentil de desplazamiento en frecuencia detectable.

### 5.2.3 VENTAJAS Y DESVENTAJAS

Como se ha podido ver tanto la detección por medio del análisis de la señal en el dominio del tiempo, como en el dominio de la frecuencia presentan ventajas y desventajas:

Ventajas correlación en frecuencia

- No es necesario realizar corrección frecuencia.
- Es más resiliente al error de captura de la señal de referencia.
- Se puede optimizar con procesamiento en GPU

- Se puede conocer la desviación en frecuencia de la señal enviada por el dron.

Desventajas correlación en frecuencia:

- Existe una gran dependencia de los parámetros de creación del espectrograma para realizar la detección.
- El tiempo de procesado puede llegar a ser mayor si no se optimiza correctamente.
- Necesidad de hardware extra para poder realizar la optimización

Ventajas correlación en tiempo

- No es necesario realizar el cálculo del espectrograma de la señal recibida
- Es método es agnóstico a los parámetros de cálculo de la señal de referencia

Desventajas correlación en tiempo

- Es necesario realizar corrección en frecuencia.
- La detección es muy sensible a desviaciones en frecuencia.

### ***5.3 IMPLEMENTACIÓN***

Para la implementación final en el sistema, se ha escogido la detección por medio del análisis de la señal en el dominio de la frecuencia.

En el hardware final se ha instalado una tarjeta gráfica de alto rendimiento que ha permitido acelerar las detecciones de forma significativa. Al no poderse sintonizar la frecuencia central de la recepción de la SDR, el procesado necesario para realizar la corrección de la desviación en frecuencia aumentaba el tiempo total de la detección, así como la carga de trabajo del ordenador donde se ejecuta todo el sistema.


Esta alta necesidad de recursos no es asumible en un sistema tan completo, en el que se incorporan algoritmos y procesos para otras funcionalidades, este hecho, unido a la alta sensibilidad de la detección en el dominio temporal, y por lo tanto menor resiliencia a la

hora de realizar el discernimiento, ha hecho que se haya optado por el método de análisis en el dominio de la frecuencia.

## Capítulo 6. DETECCIÓN DRONES DEEPLARNING

El "DeepLearning" o aprendizaje profundo (Wikipedia, s.f.) es una rama avanzada del aprendizaje automático que utiliza redes neuronales profundas para modelar y resolver problemas complejos. Estas redes están compuestas por múltiples capas de nodos o "neuronas" que imitan la estructura del cerebro humano. Su capacidad para aprender de grandes cantidades de datos y descubrir patrones intrincados lo hace fundamental en muchas aplicaciones tecnológicas actuales.

En una red neuronal con imágenes como entrada, se pueden identificar dos componentes principales: la extracción de características y la clasificación. La primera parte, la extracción de características, involucra capas de convolución y agrupamiento que procesan los datos de entrada para captar patrones y reducir dimensiones, transformando la información cruda en un conjunto resumido de características significativas. Posteriormente, la sección de clasificación toma estas características y, mediante capas densamente conectadas, las combina para asignarlas a categorías específicas, culminando generalmente en una capa de salida que usa funciones de activación como la softmax para generar probabilidades de clase. Esta estructura permite que la red no solo reconozca elementos importantes de los datos sino también realice predicciones precisas sobre ellos.



*Ilustración 47 Estructura típica red neuronal convolucional (obtenida de (Hugo Andrade Carrera , Soraya Sinche Maita , & Pablo Hidalgo Lascano , 2020))*

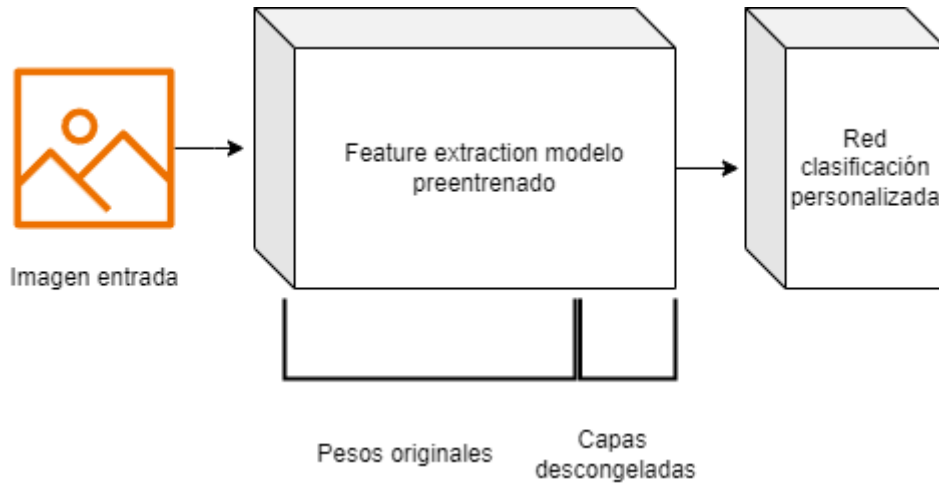
Por ello, en este trabajo, se va a intentar detectar drones en un entorno ruidoso por medio de un modelo de aprendizaje profundo desarrollado sobre un modelo anterior aprovechando el método de entrenamiento denominado “transfer learning” o aprendizaje por transferencia

