



# Centro Universitario de la Defensa en la Escuela Naval Militar

## TRABAJO FIN DE GRADO

*Identificación de emisiones radar mediante  
técnicas de inteligencia artificial*

**Grado en Ingeniería Mecánica**

**ALUMNO:** Fernando González de Canales Martínez

**DIRECTORES:** José María Núñez Ortuño

**CURSO ACADÉMICO:** 2021-2022

Universida<sub>de</sub>Vigo





# Centro Universitario de la Defensa en la Escuela Naval Militar

**TRABAJO FIN DE GRADO**

*Identificación de emisiones radar mediante  
técnicas de inteligencia artificial*

**Grado en Ingeniería Mecánica**  
Intensificación en Tecnología Naval  
Cuerpo General

Universida<sub>de</sub>Vigo



# RESUMEN

En este trabajo se estudia la viabilidad de identificar y clasificar emisiones electromagnéticas en el espectro radar mediante técnicas de Inteligencia Artificial para su posterior correlación con posibles plataformas emisoras.

En el trabajo se implementa un sistema de recepción de señal para radares marinos en banda X y unos algoritmos para la obtención de la paramétrica de las emisiones. La adquisición de señal se ha realizado para los radares de diferentes buques como las Lanchas de Instrucción de la Escuela Naval Militar (ENM), Patrulleras de la Guardia Civil y Aduanas, A-41 *Intermares*, BS-14 *María Pita* y otras embarcaciones en diversos modos de transmisión recopilando sus características en una base de datos.

Tras haber analizado y comprobado los valores obtenidos, se ha entrenado una red neuronal con los parámetros almacenados, obteniéndose conclusiones sobre la capacidad de identificación y clasificación de las señales radar de las distintas embarcaciones.

## PALABRAS CLAVE

Guerra Electrónica, Inteligencia Artificial, Radar, Emisión, Red neuronal



# AGRADECIMIENTOS

Al profesor José María Núñez Ortuño por su gran apoyo y ayuda en este Trabajo de Fin de Grado sin los cuales no se hubieran conseguido los objetivos propuestos. En particular, por su afán y motivación en líneas de investigación relacionadas con la Armada y la mejora de sus sistemas contribuyendo a la modernización de los equipos de las unidades de la Flota.

Al Núcleo de Lanchas de la Escuela Naval Militar por su aportación y ayuda en la recepción de señales de las Lanchas de Instrucción.

Al Servicio Marítimo de la Guardia Civil basado en la Escuela Naval Militar, a la dotación de la Patrullera de Aduanas *Águila I* y a la dotación del Buque de Salvamento Marítimo *María Pita* por su colaboración y total disponibilidad en la fase de recopilación de emisiones.

A mi familia por ser un apoyo constante desde que ingresé en la Escuela Naval Militar siendo un pilar fundamental en los peores momentos de estos cinco años de formación.

A la Promoción 422-152 por ser mi segunda familia y por la unión y compañerismo que nos caracteriza.







## CONTENIDO

Contenido .....	1
Índice de Figuras .....	4
Índice de Tablas.....	7
1 Introducción y objetivos .....	8
1.1 Contextualización.....	8
1.2 Motivación .....	9
1.3 Objeto del trabajo .....	9
1.4 Estructura del trabajo .....	10
2 Estado del arte .....	11
2.1 Inteligencia Artificial .....	11
2.1.1 Definición .....	11
2.1.2 Origen de la Inteligencia Artificial .....	12
2.1.3 Machine Learning .....	13
2.1.4 Redes Neuronales Artificiales .....	15
2.2 La Guerra Electrónica .....	21
2.2.1 Origen de la GE .....	21
2.2.2 Historia de la GE en la Armada .....	21
2.2.3 Tipos de GE .....	24
2.2.4 La GE y la Inteligencia Artificial .....	27
2.3 Proceso de clasificación de emisiones .....	27
2.3.1 Exploración.....	28
2.3.2 Interceptación .....	29
2.3.3 Identificación .....	30
2.3.4 Localización.....	33
2.3.5 Inteligencia de señales .....	34
3 Desarrollo del TFG.....	35
3.1 Investigación y propuestas .....	35
3.1.1 Descripción del problema .....	35
3.1.2 Propuesta inicial.....	36
3.1.3 Solución alternativa .....	40
3.2 Hardware .....	40
3.2.1 Radar Furuno 1944C.....	41

3.2.2 Antena.....	43
3.2.3 SDR HackRF .....	43
3.2.4 Down-Converter .....	44
3.2.5 Alimentación.....	45
3.2.6 FieldFox Microwave Analyzer N9917A .....	46
3.3 Software .....	46
3.4 Recepción de señales reales .....	47
3.4.1 Espectro señal LLII.....	48
3.4.2 Sistema de recepción .....	49
3.4.3 Recepción de señal con LLII en tierra.....	52
3.4.4 Recepción de señal con LLII en la mar .....	53
3.4.5 Recepción de señales de otros buques .....	58
3.5 Elaboración de la base de datos .....	64
3.5.1 Evaluación de la calidad de los valores obtenidos.....	65
3.6 Desarrollo del modelo de AI.....	66
4 Resultados / Validación / Prueba.....	66
4.1 Configuraciones posibles .....	70
4.1.1 Parámetros .....	70
4.1.2 Clases de radares.....	71
4.1.3 Número de “epochs” .....	71
4.1.4 Volumen de los sets de entrenamiento y validación.....	72
4.2 Evaluación de las predicciones .....	72
4.2.1 Funcionamiento con LLII .....	72
4.2.2 Funcionamiento con diversos buques .....	74
4.2.3 Funcionamiento con LLII y otros buques simultáneamente.....	76
5 Conclusiones y líneas futuras .....	78
5.1 Problemas encontrados .....	78
5.1.1 Emisiones reales .....	78
5.1.2 Etiquetado de valores.....	78
5.1.3 Base de datos .....	78
5.1.4 Inteligencia necesaria.....	79
5.2 Valoración de los resultados .....	79
5.3 Conclusión personal.....	80
5.4 Líneas futuras .....	80
5.4.1 Recopilación de otros parámetros.....	80
5.4.2 Combinación de emisiones reales y artificiales.....	81

5.4.3 Uso de espectogramas.....	81
6 Bibliografía.....	82
Anexo I.....	85
Anexo II.....	86
Anexo III .....	88
Anexo IV .....	89
Anexo V .....	90
Anexo VI.....	91
Anexo VII.....	92
Anexo VIII .....	95
Anexo IX .....	96
Anexo X .....	98
Anexo XI.....	99
Anexo XII.....	100
Anexo XIII .....	101
Anexo XIV .....	105

## ÍNDICE DE FIGURAS

Figura 2-1 Test de Turing.....	12
Figura 2-2 Proceso genérico de un modelo Machine Learning.....	13
Figura 2-3 Ejemplo de overfitting. [43] .....	14
Figura 2-4 Esquema resumen del modo de trabajo de una red neuronal. [13].....	17
Figura 2-5 Ejemplo de red neuronal. [12] .....	17
Figura 2-6 Neurona (Ni) con dos entradas y una salida .....	18
Figura 2-7 Ejemplo de Pooling (filtro 2x2). [14] .....	20
Figura 2-8 Pooling con 3 mapas de características. [14].....	20
Figura 2-9 Fragata F-74 Asturias (clase "Balears"). [17] .....	22
Figura 2-10 Mástil con el receptor ESM en el tope y las dos antenas emisoras del P-78 Cazadora (clase "Descubierta"). [16].....	23
Figura 2-11 Antenas ESM/ECM en el mástil del sistema Aldebarán de la F-102 A. Juan de Borbón. [17].....	24
Figura 2-12 Tipos de operaciones EW. [19] .....	24
Figura 2-13 Establecimiento del umbral de detección. [24] .....	28
Figura 2-14 <i>Deinterleaving</i> de una emisión utilizado por un procesador de señal de un sistema de EW. [28].....	31
Figura 2-15 Pulse Description Word (PDW). .....	32
Figura 2-16 Buque auxiliar A-111 Alerta. [17].....	34
Figura 2-17 Proceso de flujo de la información .....	34
Figura 2-18 Proceso de asignación SPOT number .....	34
Figura 3-1 Generación de valores para el set de entrenamiento mediante normal truncada. ....	37
Figura 3-2 Elección de número de emisiones diferentes de cada radar. ....	37
Figura 3-3 Curva de aprendizaje de la fase de entrenamiento y de la validación (20 emisiones)...	38
Figura 3-4 Matriz de confusión (20 emisiones). ....	38
Figura 3-5 Curva de aprendizaje de la fase de entrenamiento y de la validación (200 emisiones)..	39
Figura 3-6 Matriz de confusión (200 emisiones). ....	39
Figura 3-7 Lanchas de Instrucción navegando con radar alto en transmisión. [17].....	41
Figura 3-8 (Radares 1944C FURUNO) alto y bajo de la Lancha de Instrucción A-124 ( <i>GM. Salas</i> ). .....	42
Figura 3-9 Microstrip SO4100-8N. ....	43
Figura 3-10 SDR HackRF. ....	44
Figura 3-11 <i>Down-Converter</i> .....	44
Figura 3-12 Oscilador local alimentado con 6V. ....	45
Figura 3-13 Mezclador. ....	45
Figura 3-14 Fuente de alimentación 6V. ....	46

Figura 3-15 FieldFox Microwave Analyzer N9917A. ....	46
Figura 3-16 Esquema resumen recopilación señales LLII. ....	48
Figura 3-17 Figura 3 18 Detalle de frecuencia de operación del radar FURUNO de las LLII obtenido del analizador de espectros. ....	49
Figura 3-18 Pulso del radar alto modo LONG de la A-121 GM. Barrutia.....	51
Figura 3-19 Marcas del umbral para el cálculo del ancho de haz en una señal recibida de las LLII. ....	52
Figura 3-20 Montaje para recepción de señales en tierra. ....	52
Figura 3-21 Detalle de los pulsos del radar bajo en modo SHORT de la A-121 GM. Barrutia en puerto. ....	53
Figura 3-22 Diagrama de radiación del radar bajo en modo SHORT de la A-123 GM. Rull en puerto. ....	53
Figura 3-23 Montaje recepción señal LLII con Lancha de Instrucción A-124 GM Salas de fondo. ....	54
Figura 3-24 Posición punto Z0 respecto al Laboratorio de Investigación (OpenCPN). ....	55
Figura 3-25 Barrido del radar bajo modo SHORT de la A-121 GM Barrutia desde la mar (0,6 MN). ....	56
Figura 3-26 Gráfico de radiación A-121 GM. Barrutia en la mar (0,6 MN).....	56
Figura 3-27 Barridos de la A-121 GM. Barrutia a 1,014 MN de distancia. ....	57
Figura 3-28 Posición puntos Z1 y Z2 respecto al Laboratorio de Investigación (OpenCPN). ....	57
Figura 3-29 Barridos de la Lancha de Instrucción A-121 GM. Barrutia junto con interferencia de origen desconocido. ....	58
Figura 3-30 Puente de la patrullera de Aduanas <i>Águila I</i> con radar FURUNO FAR-2827. ....	59
Figura 3-31 Buque de Salvamento Marítimo BS-14 <i>María Pita</i> atracado en el muelle de Torpedos con radar bajo (banda S) y alto (banda X). ....	60
Figura 3-32 Vista desde la consola radar situada en el puente del BS-14 <i>María Pita</i> con el Laboratorio de Investigación al fondo. ....	60
Figura 3-33 Ruta realizada por BS-14 <i>María Pita</i> saliendo de la dársena de la Escuela Naval Militar (VesselFinder). ....	61
Figura 3-34 Diagrama polar de la Patrullera Guardia Civil GCM-31 <i>Corvo Mariño</i> navegando en la Ría de Pontevedra. ....	62
Figura 3-35 Recepción de barridos de una Lancha de Instrucción y de la Patrullera GCM-31 Corvo Mariño simultáneamente.....	62
Figura 3-36 A-07 <i>Río Guadalupe</i> atracado en la dársena de la Escuela Naval Militar. ....	63
Figura 3-37 BECP <i>Intermares</i> (A-41) en el muelle de Torpedos transmitiendo con el radar en banda X.....	64
Figura 3-38 Histograma de los valores obtenidos de los anchos de pulsos de la GM. Chereguini trasmitiendo con el radar bajo en modo SHORT. ....	66

Figura 3-39 Histograma de los valores de PRF obtenidos de la *GM. Chereguini* transmitiendo con el radar bajo en modo SHORT.....66

Figura 3-40 Carga de datos de la *GM. Chereguini* en el modelo de AI.....67

Figura 3-41 Selección de los parámetros y las clases de radares para entrenar al modelo de AI. ...67

Figura 3-42 Etiquetas de los buques.....68

Figura 3-43 Volumen de datos seleccionados en función del -score utilizado. ....68

Figura 4-1 Curva de aprendizaje estancándose a partir de las 150 iteraciones. ....72

Figura 4-2 Curva de aprendizaje de la red introduciendo las cuatro Lanchas de Instrucción (200 “epochs”).....73

Figura 4-3 Curva de aprendizaje de la red introduciendo las cuatro Lanchas de Instrucción (500 “epochs”).....73

Figura 4-4 Curva de aprendizaje introduciendo buques con diferentes modelos de radares (200 “epochs”).....74

Figura 4-5 Curva de aprendizaje introduciendo buques con diferentes modelos de radares (200 “epochs”).....75

Figura 4-6 Curva de aprendizaje introduciendo buques con diferentes modelos de radares (500 “epochs”).....75

Figura 4-7 Curva de aprendizaje introduciendo buques con diferentes modelos de radares (1000 “epochs”).....76

Figura 4-8 Curva de aprendizaje introduciendo valores de las LLII y de otros buques (200 “epochs”). .....76

Figura 4-9 Curva de aprendizaje introduciendo valores de las LLII y de otros buques (500 “epochs”). .....77

## ÍNDICE DE TABLAS

Tabla 2-1 Comparativa de receptores ( [26] [24]).....	30
Tabla 3-1 Valores utilizados para el set de entrenamiento de la red neuronal. ....	36
Tabla 3-2 Valores teóricos de PW, PRF y ancho de banda en función de la escala .....	42
Tabla 3-3 Relación distancia-amplitud del BS-14 <i>María Pita</i> . ....	61
Tabla 3-4 Resumen de los modelos de radar FURUNO de cada buque. ....	65

# 1 INTRODUCCIÓN Y OBJETIVOS

## 1.1 Contextualización

Los avances más visibles del siglo pasado en la guerra naval han sido la aparición del submarino, el misil y la aeronave embarcada. Sin embargo, también se produjo la irrupción de la EW (*Electronic Warfare*) la cual se ve a menudo obviada debido a su alta complejidad y secretismo, pero es una parte fundamental de la guerra naval moderna. Esta guerra es un elemento imprescindible en los enfrentamientos navales de los actuales escenarios de conflictos. Es por ello que no se concibe una operación militar moderna sin el uso de esta parte de la guerra.

*Se puede definir la GE (Guerra Electrónica) como el conjunto de acciones militares que comprenden el empleo eficaz del espectro electromagnético, así como prevenir o reducir su uso por parte del enemigo, y protegerse de las posibles acciones del enemigo. [1]*

La gran diferencia que supone esta guerra respecto al resto es que tiene lugar en un único espectro electromagnético. Podemos pensar por ejemplo en el gran cambio que supuso el desarrollo de la artillería naval, pero todas las fuerzas navales que dotasen de los sistemas necesario podían hacer uso de esta. Algo similar sucedió con la aviación o con el submarino. Sin embargo, solo existe un único campo de batalla electrónico, y por ello las fuerzas navales querrán hacer uso de él y negárselo al enemigo. [2]

Una de las tres principales áreas que se distinguen en la EW, atendiendo a sus acciones y objetivos, son las Medidas de Apoyo Electrónico o ESM (*Electronic Support Measures*) que son el conjunto de acciones estratégicas llevadas a cabo como preparación para conflictos futuros. Su objetivo primordial está orientado a la recopilación y almacenamiento de información del enemigo. En particular, en la recogida de datos de emisiones electromagnéticas de sus unidades.

En definitiva, las ESM se basan en la captura y posterior análisis y evaluación de las emisiones electromagnéticas. Dentro de las ESM, se encuentra la ELINT (*Electronic Intelligence*) que se centra en actividades que se dedican específicamente a las señales de radar, guiado y navegación.

El control del espectro electromagnético es posible si se tiene la capacidad para detectar y analizar las emisiones de manera que se pueda caracterizar e identificar las emisiones con plataformas o unidades del entorno marítimo. De este modo, la ventaja es la superioridad en información respecto al enemigo lo que garantizará una mayor probabilidad de éxito en la misión. Por tanto, resulta de vital importancia las actividades de ELINT para la obtención de información sobre el enemigo en una base de datos con la finalidad de poder posteriormente clasificar e identificar sus emisiones.

En el entorno electromagnético actual en el que los parámetros de la señal emitida cambian a menudo, es necesaria la aplicación de métodos innovadores de identificación y clasificación capaces de aprender y adaptarse al entorno de forma que evolucionen en función del mismo. En otras palabras, estamos definiendo la implementación de la Inteligencia Artificial en los sistemas de Guerra Electrónica de los buques. Las redes neuronales tienen una óptima cabida en este ámbito debido a que podrían facilitar la clasificación de las señales adquiridas y permitirían obtener mejores prestaciones que los equipos actuales. Es conveniente que la Armada Española dé el salto hacia este nuevo mundo de la Inteligencia Artificial con el objetivo de no quedarse atrás respecto al resto de Marinas punteras del mundo. Existen numerosos trabajos, investigaciones y pruebas en el ámbito militar que demuestran que los algoritmos basados en técnicas de Inteligencia Artificial mejoran los resultados obtenidos por los sistemas tradicionales.

## 1.2 Motivación

*Debemos seguir explorando para mantener la superioridad tecnológica frente a nuestros potenciales adversarios, y apostar por la investigación, desarrollo y la innovación. [3]*

Almirante Jefe de Estado Mayor de la Armada, *LLGGA 2022*

La razón principal de este trabajo es la búsqueda de la mejora continua y la investigación con el objetivo de implementar los avances tecnológicos de la actualidad en los sistemas tradicionales de Guerra Electrónica de los buques.

Es labor de cada uno de los integrantes de la Armada no limitarse a hacer simplemente su trabajo o cometidos en su puesto, sino que es de vital importancia que el personal explore y proponga nuevos métodos de trabajo para la introducción de sistemas modernos en las unidades de la Flota que mejoren las prestaciones de los equipos tradicionales o procedimientos arcaicos presentes en los buques actualmente. Es únicamente de este modo con el que la Armada podrá subirse al mismo tren que el resto de Marinas potentes de la actualidad.

En particular, la Guerra Electrónica debe ser el arma que proporcione a las unidades de la Flota una ventaja estratégica y táctica respecto al adversario. Para ello, nuestros buques deberán estar dotados de los mejores y más modernos sistemas y equipos de forma que la dotación de las unidades tenga a su disposición las más potentes herramientas para llevar a cabo su misión.

Ante los avances tecnológicos y el escenario cambiante en el que nos encontramos surge la necesidad de desarrollar nuevos métodos de clasificación e identificación de emisiones con el objetivo de que las acciones ESM no se queden estancadas y evolucionen en paralelo con el entorno tan demandante al que estamos expuestos.

En definitiva, el rumbo a seguir es la investigación continua en el ámbito de tratamiento de información electrónica para poder seguir haciendo uso de la inteligencia en los escenarios marítimos actuales de operaciones y conflictos.

## 1.3 Objeto del trabajo

El objetivo principal de este trabajo es estudiar la viabilidad desde el punto de vista conceptual y técnico de la aplicación de algoritmos de AI (*Artificial Intelligence*) y aprendizaje automático (*Machine Learning*) para la identificación de emisiones radar y su posterior correlación con las posibles plataformas emisoras. Podemos dividir la realización del trabajo en diferentes fases o metas para la consecución del objetivo final:

1. Análisis del modo de trabajo actual y tratamiento de datos ELINT en la Armada. Además, revisar el procedimiento y funcionamiento de los distintos sistemas de identificación y clasificación de señales radar empleado en las unidades de la Flota.
2. Recepción y procesamiento de señales radar marítimas reales en banda X. Para ello se debe montar un sistema receptor para obtener emisiones de diferentes buques y a partir de una serie de algoritmos y rutinas calcular la paramétrica de la señal.
3. Elaboración de una base de datos a partir de los parámetros obtenidos de las emisiones recibidas que pueda alimentar a la red neuronal.
4. Pruebas en una red neuronal que permitan clasificar emisiones e identificarlas con el buque o plataforma en cuestión. Para ello se debe entrenar la red neuronal con la librería de señales radar previamente recopiladas.

## **1.4 Estructura del trabajo**

En primer lugar, se contextualiza el trabajo definiendo la Inteligencia Artificial (Apartado 2.1) describiendo su origen, el concepto de “Machine Learning” y el funcionamiento y tipos de redes neuronales. Posteriormente, se trata la Guerra Electrónica (Apartado 2.2) explicando su origen, historia en la Armada, tipos y un breve análisis de la combinación de la Guerra Electrónica y la Inteligencia Artificial (Apartado 2.2.4). Después, el trabajo se centra en el proceso de clasificación de emisiones en los buques de la Armada (Apartado 2.3) para luego analizar en detalle la inteligencia de señales en la Armada y la forma de trabajo en las unidades (Apartado 2.3.5).

En segundo lugar, tiene lugar el desarrollo del trabajo, partiendo de la descripción del problema para posteriormente tratar la propuesta inicial (Apartado 3.1.2) y la solución alternativa (Apartado 3.1.3). A continuación, se describen el hardware (Apartado 3.2) y el software empleado (Apartado 3.3). Tras la descripción de los equipos y programas utilizados se trata detalladamente la fase de recepción de señales de los diferentes buques (Apartado 3.4) con su posterior elaboración de la base de datos (Apartado 3.5) y descripción detallada del modelo de Inteligencia Artificial desarrollado.

En tercer lugar, se procede a analizar el funcionamiento de la red neuronal con las diferentes configuraciones posibles (Apartado 4.1) y se evalúa las predicciones del modelo (Apartado 4.2).

Para terminar, se resumen los diversos problemas encontrados durante el desarrollo del trabajo (Apartado 5.1), se realiza una valoración de los resultados obtenidos (Apartado 5.2) y sus pertinentes conclusiones (Apartado 5.3). Además, se redactan unas posibles líneas futuras (Apartado 5.4).

## 2 ESTADO DEL ARTE

### 2.1 Inteligencia Artificial

La Inteligencia Artificial es uno de los campos más recientes de la ciencia y la ingeniería. Se considera una de las revoluciones más importante de la tecnología desde la invención de la informática. Últimamente se habla mucho de ella y de sus múltiples aplicaciones en infinitos ámbitos.

La AI abarca actualmente una enorme variedad de subcampos y aplicaciones. Desde lo general (aprendizaje y percepción) hasta lo específico, como una partida de ajedrez, demostrar teoremas matemáticos, escribir poesía, conducir un coche en una calle con tráfico o diagnosticar enfermedades. En definitiva, la AI tiene cabida para cualquier tarea intelectual pues es un campo verdaderamente universal. [4]

#### 2.1.1 Definición

La AI se puede definir como la actividad dedicada a hacer que las máquinas sean inteligentes. Se entiende por “inteligencia” como la cualidad que permite a una entidad funcionar correctamente y de forma que prevea el futuro de su entorno. En base a esta definición muchas cosas serían inteligentes (humanos, animales, máquinas...). Sin embargo, existen diferentes tipos y grados de inteligencia. De hecho, las capacidades de las máquinas y animales difieren bastante de las humanas. El ser humano tiene la capacidad de razonar, alcanzar metas, comprender y generar lenguaje, percibir y responder a estímulos sensoriales, sintetizar, resumir... [5]

Otra definición válida define la AI como la ciencia de construir máquinas inteligentes como programas de ordenador con la capacidad de hacer cosas inteligentes. Entendiendo en este caso “inteligencia” como la parte computacional de la habilidad de conseguir objetivos. [6]

Se puede decir entonces que la AI es la capacidad de las máquinas de aprender como lo hace un ser humano desde su nacimiento hasta su muerte. La AI aprende de los datos que se le introducen o recibe del entorno usando algoritmos para tener la capacidad de toma de decisiones. Esta capacidad es algo muy importante que está creciendo exponencialmente en los últimos años y que está permitiendo a los sistemas de AI realizar tareas que anteriormente estaban limitadas a humanos. [7]

Tras haber definido el concepto de AI y siendo conscientes de los avances de esta, podríamos poner en entredicho nuestras habilidades en comparación con las máquinas basadas en AI. De hecho, se prevé

que la AI supere a la inteligencia humana en la mayoría de los ámbitos. ¿Qué cosas hará un humano de manera más efectiva que un sistema basado en AI...? [8]

### 2.1.2 Origen de la Inteligencia Artificial

El nacimiento de la AI no tiene una fecha exacta. De hecho, existen numerosos expertos en la materia que difieren en la fecha del origen. Una gran mayoría sitúa el origen en 1943 con la definición del primer modelo de neurona de la mano de W. McCulloch y W. Pitts. Años más tarde se construye la primera máquina de redes neuronales y en 1950 A. Turing enuncia el llamado test de Turing.



Figura 2-1 Test de Turing

Esta prueba examinaba la capacidad de una máquina para demostrar que podía tener un comportamiento inteligente similar al humano. Como se muestra en la Figura 2-1, en el test se utilizaban una persona, una máquina y un evaluador/interrogador. Este último se encontraba en un habitáculo separado de la persona y la máquina. Además, el evaluador conoce a la persona y la máquina como “X” e “Y” respectivamente. Al principio del juego no sabe cuál es cada una, pero tras formular cuestiones tanto a la máquina como a la persona el evaluador llega a una conclusión. El objetivo de la máquina es intentar que el interrogador llegue a la decisión errónea confundiéndola con la persona. [9]

Ya en 1956 se consolida la AI en la Conferencia de Dartmouth definiendo los objetivos de la AI siendo estos la duplicación y desarrollo de las siguientes facultades humanas: creatividad, superación y uso del lenguaje. En esta década de los 50 se llevan a cabo varios programas para alcanzar las metas propuestas. Se instaura por tanto una actitud optimista y muy positiva con los resultados obtenidos. Sin embargo, el funcionamiento era satisfactorio para problemas particulares, mientras que para cosas reales de mayor complejidad que los humanos resolvemos cotidianamente surgían dificultades.

El primer tipo de dificultad surge porque la mayoría de los primeros programas no sabían nada del tema o materia en la que trabajaban. De hecho, se intentó crear un sistema de traducción automática financiado por el Consejo Nacional de Investigación de EEUU de documentos científicos rusos del Sputnik en 1957. El resultado no fue el deseado debido a que para realizar la traducción el programa requería un gran volumen de conocimientos y datos previos para resolver el contenido de la frase. [4]

*There has been no machine translation of general scientific text, and none is in immediate prospect.* (Informe de un Comité Consultivo, 1966).

En consecuencia, la financiación del gobierno estadounidense para proyectos de traducción académica fue cancelada. Este es el denominado invierno de la AI. Ante la carencia de resultados tanto en este caso como en otros muchos el desarrollo de la AI entró en declive.

En los años 80, se produjo la aplicación de la AI en la industria comenzada por los EEUU, Japón y Gran Bretaña. En paralelo se desarrolla el diseño de chips y la investigación de la interfaz humana. Poco a poco los recortes en financiación destinada a AI se van restableciendo. Sin embargo, los proyectos nunca alcanzaron la totalidad de sus ambiciosos objetivos. A mediados de esta década aparecen los modelos conexionistas (redes neuronales).

Ya en el siglo XXI, un ordenador de IBM superó un duelo contra la mente humana imponiéndose a los dos mejores concursantes de la historia del programa *Jeopardy*. Algo similar sucedió con el ordenador de Google desarrollado por *Google DeepMind*.