## ***6.1 TRANSFER LEARNING***

El aprendizaje por transferencia (transfer learning) es una técnica en el campo del aprendizaje automático que consiste en aprovechar el conocimiento obtenido al abordar un problema y aplicarlo a otro problema similar pero distinto. Esencialmente, en lugar de comenzar a aprender desde cero, el modelo se basa en lo que ya ha aprendido de una tarea anterior para mejorar o acelerar el aprendizaje en una nueva tarea.

En el uso de cada modelo, se reemplaza la sección de clasificación con una red neuronal diseñada a medida. Además, en cada modelo pre-entrenado, se procede a activar capas secuencialmente hasta alcanzar la precisión deseada. Este enfoque busca adaptar el modelo base de manera más efectiva al problema específico de clasificación que se desea resolver.

A modo de resumen se adjunta una ilustración en la que se diferencian las partes de los modelos finales que se va a emplear en la predicción:



*Ilustración 48 Descripción transferlearning (elaboración propia)*

## **6.2 MODELOS EMPLEADOS**

Para aplicar el aprendizaje por transferencia se han escogido varios modelos, entre los cuales se va a escoger el que mejores características presente a la hora de discernir si la señal a la entrada se trata de un dron o de una señal aleatoria.

### **6.2.1 RESNET**

ResNet, abreviatura de Redes Residuales, es una arquitectura de red neuronal diseñada para facilitar el entrenamiento de redes considerablemente más profundas mediante conexiones residuales. Estas conexiones permiten que las señales se transmitan saltando capas, lo cual es crucial para mitigar el problema del desvanecimiento de gradientes en redes de gran profundidad.




Ilustración 49 Arquitectura ResNet (obtenida de (Haruna Abdu, 2017))

## 6.2.2 VGG

VGG es un modelo de red neuronal que se destacó como uno de los pioneros en el uso de arquitecturas profundas y uniformes, caracterizadas porque todas las capas ocultas son convolucionales con un campo receptivo constante de 3x3. Este enfoque ha demostrado ser extremadamente eficaz para tareas de visión por computadora, incluida la clasificación de imágenes.





Ilustración 50 Arquitectura VGG (obtenida de (Xianjing Han, 2021))

### 6.2.3 MOBILENET

MobileNet es una arquitectura de red neuronal diseñada específicamente para funcionar eficientemente en dispositivos móviles y en entornos con recursos computacionales limitados. Emplea técnicas como las convoluciones separables en profundidad para disminuir tanto el número de parámetros como el volumen de cálculos requeridos, haciendo que sea adecuada para aplicaciones en tiempo real.




*Ilustración 51 Arquitectura MobileNet (obtenido de (Maad Shatnawi, 2022))*

### 6.3 CONJUNTO DE DATOS

Para realizar la clasificación de las señales se ha partido de un conjunto de datos de señales de dron obtenidas en entornos reales, clasificadas de forma manual en el momento de la captura.

Cada una de estas capturas se ha obtenido de diferentes drones en vuelo, a continuación, se adjunta una breve descripción del dataset en la que se puede ver la distribución de las clases obtenidas en el proceso de captura de señales.





*Ilustración 52 Distribución clases conjunto datos*

Al tratarse de una clasificación binaria, únicamente se tienen dos clases, la “Sí dron” en el caso de que la señal correspondiente a un dron se encuentre presente, y “No dron”, si no es así.

### **6.3.1 PREPROCESADO**

Antes de introducir cada una de las señales en el modelo se ha tenido que llevar a cabo una tarea de preprocesado para que la señal sea adecuada para introducirla en el modelo.

- División de las señales de entrada para poder trabajar con señales de 10ms, longitud con la que se trabaja en el sistema final de detección, y por lo tanto el modelo debe de estar entrenado para tal longitud.
- Cálculo del espectrograma de la señal con los parámetros definidos en *Tabla 11 Parámetros espectrograma Deep Learning*
- Normalización del espectrograma, debido a que la señal de entrada debe de ser en escala de grises por las restricciones que establecen los modelos pre-entrenados escogidos. Se tiene que normalizar el valor de la señal para obtener mejor precisión, ya que de otra forma la señal del dron no resaltaría por encima del ruido de fondo.



*Ilustración 53 Espectrograma dron ejemplo*

<b>Parámetro</b>	<b>Valor</b>
Tamaño FFT	1024
Ratio overlapping	0.5
Tipo de ventana	Hamming
Tamaño ventana	25000

*Tabla 11 Parámetros espectrograma Deep Learning*

## **6.1 ENTRENAMIENTO MODELOS**

Para realizar el entrenamiento de los modelos de redes neuronales, es fundamental una correcta optimización de hiperparámetros, para lo cual se utiliza Optuna, una herramienta

que permite la selección automatizada y eficiente de estos parámetros a través de técnicas como el Tree-structured Parzen Estimator.

Junto a esto, la validación cruzada se implementa para evaluar el rendimiento del modelo propuesto por Optuna. Este método implica dividir el conjunto de datos en múltiples subconjuntos, entrenando el modelo en cada posible combinación de estos y utilizando el restante para pruebas. Este procedimiento no solo maximiza la utilización del conjunto de datos, sino que también previene el sobreajuste, proporcionando una evaluación más robusta y generalizable del desempeño del modelo.

Los parámetros variados del modelo son:

<b>Parámetro variado</b>	<b>Límite inferior</b>	<b>Límite superior</b>
Número capas clasificación	5	50
Número neuronas por capa	1	100
Tasa aprendizaje	1e-5	1e-1
Dropout por capa	0.1	0.5
Capas descongeladas	1	10

*Tabla 12 Espacio búsqueda Optuna*

También se incluye en el espacio de búsqueda el optimizador empleado en el entrenamiento, pudiéndose elegir entre:

- Adam
- RMSprop
- SGD

## **6.1.1 HERRAMIENTAS EMPLEADAS**

Para poder ejecutar el entrenamiento del modelo, y poder encontrar los parámetros óptimos del modelo de clasificación, se han empleado las siguientes herramientas:

### ***6.1.1.1 Optuna***

Optuna es una biblioteca especializada en la optimización de hiperparámetros, que facilita la automatización de su ajuste. Permite establecer un espacio de búsqueda detallado para los hiperparámetros y emplea diversos algoritmos de optimización para identificar la configuración óptima de manera eficiente. Esta herramienta se ha vuelto esencial en el campo del aprendizaje automático para optimizar aspectos como la tasa de aprendizaje, el número de capas en redes neuronales y la cantidad de nodos por capa, mejorando así el desempeño de los modelos.

### ***6.1.1.2 PyTorch***

PyTorch es una plataforma de aprendizaje profundo y computación tensorial que soporta aceleración por GPU. Destaca por su flexibilidad y diseño intuitivo, lo que lo hace ideal tanto para la investigación como para el desarrollo de aplicaciones comerciales. PyTorch ofrece una amplia API para manipulación de tensores y una extensa gama de herramientas y bibliotecas predefinidas para áreas como la visión por computadora y el procesamiento de lenguaje natural. En este proyecto, se utiliza PyTorch para construir y entrenar modelos de redes neuronales.

## **6.2 RESULTADOS**

Para evaluar los resultados de los modelos escogidos, se van a analizar varias métricas. La primera de todas es la diferencia en las pérdidas entre el conjunto de entrenamiento (train) y el conjunto de prueba (test), así como la precisión en ambos conjuntos y la diferencia entre ellos para verificar que no haya overfitting.

El overfitting ocurre cuando un modelo se ajusta demasiado bien a los datos de entrenamiento, capturando incluso el ruido y las peculiaridades específicas de esos datos,

pero falla al generalizarse a datos nuevos y no vistos. En otras palabras, el modelo tiene un rendimiento excelente en el conjunto de entrenamiento, pero pobre en el conjunto de prueba. En este trabajo se quiere evitar a toda costa este comportamiento ya que lo que más se valora en este caso es la capacidad de generalizar del modelo, ya que no se conoce el entorno en el que se va a desplegar el sistema ni las características que puede tener la señal de entrada.