### 2.1.3 Machine Learning

El aprendizaje automático (en inglés, *Machine Learning*) es una rama evolutiva de los algoritmos computacionales que están diseñados para imitar la inteligencia humana aprendiendo de datos del entorno. Las técnicas basadas en el aprendizaje automático se llevan aplicando con éxito desde hace años en diversos campos como reconocimiento de patrones, ingeniería espacial, finanzas o aplicaciones médicas. Además de su aplicación en estos ámbitos mencionados, es importante destacar su reciente uso en el mundo militar. [10]

El principal objetivo del aprendizaje automático es estudiar, diseñar y mejorar modelos matemáticos que puedan ser entrenados con datos relacionados con el contexto. De esta forma, el modelo es capaz de tomar decisiones sin conocimiento completo de todos los elementos que influyen (factores externos). En otras palabras, el proceso (Figura 2-2) sigue los siguientes pasos: El software recibe una información del entorno, elige la mejor opción para conseguir su objetivo y aprende con los resultados de la misma. Adopta en cierto modo un enfoque de aprendizaje estadístico en el que, a mayor cantidad de datos y mayor entrenamiento, mayor probabilidad de éxito. [11]

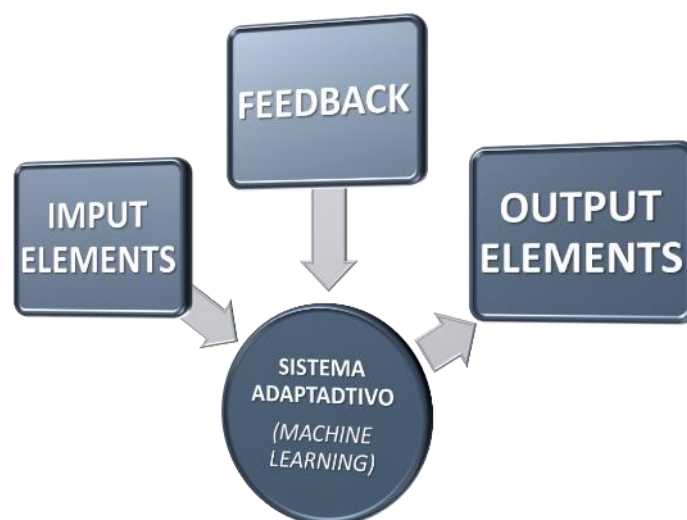


Figura 2-2 Proceso genérico de un modelo Machine Learning.

Incluso en los escenarios más complejos, como la clasificación de imágenes con redes neuronales convolucionales cada pieza de información (geometría, color, características peculiares, contraste...) ya está presente en los datos y el modelo tiene que ser lo suficientemente flexible como para extraer la información y aprenderla permanentemente.

Existen tres tipos de aprendizaje automático que se explicarán a continuación: Aprendizaje supervisado, no supervisado y de refuerzo.

### 2.1.3.1 Aprendizaje supervisado

Un escenario supervisado se caracteriza por el uso de algoritmos que aprenden iterativamente. Se denomina también como el concepto de maestro o supervisor. La tarea principal es proporcionar a la máquina medidas precisas de sus errores. Los algoritmos usan datos ya etiquetados u organizados previamente para indicarle a la máquina como tiene que ser categorizada la nueva información que le llegue. Se utiliza un conjunto de entrenamiento formado por parejas (entrada y salida esperada). A partir de esta información, la máquina puede corregir sus parámetros para mejorar sus resultados. Mediante un algoritmo lo suficientemente flexible y con datos coherentes la precisión de la máquina aumenta y la diferencia entre el valor previsto y el esperado se acerca a cero. También es conveniente que el sistema trabaje con muestras nunca vistas. De esta manera el modelo desarrolla una capacidad de generalización y evita un problema llamado *overfitting* (sobreaprendizaje).

El principal efecto que tiene este problema es que el sistema adquiere la capacidad de predecir correctamente solo las muestras utilizadas en la fase de entrenamiento. De este modo, los resultados con muestras no entrenadas previamente tienen un error muy elevado. [11]

Este fenómeno se produce cuando existe un número reducido de muestras para entrenamiento que provoca que el modelo a veces interprete detalles no deseados del set de entrenamiento. La máquina aprende a resolver únicamente casos particulares que le han sido introducidos y es incapaz de reconocer nuevos datos de entrada. Se puede distinguir en una diferencia clara entre las curvas de aprendizaje y en un estancamiento temprano del entrenamiento (Figura 2-3).




Figura 2-3 Ejemplo de overfitting. [43]

Como se puede ver en la Figura 2-3, las curvas de aprendizaje se representan en función del número de iteraciones de los datos con la red y del “accuracy”. Este último mide el porcentaje de casos que el modelo de AI ha acertado. La representación más habitual para mostrar la evolución del aprendizaje de la red es la mostrada en la figura anterior con las curvas del set de entrenamiento y validación.

Existen dos tipos de aprendizaje supervisado: Clasificación y regresión. En el primer tipo se entrena a un algoritmo para clasificar los elementos de entrada. Sin embargo, la regresión es un método en el que se entrena a un algoritmo para predecir una salida partiendo de un rango continuo de valores posibles. En la regresión, el algoritmo identifica una relación entre los valores de entrada y salida. La salida no es una variable discreta como en la clasificación, sino que es una función de los elementos de entrada.

Las aplicaciones más comunes del aprendizaje supervisado son: detección de spam, detección de patrones, clasificación automática de imágenes o procesamiento del lenguaje natural.

### *2.1.3.2 Aprendizaje no supervisado*

Este tipo se basa en la ausencia de supervisor y se utiliza cuando es necesario aprender cómo se agrupan un conjunto de datos según su similitud. Los algoritmos usados en este método no utilizan ningún dato etiquetado para indicar cómo tendrían que ser categorizadas las nuevas entradas. En este caso no hay intervención humana para proporcionar retroalimentación a la máquina. Es decir, no se necesita que se le diga cuál es la respuesta correcta. [7]

La propia red debe encontrar las características, regularidades o correlaciones que se puedan establecer entre los datos de entrada. En función de los algoritmos de este modo de aprendizaje se suelen dividir en dos tipos: Aprendizaje hebbiano y aprendizaje competitivo y comparativo. [12]

El aprendizaje hebbiano pretende extraer características de los datos de entrada basándose en la neurona biológica clásica la cual puede tener únicamente dos estados (activa o inactiva). Sin embargo, el aprendizaje competitivo y comparativo se basa en la clasificación (*cluster*) de los datos de entrada.

Algunos ejemplos de uso del aprendizaje no supervisado son: Sistemas de recomendación como los utilizados por Netflix o Amazon, detección de patrones de fraude en telecomunicaciones, compresión de imágenes...

### *2.1.3.3 Aprendizaje de refuerzo*

En este método los algoritmos aprenden de la experiencia de manera que se le tiene que dar a la máquina un refuerzo positivo cuando acierta. Se basa en la idea de no disponer de una muestra como ejemplo correcto del resultado que se desea obtener. Es decir, durante el entrenamiento no se indica la salida que se desea obtener ante una entrada en particular. [12]

En el aprendizaje por refuerzo se le tiene que indicar a la máquina mediante una señal si la salida obtenida se ajusta con la requerida (éxito = +1; fracaso = -1) y en función de ello la máquina saca sus conclusiones, ajusta las probabilidades y aprende.

### *2.1.4 Redes Neuronales Artificiales*

Las redes neuronales son otra forma de emular acciones propias de los seres humanos como son la capacidad de memorizar y de asociar hechos. Examinando los problemas que no pueden realizarse mediante algoritmos, se observa que la experiencia es la principal diferencia con el humano. El hombre tiene la capacidad de resolver ciertos problemas acudiendo a la experiencia acumulada. Por lo tanto, de ahí la necesidad de la construcción de un sistema que reproduzca esta capacidad humana.

En definitiva, una red neuronal es un modelo simplificado y artificial del cerebro humano cuya unidad básica de procesamiento está inspirada en la neurona. Por lo tanto, podemos decir que una red

neuronal consiste en una unidad de procesamiento que tiene capacidad de aprender y mejorar con el tiempo.

Las redes neuronales artificiales presentan características similares a las del cerebro como la capacidad de aprender de la experiencia, generalización de casos pasados a nuevos o abstraer características de entradas que representan información irrelevante. A continuación, se tratan las principales características: [12]

- **Aprendizaje adaptativo.** Las redes neuronales tienen la capacidad de aprender a resolver tareas en base a un funcionamiento previo. Es decir, a partir del entrenamiento la red aprende hasta el punto de que cuando se encuentre una tarea para la cual no ha sido entrenada, sepa resolverla por similitud con las tareas para las que ha sido entrenada. De hecho, se suele decir que las redes neuronales son adaptables y dinámicas ya que tienen la capacidad de adaptarse al entorno y cambiar en función de las variaciones que se producen en él.
- **Autoorganización.** Tienen la capacidad de distribuir y organizar la información que almacena durante el proceso de entrenamiento. Esto es lo que permite a la red generalizar y saber afrontar tareas diferentes a la que ha sido entrenada.
- **Tolerancia a fallos.** Existen multitud de sistemas informáticos en los que, si falla un elemento, este deja de funcionar. Sin embargo, con las redes neuronales no sucede así. Si se produce un fallo de memoria en la red, este únicamente afectará a un número determinado de neuronas, pero el sistema podrá continuar realizando su función, aunque se haya destruido parte de la red.
- **Operación en tiempo real.** La capacidad para realizar las tareas en el menor tiempo posible es una de las mayores ventajas del uso de las redes neuronales. Esto es posible debido a la cantidad de neuronas que poseen y a la división del trabajo en cada una de ellas.
- **Aplicación sencilla en la tecnología actual.** Una red puede ser entrenada y desarrollada para realizar una labor definida para su implementación en numerosos tipos de sistemas. Además, se tiene la opción de verificar y evaluar su empleo en un caso en concreto previamente a desarrollarse de forma más extensa.

Existen diferentes tipos de redes neuronales como las monocapa, multicapa, convolucionales (CNN), recurrentes (RNN) de retroalimentación utilizada para análisis de textos, subtulado, control de robots y modelado del lenguaje o redes de base radial (RBF). En el Apartado 2.1.4.2 se tratará con detalle las características de las redes convolucionales pues es el tipo de red que se va a utilizar para el desarrollo del trabajo.

#### *2.1.4.1 Funcionamiento de las redes neuronales*

En primer lugar, es conveniente tener en mente cuál es el modo de trabajo de una red neuronal. El desarrollo de la red está basado en un set de entrenamiento y un set de validación. Es necesario entrenar y validar el modelo de forma que se puedan obtener buenas predicciones con datos desconocidos para la red. En la Figura 2-4 se puede ver un resumen visual del proceso.

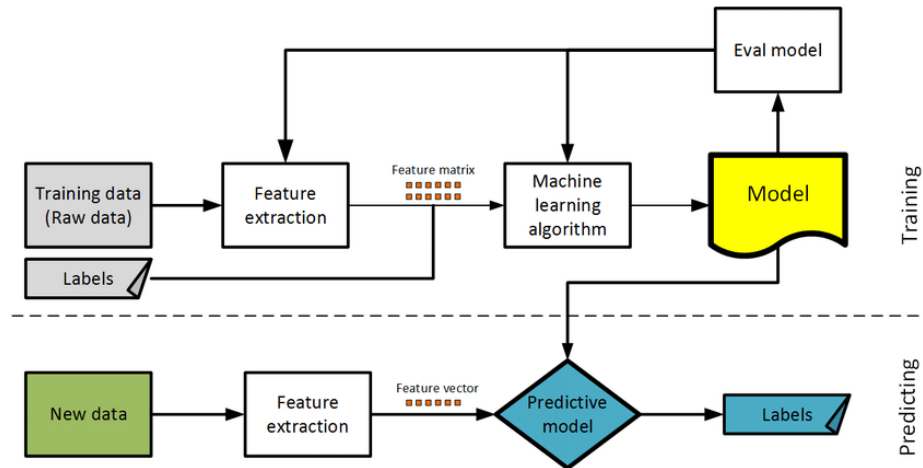


Figura 2-4 Esquema resumen del modo de trabajo de una red neuronal. [13]

Las redes neuronales están constituidas por unidades de procesamiento formadas por neuronas interconectadas y formadas por las tres capas mostradas en la Figura 2-5. Los datos se introducen en la red por medio de la “capa de entrada” pasan por las “capas ocultas” y finalmente salen por la “capa de salida”.




Figura 2-5 Ejemplo de red neuronal. [12]

La red aprende generando una predicción para cada dato que se le introduce y realizando ajustes en las ponderaciones cuando proporciona una predicción errónea. Los datos de entrada se presentan en la primera capa y la información se traspasa de neurona en neurona hasta llegar a la capa de salida donde se obtiene el resultado. La red aprende mediante el entrenamiento y ajusta las ponderaciones en función de los resultados obtenidos. A medida que el entrenamiento progresa, la red se va haciendo más precisa con datos previamente conocidos. Una vez se supera este proceso y la red está entrenada, se aplica a casos de los que se desconoce el resultado. A continuación, se tratan las distintas funciones del proceso de funcionamiento de una neurona mostrado en la Figura 2-6: [12]

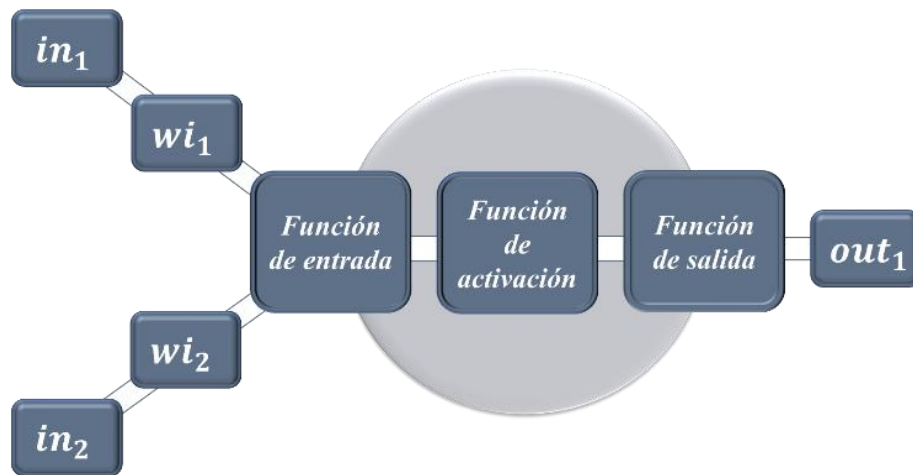


Figura 2-6 Neurona ( $N_i$ ) con dos entradas y una salida

- **Función de entrada (*input function*).** La neurona trata a los valores de entrada como si fuesen un único valor. A este valor se le llama *entrada global* y se obtiene mediante la *función de entrada*:

$$input_i = (in_1 \cdot wi_1) * (in_2 \cdot wi_2) * \dots (in_n \cdot wn)$$

Ecuación 2-1 Función de entrada.

En esta se muestra la relación entre las diferentes entradas ( $in_n$ ) con sus respectivas ponderaciones o pesos ( $w_n$ ). Los valores de entrada se multiplican por diferentes pesos de forma que varían la influencia de cada uno de los valores de entrada.

- **Función de activación (*activation function*).** Las neuronas artificiales a diferencia de las biológicas pueden estar activas, inactivas o tomar cualquier valor dentro de un rango determinado si se trata de algún tipo en concreto de neurona. La función de activación calcula el estado de activación neuronal transformando el valor de la *entrada global* en un valor que define el estado de cada neurona. En particular, la *función de activación* es función de la *entrada global* menos un umbral establecido. Existen diferentes tipos de funciones de activación como las funciones lineal, sigmoidea, tangente hiperbólica, etc. Entre ellas conviene mencionar las funciones de activación SOFTMAX y RELU. La función SOFTMAX se utiliza para filtrar un conjunto de valores que se encuentren por debajo de un valor máximo previamente establecido. Puede emplearse también para convertir valores en probabilidades. Por su parte, la función RELU activa la neurona únicamente cuando la entrada (*input*) está por encima de cero. En el caso de que el valor de entrada sea menor que cero, el valor de salida es cero. Por el contrario, si es mayor que cero, el valor de salida aumenta de forma lineal con el de entrada.
- **Función de salida (*output function*).** Finalmente, el proceso termina con la *función de salida* de forma que se obtiene el resultado a la salida de la neurona ( $out_i$ ) y su valor se transfiere a las neuronas adyacentes conectadas. En el caso de que la *función de activación* tenga un valor por debajo de un umbral determinado, no se traspasa la salida a la siguiente neurona.

### 2.1.4.2 Redes Convolucionales (CNN)

A continuación, se describe brevemente las características básicas y funcionamiento de las Redes Convolucionales pues este tipo es el elegido para utilizar en el desarrollo del trabajo. Las CNN fueron específicamente creadas para el reconocimiento de imágenes. Además de esta aplicación las CNN se utilizan en los campos de procesamiento natural del lenguaje y aprendizaje reforzado. De hecho, este tipo de red es una de las más utilizadas de entre todos los tipos de redes neuronales existentes. A pesar de que no se van a utilizar imágenes sino más bien parámetros que definen o caracterizan las emisiones radar, se ha optado por este tipo de red dado que, como se propondrá en las líneas futuras de este trabajo, una posible evolución de éste es el empleo de espectrogramas o imágenes del espectro de las señales recibidas para realizar la clasificación/identificación, por lo que sería bueno emplear un tipo de red similar para poder comparar ambos casos. Además, la CNN es hoy en día una red muy común y su funcionamiento ha sido probado en múltiples estudios e investigaciones

Las redes neuronales convolucionales están formadas por múltiples capas hasta llegar a la salida. El modelo de una CNN está formado por las capas anteriormente mencionadas (capas de entrada, capas ocultas -convolucional, agrupación y capas de abandono- y las capas de salida). Tras haber pasado la información por todas las capas, tiene lugar la clasificación. A continuación, se analizan los componentes (capas) que existen en la arquitectura de una CNN: [14]

- **Capa convolucional (*Convolutional layer*)**. Es la capa principal de este tipo de redes y es indispensable el uso de una o más capas de este tipo. Esta capa básicamente se basa en un conjunto de filtros entrenable. La red tendrá como objetivo el aprendizaje de estos filtros que se activarán en función de la entrada. De hecho, cuando se introduce una imagen en la capa convolucional, el modelo extrae las características principales de esta (filtrado de la imagen). De esta forma se va creando el llamado mapa de características el cual será el resultado de la capa de convolución y es lo que se utilizará en las capas siguientes. De forma similar sucede cuando se le introducen una serie de parámetros o valores numéricos. En definitiva, la capa de convolución es un conjunto de mapas de características que se han obtenido y que se traspasan a la capa de agrupación.
- **Capa de agrupación (*Pooling layer*)**. Se suele colocar en el medio de las capas convolucionales. Su función es tomar los mapas de características que provienen de la capa de convolución y agruparlos en una imagen. En definitiva, el objetivo de esta capa es simplificar la información de la salida de la anterior capa. La operación de agrupación de todos los parámetros de la red se denomina *pooling*. Se utiliza una serie de filtros para aplicar con objeto de reducir el número de parámetros. Estos se aplican a cada valor del volumen de entrada obteniendo como resultado lo mostrado en la Figura 2-7.




Figura 2-7 Ejemplo de Pooling (filtro 2x2). [14]

Esto permite reducir el volumen de entrada en un 75% por lo que los parámetros se reducen notablemente y se continúa entrenando las siguientes capas con muchos menos valores de forma que el aprendizaje se realiza con mayor facilidad. La capa de convolución da lugar a más de un mapa de características. En consecuencia, se aplica *pooling* a cada uno de estos mapas por separado. Por ejemplo, si estuviésemos ante el volumen de entrada mostrado en la Figura 2-8 y se obtuviesen tres mapas de características, entonces el resultado del *pooling* se vería de la siguiente forma.




Figura 2-8 Pooling con 3 mapas de características. [14]

- **Capa de unidades lineales rectificadas (*Rectified Linear Units Layer*).** Este tipo de capa es muy común en las CNN y se puede utilizar varias veces en la misma red tras la cada capa convolucional. Su función no consiste en establecer ningún parámetro ni entrenarlo, sino que se utiliza una función fijada para realizar una propagación hacia atrás. De hecho, se propagan hacia capas anteriores los errores calculados hasta el momento.
- **Capa completamente conectada (*Full connected layer*).** Esta capa se caracteriza porque todas sus neuronas se encuentran conectadas a todas las neuronas pertenecientes a la capa anterior. A diferencia de las capas tratadas anteriormente, esta capa no se basa en una conectividad local, sino que se encuentra conectada a todo el volumen de entrada y sus neuronas no comparten parámetros. El objetivo principal de este tipo de capa es realizar una agrupación de la información que se ha obtenido hasta el momento. Esta agrupación servirá para obtener la clasificación final por medio de unos cálculos previos.
- **Capa de pérdida (*Loss layer*).** En esta capa se comparan los valores reales de las imágenes con las predicciones. Cuando se requiere clasificar y elegir entre diferentes opciones, se usa un clasificador de pérdidas al que se denomina como *softmax*.

## 2.2 La Guerra Electrónica

La Guerra Electrónica, como hemos definido anteriormente es el conjunto de acciones militares que se basan en el empleo de la energía electromagnética para negar el uso hostil del espectro electromagnético y permiten su uso por unidades o fuerzas amigas.

En este apartado se explicará el nacimiento de la Guerra Electrónica, así como su historia y desarrollo en la Armada.

### 2.2.1 Origen de la GE

El nacimiento de la Guerra Electrónica no tiene razón de ser hasta que se empezó a trabajar con ondas electromagnéticas.

James Maxwell formuló en 1865 la teoría del campo electromagnético estableciendo que los campos magnético y eléctrico viajaban por el espacio en forma de onda. Años más tarde el alemán Hertz demostró esta teoría, siendo este el nacimiento de las ondas electromagnéticas. A finales del siglo XIX, el científico italiano Marconi logró la transmisión de ondas a gran distancia, sentando las bases de la radio y el radar. En definitiva, la reflexión de las ondas se podría utilizar para detectar objetos. En 1903, el investigador Christian Hulsmeyer desarrolló los primeros avances para el diseño de un radar. Un equipo con la capacidad de detectar ondas radio reflejadas como ayuda a la navegación. [2]

En un primer momento, los descubrimientos en el campo de las ondas electromagnéticas y su aplicación a las comunicaciones fueron escasamente apreciados por los ejércitos, marinas y fuerzas aéreas. Más tarde, aquellos países que los ignoraron o menospreciaron sufrieron en forma de derrota su falta de visión.

Precisamente en la mar tuvo lugar el primer episodio conocido en el que se hizo uso de la Guerra Electrónica (interferencias y captaciones de emisiones radio), durante la Guerra Ruso-Japonesa. Posteriormente, se produjeron episodios como la internada en el Mediterráneo de los cruceros alemanes Goeben y Breslau en 1914 que interfirieron las transmisiones del crucero inglés Gloucester y evitaron que este transmitiese sus posiciones. De esta forma, los cruceros alemanes pudieron internarse en el Mar Negro y bombardear Sebastopol. [15]

### 2.2.2 Historia de la GE en la Armada

Tras unos inicios tímidos, hoy en día la industria nacional ha sido capaz de desarrollar modernos equipos que cubren con creces las necesidades tecnológicas de nuestras unidades.

El comienzo en la Armada se produjo de la mano del sistema ESM de origen norteamericano WLR-1 desarrollado en los años 50. Este sistema equipó a los destructores de la clase “Churruca”, “Oquendo”, transporte de ataque *Castilla* y al portaviones *Dédalo*. El WLR-1 era un equipo de recepción en banda ancha con capacidades ELINT. Requería de habilidad del operador y tenía una capacidad de respuesta limitada. Sin embargo, era bastante preciso y fiable. [16]

A mediados de los años 70 del siglo XX, se hacía necesario el disponer de un sistema de tratamiento e integración de toda la información obtenida, por estos sistemas o por los instalados en los buques de la flota u otros. En definitiva, la Armada necesitaba dar un salto en el mundo de la GE y lleva a cabo las siguientes acciones:

- Creación de la sección de GE en la División Estratégica del EMA (Estado Mayor de la Armada).
- Adquisición de equipos más modernos con capacidad de determinar la situación de unidades a flote a través de sus emisiones HF (Radiogoniometría) y con funciones ELINT.
- Difusión de los conocimientos de la GE con la creación en la Escuela Naval de Guerra de la asignatura de Guerra Electrónica para que se estudiara y desarrollara los conceptos doctrinales y su aplicación a la guerra naval del momento.

Años más tarde la Armada siente la necesidad de disponer de sistemas que le permitan capacidades ECM (*Electronic Counter Measures*). En consecuencia, las fragatas clase *Baleares* (Figura 2-9) sustituyeron el sistema ESM WLR-1 por el italiano *Beta* que incluía elementos con capacidades tanto ESM como ECM. Años más tarde, se montó en el *Dédalo*.



**Figura 2-9** Fragata F-74 Asturias (clase "Baleares"). [17]

Con motivo de las limitaciones del sistema Beta, entre ellas la falta de sensibilidad y precisión en demora, se inició un programa nacional con el objetivo de mejorar y modernizar las capacidades de Guerra Electrónica de las unidades de la flota.

A mediados de los 80 se aprueba el primer Plan General de Guerra Electrónica en cual se analizaban y desarrollaban los equipos que se debían montar en las unidades definiendo sus características básicas y nominándolos para cada campo de actuación. Además, se establecía la utilización de equipos de fabricación nacional por lo que se intensifica la coordinación de la empresa INISEL (antecesora de la actual INDRA) en el campo de investigación y desarrollo. En estos años se desarrollan los programas Calatrava y Santiago que estaban destinados a la implementación de nuevos sistemas y a la coordinación de la inteligencia electrónica adquirida de los tres ejércitos EMACON (*Estado Mayor Conjunto de la Defensa*).

Se profundiza en procedimientos y su modo de utilización táctica con reuniones de expertos de los Estado Mayores de otras marinas. Se impulsa la necesidad de difundir este aspecto de la guerra por medio implantación de cursos específicos y la necesidad de crear la unidad de doctrina. El primer curso de Oficiales de GE se realiza en Cartagena en 1984.

De los sistemas nacionales que se pusieron en marcha conviene destacar tres programas (*Deneb*, *Canopus* y *Elnath* para la modernización) de las unidades de la flota de aquella época.

El primero fue creado para implementar un sistema ESM moderno que mejorase las capacidades de los equipos de las fragatas clase “Balears” y de las corbetas clase “Descubierta” (Figura 2-10). El segundo se aplicó al subsistema ECM (*Electronic Counter Measures*) y tenía como objetivo la integración de un sistema de lanzamiento de señuelos con el sistema de GE. Y por último el tercero, el cual se inició paralelamente al programa *Deneb* y aplicado a las mismas unidades que este. Era un sistema de GE de comunicaciones que incluía funciones de exploración del espectro y capacidades COMINT (*Communications Intelligence*). Al menos dos de los sistemas entregados a las unidades, tuvieron funciones ECM de comunicaciones con capacidad de perturbación y spoofing.



**Figura 2-10** Mástil con el receptor ESM en el tope y las dos antenas emisoras del P-78 *Cazadora* (clase “Descubierta”). [16]

Para las fragatas F-80 clase “Santa María” se optó por el sistema italiano *Nettunel*, que por esa época era el más avanzado. De hecho, las FFG-7 norteamericanas solo montaban equipos SLQ-32 con capacidades ESM, mientras que las españolas montaron desde el principio sistemas con capacidad de GE activa y pasiva (ESM y lanzaseñuelos). Se incluyó además un sistema *Elnath* para la guerra de comunicaciones.