Además, en una situación ideal, el sistema será capaz de detectar drones que empleen señales que nunca se han visto con anterioridad, por ello el overfitting se debe de mitigar lo máximo posible y va a ser un factor determinante a la hora de escoger un modelo frente a los demás

Para detectar y mitigar el overfitting, se evaluarán las siguientes métricas:

- Pérdida en el conjunto de entrenamiento y prueba: Se compararán las pérdidas en ambos conjuntos. Una gran diferencia entre las pérdidas puede indicar overfitting.
- Precisión en el conjunto de entrenamiento y prueba: La diferencia entre la precisión en el conjunto de entrenamiento y el conjunto de prueba es clave. Una alta precisión en el conjunto de entrenamiento, pero una precisión significativamente menor en el conjunto de prueba es indicativo de overfitting.
- Precisión total: Se analizará la precisión total del modelo en el conjunto de prueba para evaluar su rendimiento general y capacidad de generalización.

Estas métricas permitirán determinar la efectividad del modelo y su capacidad para manejar datos nuevos de manera confiable.

## **6.2.1 ENTRENAMIENTO MOBILENET**

### ***6.2.1.1 Parámetros finales***

Tras realizar un entrenamiento exhaustivo con numerosos intentos optimizado por medio de Optuna, se ha llegado a los siguientes parámetros de red neuronal:


Parámetro	Valor
Capas descongeladas	9
Tasa aprendizaje	0.00096
Optimizador	Adam
Número de capas	5
Neuronas capa 1	85
Neuronas capa 2	53
Neuronas capa 3	66
Neuronas capa 4	63
Neuronas capa 5	16
Dropout capa 1	0.36
Dropout capa 2	0.27
Dropout capa 3	0.35
Dropout capa 4	0.32
Dropout capa 5	0.045

*Tabla 13 Parámetros MobileNet*


### 6.2.1.2 Rendimiento

La precisión total del modelo en el conjunto es de validación es de: **97.74%**

Los resultados que se han obtenido con este modelo como base y aplicando un modelo de clasificación por encima son:



*Ilustración 54 Precisión entrenamiento vs validación MobileNet*



*Ilustración 55 Error entrenamiento vs validación MobileNet*

Ambas gráficas sugieren que este modelo tiene una precisión muy alta a la hora de clasificar las señales de entrada, además la diferencia de precisión y de error entre los conjuntos de entrenamiento y validación sugiere que este modelo no presenta sobre aprendizaje, es por ello por lo que este modelo es apropiado para la tarea de detección de drones.

## 6.2.2 ENTRENAMIENTO RESNET

La precisión total del modelo en el conjunto es de validación es de: **93.21%**

### 6.2.2.1 Parámetros finales

Los resultados que se han obtenido con este modelo como base y aplicando un modelo de clasificación por encima son:

Parámetro	Valor
Capas descongeladas	2
Tasa aprendizaje	0.00012
Optimizador	RMSprop
Número de capas	13
Neuronas capa 1	28
Neuronas capa 2	35
Neuronas capa 3	15
Neuronas capa 4	29
Neuronas capa 5	40
Neuronas capa 6	6
Neuronas capa 7	8
Neuronas capa 8	48
Neuronas capa 9	13



---


Neuronas capa 10	35
Neuronas capa 11	46
Neuronas capa 12	31
Neuronas capa 13	17
Dropout capa 1	0.17
Dropout capa 2	0.49
Dropout capa 4	0.158
Dropout capa 5	0.024
Dropout capa 6	0.16
Dropout capa 7	0.33
Dropout capa 8	0.465
Dropout capa 9	0.21
Dropout capa 10	0.065
Dropout capa 11	0.43
Dropout capa 12	0.071
Dropout capa 13	0.23

---

*Tabla 14 Parámetros ResNet*

### **6.2.2.2 Rendimiento**

Las gráficas obtenidas del entrenamiento del modelo son:



*Ilustración 56 Precisión entrenamiento vs validación ResNet*



*Ilustración 57 Error entrenamiento vs validación ResNet*

En este modelo se aprecia un ligero aumento en la diferencia entre el conjunto de entrenamiento y el conjunto de validación. Este modelo presenta un ligero overfitting de los datos de entrenamiento, reducir el número de épocas de entrenamiento no habría ayudado, puesto que se emplea un algoritmo de early stopping en el proceso de entrenamiento, y la diferencia entre ambos conjuntos es notable desde la primera iteración.

### 6.2.3 ENTRENAMIENTO VGG

La precisión total del modelo en el conjunto es de validación es de: **97.2%**

### 6.2.3.1 Parámetros finales


Los resultados que se han obtenido con este modelo como base y aplicando un modelo de clasificación por encima son:

Parámetro	Valor
Capas descongeladas	1
Número capas	5
Optimizador	SGD
Tasa aprendizaje	0.05839
Neuronas capa 1	11
Neuronas capa 2	87
Neuronas capa 3	91
Neuronas capa 4	86
Neuronas capa 5	13
Dropout capa 1	0.21
Dropout capa 2	0.351
Dropout capa 3	0.137
Dropout capa 4	0.4277
Dropout capa 5	0.2405


Tabla 15 Parámetros VGG

### 6.2.3.2 Rendimiento

Las gráficas obtenidas del entrenamiento del modelo son:



*Ilustración 58 Precisión entrenamiento vs validación VGG*



*Ilustración 59 Error entrenamiento vs validación VGG*

Como se puede apreciar, este modelo tiene una reducción clara del error al comienzo del entrenamiento, sin embargo, a medida que avanzan las épocas del entrenamiento, la precisión entre el conjunto de entrenamiento se va separando, indicando que se está

llegando a un punto de sobre entrenamiento, pero que no se ha materializado por el momento.

Este modelo tiene una precisión adecuada y al no presentar sobre aprendizaje en los datos, hace que sea un posible candidato a ser escogido como modelo final.

### ***6.3 MODELO ESCOGIDO***

Para la implementación del proyecto, se ha seleccionado utilizar MobileNet como la base del modelo debido a varias razones fundamentales que lo hacen una elección óptima.

MobileNet ha demostrado una elevada precisión en diversas tareas de clasificación y reconocimiento de imágenes, lo que asegura que el modelo puede identificar características y patrones de manera efectiva. La precisión es crucial, ya que influye directamente en la calidad de los resultados y las decisiones que el sistema tomará. Un modelo preciso permite una mejor interpretación de los datos y, por lo tanto, una mayor efectividad en la tarea específica.

Otro aspecto crítico de MobileNet es su capacidad para evitar el overfitting. Esto significa que el modelo no se ajusta demasiado a los datos de entrenamiento, capturando peculiaridades específicas que no se generalizan bien a nuevos datos. Evitar el overfitting es esencial, ya que el sistema debe ser capaz de adaptarse a diferentes situaciones y condiciones que no necesariamente estaban presentes en los datos de entrenamiento. La robustez de MobileNet en este aspecto asegura que el modelo mantendrá un rendimiento consistente y fiable, independientemente de las variaciones en los datos de entrada.

MobileNet se caracteriza por su arquitectura eficiente y de menor tamaño en comparación con otros modelos de redes neuronales profundas. Esta eficiencia no solo reduce los requisitos computacionales, facilitando su implementación en dispositivos con recursos limitados, sino que también acelera el proceso de entrenamiento y la toma de decisiones en tiempo real. En aplicaciones donde las decisiones rápidas y el tiempo de respuesta son


cruciales, el menor tamaño de MobileNet contribuye significativamente a mejorar el rendimiento del sistema.

Finalmente, MobileNet es uno de los modelos más actuales y avanzados en el campo del aprendizaje automático. Su diseño incorpora las últimas innovaciones y mejoras en arquitectura de redes neuronales, asegurando que se aprovechan las técnicas más efectivas y eficientes disponibles. Al utilizar un modelo moderno como MobileNet, se garantiza estar a la vanguardia de la tecnología, lo que no solo mejora el rendimiento del sistema, sino que también facilita la integración de futuras actualizaciones y avances en el campo.

## Capítulo 7. PRUEBAS REALES

Como broche de oro a este proyecto, se han realizado una serie de pruebas de validación del sistema completo para comprobar la veracidad de los resultados obtenidos en las simulaciones y pruebas.

Las pruebas fueron realizadas en el campo de vuelo del club de aeromodelismo de Seseña en la provincia de Toledo.



*Ilustración 60 Localización prueba reales*

El objetivo de dicha prueba era conseguir detectar drones por medio de los algoritmos y métodos explicados en este trabajo, y validar de esta manera el trabajo realizado.

Para esta prueba se montó todo el sistema completo de detección, que por incluir el trabajo de otras personas implicadas y tener intereses comerciales no se va a explicar en profundidad.

En esta prueba se volaron drones de la marca Autel empleando el protocolo SkyLink, siendo la detección más lejana a una distancia final de 900 metros

Además, se volaron drones de la marca DJI a una distancia final de 1000 metros, cumpliendo de forma satisfactoria con los mínimos establecidos en los requisitos del proyecto

En ambos casos los drones fueron detectados de manera satisfactoria, independientemente de la frecuencia de uso de las comunicaciones.

Por otro lado, en el caso de la detección por DeepLearning, se consiguieron realizar detecciones de forma satisfactoria, pero a medida que la distancia del dron aumentaba, estas detecciones se iban haciendo menos consistentes. Las señales producidas por el propio lugar de trabajo y los puntos de acceso inalámbricos conectados enmascaraban la señal verdadera del dron, haciendo que el modelo no fuera capaz de generalizar todo lo bien que se esperaba.