El *Nettunel* se convirtió en el sistema de GE de la Armada por excelencia y se montó en el portaviones *Principe de Asturias*. Posteriormente este sistema se sustituiría por el *Rigel*.

A mediados de los años 80, se puso en marcha el programa *Aldebarán* que supuso una nueva generación de equipo electrónicos para la flota. Estaba orientado a las fragatas F-100 clase “Álvaro de Bazán” (Figura 2-11).



Figura 2-11 Antenas ESM/ECM en el mástil del sistema Aldebarán de la F-102 A. Juan de Borbón. [17]

Posteriormente también se aplicó a los BAM (Buque de Acción Marítima), al buque anfibio portaerones *Juan Carlos I* y a la modernización de los equipos de las fragatas F-80 clase “Santa María”. Se apostó por nuevas tecnologías y se utilizaron equipos de altas prestaciones como los módulos que permiten la medida instantánea de frecuencia DIFM (*Digital Instantaneous Frequency Measurement*), las antenas multihaz o las de apuntamiento electrónico. INDRA se ocupó de gran parte del desarrollo para incluir al sistema capacidades ESM y ECM (*Aldebaran*) y del de interceptación de comunicaciones (*Regulus*) dotado con funciones COMINT. Posteriormente, se creó el sistema *Rigel* como un sistema Aldebarán de bajo coste basado en un sistema ESM ligero. A día de hoy se encuentra en servicio en las F-80 modernizadas, la *Cristóbal Colón* (F-105), los BAM y el *Juan Carlos I*. [18]

### 2.2.3 Tipos de GE

La Guerra Electrónica se divide en tres tipos de operaciones (Figura 2-12). ESM (*Electronic Support Measures*), ECM (*Electronic Counter Measures*) y EPM (*Electronic Protective Measures*). EN la que se centrará la redacción de este trabajo será la parte relativa a las funciones ESM.

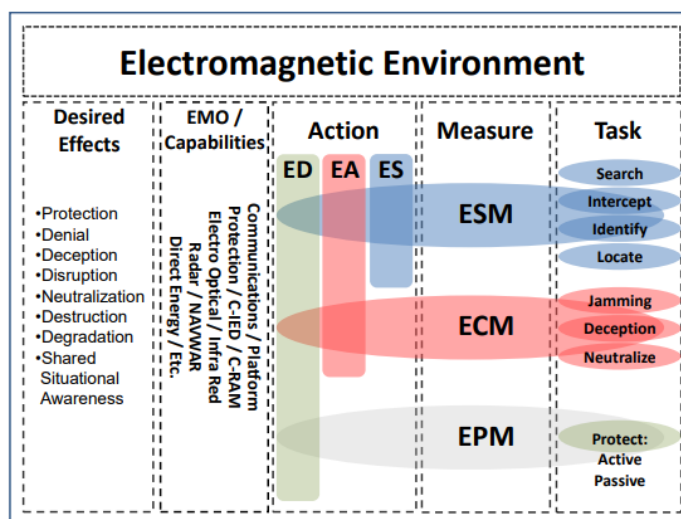


Figura 2-12 Tipos de operaciones EW. [19]

### 2.2.3.1 ESM

Se considera la parte de la EW cuyas acciones van orientadas a explorar, interceptar, identificar y localizar las emisiones electromagnéticas. Su propósito inmediato es proporcionar conocimiento de la amenaza, ya sean su posición, rumbo, velocidad, tipo de buque, intenciones... En definitiva, es una fuente de información para tomar acciones tácticas que no afecta a la política de emisiones del buque debido a que trabaja de forma totalmente pasiva.

Es posible obtener información a partir de la interceptación de todos los campos electromagnéticos y energía acústica mediante el uso de equipos de interceptación correctamente asignados. Las capacidades ESM son muy útiles para proporcionar al OTC (*Officer in Tactical Command*) de la fuerza, CWC (*Composite Warfare Commander*) o Comandantes de los buques información sobre amenazas para tomar decisiones previas a acciones del enemigo. [20] Los sistemas ESM de los buques se componen normalmente por antenas, receptores, procesadores de señal, sistema de evaluación con librería de emisiones y unidad de visualización. [11]

A continuación, se desglosan las fases del procedimiento de una operación ESM:

- a. **Búsqueda, Intercepción y Detección.** Se trata de la búsqueda de emisiones electrónicas.
- b. **Análisis.** En esta fase se determinan las características pertinentes de las emisiones electrónicas recibidas. Es decir, se analizan una serie de parámetros (frecuencia de la portadora RF (*Radio (carrier) Frequency*), ancho de pulso PW (*Pulse Width*), frecuencia de repetición de pulsos PRF (*Pulse Repetition Frequency*) ...
- c. **Búsqueda de la dirección.** Este es el proceso de determinar la dirección de la que proviene la emisión. Los equipos con funciones ESM no son capaces de determinar una localización del emisor (no dan distancias), pero sí obtener una dirección precisa (demora). De esta manera existen distintas formas para obtener la localización de un emisor (triangulación, demoras no simultáneas...). [21]
- d. **Reconocimiento del blanco emisor.** La determinación de ciertas características del contacto.
- e. **Identificación.** Asignación de clasificación según su identidad en función los datos disponibles del emisor y los criterios de identificación determinados.
- f. **Grabación.** El proceso de recopilar las características de las emisiones detectadas para futuros escenarios en bases de datos para análisis detallado.

Las funciones de búsqueda, interceptación, identificación, análisis y localización son comunes tanto a las operaciones ESM como a las SIGNIT (*Signal Intelligence*). Las diferencias entre ESM y SIGINT surgen de la finalidad que tienen cada una y del uso de la información derivada.

Las ESM corrientes o Medidas de Apoyo son capacidades que están restringidas en el momento del combate o despliegue. Sin embargo, las medidas SIGNIT son constantes y están orientadas a la recopilación de emisiones e información en zonas de interés que pueda ser útil en futuras operaciones o maniobras. Además, el volumen de datos manejados y la profundidad con que se realiza su procesado es mucho mayor en SIGINT que en ESM. La SIGINT produce y realimenta bases de datos técnicos de gran utilidad para despliegues de la flota.

A su vez, las medidas SIGNIT se pueden dividir en dos tipos de inteligencia. Cuando la actividad SIGINT se dedica específicamente a las señales de radar, guiado y navegación se denomina ELINT (*Electronic Intelligence*), en cambio la dedicada a comunicaciones y a la transmisión de datos se denomina COMINT (*Communications Intelligence*). A continuación, se muestran estos dos conceptos de forma más detallada:

- Inteligencia de Comunicaciones (COMINT). Material e información de inteligencia obtenidos de las emisiones electromagnéticas de comunicaciones y sistemas de telecomunicaciones.
- Inteligencia Electrónica (ELINT). Información de inteligencia obtenida de las emisiones electromagnéticas que no tienen que ver con las comunicaciones.

Además de las mencionadas anteriormente existen las Medidas de Inteligencia Óptica e IR (OPINT, *Optical Intelligence* e IRINT, *Infrared Intelligence*).

### 2.2.3.2 ECM

Área de la EW que trata el uso de la energía electromagnética con propósitos ofensivos. Uso del espectro electromagnético y de la DE (Energía Dirigida) para atacar las capacidades de combate del adversario destruyéndolas, interrumpiéndolas, negándolas o neutralizándolas permanentemente o temporalmente a través de la perturbación, la decepción o la neutralización electrónica. [1]

Como se mostraba en la figura superior (Figura 2-12), las medidas ECM posibilitan la realización de Jamming, Decepción y Neutralización: [19]

- Electronic Jamming.** Es el uso deliberado de radiación, reirradiación o reflexión de energía electromagnética con el objeto de deteriorar los dispositivos, equipos o sistemas electrónicos usados por el adversario. La coordinación de operaciones de Jamming se deben de planear con anterioridad y están contenidas en el EW Annex de una Orden de Operaciones. Los equipos que dispone la Armada en la actualidad pueden realizar tres técnicas diferentes de perturbación electrónica.
- Electronic Deception.** Tiene como objetivo provocar la confusión, distracción o seducción del enemigo o de sus sistemas electrónicos. Las operaciones deceptivas son particularmente efectivas cuando: El enemigo confía en las emisiones electromagnéticas recibidas, el enemigo depende de nuestras emisiones y cuando la decepción se realiza de forma hábil integrada en la operación con el resto de buques.
- Electronic Neutralization.** Es el uso de la energía electromagnética con el propósito intencionado de causar daños permanentes o temporales en los sistemas electrónicos del adversario. Al igual que con muchos sistemas de armas, las DEW (*Directed Energy Weapons*) puede presentar un riesgo para las unidades propias o aliadas y estos riesgos deben gestionarse adecuadamente.

### 2.2.3.3 EPM

Las medidas EPM son también llamadas ECCM (*Electronic Counter-Countermeasures*). Estas componen el área de la GE que trata el uso de la energía electromagnética con propósitos defensivos. Su objetivo es proporcionar protección y asegurar el uso propio o de fuerzas aliadas del espectro electromagnético. Existen dos subdivisiones de las medidas EPM: [1]

- EPM activas.** Medidas detectables por el enemigo, como la alteración de parámetros de transmisión según sea necesario para garantizar un uso efectivo del EMS (Electromagnetic System).
- EPM pasivas.** Medidas indetectables como procedimientos operativos o técnicas destinadas a la protección frente a amenazas.

### 2.2.4 La GE y la Inteligencia Artificial

Como hemos visto la GE es una guerra fundamental en los escenarios bélico modernos haciendo uso del espectro electromagnético para detectar objetivos o proporcionar información. Los desarrollos recientes en inteligencia artificial (AI) sugieren que esta tecnología emergente tendrá un gran influencia y utilidad provocando una transformación en el ámbito militar.

De hecho, las grandes potencias mundiales llevan desarrollando la inclusión de la AI en los buques desde hace años. Sin ir más lejos, la Royal Navy realizó pruebas sobre la posible utilización de la AI en su ejercicio anual *Information Warrior 2018* imitando los futuros sistemas informáticos que se instalarán en las unidades. [22]

Los algoritmos impulsados por AI pueden ser muy efectivos en diversos dominios de la GE como el procesamiento de señales radar para un reconocimiento y clasificación eficientes de emisores, detección de interferencias y sus características y para el desarrollo de algoritmos anti interferencias eficientes. El análisis de señales de forma automática y el almacenamiento de los datos de forma automática aumentará, por lo tanto, la velocidad con la que se puede identificar a un contacto.

Las técnicas de AI también pueden permitir que un sistema de GE funcione de forma autónoma. En otras palabras, un modelo basado en un proceso de toma de decisiones automático en entorno de GE para la detección de amenazas, clasificación y selección de la medida adecuada en cada caso.

Se trata de reducir la carga de trabajo a los encargados de tomar las decisiones. De esta manera se reducen los errores humanos y se actúa de una forma más rápida y eficiente. De hecho, la guerra moderna está tendiendo hacia procedimientos y acciones mucho más rápidas de manera que se requieren tiempos de reacción reducidos. De hecho, el ser humano no tiene ni mucho menos una capacidad de procesamiento de información equiparable a la de una máquina, especialmente si es en tiempo real.

## 2.3 Proceso de clasificación de emisiones

El conocimiento de los sistemas radar del enemigo es de vital importancia para poder realizar una identificación eficaz de las posibles amenazas. Por lo tanto, las unidades de la Armada cuentan con Sistemas ELINT que les permiten recibir, procesar y clasificar las emisiones radar de los contactos. Estos equipos siguen un proceso de detección (exploración, interceptación, identificación y localización). Un sistema estándar está formado por los siguientes subsistemas: [23] [24] [25]

- **Receptor de señales:** Durante la fase de exploración el principal objetivo es buscar emisiones de interés dentro de un rango determinado de frecuencia y tiempo (tiempo de adquisición suele ser muy pequeño) proporciona medidas preliminares de los parámetros característicos de la señal radiada.

Cuando se realiza una búsqueda en el espectro de grandes proporciones se utilizan receptores de banda ancha de modo que se reciben las emisiones que se encuentren dentro del margen de frecuencia que se estén cubriendo.

En cambio, cuando se realiza la llamada búsqueda “inteligente” se exploran solo las emisiones consideradas de interés mediante sistemas automatizados a través del uso de bases de datos.

- **Procesador de señal:** Este subsistema permite un análisis preciso de la señal recibida objeto de estudio dentro de un espectro electromagnético realmente denso. Realiza un desglose completo de sus características obteniendo la firma radar de la emisión.

- **Sistema de reconocimiento y clasificación:** En función de la firma radar obtenida, se compara con las características de los emisores disponibles por inteligencia (recopiladas en base de datos) e identificar la señal detectada y asociarla a una fuente emisora.

A continuación, se describe detalladamente el proceso que realizan los sistemas ELINT de los buques de la Armada. En particular, se tratarán de forma más detallada las tres primeras fases del proceso, pues son las más relacionadas con el objetivo del trabajo.

### 2.3.1 Exploración

Como se ha visto anteriormente, las acciones ESM se basan en el estudio del espectro en el dominio frecuencia/tiempo con el propósito de detectar cualquier emisión de interés. La búsqueda puede ser de dos tipos:

- **General.** En este tipo de exploración podemos diferenciar dos tipos de receptores. Los receptores de banda ancha que realizan vigilancia de grandes porciones del espectro y los receptores de exploración secuencial que admiten una única banda estrecha de frecuencias para cada instante. Estos necesitan realizar un rastreo (*scanning*) para cubrir una banda completa. En cuanto a su eficacia de trabajo, los de tipo secuencial tienen mayor capacidad interceptadora debido a su gran sensibilidad y selectividad.
- **Especial.** Implican el uso de dispositivos con capacidad de discriminación de emisiones que no sean consideradas de interés. Disponen de una memoria con registro de señales (bases de datos) de forma que el sistema asocia la señal recibida con una amenaza concreta.

El primer elemento que se debe tener en cuenta durante la exploración es el ruido. Todas las emisiones captadas por los sensores ubicados en nuestros equipos receptores contienen ruido. El ruido que tiene una apariencia similar en cualquier frecuencia o zona del espectro se conoce como ruido blanco.

Los equipos de búsqueda deberán fijar un umbral de detección que se situará por encima del nivel medio de ruido para evitar confundir las variaciones de amplitud de este con la señal recibida. El establecimiento del nivel de detección (Figura 2-13) es crítico debido a sus consecuencias dependiendo de su valor. Si este se establece muy próximo al nivel medio de ruido se detectarán un mayor número de emisiones aumentando la probabilidad de detección (PD). Sin embargo, aumentará la probabilidad de confundir la señal recibida con ruido (probabilidad de falsa alarma, PF).




Figura 2-13 Establecimiento del umbral de detección. [24]

La característica que nos permitirá confirmar la existencia de una señal es su persistencia a lo largo del tiempo. En consecuencia, el enemigo emisor intentará que su señal aparezca el mínimo tiempo posible y de la forma más irregular. Dentro de los esfuerzos por no ser detectado del enemigo destaca la técnica de espectro ensanchado. Esta se basa en repartir la energía emitida en un ancho de banda mucho mayor que el mínimo necesario para transmitir la señal de forma que la potencia de la señal se distribuye uniformemente a lo largo del espectro ensanchando. Para buques que no posean una réplica de la señal ensanchada será difícil detectarla debido a que aparecerá sepultada en el ruido.

Como solución para detectar señales de espectro ensanchado se utiliza el radiómetro. Este es un instrumento de medida de potencia compuesto por un filtro de paso de banda (BPF) y un circuito integrador. A la salida de este, la señal se compara con el umbral presintonizado. De modo, que si la salida del integrador es mayor que el umbral se confirmará la presencia de señal.

### 2.3.2 Intercepción

La siguiente fase del proceso es la interceptación de señales. Consiste en descubrir en el espectro las señales de interés. Es decir, a partir de las señales recibidas por los equipos de EW, captar la presencia de aquellas que supongan un objetivo potencial.

La interceptación tiene lugar en los mismos receptores de búsqueda. Los receptores-interceptadores se centran en bandas de frecuencia concretas debido a la incapacidad para mantener la repuesta de antenas en bandas muy anchas. A continuación, se estudian las características y los tipos de receptores.

#### 2.3.2.1 Características de los receptores

Las condiciones básicas de cualquier receptor de búsqueda-interceptación son que proporcione una alta PD y un baja PF. Para alcanzar estas condiciones, el receptor deberá poseer las siguientes características:

- **Selectividad.** Mide la capacidad para discriminar la existencia de una señal en un ambiente densamente poblado de emisiones. Además, será necesario decidir entre estudiar de modo simultáneo toda la banda o concentrar la atención en una banda estrecha tras haber descubierto una señal de interés.
- **Sensibilidad.** Mide la capacidad para distinguir señales útiles por encima del valor del ruido. Depende de la potencia necesaria a la entrada del receptor para obtener una determinada relación S/N. Evidentemente, la mínima relación S/N es 1 (0 dB), por tanto, bastará con que la señal emerja un poco del ruido para que sea detectada. Sin embargo, al fijar el umbral de detección estamos elevando la S/N necesaria y reduciendo la sensibilidad del receptor.

#### 2.3.2.2 Tipos de receptores

Existen diferentes tipos de receptores dependiendo de su finalidad de uso. Los receptores que forman parte del sistema de exploración e interceptación de emisiones cuentan con antenas y equipos integrados. En la Tabla 2-1 Comparativa de receptores (se muestran las principales ventajas e inconvenientes de cada uno de los principales receptores: [26] [24]

Receptor	Ventajas	Inconvenientes	Aplicaciones
Receptor de vídeo de cristal (CVR)	Pequeño, bajo coste y alta probabilidad de interceptación	Poca sensibilidad y dificultad para manejo de señales densas y complejas	RWR
Superheterodino de banda estrecha	Alta sensibilidad, buena resolución en frecuencia,	Tiempo de respuesta lento y baja probabilidad de	SIGINT ESM

	diseño probado y no susceptibles a jamming	interceptación si el emisor es ágil en frecuencia.	
Superheterodino de banda ancha	Mejor tiempo de respuesta y mayor probabilidad de interceptación que los de banda estrecha	Peor sensibilidad que los de banda estrecha	ESM (Alerta aérea táctica)
IFM	Alta probabilidad de interceptación y buena precisión de medición de frecuencia	Baja sensibilidad, susceptibles a jamming y dificultad para manejar señales simultáneas	ESM asociado a perturbadores SIGINT
Receptor canalizado	Alta selectividad, alta probabilidad de detección, resolución en frecuencia moderada y grandes anchos de banda	Requiere canalizador (mayor tamaño y coste), complejo y sensibilidad limitada	SIGINT asociado a perturbadores
Acústico-óptico	Buena resolución y alta probabilidad de interceptación	Alta complejidad y ancho de banda limitado	SIGINT RWR
Comprensivo	Buena resolución y gran rango dinámico	Alta complejidad, ancho de banda limitado	SIGINT

Tabla 2-1 Comparativa de receptores ( [26] [24])

### 2.3.3 Identificación

Consiste en determinar si la señal interceptada es o no de interés realizándose posteriormente un estudio detallado de los parámetros de la emisión. Mediante las características técnicas de la emisión se identifica al equipo que la produce y la plataforma asociada a partir de la correlación de la firma radar obtenida con la información almacenada en las bases de datos.


#### 2.3.3.1 Características técnicas de la emisión

A continuación, se muestran los parámetros de una emisión directamente detectables por un equipo convencional ELINT de la Armada: [27]

- **Frecuencia de la portadora (F).** La frecuencia del radar definirá su uso. Los radares que trabajan a frecuencias bajas (bandas C y F) suelen estar destinados a búsquedas a grandes alcances. Sin embargo, aquellos que trabajan con frecuencias más altas (bandas I y J) son más precisos, tienen menor alcance y se emplean como radares de seguimiento. Además de los radares pulsados, existen también los de onda continua que trabajan modificando la frecuencia de operación.
- **Frecuencia de repetición de pulsos (PRF).** El alcance también se ve afectado por el valor de la PRF de la emisión. De hecho, es uno de los valores que establece el alcance máximo del radar.
- **Ancho de pulso (PW).** Es el tiempo en el que el radar pulsado está transmitiendo. Por tanto, cuanto mayor ancho de pulso, mayor tiempo se encuentra el radar en transmisión. A mayor ancho de pulso, mayor energía se puede emitir. El problema que surge es que los contactos

dentro del mismo ancho de pulso aparecerán como un único buque. Si el ancho de pulso es mayor que el tiempo que tarda la onda en llegar desde un contacto a otro, el radar solo detectará uno. Por esta razón en los barcos se disponen de radares de navegación (ancho de pulso estrecho) para definir la costa y contactos cercanos y radares de exploración (ancho de pulso grande) con grandes alcances. [2]

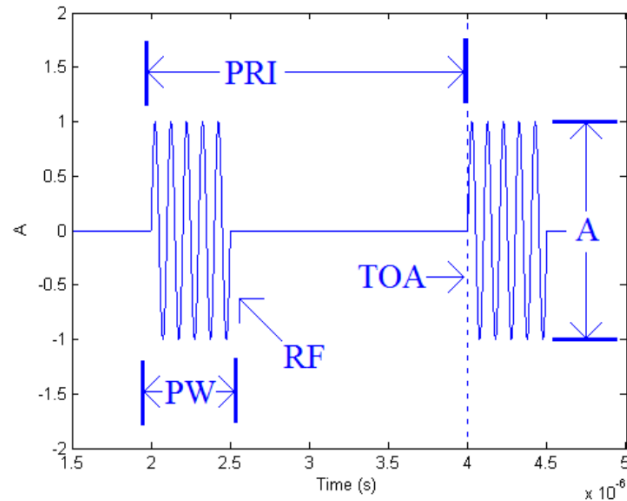
- **Patrón y velocidad de exploración.** Debido a las técnicas de contramedidas del enemigo son avanzadas y el número de emisores que operan simultáneamente ha aumentado, un solo radar puede ser identificado ocasionalmente como varios radares debido a la ambigüedad de los parámetros de las características. De hecho, el sistema de EW realiza un proceso de descomposición de la emisión recibida (Figura 2-14), denominado desentrelazado (*deinterleaving*). Para superar este problema, es necesario utilizar los parámetros individuales del radar de forma complementaria y cooperativa. Entre los distintos parámetros del radar, el patrón de exploración del radar (*radar scan pattern*) tiene propiedades distintivas útiles para identificar el radar del enemigo. [28]



**Figura 2-14 Deinterleaving de una emisión utilizado por un procesador de señal de un sistema de EW. [28]**

En cuanto a la velocidad de giro de la antena, afecta de forma similar a la PRF. Velocidades más lentas se relacionan con grandes rangos de exploración, mientras que velocidades de rotación altas se utilizan para un mayor refresco de la información y contactos cercanos.

- **Ancho de haz y nivel de lóbulos laterales (*beam width and side lobe levels*).** La anchura del haz del lóbulo principal se entiende como el ángulo entre los puntos a izquierda y derecha donde la ganancia ha disminuido a 3 dB respecto a la ganancia máxima. Los lóbulos laterales se ubican alrededor del lóbulo principal.
- **Ángulo de llegada de la señal (*Angle of Arrival, AoA*).** Se basa en la medición de las direcciones angulares (acimut y elevación).
- **Amplitud de la señal (*A*).** Distancia máxima entre los puntos más alejados del punto equilibrio de una onda.
- **Polarización.** El campo eléctrico de una emisión es perpendicular a su dirección de propagación. Los radares utilizan diferentes tipos de polarización dependiendo de su aplicación o uso.
- **Tiempo de recepción del pulso (*Time of Arrival, TOA*).** Es el tiempo que transcurre desde que el emisor transmite la señal hasta que llega a un receptor.



**Figura 2-15 Pulse Description Word (PDW).**

Los parámetros anteriores (Figura 2-15) definen lo que, en el argot de la GE, se denomina el descriptor PWD (Pulse Description Word).

Estos parámetros se transmiten al procesador para clasificarlos. Dado que cada radar tiene rangos de parámetros específicos (con una cierta variación de valores limitada) y características identificables, se relacionan con valores similares de posibles radares emisores (inteligencia). De esta manera, se clasifica e identifica la señal procesada con su correspondiente blanco en base a una plantilla.

En definitiva, este último paso se realiza mediante técnicas tradicionales paramétricas basadas en métodos de “pattern recognition”. De modo que las medidas realizadas de la señal emisora se comparan por similitud con la librería de los tipos de radar almacenados.

Es conveniente destacar que este método actualmente está un poco obsoleto debido a las condiciones del entorno electromagnético actual. De hecho, los parámetros de la señal emitida varían a menudo, por lo que es necesario la aplicación de nuevos métodos de identificación y clasificación que sean capaces de aprender y adaptarse a las condiciones del entorno.

### 2.3.3.2 Base de datos

Tras haber realizado las fases anteriormente mencionadas, se almacena la información obtenida en bases de datos para su posterior utilización. Las bases de datos permiten la recopilación y distribución al resto de unidades de la flota o a otras fuerzas amigas. Estas nos permitirán comparar los parámetros de la señal recibida con los almacenados en la librería de emisiones.

Las bases de datos están normalizadas para facilitar su gestión e intercambio de información. De hecho, la Base de Datos de Emisores de la OTAN (*Nato Emitter Data Base*, NEDB) es una base común que comparte las diferentes fuerzas aliadas. Esta puede ser utilizada por cualquier organismo o unidad de la OTAN con finalidad relacionada con la GE.

Una vez se ha realizado la identificación de una emisión como enemiga se procede a tomar decisiones en función de la amenaza, localización, grado de interés para inteligencia, etc.

### 2.3.3.3 Tratamiento y análisis de los datos

Durante esta fase tiene lugar la compilación de la información obtenida, valoración, análisis e interpretación.

Como ya se ha visto, el análisis consiste en la medición de los parámetros de la señal y su correlación con las bases de datos disponibles. La finalidad última del análisis será conocer los medios, despliegue e intenciones de la amenaza. De hecho, el conocimiento de los medios nos permitirá establecer el Orden de Batalla Electrónico del enemigo (*Electronic Order of Battle*, EOB).

Debido al gran volumen de información es necesaria la utilización de técnicas de correlación e inferencia como base de cálculo. Los equipos ESM disponen de una cierta capacidad de análisis, correlación y evaluación. Sin embargo, los datos recibidos se fusionan, correlacionan, analizan, integran e interpretan en las estaciones de mando del sistema llamadas Estaciones de Control. De esta manera, se realiza el ciclo de inteligencia transformando la información obtenida por los sistemas de GE en inteligencia de importancia inmediata o potencial para la GE de las unidades de la flota.

Particularmente, la información de interés se transfiere al elemento de inteligencia. Este flujo de inteligencia entre la unidad y el elemento de inteligencia se realiza a través de la *Electronic Warfare Coordination Cell* (EWCC).

### 2.3.4 Localización

La determinación de la localización del emisor puede resultar necesaria para su identificación. La posición de la amenaza electrónica afectará a la realización del EOB e influirá en las posteriores acciones (fuego, perturbación, plan EMCON en vigor...).

El método generalmente empleado es el de radiogoniometría (RDF) que determina la dirección de incidencia de una emisión a partir del posicionamiento de sus frentes de onda. En definitiva, la radiogoniometría pretende determinar el ángulo de incidencia de una onda electromagnética. Sus aplicaciones más importantes son ayuda a la navegación y GE. Las aplicaciones de la radiogoniometría en la GE son cada vez más importantes, sin embargo, su uso en ayudas para la navegación ha decaído y ha sido sustituida por otros métodos más complejos. [24]

El radiogoniómetro consiste en un receptor superheterodino que proporciona una marcación (horizontal o vertical) de incidencia. Existen diferentes técnicas de determinar la localización de un emisor. Algunas como el uso de varias distancias o ángulo y distancia únicamente nos proporcionan aproximaciones debido a que los equipos ESM no dan distancias. Estas técnicas estiman las distancias a origen de la emisión a partir de la potencia de la señal recibida. A continuación, se tratarán brevemente las más comunes: [21] [2]

- **Triangulación.** Este método se basa en el cruce de demoras desde diferentes posiciones respecto a la emisión. Aunque es posible obtener la posición con dos demoras, es preferible tener al menos tres para eliminar posibles errores. La intersección de las LOB sobre el plano nos indicará la situación de la amenaza. Si se desea obtener la altura, entonces se necesitará un ángulo de elevación además de las demoras. En el ámbito táctico de la GE es un procedimiento llamado "CRISS CROSS". En este, cada unidad de la fuerza pasa por circuito táctico su demora a la traza electrónica en cuestión. A continuación, el EWC (*Electronic Warfare Commander*) realiza la triangulación e informa de la posición geográfica de la amenaza. [1]
- **Demoras no simultáneas.** Es la aplicación del método tradicional de navegación costera. Suele estar limitado para aeronaves ya que es menos fiable que la triangulación. La unidad que porte el receptor ESM deberá moverse a gran velocidad respecto al emisor para tomar varias demoras.

### 2.3.5 *Inteligencia de señales*

La importancia de la información en el ámbito militar es innegable. En particular, la relación entre inteligencia y GE. De hecho, la GE no solo proporciona información sobre el enemigo, sino que también necesita inteligencia para desarrollar sus acciones.

De hecho, las ESM proporcionan inteligencia general de interés táctico, información de apoyo a las acciones EPM y para dirigir acciones ECM. Para poder aplicar la información obtenida del enemigo a las acciones ECM, EPM e incluso ESM, es necesario que realice un análisis y evaluación en el propio sistema de GE de cada unidad. De este modo, surge el concepto de Inteligencia de Guerra Electrónica (EWD):

*Inteligencia que resulta del acopio, integración, análisis, interpretación y evaluación de la información obtenida por cualquier medio, de importancia inmediata o potencial para la EW [24]*

El órgano responsable de facilitar y recopilar la inteligencia de las Fuerzas Armadas es el CIFAS (Centro de Inteligencia de las Fuerzas Armadas). Su función es alertar sobre situaciones internacionales susceptibles de generar crisis o amenazas que afecten a la Defensa Nacional. Además, presta el apoyo necesario en términos de información e inteligencia para las operaciones en las que se integran las unidades de las FAS (Fuerzas Armadas) de forma que la Fuerza llegue preparada a los escenarios de conflicto u operaciones. [29]

#### 2.3.5.1 *Obtención de Inteligencia en la Armada*

SUPRIMIDO POR CONFIDENCIALIDAD

SUPRIMIDA POR CONFIDENCIALIDAD

**Figura 2-16 Buque auxiliar A-111 Alerta. [17]**

SUPRIMIDO POR CONFIDENCIALIDAD

**Figura 2-17 Proceso de flujo de la información**

#### 2.3.5.2 *Forma de trabajo en las unidades*

SUPRIMIDO POR CONFIDENCIALIDAD

SUPRIMIDO POR CONFIDENCIALIDAD

**Figura 2-18 Proceso de asignación SPOT number**

## 3 DESARROLLO DEL TFG

### 3.1 Investigación y propuestas

Como se ha descrito, las ESM suponen una parte muy importante de la GE proveyendo información valiosa para conocimiento de la situación táctica en tiempo real y la detección de amenazas. Una vez tratado el actual modo de clasificación de emisiones radar en los buques de la Armada, la comparación con el resto de Marinas de las principales potencias permitirá detectar nuestras carencias en este ámbito de la GE.

#### *3.1.1 Descripción del problema*

Una función crítica de los sistemas ESM, que da nombre a este trabajo, es la de identificación del tipo de radar asociado a una emisión. El método actual de trabajo descrito en el Apartado 2.3.5.2 es mejorable en cuanto al tiempo de respuesta, selección y a la discriminación del tipo de radar en función de los parámetros de la emisión recibida. El sistema tiene diferentes carencias. A continuación, entre las que se exponen las más importantes: [31]

- Gran densidad electromagnética. Múltiples de emisiones son recibidas por el equipo de GE de forma que se solapan entre ellas.
- Existen radares con diferentes modos de trabajo que aumentan la dificultad de clasificación.
- Agilidad en parámetros como el PRI, frecuencia, PW o velocidad de barrido. Los valores de la señal recibida cambian. Tan solo el propio calentamiento del sistema de las antenas del radar emisor desde su arranque, provoca variaciones en los parámetros de la señal.
- Solapamiento de parámetros. Muchos radares tienen valores de características similares por lo que la labor de clasificación e identificación se dificulta en gran medida. Difícil proceso de discriminación entre parámetros tan análogos.

Estudiada la problemática, es obvio que es necesario la aplicación de nuevos de métodos de clasificación e identificación que tenga la capacidad de aprender a la vez que adaptarse a las condiciones cambiantes del entorno. Es por ello que se proponga el desarrollo la aplicación de desarrollos de AI basados en redes neuronales.

### 3.1.2 Propuesta inicial

En este apartado se describe una primera aproximación alternativa realizada para la mejora del sistema de clasificación de emisiones actual. El componente principal de esta propuesta es una red neuronal con capacidad de aprendizaje a partir de una serie de parámetros simulados de diferentes emisiones radar. Para llevar a cabo esta propuesta se han realizado los siguientes pasos, tal y como puede observarse en el Anexo XIII:

- Examinar y comprender los datos o parámetros que se le van a introducir al modelo.
- Construir el modelo.
- Entrenar al modelo con emisiones de forma que le sirva para aprender a enfrentarse a este tipo de entradas. Este paso es la llamada fase de entrenamiento que se debe realizar mediante la mayor parte del volumen de emisiones disponibles. Veremos más adelante que la cantidad de emisiones utilizadas en esta fase es seleccionable.
- Validar al modelo durante la fase de testeo.
- Realizar cambios o repetir el proceso con el fin de mejorar el desarrollo del modelo.

#### 3.1.2.1 Desarrollo del modelo de AI

Se programa en *Google Colaboratory* trabajando online y se desarrolla el modelo descrito a continuación.

La red neuronal empleada es una red convolucional de 3 capas densas. La primera de ellas es una red neuronal que recibe los datos de las distintas características (ancho de pulso, PRF, velocidad de rotación, etc.) y genera una salida de 32 parámetros. El resultado del aprendizaje de esta capa activa una función de activación RELU descrita en el Apartado 2.1.4.1 que alimenta una segunda capa, esta vez oculta pero también densa, de 16 parámetros de salida activados también mediante una función RELU. Por último, la tercera capa densa, tiene tantas salidas como posibles radares y se activan mediante una función SOFTMAX (Apartado 2.1.4.1). En total la CNN tiene 981 parámetros entrenables.

El optimizador empleado en la fase de aprendizaje emplea el algoritmo de Adam que no es más que un método estocástico de gradiente descendiente basado en una estimación adaptativa de los momentos de primer y segundo orden.

Se parte del valor de los parámetros de las emisiones radar que se tengan a disposición. En este caso, se ha trabajado con 5 radares con distintas características y de diferente tipo (climatológico, navegación, detección de misiles balísticos, exploración aérea y de superficie). Para el entrenamiento del modelo se utilizan una serie de valores de parámetros (Frecuencia, PW y PRF) mostrados en la Tabla 3-1 de los radares mencionados.

ID	Rango frecuencia (MHz)	PW ( $\mu s$ )	PRF (MHz)
Radar 1	5260	0,5	1200
Radar 2	9415 - 9475	0,08	375
Radar 3	1295	1000	375
Radar 4	1250 - 1350	1	40
Radar 5	850 - 942	2	280

**Tabla 3-1 Valores utilizados para el set de entrenamiento de la red neuronal.**

A estos valores se les aplica una normal truncada de forma que a partir de cada tipo de radar se generen aleatoriamente un número determinado de emisiones con valores similares, pero no idénticos a cada uno de los 5 radares. De esta manera se crean diferentes valores de cada uno de los tres parámetros utilizados (frecuencia, PW y PRF). Un dilema que se presenta es, qué variación debemos meterle a cada uno de los valores aleatorios que estamos generando de los parámetros en cuestión. En este caso, como se muestra en la Figura 3-1 se ha elegido generar nuevos valores con un  $\pm 1\%$  de variación respecto al parámetro nominal.

```
freq = truncated_normal_ints(mean=freq, sd=freq*0.01, low=freq*0.99, upp=freq*1.01,
                             num=number_of_items)
pw = truncated_normal_floats(mean=pw, sd=pw*0.01, low=pw*0.99, upp=pw*1.01,
                              num=number_of_items)
pri = truncated_normal_ints(mean=pri, sd=pri*0.01, low=pri*0.99, upp=pri*1.01,
                             num=number_of_items)
```

**Figura 3-1 Generación de valores para el set de entrenamiento mediante normal truncada.**

Existe la posibilidad de trabajar con el número de emisiones de cada radar que se requiera como se muestra en la Figura 3-2.

```
# number of items for each radar class:
number_of_items_per_class = [20, 20, 20, 20, 20]
number_of_classes = len(number_of_items_per_class)
```

**Figura 3-2 Elección de número de emisiones diferentes de cada radar.**

Una vez introducidos los tres valores, frecuencia, PW y PRF, de los 5 radares, se selecciona el número de emisiones que queremos generar de cada radar (20 emisiones en este caso) y se asignan las etiquetas para realizar el entrenamiento de la red.

Este paso consiste en etiquetar los valores pertenecientes a la fase de entrenamiento (*training\_data*) y los de la fase de test o validación (*test\_data*). Teniendo un volumen considerable de datos es posible configurar el porcentaje de muestras destinadas al set de entrenamiento y aquellos restantes para el set de validación. De esta forma se posibilita la utilización de un el punto medio en el que se obtienen los mejores resultados.

Por último, tiene lugar la prueba del modelo con datos nuevos desconocidos para el modelo. Esta prueba permite observar sus predicciones ante diferentes parámetros introducidos, analizar los resultados y comprobar si son correctas sus predicciones.

A continuación, se estudia la diferencia de resultados en el caso de que modifiquemos el número de emisiones introducidas. En el caso de aplicar una entrada de 20 emisiones por radar se obtiene las siguientes curvas de aprendizaje de entrenamiento y validación y finalmente su correspondiente matriz de confusión (Figura 3-3 y Figura 3-4).




Figura 3-3 Curva de aprendizaje de la fase de entrenamiento y de la validación (20 emisiones).

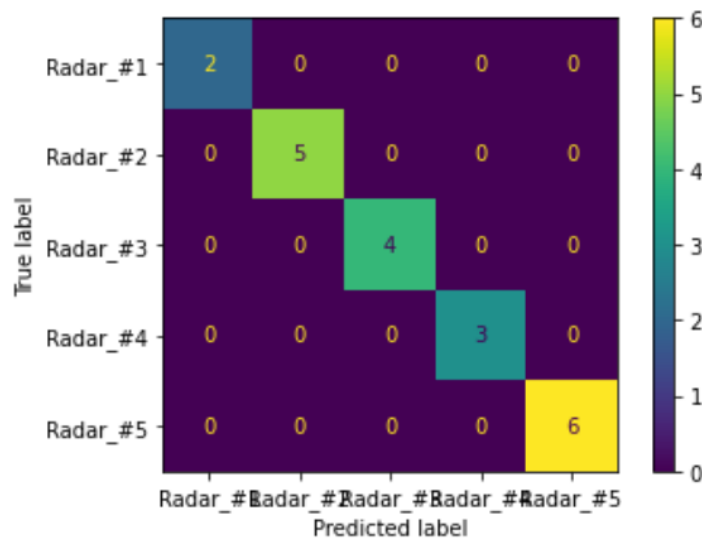



Figura 3-4 Matriz de confusión (20 emisiones).

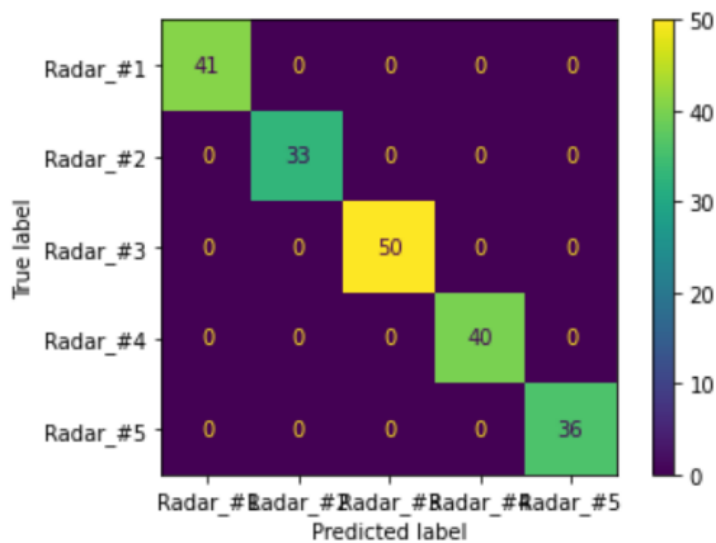
En la Figura 3-3 se puede apreciar que las dos curvas de aprendizaje tienen una relación lineal y aparentemente no existe sobreaprendizaje. En cuanto a la matriz de confusión mostrada en la Figura 3-4, los valores de la diagonal principal corresponden a los valores predichos correctamente por el modelo. Como se puede observar, el modelo creado no comete errores en la clasificación de las emisiones que recibe en su entrada. Más adelante, se realizan las pertinentes conclusiones.

A continuación, se analiza el caso de utilizar 200 emisiones para el entrenamiento y validación del modelo en lugar de las 20 emisiones de radar anteriormente tratadas.



**Figura 3-5** Curva de aprendizaje de la fase de entrenamiento y de la validación (200 emisiones).

Como se muestra en la Figura 3-5, las dos curvas van a la par al igual que en el anterior caso (20 emisiones por radar), sin embargo, se puede apreciar que la pendiente de la curva de aprendizaje es mucho mayor y se llega al 80% de precisión mucho antes que en el proceso efectuado anteriormente.



**Figura 3-6** Matriz de confusión (200 emisiones).

En cuanto a la matriz de confusión se puede observar que al igual que en el caso previo, el modelo no falla en sus predicciones asignando a cada emisión su radar correcto (Figura 3-6).

### 3.1.2.2 Conclusiones

Desde un punto de vista autocrítico y a la vista de los resultados se razonan una serie de conclusiones que ayuden a mejorar y desarrollar el modelo creado. Según los diagramas de confusión y las posteriores

pruebas con valores desconocidos para modelo, las predicciones realizadas por la red son correctas y esta no comete errores en la clasificación de las emisiones de cada radar.

Sin embargo, es conveniente decir que los casos introducidos son muy diferentes unos de otros. Es decir, los valores de cada radar introducido difieren mucho entre sí. De este modo, la red aprende rápido a diferenciarlos.

En cuanto al funcionamiento de la simulación de valores de los diferentes parámetros, se puede decir que ha resultado ser muy positiva debido a la posibilidad de crear un gran volumen de inteligencia a partir de unos pocos valores de la paramétrica del radar enemigo.

Para comprobar si el modelo está sufriendo sobreaprendizaje se compara una imagen de un ejemplo del mismo, mostrado en el Apartado 2.1.3.1 (Figura 2-3), con la curva obtenida en la Figura 3-3 y Figura 3-5. Como se puede ver en la gráfica la curva de entrenamiento se mantiene muy por encima de la curva de validación/test a diferencia de las curvas de nuestro modelo. Por lo que se puede confirmar que no sufre sobreaprendizaje.

El problema de esta solución propuesta es que parte de los parámetros PWD que caracterizan los distintos radares han sido obtenidos como productos derivados e interpretados del análisis de las señales radar. En este caso, la red se está entrenando con algunos parámetros “de alto nivel” que caracterizan dicha señal. Probablemente, si se pudiese alimentar la red con la propia señal radar o con alguno de sus descriptores de más bajo nivel, como por ejemplo un espectrograma, los resultados serían mejores ya que la red sería capaz de aprender observando pequeños matices y patrones de la señal y no observando parámetros.

Sin llegar a esa solución ideal propuesta en el párrafo anterior si podríamos comprobar cómo funciona la red neuronal cuando se alimenta con parámetros reales, es decir, que provengan de una señal radar real, y no con parámetros generados por simulación. Esta es la solución que se plantea en el siguiente apartado como solución alternativa.

### *3.1.3 Solución alternativa*

La solución alternativa a la propuesta inicial se basa en la recopilación de señales radar reales de forma que el modelo aprenda mediante un set de entrenamiento de mayor calidad formado por emisiones reales. Para ello se necesitan emisiones radar de varios buques diferentes por lo que se recurre a las Lanchas de Instrucción de la ENM y otros buques para realizar estas medidas.

Se utiliza un sistema receptor descrito más adelante en el Apartado 3.4.1 y se realizan un muestreo de gran volumen con cada radar de cada lancha y con diferentes tipos de ancho de pulso y PRF. La clave es estudiar qué parámetros son los más útiles para que el aprendizaje de la red.

La gran ventaja que tiene esta propuesta respecto a la primera aproximación del Apartado 3.1.2 es que los valores de los parámetros no son simulados a partir de valores nominales.

Para recopilar las señales se utiliza un sistema receptor que mediante una serie de códigos de Matlab nos permite visualizar la señal y obtener las matrices de los parámetros que se introducirán en la red neuronal para entrenar al modelo.

## **3.2 Hardware**

En este apartado se describirá el hardware empleado en el desarrollo del trabajo y la recopilación de señal real de las Lanchas de Instrucción.

### 3.2.1 Radar Furuno 1944C

Este radar de navegación es el utilizado por las Lanchas de Instrucción de la ENM. Utiliza como elemento radiante un array guíaondas ranurada con polarización horizontal. Tiene una escala máxima de 64 MN, una potencia pico de 6KW y una velocidad de rotación de antena de 24 rpm según las especificaciones del manual (Anexo II). La antena tiene una velocidad de giro de 24 rpm de forma que realiza un barrido en 2,51 s. Consta con un ancho de haz horizontal de  $1,9^\circ$  ( $\theta_{horizontal}$ ) a 3dB y un ancho de haz en elevación de  $22^\circ$  ( $\theta_{vertical}$ ) como se muestra en la Figura 3-7.



Figura 3-7 Lanchas de Instrucción navegando con radar alto en transmisión. [17]

Cada una de las cuatro Lanchas de Instrucción consta con dos equipos de este tipo similares (radar alto y radar bajo) mostrados en la . Se encuentran a 7 y 5,3 metros de altura respectivamente como se muestra en la

Ambos radares transmiten en banda X, a una frecuencia de 9.410 MHz con una tolerancia de  $\pm 30$  MHz para intercalar radares que se pueden llegar a interferir con un uso simultáneo. Precisamente, un factor importante para la discriminación de cada lancha es la frecuencia a la que operan cada uno de los radares debido a que varía levemente. Otro factor a comentar es que cuando los dos radares trabajan a la vez provocan que en la presentación los crudos tengan mayor ruido y menor precisión. Por lo que en ambientes y condiciones ambientales con mucho ruido se obtienen mejores resultados trabajando únicamente con uno de los radares aislado y no con los dos en transmisión simultánea como se suele navegar.



**Figura 3-8 (Radares 1944C FURUNO) alto y bajo de la Lancha de Instrucción A-124 (GM. Salas).**

En cuanto a la duración del pulso, el radar cuenta con tres modos de trabajo dependiendo del PW (SHORT, MED y LONG). Existen duraciones de pulso predefinidas para cada escala (Tabla 3-2), de forma que el operador no tiene que establecer el modo de PW. Para la detección a grandes distancias el sistema utilizará pulsos de mayor duración (LONG), mientras que para discriminar mejor en distancia y alcances cortos se utilizarán anchos de pulso pequeños (SHORT). Además, cuando el radar se encuentra en escalas intermedias el operador tiene la posibilidad de elegir el PW entre SHORT o MED y MED o LONG.

<b>Escala (MN)</b>	<b>Modo</b>	<b>PW (<math>\mu s</math>)</b>	<b>PRF (Hz)</b>	<b>BW (MHz)</b>
0,125 a 1,5	SHORT	0,08	2100	25
1,5 a 3	MED	0,3	1200	6,6
3 a 72	LONG	0,8	600	2,5

**Tabla 3-2 Valores teóricos de PW, PRF y ancho de banda en función de la escala.**

Es conveniente comentar que la última columna de la Tabla 3-2 muestra el ancho de banda (BW) del pulso efectuado por el radar que se obtiene de aplicar la siguiente fórmula al PW:


$$BW = \frac{2}{PW} \text{ (MHz)}$$

**Ecuación 3-1 BW.**

Este valor tiene una notable importancia debido a que según el Criterio de Nyquist la tasa de muestreo debe ser mayor o igual al doble del ancho de banda de la señal en cuestión. En el Apartado 3.4 se tratará de forma más detallada.

### 3.2.2 Antena

La antena utilizada es la Microstrip SO4100-8N de la casa alemana Lucas Nülle (Figura 3-9) que incluye un trípode giratorio y oscilador en banda X. Este tipo de antenas utilizan un tipo de línea de transmisión eléctrica llamada microstrip. Las principales ventajas de este tipo de antenas son robustez, ligereza y bajo coste. Para el uso que necesitamos, cumple con creces los requisitos



**Figura 3-9 Microstrip SO4100-8N.**

### 3.2.3 SDR HackRF

Antes definir el tipo de SDR (*Software Defined Radio*) que se utiliza, es conveniente definir su concepto. Se puede decir que un SDR es un sistema de radiocomunicaciones que implementa virtualmente los elementos habituales del hardware como mezcladores, amplificadores, detectores de señal...etc. De esta manera, mediante el ordenador u otro dispositivo es posible configurar las funciones de los elementos del hardware. [32]

Mediante el soporte informático se manejan las características o parámetros de la recepción/transmisión del sistema en cuestión. Además, a través de técnicas de procesamiento de señales se visualiza en el equipo con la opción de medir valores o modificar parámetros de medición. El equipo SDR (Figura 3-10) junto con el mezclador, oscilador local y el programa informático que se utilice para visualización y análisis de la señal conforman la estructura de un sistema estándar de Guerra Electrónica. [33]

El funcionamiento de un receptor SDR parte de la conversión de la señal recibida a frecuencia intermedia. Aplica unos filtros de banda en lo que se conoce como sintonizador o *tuner* y a continuación, se demodula la señal para extraer datos con el software adecuado en el ordenador. El SDR incluye conversores analógico-digital (A/D) para la digitalización de la señal generando un flujo continuo de bits equivalente a la entrada analógica recibida. [34]

En el proceso de digitalización de la entrada recibida por la antena se convierten las señales analógicas en una secuencia de señales discretas llamadas “muestras” que el software del ordenador puede interpretar los valores. El sistema más habitual para transformar la frecuencia es el uso de un mezclador y un oscilador local (señal pura sin modular y estable en frecuencia).



Figura 3-10 SDR HackRF.

### 3.2.4 Down-Converter

Debido a que los radares de las lanchas trabajan en banda X se debe convertir esta frecuencia a una frecuencia intermedia. Por ello, cuando se quiere sintonizar una frecuencia alta, se utiliza un *down-converter*. Este está formado por un mezclador (Apartado 3.2.4.2) y un oscilador local (Apartado 3.2.4.1) cuya función es convertir la frecuencia recibida en una frecuencia intermedia. La señal de radiofrecuencia ( $f_{RF}$ ) se mezcla con la señal del oscilador local ( $f_{LO}$ ) y se obtiene la frecuencia intermedia ( $f_{IF}$ ). (Figura 3-11)

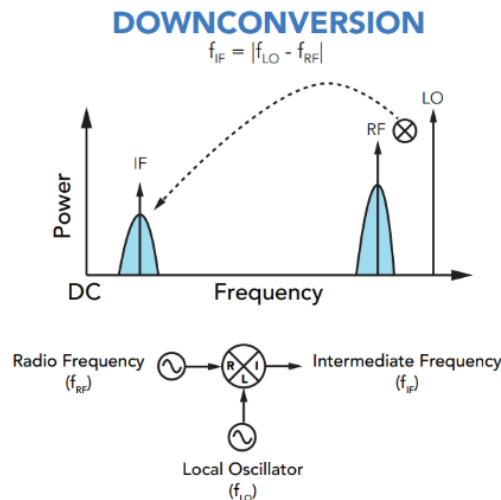


Figura 3-11 Down-Converter

Este montaje responde a la Ecuación 3-2, considerando un mezclador ideal. Sin embargo, debido a la no-linealidad de este tipo de aparatos es posible que se generen armónicos en la frecuencia de salida. En nuestro caso, teóricamente se recibe una señal con una frecuencia RF ( $f_{RF}$ ) de 9410 MHz por lo que deberíamos configurar el oscilador local a 10410 MHz ( $f_{LO}$ ) de forma que obtengamos 1000 MHz de frecuencia IF ( $f_{IF}$ ). Sin embargo, más adelante en el Apartado 3.4.2.1 se verá que no se utilizarán estos valores de frecuencia debido a que los radares de las Lanchas de Instrucción no trabajan a la frecuencia teórica mostrada en el manual (Anexo II).

$$f_{IF} = |f_{LO} - f_{RF}|$$

Ecuación 3-2  $f_{IF}$

### 3.2.4.1 Oscilador local

La función principal del oscilador local es bajar la frecuencia recibida del radar en banda X de las Lanchas a frecuencia intermedia como se ha explicado en Aparatado 3.2.3. Este equipo genera una señal denominada oscilador local y frecuencia ( $f_{LO}$ ) que mezclada con la recibida por la antena ( $f_{RF}$ ) desplaza la señal del radar a una frecuencia intermedia ( $f_{IF}$ ).

El oscilador utilizado es el ADF 5355-EVAL (Figura 3-12) que se encargará de desplazar la frecuencia de RF de las lanchas a un valor dentro del rango de trabajo del SDR (0-6 GHz).




Figura 3-12 Oscilador local alimentado con 6V.

### 3.2.4.2 Mezclador

El mezclador utilizado es de la casa Mini-Circuits que se encarga de cumplir la función de Up/Down Converter junto con el oscilador local. (Figura 3-13)



Figura 3-13 Mezclador.

### 3.2.5 Alimentación

A partir de una fuente de alimentación se alimenta al oscilador local. (Figura 3-14)



**Figura 3-14 Fuente de alimentación 6V.**

### 3.2.6 FieldFox Microwave Analyzer N9917A

Este aparato mostrado en la Figura 3-15 es un analizador de espectros portátil de alto rendimiento que permite múltiples funciones con entrega precisa de microondas y RF. Sus aplicaciones básicas son el análisis de cables, antenas y espectros.



**Figura 3-15 FieldFox Microwave Analyzer N9917A.**

## 3.3 Software

Para el procesado de la señal recibida, obtención de los principales parámetros de la emisión, así como el desarrollo del modelo de Inteligencia Artificial se han utilizado los siguientes programas.

- Matlab. Tiene múltiples aplicaciones como sistemas de aprendizaje automático, procesamiento de señales (nuestro caso), visión artificial, robótica, diseño de control... El lenguaje de Matlab se basa en matrices y mediante las gráficas integradas facilitan la visualización de los datos y la obtención de información y parámetros a partir de ellos. [35] En el desarrollo y trabajo con señales este software sirve para interpretar los archivos .dat de muestreo obtenidos con las Lanchas de Instrucción. Mediante este programa es posible procesar la señal recibida e interpretar sus valores.
- Google Collaboratory. Permite al usuario escribir y ejecutar código de Python en el navegador. Es muy utilizado para tareas de aprendizaje automático, análisis de datos y educación. Además, permite almacenar cuadernos y trabajar con datos que estén

almacenados en drive. En este caso lo se utiliza para crear el modelo, entrenarlo con datos almacenados en una librería de parámetros y evaluar sus predicciones de identificación y clasificación de emisiones. [36]

- El SDR HackRF descrito en el Apartado 3.2.3 lleva asociado un programa que nos permite realizar la grabación de las señales. Requiere de la introducción de la frecuencia de muestreo, el ancho de banda, la ganancia receptora y la velocidad de muestreo.