Estas pruebas han servido para validar el funcionamiento final del enfoque propuesto en este trabajo y para confirmar que un sistema de detección de drones en zonas delimitadas de bajo coste es viable a nivel técnico y práctico.



## Capítulo 8. CONCLUSIONES Y TRABAJOS FUTUROS

Como conclusión, se puede derivar que el desarrollo de un sistema de detección anti-drones ha demostrado ser una tarea desafiante pero alcanzable. A lo largo de este proyecto, se han abordado múltiples aspectos críticos, desde la identificación de las características técnicas de los drones hasta la implementación y validación de técnicas avanzadas de detección.

El sistema desarrollado ha logrado detectar drones de manera satisfactoria, cumpliendo con los objetivos planteados al inicio del proyecto. Se ha demostrado que el sistema es capaz de identificar la presencia de drones en diversas condiciones ambientales y operativas, lo que valida su utilidad en escenarios reales. La integración de tecnologías como el uso de radares, cámaras ópticas e infrarrojas, y técnicas de procesamiento de señales ha sido crucial para el éxito del sistema, permitiendo una detección precisa y oportuna, aumentando la fiabilidad de este.

Los algoritmos de procesamiento de imágenes y señales, incluyendo técnicas de aprendizaje automático e inteligencia artificial, han demostrado ser efectivos en la clasificación y diferenciación de drones frente a otros objetos en el entorno. La implementación de estos algoritmos ha sido fundamental para reducir los falsos positivos y aumentar la precisión del sistema. Además, uno de los retos más significativos fue garantizar que el sistema operara en tiempo real. A través de optimizaciones en el software y el hardware, se ha conseguido un rendimiento adecuado que permite la detección y respuesta rápida ante la presencia de drones.

El sistema ha sido diseñado con un enfoque modular, lo que facilita su escalabilidad y adaptación a diferentes entornos y necesidades. Esta flexibilidad es esencial para su implementación en diversas aplicaciones, desde la seguridad en aeropuertos hasta la protección de infraestructuras críticas. Las pruebas realizadas en diferentes escenarios han

demostrado la robustez del sistema, evaluando su desempeño en condiciones adversas, incluyendo interferencias y obstáculos, confirmando su capacidad para mantener un alto nivel de detección.

A pesar del éxito alcanzado, se han identificado áreas de mejora. Entre ellas, la necesidad de aumentar la autonomía del sistema y mejorar su capacidad para operar en entornos altamente congestionados. Además, se sugiere explorar nuevas tecnologías emergentes que puedan complementar y mejorar las capacidades actuales del sistema.

En resumen, el sistema de detección anti-drones desarrollado en este trabajo fin de máster ha cumplido con los objetivos propuestos, demostrando ser una solución eficaz y viable para la detección de drones. Los resultados obtenidos no solo validan el enfoque y las tecnologías utilizadas, sino que también abren la puerta a futuras investigaciones y desarrollos en este campo tan dinámico y relevante.

Entre las mejoras posibles a corto plazo se encuentran:

- Desarrollar inteligencia artificial multi clase, que sea capaz de clasificar no solo si existe un dron en el área o no, si no que sea capaz de derivar la marca y tipo de dron.
- Buscar mejores modelos de transferlearning que sean capaces de generalizar aún más y tener un tiempo de inferencia aún menor a los que se han visto hasta ahora.
- Generar el preámbulo de los drones Autel empleando el protocolo SkyLink de manera sintética. De esta forma se podrá afinar la detección aún más de lo que se ha hecho.
- Ampliar el número de protocolos detectados.

## Capítulo 9. BIBLIOGRAFÍA

Autel. (s.f.). *Autel-Home*. Obtenido de <https://www.autel.com/es/>

Bender, C. (2022). *DJI drone IDs are not encrypted*. The University of Tulsa.

DJI. (s.f.). *DJI-Aeroscope*. (DJI) Obtenido de <https://www.dji.com/es/aeroscope>

DJI. (s.f.). *DJI-Official Website*. Obtenido de <https://www.dji.com/es>

Enaire. (2024). *Enaire*. Obtenido de <https://www.enaire.es/home>

Enebral, A. R. (5 de Octubre de 2023). *elconfidencialdigital.com*. Obtenido de <https://www.elconfidencialdigital.com/articulo/defensa/ejercito-aire-incorpora-sistema-que-captura-drones-derribarlos/20231004171006646942.html>

FAA. (2020). *Standard Specification for Remote ID and Tracking*. ASTM.