### 3.4 Recepción de señales reales

Para la recepción de las señales de las LLII se prepara un sistema receptor compuesto por los componentes mencionados anteriormente. Se utiliza una velocidad de muestreo de 20 MHz, máxima frecuencia a la que el SDR HackRF es capaz de muestrear. El Criterio de Nyquist, exige que la tasa de muestreo debe ser superior al doble del ancho de banda tal y como se muestra en la Ecuación 3-3.

$$f_s > 2 * BW$$

**Ecuación 3-3 Criterio de Nyquist**

En el caso de las LLII, según el Anexo II los modos SHORT y MED transmiten con 25 MHz de ancho de banda, mientras que el modo LONG lo hace con 3 MHz. Si se hacen los cálculos se obtiene que es necesario al menos 50 MHz para la transmisión con ancho de pulso corto y medio y 6 MHz para ancho de pulso largo. De esta forma, se concluye que no se cumple el Criterio para los modos SHORT y MED.

En estos casos en los que no se cumple el Criterio de Nyquist es posible que se produzca un fenómeno llamado “Aliasing”. Este se produce cuando se muestrea a una velocidad muy baja de forma que se pierde información obteniendo la señal con distorsiones. Sin embargo, en las muestras recogidas con los modos de transmisión SHORT y MED no se aprecia una distorsión notable que nos afecte.

En el desarrollo del modelo trabajando con emisiones reales se procede a recopilar las señales de cada una de las Lanchas de Instrucción. En particular, se obtiene señal de cada radar (alto y bajo) de la lancha por separado con modo PW SHORT y PW LONG. De esta manera, se graban dos señales por radar y por tanto cuatro por lancha (Figura 3-16). El motivo de no utilizar la variante del PW MED es que apenas se aprecia diferencia mientras que entre el SHORT y el LONG sí existe una variación más marcada.

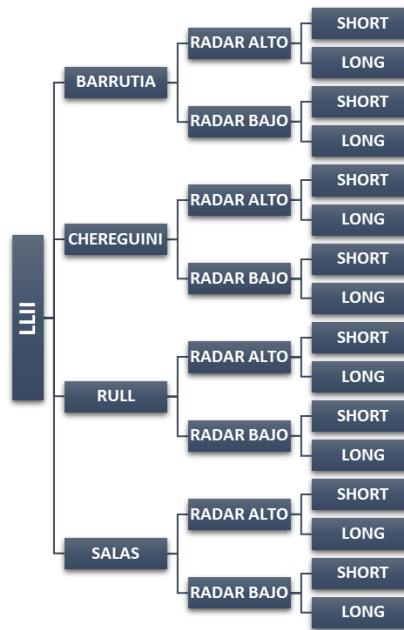


Figura 3-16 Esquema resumen recopilación señales LLII.

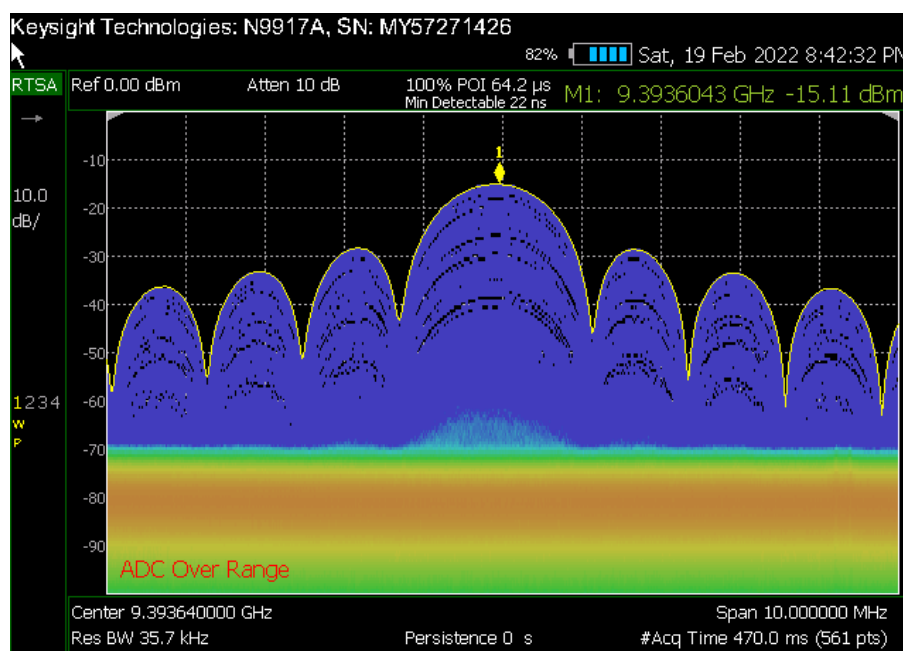
Tras haber realizado varios periodos de prueba de recepción y análisis de las señales, se obtiene emisión de las LLII en puerto atracadas en el muelle Almirante Vierna desde el Laboratorio de Investigación del CUD de cara a la dársena y, posteriormente desde el mismo Laboratorio, pero cara a la ría.

Los parámetros que se analizan y se recopilan en la base de datos para generar el set de entrenamiento y validación son los siguientes:

- **Frecuencia de operación de la antena.** Como se ha visto en el Apartado 3.4.1 el pico de frecuencia de transmisión de las LLII no se produce en 9,410 GHz. Es cierto que las cuatro LLII operan a la misma frecuencia. Sin embargo, este valor será de gran utilidad como un parámetro discriminatorio con otros modelos de radar.
- **Ancho de pulso.** Se tendrán en cuenta los diferentes valores de ancho de pulso obtenidos haciendo distinción si la señal corresponde a un modo de ancho de pulso u a otro.
- **Frecuencia de repetición de pulsos.** Al igual que en el caso anterior con el ancho de pulso se hará distinción en función de su modo de transmisión.
- **Ancho de banda a 6 dB.** Existen diferentes anchos de banda de los barridos en función del radar emisor. Un valor característico de cada radar que permite discriminarlos.
- **Velocidad de rotación de la antena.** Este parámetro es sin duda uno de los valores más importantes que se van a estudiar. Se obtiene a partir del tiempo transcurrido entre barridos.

### 3.4.1 Espectro señal LLII

Para comprobar la frecuencia exacta a la que operan los radares de las LLII se utiliza el equipo descrito en el Apartado Figura 3-15. Con el radar FURUNO de las Lanchas en transmisión en puerto se comprueba en que frecuencia está centrado el radar. En teoría según las características de este radar mostradas en el Anexo II la frecuencia de transmisión es 9,410 GHz. Sin embargo, como se muestra en la Figura 3-17 está desviado respecto al valor teórico.



**Figura 3-17 Figura 3 18 Detalle de frecuencia de operación del radar FURUNO de las LLII obtenido del analizador de espectros.**

El pico de potencia se produce en 9,3936 GHz que se encuentra dentro de los  $\pm 30$  MHz que indica el fabricante en el manual. De este modo, teóricamente deberíamos de muestrear a 1015 MHz para muestrear en el punto de máxima potencia.

Esta variación respecto al valor establecido de fábrica puede deberse al tiempo de uso y falta de revisiones para reajustar lo valores iniciales.

### 3.4.2 Sistema de recepción

El sistema receptor diseñado se utilizará para la recopilación de las señales de las LLII con el objetivo de tener una base de datos suficiente como para alimentar a la red neuronal. Una vez obtenidas todas las medidas deseadas de las señales se organizarán en un set de entrenamiento y un set de validación. Para ello se desarrolla una serie de algoritmos con el fin de procesar la señal recibida y los parámetros más relevantes de esta.

#### 3.4.2.1 Funcionamiento del sistema receptor

En primer lugar, la antena recibe la emisión radar que pasa al mezclador dónde se produce la conversión de la frecuencia a la que trabajan los radares de las LLII mediante el oscilador local que genera la señal que se mezcla con la recibida para generar la señal en frecuencia intermedia como se ha explicado en el Apartado 3.2.4.

Teóricamente, para poder procesar la señal se debería ajustar el oscilador local a 10410 MHz de forma que como el radar de las LLII trabaja en teoría a 9410 MHz, se generaría una señal a frecuencia intermedia de 1000 MHz. Sin embargo, vista la desviación del pico de potencia de la señal se genera la señal con una frecuencia de 1006 MHz para corregir esa diferencia. Es cierto que si fuésemos rigurosos deberíamos de utilizar una frecuencia intermedia de 1015 MHz, sin embargo, no cambiaría en gran medida los valores obtenidos. Si bien es importante tener en cuenta que el alcance de nuestro sistema receptor con las LLII sería mayor ajustando bien esta frecuencia.

La señal a frecuencia intermedia entre en el SDR HackRF y posteriormente mediante la conversión analógica/digital se conecta el sistema con el ordenador. Finalmente, se graba la señal y se procesa mediante Matlab a partir de una serie de algoritmos.

### 3.4.2.2 Algoritmos empleados

Para la realización de los algoritmos se parte de la base de otros trabajos anteriores que estaban relacionados con el tratamiento de señales radar y con la Guerra Electrónica. [33] El algoritmo de detección generado con Matlab se puede dividir en diferentes partes con diversas funciones y rutinas con el objetivo de agilizar el proceso de obtención de parámetros a partir de la señal: *load\_radar\_data*, *signal\_processing*, *calculate\_PDW*, *calculate\_BW* y *calculate\_n*.

- El código *load\_radar\_data.m* (Anexo VIII) tiene como función la carga de datos. Recibe el archivo del muestreo realizado previamente en formato .dat y lo carga en el programa. Consta con varias opciones de carga de datos dependiendo del SDR utilizado. En nuestro caso, utilizamos el HackRF (fopen).
- El código de detección *signal\_processing.m* (Anexo VII) incluye la ejecución del resto de funciones permitiendo la entrada del directorio del archivo que se desea visualizar. Además, incluye la función de representar el diagrama polar. En este código el usuario que esté realizando la recepción de señal debe introducir tres valores numéricos que se explicarán a continuación en el Apartado 3.4.2.3. Por este motivo, definimos el código desarrollado como semiautomático. De hecho, es conveniente revisar la ubicación de estos umbrales en las gráficas obtenidas de la señal para evitar tomar valores erróneos.
- *Calculate\_PDW.m* (Anexo IX) es el algoritmo de cálculo del PDW (Pulse Descriptor Word). Se denomina de esta forma a un conjunto de parámetros de una señal radar. El PDW cambia en función de los parámetros que se consideren más importantes de la emisión en cuestión. En nuestro caso, incluye parámetros como ancho de pulso (pw) y el periodo de repetición de pulsos (PRI) para el posterior cálculo del PRF. Este algoritmo se basa en el uso de los tiempos de llegada (TOA), tiempos de salida (TOD) y diferencia del tiempo de llegada (DTOA) los cuales son divididos por la frecuencia de muestreo para obtener los parámetros mencionados anteriormente. De esta forma, se obtienen los vectores con todos los PW y PRF del barrido que se está analizando.
- El algoritmo para el cálculo del ancho de haz a 6 dB es el *calculate\_BW* (Anexo IX). Este utiliza un umbral para obtener el valor del ancho en grados. Este valor se obtiene a partir del tiempo de barrido multiplicado por la velocidad de rotación y pasado a grados.

$$thetav = 6 * N * \frac{(nthend - nthini)}{fs}$$

**Ecuación 3-4 Ancho de haz a 6 dB (°)**

- *Calculate\_N.m* (Anexo X) sirve para obtener el valor de la velocidad de rotación de la antena en rpm. El cálculo se realiza a partir de la diferencia de tiempo entre los máximos de dos barridos consecutivos.

$$tscan = abs(loc(2) - loc(1)); N = \frac{60}{tscan}$$

**Ecuación 3-5 Velocidad de rotación (rpm)**

### 3.4.2.3 Obtención de parámetros de la señal

Para alimentar la red neuronal se necesitan extraer los parámetros de las señales recopiladas de las Lanchas de Instrucción que serán etiquetados para posteriormente se introducidos en la red neuronal. Para la obtención de los parámetros se utiliza un sistema de umbrales (*thresholds*) que determinan el margen dentro del cual las detecciones de los TOA (Figura 2-15) y los TOD son correctas y no se obtienen valores erróneos. Los TOA y los TOD marcan el inicio y el final de cada pulso de tal forma que mediante ellos se pueden obtener varios parámetros de la señal.

Los dos umbrales ( $th1$  y  $th2$ ) se introducen manualmente dependiendo de la amplitud de la señal en cuestión. En la Figura 3-18 se muestra cuales se han escogido en este caso ( $th1 = 0.4$  y  $th2 = 0.4$ ). A mayores existe un tercer umbral que se utiliza para fijar el ancho de banda a 6 dB como ya se ha explicado anteriormente. Dependiendo de la calidad de la señal, amplitud, ruido o interferencias de otros buques se escogerán los umbrales más adecuados para obtener los valores de los parámetros con la mayor precisión posible.

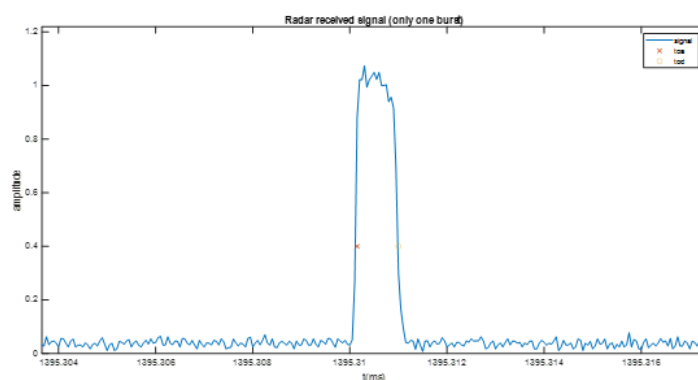
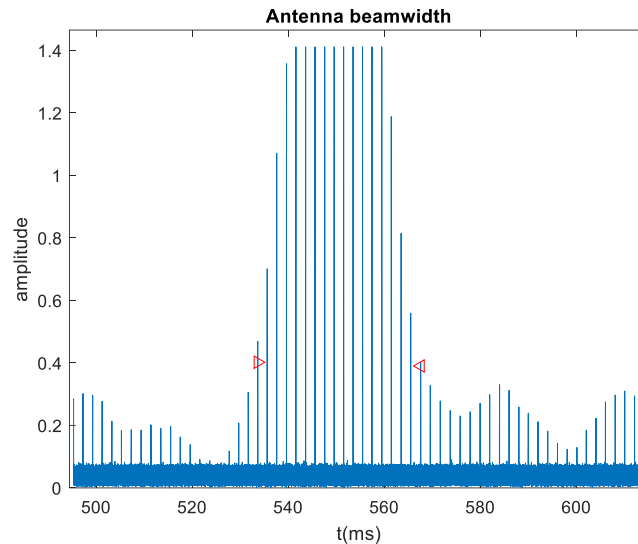


Figura 3-18 Pulso del radar alto modo LONG de la A-121 GM. Barrutia.

En la Figura 3-18 se muestran los TOA con una cruz en rojo y los TOD con un círculo en amarillo. Estos valores nos proporcionarán el ancho de pulso y el PRF de la señal. Para la determinación del PW se utiliza la diferencia entre el TOA y el TOD de cada pulso. Mientras que para la obtención del PRF, el código obtiene en primer lugar el PRI a partir de la diferencia entre dos comienzos de pulso consecutivos (TOA). Para cada de TOAs y TODs el código funciona como un bucle de manera que se obtienen diferentes valores de PW y de PRF. Los valores son divididos por la frecuencia de muestreo y finalmente se obtienen el PW y el PRF.




**Figura 3-19** Marcas del umbral para el cálculo del ancho de haz en una señal recibida de las LLII.

En cuanto a la obtención del ancho de haz es conveniente decir que se debe de establecer el umbral lo más bajo posible sin ser afectado por el ruido recibido. En la Figura 3-19 se muestra en umbral establecido para una señal en particular.

En ciertas ocasiones debido a las interferencias de otros buques o a la saturación de la señal, los algoritmos no son capaces de aportar valores precisos. Por lo que se realizan los cálculos del PRF, N y ancho manualmente.

### 3.4.3 Recepción de señal con LLII en tierra

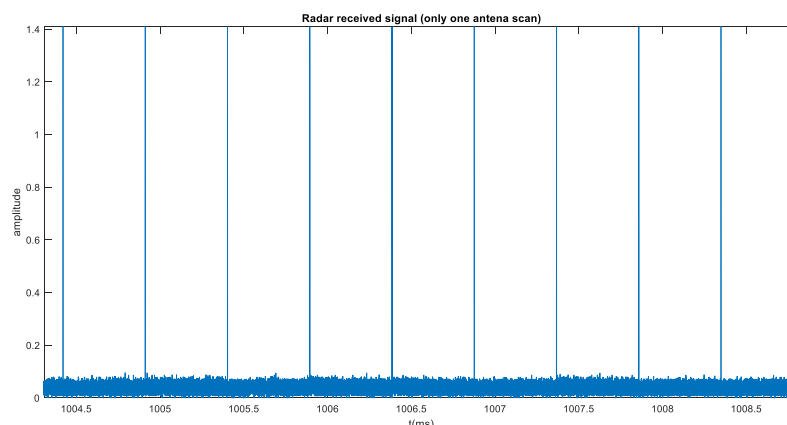
En esta fase de recopilación de señales se obtienen emisiones de las LLII atracadas en el muelle desde el Laboratorio Investigación del CUD obteniendo 16 archivos con el muestreo de cada señal. El montaje del sistema receptor se muestra en la Figura 3-20. Se obtiene un muestreo de 6 segundos de duración de forma que se puedan recoger dos barridos completos ( $t_{barrido} = 2,51 s$ ). Los resultados obtenidos son bastantes buenos debido a la cercanía de las LLII. La saturación de la señal se puede observar fácilmente.



**Figura 3-20** Montaje para recepción de señales en tierra.


Como se puede observar en la Figura 3-21, la calidad de la señal obtenida es muy buena y se pueden apreciar los pulsos con un umbral de ruido de 0,1 V de amplitud. Con estos parámetros, la rutina de Matlab proporciona el vector con los valores de los diferentes anchos de pulso del barrido y obtiene

como resultado valores constantes que concuerdan con el teórico detallado en el manual del radar (Anexo II).



**Figura 3-21** Detalle de los pulsos del radar bajo en modo SHORT de la A-121 GM. *Barrutia* en puerto.

Además, se procesa el diagrama de radiación de las señales tomadas que representa en coordenadas polares la señal recibida de un barrido completo. Este será de gran utilidad para visualizar el ancho de haz, aunque la forma de obtenerlo no será mediante los diagramas polares de las señales sino a partir de gráficas respecto al tiempo de los barridos de la señal emitida como por ejemplo la mostrada en la Figura 3-19. En particular, el barrido mostrado en la Figura 3-22 corresponde a una Lancha de Instrucción en puerto por lo que la señal satura. Además, se obtienen los lóbulos principales, laterales y posterior.



**Figura 3-22** Diagrama de radiación del radar bajo en modo SHORT de la A-123 GM. *Rull* en puerto.

Más adelante se observará que a mayor distancia ya no satura de la misma manera en el caso anterior (medición en puerto) y que únicamente se observan unos pequeños lóbulos laterales.

### 3.4.4 Recepción de señal con LLII en la mar


A diferencia de la recepción de emisiones descrita en el Apartado 3.4.3, la recepción de señales con las Lanchas de Instrucción en navegación está condicionada por muchos parámetros como la meteorología interferencias propias de otras LLII o buques ajenos transmitiendo en banda X. Además,

se debe de tener en cuenta la gran sensibilidad de los equipos ante cualquier cambio de condiciones en el ambiente. De este modo, es muy importante revisar los valores obtenidos y comprobar que estamos recogiendo señal de cada Lancha y no existe ninguna otra plataforma transmitiendo.

Se realizan dos fases descritas detalladamente a continuación. Como resultado se obtienen muestras para tres distancias distintas ( $Z_0$ ,  $Z_1$  y  $Z_2$ ) respecto a la posición del equipo receptor (Laboratorio de Investigación).

#### *3.4.4.1 Primera fase de recepción de señal con LLII en la mar*

Para esta fase se obtiene señal de las LLII desde la parte de cara a la ría de Pontevedra del edificio del Laboratorio de Investigación como se muestra en la Figura 3-23. Para esta fase se coordina con el Núcleo de Lanchas y las dotaciones para la preparación de la secuencia de transmisiones radar. Respecto al montaje del sistema receptor es el mismo que el utilizado para recopilar señal de las LLII en puerto descrito en el Apartado 3.4.1.



**Figura 3-23 Montaje recepción señal LLII con Lancha de Instrucción A-124 GM Salas de fondo.**

Se establece un punto  $Z_0$  que se encuentra a 0,6 MN de la posición de recepción por el que van pasando cada una de las lanchas para realizar las mediciones. En el punto  $Z_0$  cada una de las lanchas comienza la secuencia establecida de transmisión. (Figura 3-24)


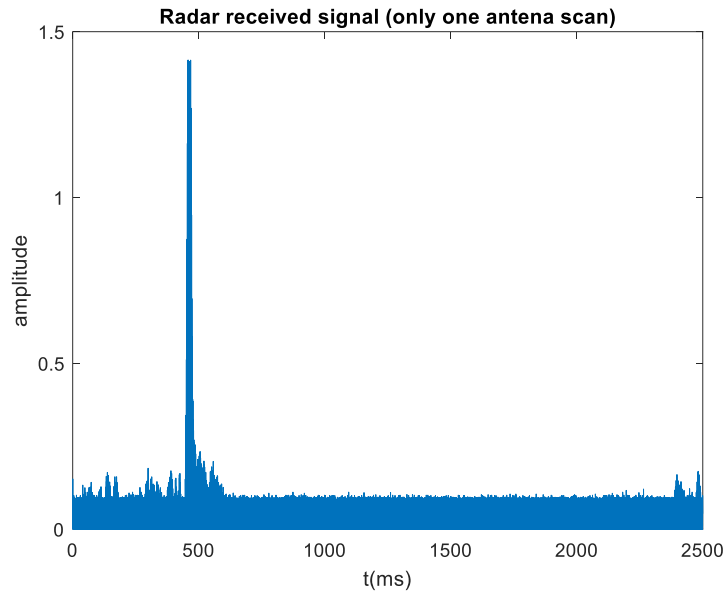


Figura 3-24 Posición punto Z0 respecto al Laboratorio de Investigación (OpenCPN).

Se lleva a cabo la siguiente secuencia con la colaboración de los Guardiamarinas de 2º embarcados en las Lanchas.


1. Al llegar a Lancha se encienden los radares y se ponen en STAND BY, de forma que ninguna Lancha tenga equipos en transmisión.
2. Se procede a salir a la mar por orden habitual (*GM. Salas – GM. Rull – GM. Chereguini – GM. Barrutia*) sin radares en transmisión. Una vez fuera de la dársena se dirigen en este orden al punto Z0 con coordenadas ( $42^{\circ} 23.88 \text{ N} - 008^{\circ} 43.21 \text{ W}$ ) mostrado en la Figura 3-24.
3. Una vez en las inmediaciones del punto indicado, cada Lancha enciende sus radares y empieza la transmisión para su recepción en tierra. Se coordina con tierra para ir transmitiendo en los distintos modos y con los dos radares.
4. Al finalizar la transmisión y verificar la señal en los equipos de tierra, la Lancha en cuestión procede a apagar sus radares mientras que la Lancha siguiente comienza a transmitir.

La calidad de las señales obtenidas es buena debido a la potencia del radar de las LLII y al bajo ruido ambiente que se mantiene en todas las mediciones en una amplitud de 0,1. En la Figura 3-25 se muestra un barrido tomado a 0,6 MN de la Lancha. Es conveniente comentar que existen diferencias muy marcadas entre las señales obtenidas en puerto y las realizadas con emisores en navegación a largas distancias.



**Figura 3-25 Barrido del radar bajo modo SHORT de la A-121 GM Barrutia desde la mar (0,6 MN).**

De hecho, en las muestras tomadas con las LLII en tierra se podía apreciar mayor saturación de la señal a su llegada al receptor. De hecho, si comparamos la Figura 3-22 con la mostrada a continuación (Figura 3-26), podemos observar que en la muestra tomada con la Lancha A-121 GM. Barrutia navegando no figuran los lóbulos laterales ni posterior.



**Figura 3-26 Gráfico de radiación A-121 GM. Barrutia en la mar (0,6 MN).**

Tras haber realizado el muestreo se procede a comprobar el alcance del sistema receptor con la última Lancha en realizar la secuencia (A-121 GM. Barrutia). En función de las primeras mediciones realizadas se estima que el alcance del sistema de recepción se encuentra alrededor de 1,1 MN. De hecho, la última señal que se obtiene es del radar alto con ancho de pulso LONG a una distancia de 1,014 MN como se muestra en la Figura 3-27. Se puede apreciar que a diferencia de la señal obtenida en puerto la amplitud de la señal recibida es mucho menor ( $A = 0,27 \text{ V}$ ). Sin embargo, posteriormente veremos la dificultad de encontrar un valor exacto para el alcance de nuestro sistema receptor. Por lo tanto, es complicado estimar el alcance de nuestro montaje debido a las condiciones cambiantes del entorno y la

dependencia de la potencia emisora. Por otro lado, otro factor importante a destacar en esta medición es el valor constante de la amplitud del ruido que se mantiene con una amplitud de 0,1 V durante todas las recepciones realizadas.

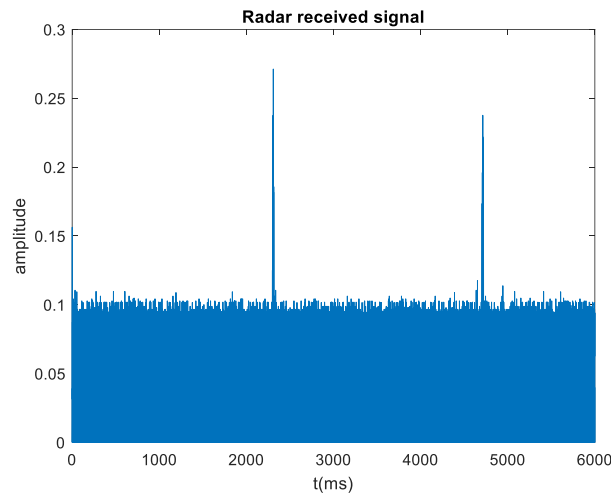


Figura 3-27 Barridos de la A-121 GM. Barrutia a 1,014 MN de distancia.

### 3.4.4.2 Segunda fase de recepción de señal con LLII en la mar

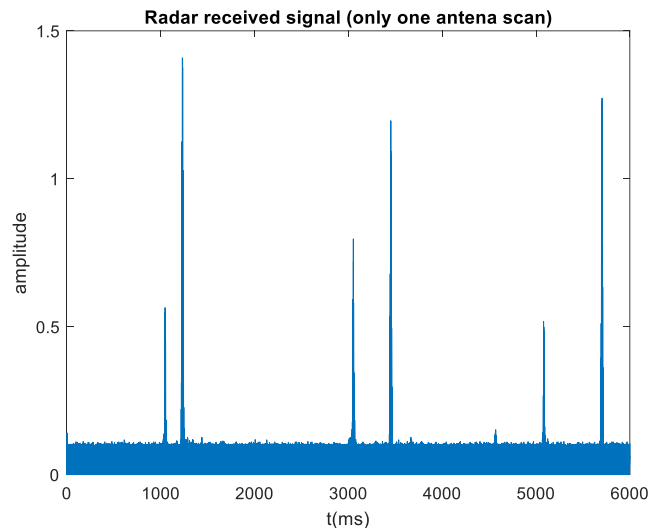
En esta fase de recepción se aumentaron las distancias para obtener situaciones diferentes que pudiesen alimentar a la base de datos del modelo. Debido a las conclusiones obtenidas en la primera fase de recepción de señales con las LLII navegando se decide colocar dos puntos para realizar las medidas de cada Lancha, cada radar en cada modo de ancho de pulso. Estos dos puntos son el Z1 y el Z2 que se ubican 0,8 y 1 MN respectivamente desde el Laboratorio de Investigación (Figura 3-28).



Figura 3-28 Posición puntos Z1 y Z2 respecto al Laboratorio de Investigación (OpenCPN).

En esta recepción de señales se coordina con las LLII de igual modo que en el Apartado 3.4.4.2 excepto que se realiza la secuencia dos veces. Esta fase de recepción se ve condicionada por una interferencia que probablemente fuese un pesquero o una embarcación pequeña transmitiendo en banda

X. Esto supone que todas las medidas tomadas están contaminadas. En consecuencia, se tendrá que analizar detalladamente los parámetros de cada uno de los barridos con el objetivo de identificar cual es la señal de las LLII. A partir de los valores teóricos del manual del radar FURUNO de las LLII (Anexo II) y comparándolos con los parámetros obtenidos de las señales recibidas se clasifican los barridos.



**Figura 3-29 Barridos de la Lancha de Instrucción A-121 GM. Barrutia junto con interferencia de origen desconocido.**

Como se muestra en la Figura 3-29, existe un radar que estamos recibiendo a la vez que la Lancha de Instrucción por lo es necesario identificar que barridos corresponden a la Lancha.

A partir del algoritmo de cálculo de la velocidad de rotación descrito en el Apartado 3.4.2.2 se calculan las velocidades de rotación de cada emisión y se obtiene que el emisor interferente tiene un radar que opera a 28,3 rpm, mientras que el giro de antena teórico de las LLII es 24 rpm. Aun así, se analizan los valores de la velocidad de rotación de las Lanchas para comprobar si coinciden con el manual.

Tras haber analizado las diferentes velocidades de rotación de las LLII se concluye que debido al tiempo desde su adquisición y las escasas revisiones al equipo la velocidad de rotación ha variado respecto al valor inicial marcado en el manual del FURUNO.

### *3.4.5 Recepción de señales de otros buques*

Durante el proceso de recopilación de emisiones de las LLII surge la posibilidad de agrandar el volumen de la base de datos. Se obtienen señales de diversos buques con otros modelos de radar FURUNO para utilizarlos de forma que el modelo indique que no coincide con ninguna de las LLII. Estas medidas se almacenan en la base de datos de emisiones. Servirán para completar el set de entrenamiento para que el modelo discrimine si una emisión es de una Lancha o si pertenece a otro buque cuyos parámetros no coinciden con los de las LLII.

### 3.4.5.1 Buque desconocido interferente

En la segunda fase de recepción de señales en la mar descrita en el Apartado 3.4.4.2 se mencionó la presencia de un radar en banda X interferente al grabar señal de las LLII. A pesar de ser un problema que ralentiza la recopilación y el análisis de valores, tiene su lado positivo pues su paramétrica puede ser introducida en la base de datos al igual que la del resto de buques descritos más adelante.

En consecuencia, se procede a la recopilación de los valores mencionados. Este proceso lleva más tiempo que el habitual (señales limpias sin interferencias) debido a que tenemos barridos de emisores diferentes.

### 3.4.5.2 “Águila I”

Se recoge señal del patrullero de alta velocidad clase “Cormorán” *Águila I* en una colaboración con la dotación de este buque basado en la Escuela Naval Militar. Esta patrullera tiene un radar FURUNO modelo FAR-2827 (Figura 3-30) cuyas características se exponen en el Anexo IV.



Figura 3-30 Puesto de la patrullera de Aduanas *Águila I* con radar FURUNO FAR-2827.

La recepción de señal se realiza con el buque en puerto desde el Laboratorio de Investigación cara a la dársena. A diferencia del radar 1944C de las LLII, el FAR-2827 tiene una velocidad de rotación mucho mayor. De hecho, los valores obtenidos superan las 36 rpm, mientras que la señal recibida del radar de las LLII oscila entre 24 y 26 rpm.

### 3.4.5.3 Buque de Salvamento Marítimo (BS-14) “María Pita”

Se realiza una colaboración con el Buque de Salvamento Marítimo BS-14 *María Pita* en el muelle de torpedos. Este buque es un remolcador de altura cuya función es el adiestramiento y preparación para situaciones de rescate de naufragos, remolque de buques en situación comprometida o apoyo a barcos con problema de diferente índole. Como se puede observar en la Figura 3-31 consta de dos radares FURUNO que operan en banda S y X (radares bajo y alto respectivamente). Este último es con el que se realiza el muestreo de la emisión, de la que se obtienen los principales parámetros característicos de este buque para su incorporación a la base de datos. En concreto se trata del modelo FAR-2127 cuyas características principales se exponen en el Anexo III.



**Figura 3-31 Buque de Salvamento Marítimo BS-14 *María Pita* atracado en el muelle de Torpedos con radar bajo (banda S) y alto (banda X).**

La primera medición de las señales se realiza con el buque atracado en la Escuela Naval Militar desde el Laboratorio de Investigación cara a la dársena. La cercanía y la potencia radar facilitaron la detección de una buena señal. (Figura 3-32)



**Figura 3-32 Vista desde la consola radar situada en el puente del BS-14 *María Pita* con el Laboratorio de Investigación al fondo.**

Además de estas capturas de emisiones en puerto se realizan otras con el buque en navegación saliendo de la Ría de Pontevedra (Figura 3-33). Se obtiene señal cada minuto con el buque navegando a una rumbo y velocidad constante. De esta manera, podemos estudiar cómo evoluciona la potencia de la señal recibida en nuestro sistema respecto a la distancia al mismo.



**Figura 3-33 Ruta realizada por BS-14 *María Pita* saliendo de la dársena de la Escuela Naval Militar (VesselFinder).**


En la Tabla 3-3 se puede apreciar la evolución de la amplitud respecto a la distancia al sistema receptor. Es conveniente comentar que la amplitud de los dos primeros valores es 1,4 V debido a que la señal está saturando en nuestro sistema receptor.

Distancia (MN)	Amplitud de señal (V)
0,28	1,4
0,58	1,4
0,88	0,68
1,37	0,54
1,54	0,38
1,69	0,32
1,86	0,22

**Tabla 3-3 Relación distancia-amplitud del BS-14 *María Pita*.**


#### 3.4.5.4 GCM-31 “*Corvo Mariño*”

Con el objetivo de aumentar la base de datos de emisiones radar se realiza una colaboración con la patrullera GCM-31 *Corvo Mariño* de la Guardia Civil. Este buque pertenece al Servicio Marítimo de la Guardia Civil (SEMAR) cuya función se basa en la vigilancia de las aguas territoriales y tiene encomendadas misiones de diversos ámbitos (judicial, fiscal, administrativo, gubernativo...). Se obtienen muestras de la patrullera navegando en la Ría de Pontevedra en las inmediaciones de la Escuela Naval Militar como la mostrada en la Figura 3-34. Esta Patrullera consta de un radar FURUNO modelo FAR-2117BB en banda X. Este modelo de radar es muy común en pesqueros de medianas esloras.



**Figura 3-34 Diagrama polar de la Patrullera Guardia Civil GCM-31 *Corvo Mariño* navegando en la Ría de Pontevedra.**

El muestreo de la señal radar de este buque se realizó en periodo de adiestramiento de las LLII, se obtuvieron algunas muestras donde se pueden apreciar los barridos de una Lancha de Instrucción y del GCM-31 *Corvo Mariño*. En la Figura 3-35 se puede observar que la emisión de la Lancha de Instrucción se recibe con menor potencia y una velocidad de rotación del radar mucho menor (25,89 rpm y 34,97 rpm respectivamente). Por lo tanto, es conveniente percatarse de la importancia del parámetro “N” para la discriminación de las diferentes emisiones introducidas en el modelo.



**Figura 3-35 Recepción de barridos de una Lancha de Instrucción y de la Patrullera GCM-31 *Corvo Mariño* simultáneamente.**

#### 3.4.5.5 A-07 “Río Guadalope”

Además de recibir señal del GCM-31 *Corvo Mariño* como se ha descrito en el Apartado 3.4.5.5 se graba la emisión A-07 *Río Guadalope* (Figura 3-36). Este último es de mayor eslora y manga que al igual que el GCM-31 *Corvo Mariño* está basado en la Escuela Naval Militar.



Figura 3-36 A-07 *Río Guadalupe* atracado en la dársena de la Escuela Naval Militar.

Consta de dos radares FR-2125 posicionados a diferentes alturas que transmiten en banda X. En el momento de la recepción de señal en puerto surgen algunos problemas debido a que el sistema receptor se encontraba dentro de la mínima distancia de transmisión. Sin embargo, una vez posicionado el montaje fuera de este rango, se consigue recibir señal y obtener los parámetros característicos de la misma.

Tras haber analizado los valores del “pw” de la señal, se observa, que el radar en cuestión varía su ancho de pulso cada varios pulsos. Transmitiendo con pulsos de 0,8 y 0,3  $\mu\text{s}$  alternativamente. Sin embargo, se ha utilizado solo los valores cercanos a 0,8  $\mu\text{s}$  con el objetivo de simplificar el entrenamiento de la red neuronal. Esto tiene que ver con la escala seleccionada. De hecho, este radar alterna diferentes anchos de pulso en escalas intermedias.

El motivo de este sistema de transmisión de pulsos cortos y largos alternativamente es evitar la pérdida de información sobre crudos o contactos cercanos cuando se está utilizando una escala grande. De hecho, en radares no dotados de este sistema cuando se utiliza una escala grande (anchos de pulso grandes) se pierde precisión y capacidad de detección en distancias cortas.

#### 3.4.5.6 Buque Escuela de Cooperación Pesquera (BECP) (A-41) “*Intermares*”

Con motivo de la recalada del BECP *Intermares* (A-41) en el muelle de Torpedos de la Escuela Naval Militar se recopilan muestras de la señal radar del mismo. Este buque cuenta con un radar Sperry en banda S y un FURUNO FAR-2827 que transmite en banda X (Anexo IV). De este último, se recopila y analiza la paramétrica para ser implementada en la base de datos. El muestreo se realiza con el buque navegando en las inmediaciones de la Escuela Naval Militar y finaliza con su atraque (Figura 3-37). Al contrario que en el caso de la Patrullera de la Guardia Civil GCM-31 *Corvo Mariño* descrito en el Apartado 3.4.5.4, la velocidad de rotación no difiere de las LLII en gran medida. Sin embargo, los valores obtenidos de ancho de pulso y frecuencia de repetición de pulsos pueden significar dos parámetros de gran valor discriminatorio respecto al resto de buques.



Figura 3-37 BECP *Intermares* (A-41) en el muelle de Torpedos transmitiendo con el radar en banda X.

### 3.5 Elaboración de la base de datos

Una de las partes con mayor importancia para obtener buenos resultados en el entrenamiento del modelo de red neuronal creado es la base de datos a partir de la cual se crearán el set de entrenamiento y validación. Estos se elaboran a partir de todas las emisiones almacenadas en la librería elaborada a partir de la obtención de parámetros de las señales recopiladas. Contiene cinco parámetros de cada tipo y modo de radar. Se deciden utilizar 15 valores de cada uno de los parámetros ya descritos en el Apartado 3.4.2.3. Sin embargo, existen ocasiones en las que no es posible disponer de esta cantidad de datos. Es preferible introducir pocas muestras correctas que un gran volumen de estas, pero sin tener la certeza que sean buenas. Es por ello que los valores obtenidos a partir de los algoritmos desarrollados descritos el en Apartado 3.4.2.2 deben ser revisados a conciencia para evitar confundir al modelo. De hecho, se han tenido que realizar manualmente los cálculos de algunos parámetros debido al mal funcionamiento de las rutinas en presencia de interferencias o ruido.

Es conveniente decir que la frecuencia de trabajo de los radares analizados no varía de manera notable mientras que las velocidades de rotación y anchos de haz cambian para cada radar/modo en cuestión. Por otro lado, se obtiene un gran volumen de anchos de pulso y frecuencias de repetición de pulsos que coinciden dentro de un rango comprensible con los teóricos mostrados en el manual del radar.

Para la introducción de valores en la base de datos es importante comprobar y analizar los valores obtenidos de forma que sean coherentes. Eliminar los *outliers* o valores muestreados anormales que puedan afectar potencialmente al entrenamiento y aprendizaje de la red neuronal es de vital importancia. Las consecuencias de alimentar al modelo con valores incorrectos pueden provocar un desaprendizaje y la no consecución de los objetivos propuestos.

En la Tabla 3-4 se muestra un esquema resumen de los radares con los que se ha trabajado durante el trabajo. Es conveniente decir que todos los radares son marca FURUNO y que todos transmiten en banda X.

**Buque**

**Radar  
FURUNO**

---

Lanchas de Instrucción	1944C
Buque X	-
<i>Águila I</i>	FAR 2827
BS-14 <i>María Pita</i>	FAR 2127
GCM-31 <i>Corvo Mariño</i>	FAR-2117BB
A-07 <i>Río Guadalupe</i>	FAR-2125
A-41 <i>Intermares</i>	FAR-2827

**Tabla 3-4 Resumen de los modelos de radar FURUNO de cada buque.**

Como se puede observar el *Águila I* y el A-41 *Intermares* tienen el mismo modelo de radar por lo que es probable que el modelo se confunda en mayor medida entre los dos buques, al igual que ocurre con las cuatro Lanchas de Instrucción entre sí.

### 3.5.1 Evaluación de la calidad de los valores obtenidos

Como se ha dicho en el Apartado 3.5, para evitar confundir al modelo de AI es vital evaluar si los valores obtenidos son coherentes con sus respectivos manuales de sus radares antes de ser introducidos en la red neuronal.

En particular, los dos parámetros de más dudosa calidad son la frecuencia de operación del radar y el ancho de haz a 6 dB. En cuanto al primero, los valores obtenidos con las diferentes emisiones analizadas son constantes y no aportan ninguna información relevante a la librería de señales. Por otro lado, el segundo parámetro tampoco aporta valores claros o patrones de cada radar. De hecho, el ancho de haz obtenido varía en función de la calidad, distancia al emisor o potencia con la que se haya recibido. Aun realizando el cálculo a mano no se obtienen conclusiones rigurosas como para afirmar que este parámetro pueda aportar algo al modelo. Pese a esto, estos dos parámetros serán probados y evaluados en el modelo para comprobar cómo responde la red al entrenamiento y observar su funcionamiento y predicciones.


En cuanto al ancho de pulso (“pw”), periodo de repetición de pulsos (“PRF”) y velocidad de rotación del radar (“N”) se prevé que su implementación en el modelo sea de provecho debido a que a simple vista siguen un patrón constante en función del buque y radar en cuestión.

Un punto importante a comentar son los valores obtenidos en la Patrullera de Aduanas *Águila I* y en la Patrullera de la Guardia Civil GCM-31 *Corvo Mariño*. Pese a que en las especificaciones de sus radares (Anexo IV y Anexo V) aparecen velocidades de rotación fijas, se han analizado velocidades que no coinciden con las previstas en los mismos. Tras revisar las señales recibidas y notificar este hecho al personal de mantenimiento de los equipos radar de las embarcaciones, se llega a la conclusión que este tipo de patrulleras rápidas tienen un complemento instalado en los equipos radar. El motivo es la necesidad de poder modificar el tiempo de refresco de la información. De hecho, esta modificación es de gran utilidad para cuando la embarcación navega a altas velocidades. De esta forma, a grandes velocidades se seleccionarán mayores velocidades de rotación con el objetivo de actualizar la información cada menos tiempo.

Finalmente, conviene observar cómo se distribuyen los valores del ancho de pulso y del periodo de repetición de pulso en histogramas generados en Matlab. A continuación, se muestran los histogramas


de una señal recibida de la Lancha de Instrucción A-123 *GM. Chereguini* navegando en la Ría de Pontevedra.

En cuanto al ancho de pulso, se puede identificar claramente dónde se produce el pico de los valores más comunes. En este caso mostrado en la Figura 3-38, el pico de los datos se produce en 0,15  $\mu\text{s}$  y la dispersión de los datos es desde los 0,05  $\mu\text{s}$  hasta los 0,25  $\mu\text{s}$ .



**Figura 3-38** Histograma de los valores obtenidos de los anchos de pulsos de la *GM. Chereguini* transmitiendo con el radar bajo en modo **SHORT**.

En cuanto al periodo de repetición de pulsos, podemos observar en la Figura 3-39 que los valores más comunes se producen entre los 2080 Hz y 2090 Hz. Los valores oscilan desde los 2010 Hz hasta los 2130 Hz.



**Figura 3-39** Histograma de los valores de PRF obtenidos de la *GM. Chereguini* transmitiendo con el radar bajo en modo **SHORT**.

Ambos histogramas nos indican cómo se comportan los valores de ancho de pulso y frecuencia de repetición de pulsos. Aparentemente, la forma de los histogramas es coherente ya que los valores más comunes aparecen en el centro de la campana mientras que los menos frecuentes se ubican en los extremos.

### 3.6 Descripción del modelo de AI

En este apartado se describe detalladamente el funcionamiento del modelo tratado previamente en el Apartado 3.1.2.1 y las variaciones aplicadas respecto a la propuesta inicial.

Una vez realizada y revisada la base de datos creada a partir de los parámetros de los diferentes radares recibidos, se procede a realizar las modificaciones necesarias al código descrito en el Apartado 3.1.2.1 para adaptarlo a la base de datos creada a partir de emisiones reales. En este apartado se describirán las partes más importantes del mismo.

Uno de los primeros pasos es importar los valores numéricos de los radares de cada uno de los buques que se encuentran en sus correspondientes hojas del Excel (BBDD.xlsx).

```
# Append "Chereguini" dataset
df = pd.read_excel('/content/drive/MyDrive/BBDD.xlsx', sheet_name = 1, usecols = require_cols, skiprows=1, nrows=239, header=None, dtype=float)
radars_raw = radars_raw.append(df, ignore_index=True)
#radars_raw.tail()
#df.hist(column=[6,7])
```

**Figura 3-40 Carga de datos de la GM. Chereguini en el modelo de AI.**

Como se puede ver en la Figura 3-40 es necesario introducir la hoja del Excel (*sheet\_name*) que corresponde con el buque en cuestión, las filas que se deseen ser cargadas (*skiprows*, *nrows*). En caso de que haya celdas vacías en el archivo, estas no son leídas por el modelo.

El código permite la entrada de los parámetros que se desee. De esta forma, se puede estudiar el comportamiento del modelo implementando todos o solo aquellos parámetros que se quieran estudiar. De hecho, veremos más adelante en el Apartado 4.1.1 cómo reacciona con cada uno de ellos por separado y en conjunto. Esta opción permite conocer con que configuración aprende mejor el modelo.

```
# Simulation parameters
require_cols = [4,6,7,9] # columns to process
number_of_classes = 24 # number of radar classes
keep = [19,21,22,23] # classes to keep
threshold = 3
```

**Figura 3-41 Selección de los parámetros y las clases de radares para entrenar al modelo de AI.**

En la Figura 3-41 se muestran las líneas donde se seleccionan los parámetros con los que se quiere realizar el entrenamiento de la máquina indicando el número de columna correspondiente de la base de datos. Además, se indican las clases de radares con las que se quiera entrenar y verificar el comportamiento y las posteriores predicciones del modelo.

Los diferentes radares y sus modos de operación están correlacionados con una serie de etiquetas numéricas como se muestra en la Figura 3-42. En el caso de las Lanchas de Instrucción o en el del BS-14 *María Pita* se ha optado por utilizar diferentes etiquetas para distintos modos de transmisión con el objetivo de que el modelo detecte un patrón concreto de cada etiqueta. En total son 23 etiquetas de las cuales se seleccionarán aquellas con las que se quiera entrenar a la máquina. Esto se materializa introduciendo el número de etiqueta en el vector *keep* mostrado en la Figura 3-42. De esta forma, tenemos la posibilidad de estudiar el nivel de aprendizaje alcanzado en función de las clases de radar introducidas.

```

display_labels= ['BAR_B_L', 'BAR_B_S', 'BAR_A_L', 'BAR_A_S'] # 1-4
display_labels+= ['CHE_B_L', 'CHE_B_S', 'CHE_A_L', 'CHE_A_S'] # 5-8
display_labels+= ['RUL_B_L', 'RUL_B_S', 'RUL_A_L', 'RUL_A_S'] # 9-12
display_labels+= ['SAL_B_L', 'SAL_B_S', 'SAL_A_L', 'SAL_A_S'] # 13-16
display_labels+= ['DESCON'] # 17
display_labels+= ['MAPITA-I', 'MAPITA-II'] # 18-19
display_labels+= ['ADUANAS'] # 20
display_labels+= ['CORVOMARIÑO'] # 21
display_labels+= ['INTERMARES'] # 22
display_labels+= ['RIOGUADALOPE'] # 23
label_list = labels.value_counts().sort_index()
    
```

Figura 3-42 Etiquetas de los buques.

A pesar de haber comprobado los valores de la base de datos y eliminar los *outliers* de cada una de las señales, se implementa un código para realizar un filtrado de valores con cada uno de los parámetros introducidos. Para ello se emplea el concepto de z-score (Figura 3-43) que nos permite estandarizar la distribución de valores y filtrar los valores que se separen una determinada distancia de la media. Este concepto se mide mediante una proporción del número de desviaciones estándar que se desvían los datos de la media. El resultado obtenido de la Ecuación 3-6 revela el número de desviaciones estándar de la media del valor en cuestión.

$$z = \frac{x - \mu}{\sigma}$$

Ecuación 3-6 Z-score

En nuestro caso utilizaremos este concepto para eliminar los valores incorrectos o excesivamente separados de la media con posibilidad de seleccionar el z-score oportuno (1, 2 ó 3) en función de los datos disponibles. De esta forma, filtraremos un mayor número de valores dependiendo del z-score escogido.




Figura 3-43 Volumen de datos seleccionados en función del z-score utilizado.

Otro punto a comentar es escoger el volumen de datos que se quieran destinar al set de entrenamiento y al de validación. En general, se suele utilizar un 80% de los valores disponibles para el set entrenamiento y un 20% para el de validación. Sin embargo, más adelante estudiaremos el comportamiento del modelo en función de la modificación de este parámetro.

En la fase de entrenamiento de la máquina existe la posibilidad de seleccionar el número de “epochs”. Dentro del contexto del aprendizaje automático, se refiere a un ciclo completo a través de todo

el conjunto de datos del set de entrenamiento. Indica el número de pasadas que el algoritmo de aprendizaje automático completa durante el entrenamiento en cuestión. Es común pensar que a mayor número de “epochs” más nivel de aprendizaje alcanza el modelo. Sin embargo, esto no es del todo cierto debido a que llega un momento que la maquina no aprende más por mucho que aumentemos el número de iteraciones con cada uno de los datos introducidos.

Finalmente, se representa la evolución del aprendizaje en las fases de entrenamiento y validación y se prueba el funcionamiento del modelo obteniendo la predicción del mismo ante los valores introducidos. Además, se representa la matriz de confusión correspondiente a los buques analizados.

## 4 RESULTADOS / VALIDACIÓN / PRUEBA

Una vez realizada la base de datos de emisiones para alimentar a la red neuronal y desarrollado el modelo de Inteligencia Artificial, se comprueba el funcionamiento del mismo entrenándolo con diferentes parámetros y buques. Este, este apartado analiza las predicciones del modelo creado y aporta las conclusiones de su funcionamiento.

### 4.1 Configuraciones posibles

En este apartado se analizan las diferentes configuraciones del modelo de AI con el objetivo de descubrir hasta qué punto es capaz de discriminar los diferentes modelos de radares y con qué parámetros se comporta mejor y llega a un mayor nivel de aprendizaje.

#### 4.1.1 Parámetros

El primer paso que debemos dar es analizar la respuesta de la red a los diferentes parámetros. De esta forma, podremos verificar cuáles de ellos son discriminatorios respecto al resto de radares.

En primer lugar, se comprueba que al introducir la frecuencia de operación de cada radar en el modelo no se aprecia diferencia en el aprendizaje del mismo. Por lo tanto, descartamos este parámetro para el resto de pruebas. El motivo puede estar relaciona con la calidad de los valores de la base de datos. Es probable que el algoritmo de cálculo de la frecuencia de transmisión de las señales recibidas no esté funcionando correctamente.

En segundo lugar, se analiza el comportamiento del ancho de haz (“bw”). Tras probar varias combinaciones se llega a la conclusión que el modelo no aumenta de forma notable su nivel de “accuracy” (porcentaje de casos que el modelo ha acertado). En este caso, si se puede apreciar una leve mejora en alguna prueba en comparación con la introducción de los valores de la frecuencia de los distintos radares. Sin embargo, no se considera oportuna su utilización debido a que no aporta gran carácter discriminatorio al modelo y en ocasiones lo confunde.

Posteriormente se analizan los otros tres parámetros que a simple vista en la base de datos constituyen en mayor o menor medida un patrón. Se comprueba que el parámetro “N” es verdaderamente útil para conseguir un buen aprendizaje. De hecho, se verifica que existe aproximadamente un 0,275 de

“accuracy” de diferencia entre el uso o no de los valores de las velocidades de rotación. Se concluye entonces que este parámetro es de los más importantes en el entrenamiento de la máquina.

En cuanto al periodo de repetición de pulsos (“PRF”), se verifica que este parámetro tiene un gran peso en el aprendizaje del modelo, pero nunca a la altura de la velocidad de rotación (“N”).

Finalmente, el último parámetro por comentar es el ancho de pulso (“pw”). Este parámetro es de gran utilidad para la máquina al nivel del “PRF” pero no llega a tener el peso de la velocidad de rotación. En definitiva, se llega a la conclusión de que el ancho de haz y la frecuencia de transmisión de los radares no aportan nada positivo que se pueda apreciar en los resultados finales. En cambio, el ancho de pulso (“pw”), la frecuencia de repetición de pulsos (“PRF”) y la velocidad de rotación (“N”) son parámetros cuyos valores son esenciales para el entrenamiento del modelo.


### 4.1.2 Clases de radares

El objetivo principal de realizar pruebas con el modelo es visualizar su comportamiento ante distintos tipos de radar. Para ello debemos comprobar sus niveles de aprendizaje analizando su capacidad de discriminación entre Lanchas de Instrucción (misma marca y modelo de radar) y entre diferentes clases de radar de distintos buques. Es de esperar que los resultados difieran en gran medida dependiendo de los radares seleccionados. En el Apartado 4.1.3 se evaluarán los niveles de aprendizaje conseguidos, las predicciones y se analizarán las matrices de confusión correspondientes.

### 4.1.3 Número de “epochs”

Como se ha avanzado en el Apartado 3.6 existe de la posibilidad de jugar con el número de iteraciones de los datos del set de entrenamiento. Se analiza el aprendizaje obtenido con diferentes valores de “epochs” y clases de radares.

En primer lugar, seleccionamos las cuatro Lanchas de Instrucción y analizamos la curva de aprendizaje en función de los “epochs” seleccionados. Se obtiene que a partir de las 400 iteraciones la pendiente de la curva no aumenta y se mantiene constante. Por otro lado, en el caso de radares diferentes exceptuando a las LLII se obtiene que, a mayor número de iteraciones, mejor “accuracy” se obtiene. Sin embargo, al llegar a los 1000 “epochs” la pendiente se estanca y se llega a prácticamente el máximo “accuracy”. Finalmente, si combinamos LLII con más radares de otros buques la curva se estanca a las 150 iteraciones (Figura 4-1).