Haruna Abdu, M. H. (2017). A Survey on Waste Detection and Classification using Deep Learning. *ResearchGate*.

Hugo Andrade Carrera , Soraya Sinche Maita , & Pablo Hidalgo Lascano . (12 de Noviembre de 2020). RITI Journal, Vol. 9, 17 (Especial 2021) e-ISSN: 2387-0893 © RITI. CC BY-NC Taller Andino de Comunicaciones Inalámbricas y sus Aplicaciones 111 Modelo para detectar el uso correcto de mascarillas en tiempo real utilizando redes neuronales con.

Indra. (s.f.). Obtenido de <https://www.indracompany.com/es/anti-drone-system>

Maad Shatnawi, N. A. (2022). Deep Learning Approach for Masked Face Identification. *International Journal of Advanced Computer Science and Applications*.

Mohammad F. Al-Sa'd, Abdulla Al-Ali, Tamer Khattab, & Aiman Erbad. (2019). RF-based drone detection and identification using deep learning approaches: An initiative towards a large open source drone database. *sciencedirect*.

proto17. (2022). *dji\_droneid*. Obtenido de [https://github.com/proto17/dji\\_droneid](https://github.com/proto17/dji_droneid)

RUB-SysSec. (2023). *DroneSecurity*. Obtenido de <https://github.com/RUB-SysSec/DroneSecurity>

Target Tecnologia. (s.f.). *Target Tecnologia*. Obtenido de [https://www.target-tecnologia.es/categoria\\_producto/sistemas-anti-dron/](https://www.target-tecnologia.es/categoria_producto/sistemas-anti-dron/)

Wikipedia. (27 de Septiembre de 2023). *Multiplexación por división de frecuencias ortogonales*. Obtenido de [https://es.wikipedia.org/wiki/Multiplexaci%C3%B3n\\_por\\_divisi%C3%B3n\\_de\\_frecuencias\\_ortogonales#:~:text=OFDM%20es%20un%20esquema%20de,y%20patentado%20cuatro%20a%C3%B1os%20despu%C3%A9s](https://es.wikipedia.org/wiki/Multiplexaci%C3%B3n_por_divisi%C3%B3n_de_frecuencias_ortogonales#:~:text=OFDM%20es%20un%20esquema%20de,y%20patentado%20cuatro%20a%C3%B1os%20despu%C3%A9s).

Wikipedia. (11 de Septiembre de 2023). *Zadoff-Chu sequence*. Obtenido de [https://en.wikipedia.org/wiki/Zadoff%E2%80%93Chu\\_sequence](https://en.wikipedia.org/wiki/Zadoff%E2%80%93Chu_sequence)

Wikipedia. (s.f.). *Aprendizaje profundo*. Obtenido de [https://es.wikipedia.org/wiki/Aprendizaje\\_profundo](https://es.wikipedia.org/wiki/Aprendizaje_profundo)

Wikipedia. (s.f.). *Espectro ensanchado por salto de frecuencia*. Obtenido de [https://es.wikipedia.org/wiki/Espectro\\_ensanchado\\_por\\_salto\\_de\\_frecuencia](https://es.wikipedia.org/wiki/Espectro_ensanchado_por_salto_de_frecuencia)

Wikipedia. (s.f.). *Software defined radio*. Obtenido de [https://en.wikipedia.org/wiki/Software-defined\\_radio](https://en.wikipedia.org/wiki/Software-defined_radio)

Wikipedia. (s.f.). *Transformada rápida de Fourier*. Obtenido de [https://es.wikipedia.org/wiki/Transformada\\_r%C3%A1pida\\_de\\_Fourier#Algoritmos](https://es.wikipedia.org/wiki/Transformada_r%C3%A1pida_de_Fourier#Algoritmos)

s

Xianjing Han, G. L. (2021). Echocardiographic Features of Patients with Coronary Heart Disease and Angina Pectoris under Deep Learning Algorithms. *ResearchGate*, pág. 8.