**Figura 4-1 Curva de aprendizaje estancándose a partir de las 150 iteraciones.**

Analizando los resultados con los diferentes números de iteraciones se comprueba que no existe un patrón en concreto. Por tanto, se concluye que el funcionamiento de la red neuronal se produce en función del número de “epochs” con una fuerte dependencia de los radares seleccionados.

#### *4.1.4 Volumen de los sets de entrenamiento y validación*

La división del conjunto de datos que disponemos en un conjunto de entrenamiento y otro de validación se denomina método *cross-validation*. Como ya se ha dicho anteriormente, esta técnica se usa para poder evaluar de forma independiente a la fase de entrenamiento cómo se comporta la máquina ante datos con los que no ha sido entrenada.

Habitualmente se dividen los datos en un 70% para entrenamiento y un 30% para su validación, aunque también es común la proporción 80/20.

Tras varias ejecuciones de la máquina para ver sus distintas curvas de aprendizaje se concluye en base a los resultados obtenidos que la proporción 80/20 es la más adecuada para el número de entradas que tenemos disponibles en la base de datos. Este análisis se ha realizado ejecutando el modelo al menos cinco veces con cada configuración con el objetivo de verificar los niveles de aprendizaje alcanzados con cada proporción.


## **4.2 Evaluación de las predicciones**

Una vez realizadas las diferentes configuraciones con el objetivo de encontrar la combinación más efectiva, se analizan los niveles de aprendizaje y predicciones de la máquina. En este apartado se tratará por separado el comportamiento del modelo de AI en función de los buques introducidos. La razón de realizar el análisis independiente es debido a que no podemos comparar los resultados obtenidos con radares diferentes que con radares del mismo modelo (Lanchas de Instrucción).

La evaluación se realizará estudiando el porcentaje de acierto alcanzado en función de los “epochs” seleccionados (200, 500 y 1000).

### *4.2.1 Funcionamiento con LLII*


Este apartado trata de evaluar cómo responde la máquina ante los radares de las cuatro Lanchas Instrucción. Esta situación es la más exigente para el modelo debido a la poca diferencia en la paramétrica de las señales de las LLII. Se analizan las diferentes combinaciones de señales con diferentes modos de transmisión y radares altos y bajos.



**Figura 4-2** Curva de aprendizaje de la red introduciendo las cuatro Lanchas de Instrucción (200 “epochs”).

En primer lugar, se realizan varias ejecuciones con 200 iteraciones para observar el comportamiento del modelo y se obtiene un porcentaje de acierto de un 54,55% como se muestra en la Figura 4-2.

En segundo lugar, se prueba a aumentar el número de “epochs” a 500 iteraciones de forma que se obtienen mejores resultados que en el anterior caso. Se consigue un porcentaje de acierto de un 73,02% (Figura 4-3). Este resultado es algo esperanzador y muy positivo ya que estamos hablando de discernir radares de la misma marca y modelo.



**Figura 4-3** Curva de aprendizaje de la red introduciendo las cuatro Lanchas de Instrucción (500 “epochs”).


Sin embargo, conviene comentar que existe una oscilación de los valores de forma que varía el nivel de “accuracy” entre un rango concreto. En este caso, oscila entre el 75% y el 35% (Figura 4-3). La cuestión es que se alcanzan diferentes valores de “accuracy” en función de las ejecuciones del código. Es decir, sin cambiar ningún parámetro varía el “accuracy” conseguido. Teóricamente, este hecho puede deberse a la naturaleza no determinista del entrenamiento, tamaño desigual de las distintas clases o a la reasignación de grupos entrenamiento-validación en cada ejecución. En consecuencia, sería oportuno realizar un “cross-validation” para minimizar el efecto estocástico y obtener unos resultados más estables.

Finalmente, se eleva el número de iteraciones a 1000 para ver si se mejora el nivel de aprendizaje. Se comprueba que la pendiente de la curva se mantiene constante y el nivel porcentaje de acierto no aumenta.

#### 4.2.2 Funcionamiento con diversos buques


Este apartado tiene como objetivo evaluar el aprendizaje del modelo con todos los buques de la base de datos exceptuando las Lanchas de Instrucción. En principio, se esperan mejores resultados debido a estar introduciendo diferentes modelos de radares exceptuando la Patrullera de Aduanas *Águila I* y el A-41 *Intermares* que cuentan con el mismo modelo de radar.

Se introducen los datos de los siguientes buques: *Águila I*, BS-14 *María Pita*, GCM-31 *Corvo Mariño*, A-07 *Río Guadalupe* y A-41 *Intermares*. En primer lugar, se evalúa el funcionamiento del modelo con 200 iteraciones obteniendo un porcentaje de acierto de un 73,42% (Figura 4-4).



**Figura 4-4** Curva de aprendizaje introduciendo buques con diferentes modelos de radares (200 “epochs”).

Es conveniente decir que, en función de la ejecución, el modelo realiza una gráfica de aprendizaje diferente. Es decir, no aprende de la misma forma debido a que va cogiendo los datos para su entrenamiento de forma aleatoria. Este es el motivo de que para idénticas configuraciones entrenando al modelo con los mismos radares se puedan obtener distintas gráficas de evolución del aprendizaje de la máquina. Para diferentes ejecuciones es habitual que se obtengan resultados parecidos o idénticos. De hecho, a pesar de tener diferentes curvas de aprendizaje, la Figura 4-5 alcanza un porcentaje de acierto de un 73,42% al igual que la Figura 4-4 mostrada anteriormente.




**Figura 4-5** Curva de aprendizaje introduciendo buques con diferentes modelos de radares (200 “epochs”).

Se pueden apreciar diferentes aprendizajes ya que, en el caso de la Figura 4-4, el modelo aprende muy rápido en las primeras iteraciones (pendiente pronunciada) y luego se estanca y mantiene el nivel de aprendizaje durante el resto de “epochs”.


En cambio, en el caso de la Figura 4-5, la pendiente de la curva no crece de forma tan pronunciada, sino que el modelo va aprendiendo de forma progresiva hasta llegar al mismo nivel (73,42%).

En segundo lugar, se aumenta el número de iteraciones a 500 y se verifica un gran aumento del nivel de acierto alcanzando un 92,41% (Figura 4-6).



**Figura 4-6** Curva de aprendizaje introduciendo buques con diferentes modelos de radares (500 “epochs”).

Para terminar, el testeo del modelo se eleva a 1000 el número de iteraciones. En consecuencia, se obtiene que el modelo mejora notablemente acertando en el 100% de los casos (Figura 4-7).




**Figura 4-7** Curva de aprendizaje introduciendo buques con diferentes modelos de radares (1000 “epochs”).

De esta forma, se puede concluir que el modelo se comporta satisfactoriamente ante buques con distintos modelos de radar. De hecho, existe una gran diferencia entre estos niveles de aprendizaje y los alcanzados en el Apartado 4.2.1 con las Lanchas de Instrucción.

#### 4.2.3 Funcionamiento con LLII y otros buques simultáneamente


Esta fase de la validación del modelo trata de evaluar el funcionamiento del mismo combinando la entrada de datos de Lanchas de Instrucción y otros buques de la base de datos. Se analiza su comportamiento introduciendo los datos de los siguientes buques: GM. Barrutia (radar bajo y modo SHORT), GM. Rull (radar alto y modo LONG), BS-14 *María Pita*, GCM-31 *Corvo Mariño*, A-07 *Río Guadalupe* y A-41 *Intermares*.

En la primera prueba que se realiza se obtiene un 88,00% de porcentaje de acierto con 200 iteraciones como se muestra en la Figura 4-8.



**Figura 4-8** Curva de aprendizaje introduciendo valores de las LLII y de otros buques (200 “epochs”).

Posteriormente, se procede a comprobar el nivel alcanzado con 500 iteraciones y se obtiene un 95,00% (Figura 4-9). Finalmente, se aumenta a 1000 “epochs” consiguiendo un 100% de “accuracy”.



**Figura 4-9** Curva de aprendizaje introduciendo valores de las LLII y de otros buques (500 “epochs”).

## 5 CONCLUSIONES Y LÍNEAS FUTURAS

El presente apartado trata de razonar los principales problemas con los que nos hemos encontrado en las fases más importantes desarrolladas en este trabajo, valorar los resultados obtenidos y dar las conclusiones pertinentes finalizando con unas conclusiones personales. Además, se discutirá la posible continuidad del trabajo y el rumbo que se debe poner para llevar a buen puerto las conclusiones y resultados obtenidos con el objetivo de ayudar a implementar la Inteligencia Artificial en los sistemas de Guerra Electrónica de la Armada.

### 5.1 Problemas encontrados

#### 5.1.1 Emisiones reales

El primer obstáculo con el que se topó el desarrollo de este trabajo fue la necesidad de conseguir señales reales de radares marinos en vista a los resultados obtenidos con la primera propuesta realizada con emisiones simuladas. En un principio, se obtiene señal de los radares de las LLII y posteriormente de todos los buques disponibles en la Escuela Naval Militar y en sus inmediaciones durante el periodo de realización del trabajo.

#### 5.1.2 Etiquetado de valores

Este problema surge de los distintos parámetros de transmisión de los radares en función de la escala seleccionada. En el caso de las LLII no hubo problema ya que se pudo seleccionar el modo de ancho de pulso en cada momento de transmisión. Sin embargo, en el caso de otros buques, se recopilaban emisiones con parámetros que diferían en gran medida en función de si la señal se había tomado en puerto o navegando (otra escala diferente). En consecuencia, se optó por nombrar con diferentes etiquetas a los valores recogidos en la base de datos en función de si se habían recopilado en puerto o navegando. De esta forma, se evitó confundir al modelo de Inteligencia Artificial con valores distintos para un mismo radar. Es decir, no se han etiquetado buques ni radares de buques si no “modos” de funcionamiento de distintos radares de diferentes buques.

#### 5.1.3 Base de datos

Como se ha podido interpretar en las líneas de este trabajo, la calidad de los valores de la base de datos son clave en el nivel de aprendizaje y en las posteriores predicciones del modelo. En ocasiones,

los algoritmos desarrollados para la obtención de los parámetros PWD de Los radares no funcionaban correctamente debido a interferencias o mala calidad de las señales, por lo que se obtuvieron los valores manualmente.

Además, analizando detalladamente los valores de los parámetros recibidos de las emisiones de los distintos buques se concluye que los valores del ancho de pulso disminuyen progresivamente en función de la distancia al emisor debido a la disminución de la amplitud de estos con la distancia. Se debería comprobar el motivo de esta distorsión de valores en la recepción de las emisiones. Pese a esto, el funcionamiento del modelo no se ve afectado debido a que todas las señales sufren esta distorsión por lo que no afecta a la calidad de la base de datos.

#### *5.1.4 Inteligencia necesaria*

Una conclusión a la que se llega en las últimas fases del desarrollo del trabajo es la necesidad de contar con un gran volumen de datos para alimentar la red neuronal. Es decir, se necesita una inteligencia muy potente para poder entrenar al modelo. Como ya sea dicho, uno de los principales problemas que tiene el sistema desarrollado es hacer frente a la variabilidad de la paramétrica de las emisiones en función de la escala. Siendo estrictos se deberían tener recopiladas señales de los radares en cada una de sus escalas para contar con todo el abanico de valores posibles. Sin embargo, este problema se podría solventar fácilmente a partir de una gran base de datos de las señales de los radares enemigos.

Además, cabe la posibilidad de aumentar la inteligencia del enemigo mediante la generación de datos mediante la simulación descrita en la propuesta inicial (Apartado 3.1.2). De esta manera, a partir de pocos valores de las señales enemigas se podría generar una gran base de datos de sus parámetros característicos.

## **5.2 Valoración de los resultados**

Una vez testeado el modelo de Inteligencia Artificial que se ha desarrollado se puede comprobar que su funcionamiento supera con creces las expectativas iniciales. Tanto la propuesta inicial como la definitiva ponen de manifiesto el buen funcionamiento y cabida de las redes neuronales en los sistemas de clasificación e identificación de emisiones. Las predicciones de la máquina y los niveles de aprendizaje alcanzados representan el fruto al trabajo realizado en las fases anteriores de recepción y procesado de señal, elaboración de la base de datos y desarrollo del modelo.

En total se ha recibido señal de 10 buques diferentes y 6 modelos de radar distintos a diversas distancias y modos de transmisión elaborando una base de datos con un volumen más que suficiente para evitar un posible sobreaprendizaje del modelo. Además, los valores de los parámetros recopilados son coherentes y de calidad por lo que el set de entrenamiento creado se salda con una valoración muy positiva.

Se concluye que los parámetros de mayor utilidad para la red son el ancho de pulsos, la frecuencia de repetición de pulsos y la velocidad de rotación de la antena. En cambio, la frecuencia de transmisión del radar y el ancho de haz no aportan ningún aprendizaje significativo al modelo. De hecho, incluso llegan a confundirlo en ocasiones.

En cuanto a las predicciones y porcentaje de aciertos del modelo ante diferentes radares, es conveniente destacar que los resultados obtenidos en discriminación de las señales de las Lanchas de Instrucción son muy positivos. Esta situación es la más exigente para el modelo ya que, como ya se ha visto, las LLII tienen el mismo modelo de radar. Pese a esto, se alcanzan niveles razonablemente positivos y buenas predicciones. Por otro lado, los resultados obtenidos con diferentes modelos de

radares y con combinaciones de LLII con otros buques son más que satisfactorios. Todo esto es muestra de la gran capacidad de clasificación y discriminación del modelo empleado.

En definitiva, el modelo responde con un mejor porcentaje de acierto (100% con 1000 “epochs”) para buques con modelos diferentes de radar que para plataformas con el mismo modelo como es el caso de las Lanchas de Instrucción (73,02% con 1000 “epochs”). Incluso con un menor número de iteraciones se alcanzan niveles altos de “accuracy” (73,42% con 200 “epochs”) en discriminación de distintos modelos de radares.

Por tanto, se puede concluir que este trabajo asienta las bases e indica el rumbo a seguir en el proceso de implementación de técnicas de Inteligencia Artificial en los sistemas de Guerra Electrónica de los buques de la Armada.

### **5.3 Conclusión personal**

Haber tenido la posibilidad de realizar este trabajo de fin de carrera tan relacionado con mi futuro profesional ha sido una gran motivación y suerte para mí. Es una gran oportunidad para aportar mi granito de arena en algo que puede ser muy útil para la Armada y más concretamente para la modernización de los sistemas de Guerra Electrónica de las unidades de la Flota.

Este trabajo me ha aportado muchos conocimientos relacionados con la Guerra Electrónica, la obtención de inteligencia y el tratamiento, clasificación e identificación de emisiones. Además, me ha hecho ponerme al día en materias como la Inteligencia Artificial o conocer a fondo el funcionamiento de los radares. También, me ha brindado la oportunidad de tratar y aprender de personal experto en la materia perteneciente a las dotaciones de distintos buques.

A lo largo del desarrollo del trabajo y a medida que nos encontrábamos con diferentes obstáculos en el camino hacia el objetivo final, me he dado cuenta de que uno debe ser constante y no tirar la toalla por obtener resultados contrarios. De hecho, soy consciente de que la realización de este trabajo me aportará conocimientos de gran utilidad como oficial en los buques de la Armada.

En definitiva, estoy muy orgulloso de todo el trabajo realizado y de los excelentes resultados obtenidos. Estoy seguro de que servirá para que un futuro próximo nuestras unidades puedan estar dotadas de equipos modernos de clasificación e identificación de emisiones basados en redes neuronales.

### **5.4 Líneas futuras**

En vistas a los resultados obtenidos y el funcionamiento del modelo de Inteligencia Artificial se propone las siguientes líneas de investigación y posibles mejoras al trabajo realizado.

#### *5.4.1 Recopilación de otros parámetros*

Como se ha podido comprobar no todos los parámetros recopilados han sido efectivos para el entrenamiento del modelo. De hecho, finalmente únicamente se han utilizado el ancho de pulso, el periodo de repetición de pulsos y la velocidad de la antena del radar.

Para futuras pruebas sería conveniente el estudio de otros parámetros diferentes a mayores de los tres ya probados. La idea inicial de utilizar el ancho de haz y la frecuencia de transmisión del radar no está mal orientada. Sin embargo, es necesario desarrollar algoritmos o rutinas que consigan obtener valores precisos de forma que se pueda obtener el patrón característico de cada radar.

### 5.4.2 Combinación de emisiones reales y artificiales

La generación de emisiones simuladas a partir de ciertos valores nominales de partida ya se ha demostrado en la propuesta inicial descrita en el Apartado 3.1.2. Se propone la opción de combinar emisiones reales y artificiales en el caso de no contar con una base de datos lo suficientemente grande. De esta manera, si al menos se tiene una pequeña inteligencia de la paramétrica de la emisión enemiga, existe la posibilidad de generar los datos necesarios para poder completar la librería necesaria para crear el set de entrenamiento.

Otra opción consiste en crear nuevas señales, modificando ligeramente emisiones reales. Este procedimiento se denomina *aumentación de datos (data augmentation)* y es una técnica habitual para incrementar el tamaño de la base de datos en el mundo del *Machine Learning*.

En el caso de haber dispuesto de más tiempo se habría analizado y comprobado el funcionamiento de esta combinación de valores reales y artificiales. En el caso de obtener buenas predicciones y niveles de aprendizaje sería una gran solución ante la posible escasez de inteligencia del enemigo como ya se ha tratado previamente en el Apartado 5.1.4.

### 5.4.3 Uso de espectogramas

La clasificación de imágenes mediante comparación basada en técnicas de Inteligencia Artificial es cada vez más común. De hecho, basta con mirar la galería y observar la clasificación automática que *Google Photos* realiza agrupando las fotos de una misma persona u objeto. Este servicio inteligente es capaz de reconocer rostros y detalles de las fotografías con el fin de agrupar las imágenes por contenidos al usuario. Este sistema lleva funcionando desde hace ya bastantes años con excelentes resultados.

En el ámbito de la clasificación de señales, podría ser una opción factible utilizar espectrogramas (representaciones del espectro de la señal recibido en función del tiempo) con el objetivo de que el modelo se entrene a partir de imágenes espectrales de las emisiones. De esta forma, no se obtendrían los parámetros de la señal, sino que directamente se alimentaría a la red con toda la información disponible en el espectrograma. La ventaja de esta propuesta es que evita el factor humano en la recopilación de los parámetros y la pérdida de información que conlleva utilizar únicamente una serie de parámetros.

### 5.4.1 Prueba de otros algoritmos de ML

En este trabajo sólo se ha testeado, a modo de “prueba de concepto”, el aprendizaje en una red neuronal convolucional de 3 capas. Una línea futura evidente es comprobar con otros tipos de redes neuronales como, por ejemplo, las LSTM (*Long-Short Term Memory*).

También podrían probarse otras técnicas y algoritmos de clasificación basados en inteligencia artificial, tanto con aprendizaje supervisado (árboles de decisión, regresión logística, máquinas de vector soporte –SVM-, etc.), como no supervisado (*clustering*, análisis de componentes principales –PCA-, descomposición en valores singulares –SVD-, análisis de componentes independientes –ICA-, etc.).

## 6 BIBLIOGRAFÍA

- [1] ENM, Táctica Naval, 2021.
- [2] F. S. Bergés, «El espectro electromagnético y el origen de la Guerra Electrónica,» *Ejércitos*, 2021.
- [3] A. J. d. E. M. d. I. Armada, «Líneas Generales de la Armada 2022,» 2022.
- [4] S. J. Russell y P. Norvig, *Artificial Intelligence: a Modern Approach*, 1995.
- [5] N. J. Nilsson, ««Stanford University,» 2009. [En línea]. Available: <https://ai.stanford.edu/~nilsson/QAI/qai.pdf>.
- [6] M. Negnevitsky, *Artificial Intelligence: A Guide to Intelligent Systems*, Edinburgh: Pearson Education, 2005.
- [7] L. Rouhiainen, *Inteligencia*, Barcelona: Planeta, 2018.
- [8] M. A. Boden, *Inteligencia artificial*, Madrid: Turner Publicaciones, 2017.
- [9] E. N. Zalta, «Stanford Encyclopedia of Philosophy, The Turing Test,» 9 Abril 2003. [En línea]. Available: <https://plato.stanford.edu/entries/turing-test/#Tur195ImiGam>.
- [10] M. M. El Naqa I., *What Is Machine Learning?*, 2015.
- [11] G. Bonaccorso, *Machine Learning Algorithms*, Birmingham: Packt Publishing, 2017.
- [12] D. J. Matich, «Redes Neuronales: Conceptos Básicos y Aplicaciones,» 2001.
- [13] Dong Nguyen, Canh Nguyen, Thuan Duong-Ba, Hung Nguyen, Anh Nguyen y Tuan Tran, «Joint Network Coding and Machine Learning for Error-prone Wireless Broadcast,» 2017.
- [14] C. B. Carrión, «Redes Convolucionales,» 2020.
- [15] P. P. Chorro, «Guerra Electrónica: Una visión histórica,» *Especial Defensa*, 1982.
- [16] G. L. M. Mezo, «Sistemas de Guerra Electrónica en la Armada Española,» *Foro Naval*, 2016.
- [17] «Armada Española».

- [18] J. M. N. García, «El sistema de guerra electrónica de la fragata F-110,» 2018.
- [19] NATO, ATP-3.6.2, Electronic Warfare in the land battle.
- [20] NATO, ATP-31, Nato Above Warfare Manual.
- [21] D. Adamy, EW 101: A First Course in Electronic Warfare, 2001.
- [22] «Artificial intelligence and electronic warfare,» 2018. [En línea]. Available: <https://www.defenceprocurementinternational.com/news/air/artificial-intelligence-and-electronic-warfare>.
- [23] Centro de Inteligencia Artificial de la Armada (CIA2), «Estudio de viabilidad de identificación de señales electromagnéticas en el espectro radar mediante técnicas de IA».
- [24] ENM, Guerra Electrónica E.W. Pub. 5351, 2005.
- [25] J. Matuszewski, «The specific radar signature in electronic recognition system».
- [26] K. K. Sarma, Artificial Intelligence Aided Electronic Warfare Systems, 2020.
- [27] C. Wolff, «Radar Tutorial,» [En línea]. Available: [www.radartutorial.eu/](http://www.radartutorial.eu/).
- [28] Y.-H. Kim, Kyu-Ha Song, Jin-Woo Han y Hyoung-Nam Kim, «Radar scan pattern analysis for reduction of false identification in electronic warfare support systems,» 2014.
- [29] Ministerio de Defensa, «El Centro de Inteligencia de las Fuerzas Armadas (CIFAS),» [En línea]. Available: <https://emad.defensa.gob.es/unidades/cifas/>.
- [30] «La página de ASR,» [En línea]. Available: <https://intelpage.info/buque-a-111-alerta-de-la-armada.html>.
- [31] A. Trobiani, C. Rancán, P. Britos y R. García-Martínez, «Clasificación automática de emisiones radar mediante combinación de Artmap y filtros Kalman».
- [32] J. Mitola, The Software Radio Architecture, IEEE Communications Magazine, 1995.
- [33] M. G. d. C. Martínez, Desarrollo de un sistema de Guerra Electrónica para la detección y perturbación de radares en banda X, 2020.
- [34] F. F. d. Villegas, «Unión de Radioaficionados de Ourense, Equipos de radio definido por software,» 2008. [En línea].
- [35] «MathWorks,» [En línea]. Available: [https://es.mathworks.com/help/matlab/learn\\_matlab/product-description.html](https://es.mathworks.com/help/matlab/learn_matlab/product-description.html). [Último acceso: 12 02 2022].
- [36] «Google Colaboratory,» [En línea]. Available: <https://colab.research.google.com/?hl=es#scrollTo=OwuxHmxllTwN>. [Último acceso: 05 03 2022].
- [37] «Web de La Moncloa,» [En línea]. Available: <http://www.lamoncloa.gob.es>. [Último acceso: 13 enero 2015].
- [38] J. Rodríguez y V. Fernández, Cómo redactar el estado del arte de un trabajo, Editorial Genios, 2010.

- [39] P. Martínez y A. García, Cómo escribir una buena memoria de TFG, Publicaciones del 2000, 2013.
- [40] A. Pérez, Cómo escribir una bibliografía, Nuevas publicaciones.
- [41] E. e. ejemplo, La guerra, 2020.
- [42] J. I. Bagnato, «Aprende Machine Learning,» 2017. [En línea]. Available: <https://www.aprendemachinelearning.com/que-es-overfitting-y-underfitting-y-como-solucionarlo/>. [Último acceso: 02 02 2022].
- [43] F. Julin, «Reserch Gate,» 2019. [En línea]. Available: [https://www.researchgate.net/figure/Overfitting-seen-in-a-graph-given-from-a-training-session-of-a-CNN\\_fig2\\_331672563](https://www.researchgate.net/figure/Overfitting-seen-in-a-graph-given-from-a-training-session-of-a-CNN_fig2_331672563). [Último acceso: 02 02 2022].
- [44] M. Swamynathan, Mastering Machine Learning with Python in Six Steps, New York: Apress, 2017.
- [45] ENM, Manual de Lanchas de Instrucción A-121 Pub. ENM 4810, 2016.

## ANEXO I

### Siglas y Acrónimos

A. Amplitude	EW. Electronic Warfare
ACINT. Acoustic Intelligence	EWC. Electronic Warfare Commander
AoA. Angle of Arrival	EWCC. Electronic Warfare Coordination Cell
BAM. Buque de Acción Marítima	EWI. Electronic Warfare Intelligence
BPF. Band-Pass Filter	FAM. Fuerza de Acción Marítima
CNN. Convolutional Neural Network	GE. Guerra Electrónica
COMINT. Communications Intelligence	ID. Identificación
CWC. Composite Warfare Commander	IFM. Instantaneous Frequency Measurement
DE. Energía Dirigida	IRINT. Infrared Intelligence
DIFM. Digital Instantaneous Frequency Measurement	LLII. Lanchas de Instrucción
ECCM. Electronic Counter-Countermeasures	LOB. Line of Bearing
ECM. Electronic Counter Measures	NEDB. Nato Emitter Data Base
ELINT. Electronic Intelligence	OPINT. Optical Intelligence
EMA. Estado Mayor de la Armada	OTC. Officer in Tactical Command
EMACON. Estado Mayor Conjunto de la Defensa	PD. Probability of Detection
EMCON. Emissions Control	PF. Probability of False alarm
EMS. Electromagnetic System	PRF. Pulse Repetition Frequency
EOB. Electronic Order of Battle	PW. Pulse Width
EPM. Electronic Protective Measures	RDF. Radigoniometría
ESM. Electronic Support Measures	RF. Radio(carrier) Frequency
	RWR. Radar Warning Receivers
	SIGNIT. Signal Intelligence

## ANEXO II

### Especificaciones radar 1944C FURUNO

#### CARACTERÍSTICAS PRINCIPALES

- Radiador Array guíaondas ranurada
- Polarización Horizontal
- Rotación de la antena 24 rpm (nominal)
- Longitud del radiador 120 cm (XN12)
- Ancho del haz horizontal  $1,9^\circ$
- Ancho del haz vertical  $22^\circ$
- Atenuación del lóbulo lateral -24 dB como máximo (hasta  $\pm 20^\circ$  del lóbulo principal), -30 dB como máximo ( $\pm 20^\circ$  del lóbulo principal o más)
- Escala máxima: 64 MN
- Escala mínima: 42 m
- Resolución de escala: 15 m
- Precisión en demora  $\pm 1^\circ$
- Precisión del anillo fijo de escala 0,9% de escala o 8 m; se utilizará la que sea más alta

#### MÓDULO TRANSCÉPTOR

- Frecuencia y modulación 9.410 MHz  $\pm$  30 MHz (banda X), P0N
- Potencia de salida máxima M1824C-BB: 2,2 kW (nominal), M1944C-BB: 6 kW (nominal), M1954C-BB: 12 kW (nominal)
- Modulador Método de conmutación de FET
- Frecuencia intermedia 60 MHz
- Sintonización Automática o manual
- Receptor (Front End) MIC (Microwave Integrated Circuit, circuito integrado de microondas)
- Ancho de banda Longitud de impulso Tx 0,08 s y 0,3 s: 25 MHz
- Longitud de impulso Tx 0,8 s: 3 MHz
- Duplexor Circulador con diodo limitador
- Calentamiento 90 s aprox.