# ANEXO A

## ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA

### I.C.A.I.

#### PROYECTOS FIN DE MÁSTER

CURSO: 2º

## Ficha de proyecto fin de máster

Titulación y optatividad: 2º Máster Universitario en Ingeniería de Telecomunicación

Alumno 1º Apellido: González

2º Apellido: Gómez

Nombre: Raúl

Teléfono de contacto: 646219829

e-mail: 201801914@alu.comillas.edu

Título del Proyecto Fin de Máster: Detección de Protocolos de Comunicación en Drones Comerciales

Director (nombre y dos apellidos): Javier Matanza Domingo

Teléfono de contacto: 606580747

e-mail: jmatanza@comillas.edu

Breve descripción del proyecto (5 o 6 líneas)

El presente trabajo de máster se enfoca en el análisis y detección de protocolos de comunicación empleados en drones comerciales, con especial atención en Wifi, Ocusync y Frequency-Hopping Spread Spectrum (FHSS). Los drones comerciales han experimentado un crecimiento significativo en su adopción y uso en diversos sectores, desde la fotografía y la cinematografía hasta la vigilancia y la entrega de paquetes. Estos dispositivos dependen de protocolos de comunicación eficientes y seguros para establecer conexiones confiables entre el dron y el controlador. El objetivo principal de este trabajo es investigar, diseñar y desarrollar métodos para la identificación y análisis de los protocolos mencionados, lo que contribuirá a mejorar la comprensión de la tecnología subyacente y permitirá abordar cuestiones relacionadas con la seguridad y la interoperabilidad.

El documento final del proyecto será subido al Repositorio Institucional de Comillas con acceso público. El alumno podrá solicitar un nivel restringido de acceso (incluido el “cerrado” o “confidencial”) que podrá concederse, excepcionalmente, si está plenamente justificado.

The final report of the Project will be uploaded to the Comillas Institutional Repository with public access. The student will be able to ask for a restricted access (even “closed” or “confidential”) which will be exceptionally accepted if it is fully justified.

Aceptación del director (firma y fecha)

## DATOS RELATIVOS AL PROYECTO FIN DE GRADO

Título del Proyecto Fin de Grado: Desarrollo software radar pasivo

Director/es del Proyecto Fin de Grado: Javier Matanza Domingo, Carlos García de la Cueva

Curso Académico en el que se realizó: 4º

Universidad (indicarla si no es Comillas):

En el caso de realización en Comillas, indicar especialidad en el Grado:

GITT (Grado en Ingeniería en Tecnologías de Telecomunicación)



## ANEXO B

### ALINEACIÓN DEL PROYECTO CON LOS ODS

Los objetivos de desarrollo sostenible son ideas que abordan las problemáticas de desarrollo sustentable, es decir, que tienen como objetivo la prosperidad económica, la integridad del medio ambiente y la equidad social. Son objetivos marcados por la Organización de Naciones Unidas, y defendidos por la inmensa mayoría de países.



## OBJETIVOS DE DESARROLLO SOSTENIBLE



- Fin de la pobreza
- Hambre cero
- Salud y bienestar
- Educación de calidad
- Igualdad de género

- Agua limpia y saneamiento
- Energía asequible y no contaminante
- Trabajo decente y crecimiento económico
- Industria, innovación infraestructura
- Reducción de desigualdades
- Ciudades y comunidades sostenibles
- Producción y consumo responsables
- Acción por el clima
- Vida submarina
- Vida de ecosistemas terrestres
- Paz, justicia e Instituciones sólidas
- Alianzas para lograr los objetivos

Específicamente, este trabajo se alinea con dos ODS que destacan por su importancia en la promoción de la paz, la justicia y la innovación tecnológica.

#### *ODS 16: Paz, Justicia e Instituciones Sólidas*

El ODS 16 busca promover sociedades pacíficas e inclusivas, proporcionar acceso a la justicia para todos y construir instituciones eficaces, responsables e inclusivas. La detección de protocolos de drones para uso militar juega un papel crucial en la seguridad nacional, permitiendo a las fuerzas armadas y a las agencias de seguridad identificar y neutralizar posibles amenazas en tiempo real. Esta capacidad es esencial para la prevención de conflictos y el combate al terrorismo, contribuyendo así a la estabilidad y la paz en las sociedades. Además, al fortalecer las capacidades de defensa, se mejora la confianza en las

instituciones encargadas de mantener la seguridad y el orden, lo que es un pilar fundamental para el desarrollo sostenible.

*ODS 9: Industria, Innovación e Infraestructura*

El ODS 9 se centra en construir infraestructuras resilientes, promover la industrialización inclusiva y sostenible, y fomentar la innovación. La investigación y desarrollo en la detección de protocolos de drones representa un avance significativo en el campo de la tecnología de la defensa. Este tipo de innovación no solo mejora las capacidades militares, sino que también puede tener aplicaciones civiles, como en la vigilancia de infraestructuras críticas y la gestión de emergencias. La tecnología desarrollada puede impulsar la industria de defensa y seguridad, creando nuevas oportunidades económicas y mejorando las infraestructuras tecnológicas necesarias para la protección y el desarrollo sostenible de la sociedad.