#### ALIMENTACIÓN

- M1944C-BB (24 rpm) 12-24 VCC: 6,3-3,1 A (7,4-3,5 A)

#### CONDICIONES AMBIENTALES

- Temperatura ambiente Unidad de antena: de  $-25^\circ\text{C}$  a  $+70^\circ\text{C}$
- Unidad de procesador y unidad de control: de  $-15^\circ\text{C}$  a  $+55^\circ\text{C}$
- Unidad de alimentación: de  $-15^\circ\text{C}$  a  $+55^\circ\text{C}$
- Humedad relativa 93% o inferior a  $+40^\circ\text{C}$
- Resistencia al agua Unidad de antena: IPX6
- Unidad de control: IPX5 (panel frontal), IPX2 (panel posterior)

- Unidad de procesador, unidad de alimentación. IPX0
- Vibración según IEC 60945-3th en el rango 5-100 Hz

## ANEXO III

# Especificaciones radar FAR-2127 FURUNO

### CARACTERÍSTICAS PRINCIPALES

- Radiador Array guíaondas ranurada
- Polarización Horizontal
- Rotación de la antena 24 rpm o 42 rpm (nominal)
- Ancho del haz horizontal 1,8°
- Ancho del haz vertical 20°
- Atenuación del lóbulo lateral -24 dB como máximo (hasta  $\pm 10^\circ$  del lóbulo principal), -30 dB como máximo ( $\pm 10^\circ$  del lóbulo principal o más)
- Distancia mínima y discriminación en distancia: 35 m
- Discriminación en demora: 30 m en 0.75 MN de escala
- Precisión en demora  $\pm 1^\circ$

### MÓDULO TRANSEPTOR

- Frecuencia: 9410  $\pm$  30 MHz (banda X)
- Potencia de salida máxima: 25 kW (nominal),
- Modulador Método de conmutación de FET
- Frecuencia intermedia 60 MHz
- Sintonización Automática o manual
- Receptor (Front End) MIC (Microwave Integrated Circuit, circuito integrado de microondas)
- Ancho de banda: 40MHz (Short pulse), 10 MHz (Middle pulse) y 3 MHz (Long pulse)
- Duplexor Circulador con diodo limitador
- Calentamiento 90 s aprox.

### ALIMENTACIÓN

- 24 VCC: 8,8 A<sup>1</sup>/9,7 A<sup>2</sup>; 100-115 V CA: 3,0 A<sup>1</sup>/3,4 A<sup>2</sup> (1: 24 rpm; 2: 42 rpm)

### CONDICIONES AMBIENTALES

- Temperatura ambiente (IEC 60945)
  - Unidades interiores -15 °C a +55 °C
  - Antena -25 °C a +55 °C (almacenamiento +70 °)
- Humedad relativa 95% a 40 °C
- Estanqueidad
  - Antena: IPX6 (IEC 60529)
  - Unidades interiores: IPX0 (IEC 60529)
- EMC Cumpliendo con IEC 60945 Ed. 4 (radiación de la cabina a 2 GHz)

## ANEXO IV

# Especificaciones radar FAR-2827 FURUNO

### CARACTERÍSTICAS PRINCIPALES

- Radiador Array guíaondas ranurada
- Polarización Horizontal
- Rotación de la antena 24 rpm (nominal)
- Ancho del haz horizontal 1,8°
- Ancho del haz vertical 20°
- Atenuación del lóbulo lateral -24 dB como máximo (hasta  $\pm 10^\circ$  del lóbulo principal), -30 dB como máximo ( $\pm 10^\circ$  del lóbulo principal o más)
- Distancia mínima y discriminación en distancia: 35 m
- Discriminación en demora: 30 m en 0.75 MN de escala
- Precisión en demora  $\pm 1^\circ$

### MÓDULO TRANSECTOR

- Frecuencia: 9410  $\pm$  30 MHz (banda X)
- Potencia de salida máxima: 25 kW (nominal),
- Modulador Método de conmutación de FET
- Frecuencia intermedia 60 MHz
- Sintonización Automática o manual
- Receptor (Front End) MIC (Microwave Integrated Circuit, circuito integrado de microondas)
- Ancho de banda: 40MHz (Short pulse), 10 MHz (Middle pulse) y 3 MHz (Long pulse)
- Duplexor Circulador con diodo limitador
- Calentamiento 90 s aprox.

### ALIMENTACIÓN

- 24 VCC: 8,8 A; 100-115 V CA: 3,0 A

### CONDICIONES AMBIENTALES

- Temperatura ambiente (IEC 60945)
  - Unidades interiores -15 °C a +55 °C
  - Antena -25 °C a +55 °C (almacenamiento +70 °)
- Humedad relativa 95% a 40 °C
- Estanqueidad
  - Antena: IPX6 (IEC 60529)
  - Unidades interiores: IPX0 (IEC 60529)
- EMC Cumpliendo con IEC 60945 Ed. 4 (radiación de la cabina a 2 GHz)

## ANEXO V

# Especificaciones radar FAR-2117BB FURUNO

### CARACTERÍSTICAS PRINCIPALES

- Radiador Array guíaondas ranurada
- Polarización Horizontal
- Rotación de la antena 24 ó 42 rpm (nominal)
- Ancho del haz horizontal 1,8°
- Ancho del haz vertical 20°
- Atenuación del lóbulo lateral -24 dB como máximo (hasta  $\pm 10^\circ$  del lóbulo principal), -30 dB como máximo ( $\pm 10^\circ$  del lóbulo principal o más)
- Distancia mínima y discriminación en distancia: 35 m
- Discriminación en demora: 30 m en 0.75 MN de escala
- Precisión en demora  $\pm 1^\circ$

### MÓDULO TRANSCEPTOR

- Frecuencia: 9410  $\pm$  30 MHz (banda X)
- Potencia de salida máxima: 12 kW (nominal),
- Modulador Método de conmutación de FET
- Frecuencia intermedia 60 MHz
- Sintonización Automática o manual
- Receptor (Front End) MIC (Microwave Integrated Circuit, circuito integrado de microondas)
- Ancho de banda: 40MHz (Short pulse), 10 MHz (Middle pulse) y 3 MHz (Long pulse)
- Duplexor Circulador con diodo limitador
- Calentamiento 90 s aprox.

### ALIMENTACIÓN

- 24 VCC: 7,6 A<sup>1</sup>/8,5 A<sup>2</sup>; 100-115 V CA: 2,6 A<sup>1</sup>/3,0 A<sup>2</sup> 220-230 VCA: 1,6 A<sup>1</sup>/1,7 A<sup>2</sup> (1: 24 rpm; 2: 42 rpm)

### CONDICIONES AMBIENTALES

- Temperatura ambiente (IEC 60945)
  - Unidades interiores -15 °C a +55 °C
  - Antena -25 °C a +55 °C (almacenamiento +70 °)
- Humedad relativa 95% a 40 °C
- Estanqueidad
  - Antena: IPX6 (IEC 60529)
  - Unidades interiores: IPX0 (IEC 60529)
- EMC Cumpliendo con IEC 60945 Ed. 4 (radiación de la cabina a 2 GHz)

## ANEXO VI

### Especificaciones radar FR-2125 FURUNO

#### CARACTERÍSTICAS PRINCIPALES

- Radiador Array guíaondas ranurada
- Polarización Horizontal
- Rotación de la antena 24 rpm (nominal)
- Ancho del haz horizontal 1,8°
- Ancho del haz vertical 20°
- Atenuación del lóbulo lateral -24 dB como máximo (hasta  $\pm 10^\circ$  del lóbulo principal), -30 dB como máximo ( $\pm 10^\circ$  del lóbulo principal o más)
- Distancia mínima y discriminación en distancia: 35 m. Mejor que 2,5°
- Precisión en demora  $\pm 1^\circ$
- Discriminación en demora: 30 m en 0.75 MN de escala
- Escala máxima 120 MN

#### MÓDULO TRANSCÉPTOR

- Frecuencia: 9410  $\pm$  30 MHz (banda X)
- Potencia de salida máxima: 25 kW (nominal),
- Modulador Método de conmutación de FET
- Frecuencia intermedia 60 MHz
- Sintonización Automática o manual
- Receptor (Front End) MIC (Microwave Integrated Circuit, circuito integrado de microondas)
- Ancho de banda: 40MHz (Short pulse), 10 MHz (Middle pulse) y 3 MHz (Long pulse)

#### ALIMENTACIÓN

- 24 V, 10,8 A; 32 V, 8,2 A; 230 VCA, 2,7 A

## ANEXO VII

Código de procesamiento de señal (*signal\_processing.m*)

```

clear all
close all

% Acquisition parameters
% hackrf_transfer -r barrutia_alto_long_D.dat -f 1006000000 -a 1 -l 40 -s 20000000 -n
120000000
fs = 20000000; % sampling rate (Hz)
fif = 1006.0; % sampler frequency (MHz)
flo = 10410.0; % local oscillator frequency (MHz)
f0 = 9410.0; % theoretical radar central frequency

% Threshold levels
% TODO: calculate automatically threshold levels
th1 = 0.2;
th2 = 0.2;
fprintf('\nThreshold level 1: %2.2f \n',th1);
fprintf('Threshold level 2: %2.2f \n',th2);

% File path
filename =
['C:\Users\ferca\OneDrive\Escritorio\TFG\Medidas\Señales\Lanchas\Mar\Mar_22_02_16\rull_z2_a
lto_short.dat'];
%filename = 'D:\salvamento_08_46.dat';

% Calculate file duration
f = fopen (filename, 'rb');
if (f < 0)
    ReferenceSigLength = 0;
else
    fseek(f, 0, 'eof');
    % signal length
    nb = ftell(f)/2; % int8 samples: 2*8 bits = 2 bytes, only for HackRF
end
fclose(f);

tfile = nb/fs;
fprintf('File duration: %d MS (%2.2f s)\n',nb/1e6,tfile)

% Take the whole file
%tfile=2
y = load_radar_data(filename,fs,tfile,'hackrf');
video = abs(y);
%clear y;
t = 0:1/fs:tfile-1/fs;

% Plot whole waveform
figure
plot(t*1000,video)
title('Radar received signal')
ylabel('amplitude')
xlabel('t(ms)');

% Calculate antenna rotation rate

```

```

Df = 16; % decimation factor for speeding-up
[N,tscan] = calculate_N(video,Df,fs);

% Take only first rotation
iend = interp1(t,1:length(t),tscan,'nearest');
t = t(1:iend);
yscan = y(1:iend);
video = video(1:iend);

% Plot waveform for one antenna scan
figure
plot(t*1000,video)
title('Radar received signal (one antenna scan)')
ylabel('amplitude')
xlabel('t(ms)');
grid on

% Polar plot
figure
theta = linspace(0,2*pi,length(video));
rodB = 10*log10(video);
rodB = rodB - max(rodB);
rodB(rodB<-10) = -10;
h = polarplot(theta,rodB+10);
haxes = get(h,'Parent');
haxes.RTickLabel = {'-40','-30','-20','-10','0'};

% calculate frequency deviation
df = calculate_dfreq(yscan,length(yscan),fs);

% filter video to avoid false pulse detection
videof = medfilt1(video,2);

% Calculate antenna beamwidth
vsrch = 0.27; % voltage threshold within search should be done

[theta6dB,thetav] = calculate_BW(videof,t,vsrch,N,fs,true);
fprintf('Calculated radar antenna 6dB beamwidth: %2.2f°\n',theta6dB);
fprintf('Calculated radar burst duration: %2.2f ms\n',(theta6dB/6/N)*1000);

% calculate toa, tod, pw and prf
[toa,tod,pw,prf] = calculate_PDW(videof,th1,th2,length(videof),fs,true);

% Plot spectrogram
%figure
%spectrogram(abs(y, 512, 400, 512, fs,'centered')); % X,WINDOW,NOVERLAP,NFFT,Fs,type

% Remove outliers in prf vector (Inf,NaN and Zero elements)
prf(isinf(prf) | isnan(prf) | prf == 0) = [];
% rmoutliers(prf,'mean')
fprintf('Detected PRF: %4.0f Hz \n',mean(rmoutliers(prf,'percentiles',[75 90])));

% Remove outliers in pw vector (Inf,NaN and Zero elements)
pw(isinf(pw) | isnan(pw) | pw == 0) = [];
fprintf('Detected PW: %4.2f us \n',mean(rmoutliers(pw,'percentiles',[75 90]))*1e6);

fprintf('Sampler frequency: %f MHz \n',fif);

```

```
fprintf('Detected f0: %f MHz \n', flo-fif-df); % F0=FLO-IFD-DF
```

## ANEXO VIII

### Código de carga de datos (*load\_radar\_data.m*)

```
function y = load_radar_data(filename,fs,ta,sdr_type)
% filename: file path
% fs: sampling rate
% ta: analysis duration
% sdrtype: Type of SDR HW 'usrp' or 'hackrf' or 'sdr-console'

% y: data vector

%samples = [1,2*ta*fs];
samples = [1,ta*fs];

if strcmp(sdr_type,'usrp')
    % USRP
    % Read samples
    y = audioread(filename,samples,'native');
    % Convert int16 to double and normalize
    y = double(y(1:2:end)/32768) + j*double(y(2:2:end)/32768);
elseif strcmp(sdr_type,'hackrf')
    % HackRF
    fid = fopen(filename,'r');
    y = fread(fid, 2*max(samples), 'int8');
    y = y(1:2:end)/128 + j*y(2:2:end)/128;
    fclose(fid);
elseif strcmp(sdr_type,'sdr-console') % no está probado
    % SDR-Console
    y = audioread(filename,samples,'native');
    % Normalize
    y = y(1:2:end)/32768.0 + j*y(2:2:end)/32768.0;
else
    y=[];
end
```

## ANEXO IX

### Código de cálculo del PDW (*calculate\_PDW.m*)

```

function [toa,tod,pw,prf] = calculate_PDW(video,th1,th2,framesize,fs,fpaint)
% Calculates the Pulse Descriptor Word (PDW) of a pulsed radar waveform
%
% video: signal vector (module)
% th1: threshold level nr. 1
% th2: threshold level nr. 2
% framesize: data frame size
% fs: sampling rate (Hz)

% toa: pulse time of arrival (s)
% tod: pulse time of departure (s)
% pw: pulse width (s)
% prf: pulse repetition frequency (Hz)

toa = [];
tod = [];
pri = [];
pw = [];

% initialize counters
toa_cnt = 1;
tod_cnt = 1;
counter = 1;

% Create constant false alarm rate detection video
while counter < framesize
    if (video(counter)>th2)
        while (video(counter)>th1) && (counter<framesize)
            counter = counter+1;
        end
    else
        video(counter) = 0;
        counter = counter+1;
    end
end

% Calculate TOA and TOD vectors
counter = 1;
while counter < framesize
    if (video(counter)<th2) && (video(counter+1)>th2)
        toa(toa_cnt) = counter;
        toa_cnt = toa_cnt+1;
    end
    if (video(counter)>th1) && (video(counter+1)<th1)
        tod(tod_cnt) = counter;
        tod_cnt = tod_cnt+1;
    end
    counter = counter+1;
end

% Calculate PRI vector
if toa_cnt>1
    for idx = 2:toa_cnt-1
        pri(idx) = toa(idx) - toa(idx-1);
    end
end

```

```

else
    disp('Not enough data to calculate PRI');
end

% Calculate PW vector
if (toa_cnt >= 1) && (tod_cnt >= 1)
    for idx = 1:tod_cnt-1
        pw(idx) = tod(idx) - toa(idx);
    end
else
    disp('No hay datos suficientes para calcular el PW');
end
toa = toa/fs;
tod = tod/fs;
pw = pw/fs;
prf = fs./pri;

if fpaint==true
    figure
    t = 0:1/fs:framesize/fs-1/fs;
    plot(t*1000,video)
    title('Detected CFA Video')
    ylabel('amplitude')
    xlabel('t(ms)');
    hold on
    plot(toa*1000,th1*ones(size(toa)), 'x')
    plot(tod*1000,th2*ones(size(tod)), 'o')
    legend('signal', 'toa', 'tod')
%     plot(t*1000, (envelope(video)))

% igual habria que quedarse con N muestras antes y N despues del t1toa y el tntod
iltoa = interp1(t,1:length(t),toa(1), 'nearest'); % sample index of first toa
intod = interp1(t,1:length(t),tod(end), 'nearest'); % sample index of last tod
toatod_t = t(iltoa:intod);
toatod_video = video(iltoa:intod);

% Plot burst waveform
figure
plot(toatod_t*1000,toatod_video)
title('Radar received signal (one burst)')
ylabel('amplitude')
xlabel('t(ms)');
hold on
plot(toa*1000,th1*ones(size(toa)), 'x')
plot(tod*1000,th2*ones(size(tod)), 'o')
legend('signal', 'toa', 'tod')
grid on
end

```

## ANEXO X

### Código de cálculo de la velocidad de rotación del radar (*calculate\_N.m*)

```
function [N,tscan] = calculate_N(video,Df,fs)
% Calculate antena rotation rate
% video: signal vector (module)
% Df: decimation factor
% N: estimated antenna rotation rate (rpm)

s = decimate(video,Df);
% findpeaks chooses the tallest peak in the signal and eliminates all peaks
% within 'MinPeakWidth' seconds of it. The function then repeats the
% procedure for the tallest remaining peak and iterates until it runs out
% of peaks to consider
[pk,loc] = findpeaks(s,fs/Df,'SortStr','descend','NPeaks',2,'MinPeakDistance',1);
tscan = abs(loc(2) - loc(1));
N = 60/tscan;

end
```

## ANEXO XI

### Código de cálculo de la frecuencia de trabajo del radar (*calculate\_dfreq.m*)

```
function [fp] = calculate_dfreq(y,framesize,fs)
% Calculates the Pulse Descriptor Word (PDW) of a pulsed radar waveform
%
% y: signal vector
% th1: threshold level nr. 1
% th2: threshold level nr. 2
% framesize: data frame size
% fs: sampling rate (Hz)
%
% toa: pulse time of arrival (s)
% tod: pulse time of departure (s)
% pw: pulse width (s)
% prf: pulse repetition frequency (Hz)
% fp: detected pulse intermediate frequency (MHz)
%
% Calculate data frame FFT
frame_fft = fft(y(1:framesize));
% remove DC
frame_fft(1)=[];
% calculate index for max
[~,ifftmax] = max(abs(frame_fft));
fp = (ifftmax+1)*fs/framesize/2/1e6;
```

## ANEXO XII

### Código de cálculo del ancho de haz (*calculate\_BW.m*)

```
function [theta6dB,thetav] = calculate_BW(video,t,vsrch,N,fs,fpaint)
% Calculate antenna beamwidth

% video: signal vector (module)
% t: time vector (s)
% vsrch: search threshold
% N: antenna rotation rate (rpm)
% fs: sample rate (Hz)
% fpaint: plot yes/no
% theta6dB: 6dB (voltage) beamwidth
% thetav: vsrch (voltage) beamwidth

% calculate voltage threshold
nth = find(video>vsrch);
nthini = nth(1);
nthend = nth(end);
thetav=6*N*(nthend-nthini)/fs;

% trim vectors
vscan = video(nthini:nthend);
tscan = t(nthini:nthend);

% calculate max. amplitude
[vmax,nmax]=max(vscan);

% calculate 6dB voltage threshold
v6dB=vmax/10^(6/10);
i6dB = find(vscan>v6dB);

% calculate 6dB beamwidth
theta6dB=6*N*(i6dB(end)-i6dB(1))/fs;

if fpaint==true
    figure
    plot(tscan*1000,vscan)
    hold on
    plot(1000*(i6dB(1)+nthini)/fs,vscan(i6dB(1)), 'r>')
    plot(1000*(i6dB(end)+nthini)/fs,vscan(i6dB(end)), 'r<')
    title('Antenna beamwidth')
    ylabel('amplitude')
    xlabel('t (ms)');
end
```

## ANEXO XIII

### Código del modelo de AI de la propuesta inicial

(*radar.ipynb*)

```
import matplotlib.pyplot as plt
import numpy as np
import pandas as pd
from tensorflow.keras import datasets, layers, models
from keras.layers import Dense
from scipy.stats import truncnorm
from sklearn.model_selection import train_test_split
import tensorflow as tf
from sklearn.metrics import confusion_matrix, ConfusionMatrixDisplay
from tensorflow.keras.utils import to_categorical

def truncated_normal(mean=0, sd=1, low=0, upp=10, type=int):
    return truncnorm(
        (low - mean) / sd, (upp - mean) / sd, loc=mean, scale=sd)

def truncated_normal_floats(mean=0, sd=1, low=0, upp=10, num=100):
    res = truncated_normal(mean=mean, sd=sd, low=low, upp=upp)
    return res.rvs(num)

def truncated_normal_ints(mean=0, sd=1, low=0, upp=10, num=100):
    res = truncated_normal(mean=mean, sd=sd, low=low, upp=upp)
    return res.rvs(num).astype(np.uint16)

#radars = pd.DataFrame(columns=('frq', 'pw', 'prf', 'radar_type'))
radars = pd.DataFrame()

# number of items for each radar class:
number_of_items_per_class = [20, 20, 20, 20, 20]
number_of_classes = len(number_of_items_per_class)

# radar #1: 5260±1%; 0.5±1%; 1200±1%
freq = 5260
pw = 0.5
pri = 1200
number_of_items = number_of_items_per_class[0]
freq = truncated_normal_ints(mean=freq, sd=freq*0.01, low=freq*0.99, upp=freq*
1.01,
                             num=number_of_items)
pw = truncated_normal_floats(mean=pw, sd=pw*0.01, low=pw*0.99, upp=pw*1.01,
                             num=number_of_items)
```

```

pri = truncated_normal_ints(mean=pri, sd=pri*0.01, low=pri*0.99, upp=pri*1.01,
                             num=number_of_items)

rtype = np.full((number_of_items,), 0)
radar_data = np.column_stack((freq, pw, pri, rtype))
radars = radars.append(pd.DataFrame(radar_data, columns=['frq', 'pw', 'prf', '
radar_type']),ignore_index=True)
#print(radars.head())
print(radars)
hist = radars.hist(column=['frq', 'pw', 'prf'])

# radar #2: 9415-9475±1%; 0.08±1%; 375±1%
lfreq = 9415
hfreq = 9475
cfreq = (lfreq + hfreq)/2
pw = 0.08
pri = 375
number_of_items = number_of_items_per_class[1]
freq = truncated_normal_ints(mean=cfreq, sd=cfreq*0.01, low=lfreq, upp=hfreq,
                              num=number_of_items)
pw = truncated_normal_floats(mean=pw, sd=pw*0.01, low=pw*0.99, upp=pw*1.01,
                              num=number_of_items)
pri = truncated_normal_ints(mean=pri, sd=pri*0.01, low=pri*0.99, upp=pri*1.01,
                              num=number_of_items)

rtype = np.full((number_of_items,), 1)
radar_data = np.column_stack((freq, pw, pri, rtype))
radars = radars.append(pd.DataFrame(radar_data, columns=['frq', 'pw', 'prf', '
radar_type']),ignore_index=True)

# radar #3: 1295±1%; 1000±1%; 375±1%
freq = 1295
pw = 1000.0
pri = 375
number_of_items = number_of_items_per_class[2]
freq = truncated_normal_ints(mean=freq, sd=freq*0.01, low=freq*0.99, upp=freq*
1.01,
                              num=number_of_items)
pw = truncated_normal_floats(mean=pw, sd=pw*0.01, low=pw*0.99, upp=pw*1.01,
                              num=number_of_items)
pri = truncated_normal_ints(mean=pri, sd=pri*0.01, low=pri*0.99, upp=pri*1.01,
                              num=number_of_items)

rtype = np.full((number_of_items,), 2)
radar_data = np.column_stack((freq, pw, pri, rtype))
radars = radars.append(pd.DataFrame(radar_data, columns=['frq', 'pw', 'prf', '
radar_type']),ignore_index=True)

# radar #4: 1250-1350±1%; 1.0±1%; 40±1%
lfreq = 1250

```

```

hfreq = 1350
cfreq = (lfreq + hfreq)/2
pw = 1.0
pri = 40
number_of_items = number_of_items_per_class[3]
freq = truncated_normal_ints(mean=cfreq, sd=cfreq*0.01, low=lfreq, upp=hfreq,
                             num=number_of_items)
pw = truncated_normal_floats(mean=pw, sd=pw*0.01, low=pw*0.99, upp=pw*1.01,
                              num=number_of_items)
pri = truncated_normal_ints(mean=pri, sd=pri*0.01, low=pri*0.99, upp=pri*1.01,
                             num=number_of_items)

rtype = np.full((number_of_items,), 3)
radar_data = np.column_stack((freq, pw, pri, rtype))
radars = radars.append(pd.DataFrame(radar_data, columns=['frq', 'pw', 'prf', '
radar_type']), ignore_index=True)

# radar #5: 850-942±1%; 2.0±1%; 280±1%
lfreq = 850
hfreq = 942
cfreq = (lfreq + hfreq)/2
pw = 2.0
pri = 280
number_of_items = number_of_items_per_class[4]
freq = truncated_normal_ints(mean=cfreq, sd=cfreq*0.01, low=lfreq, upp=hfreq,
                             num=number_of_items)
pw = truncated_normal_floats(mean=pw, sd=pw*0.01, low=pw*0.99, upp=pw*1.01,
                              num=number_of_items)
pri = truncated_normal_ints(mean=pri, sd=pri*0.01, low=pri*0.99, upp=pri*1.01,
                             num=number_of_items)

rtype = np.full((number_of_items,), 4)
radar_data = np.column_stack((freq, pw, pri, rtype))
radars = radars.append(pd.DataFrame(radar_data, columns=['frq', 'pw', 'prf', '
radar_type']), ignore_index=True)

labels = radars['radar_type']
features = radars.drop('radar_type', 1)

training_data, test_data, training_labels, test_labels = train_test_split(fea

print(training_data.shape)
print(training_labels.shape)
print(test_data.shape)
print(test_labels.shape)

# .
model = models.Sequential()

```

```
model.add(Dense(32, input_dim=3, activation='relu'))
model.add(Dense(16, activation='relu'))
model.add(Dense(number_of_classes, activation='softmax'))
model.summary()

model.compile(optimizer='adam',
              loss=tf.keras.losses.SparseCategoricalCrossentropy(from_logits=True),
              metrics=['accuracy'])

history = model.fit(training_data, training_labels, epochs=50,
                   validation_data=(test_data, test_labels))

plt.plot(history.history['accuracy'], label='accuracy')
plt.plot(history.history['val_accuracy'], label = 'val_accuracy')
plt.xlabel('Epoch')
plt.ylabel('Accuracy')
plt.ylim([0.5, 1])
plt.legend(loc='lower right')

test_loss, test_acc = model.evaluate(test_data, test_labels, verbose=2)

# Prediction for one radar
data = [[9400, 0.1, 410]]
radar_to_predict = pd.DataFrame(data, columns=['frq', 'pw', 'prf'])
pred_radar = model.predict(radar_to_predict)
print(pred_radar)
pred_radar = np.round(pred_radar).astype(int)
print(pred_radar)

# Prediction for test_data
predictions = model.predict(test_data)
predictions = np.round(predictions).astype(int)

test_labels = to_categorical(np.asarray(test_labels), dtype = "uint8")

cm = confusion_matrix(test_labels.argmax(axis=1), predictions.argmax(axis=1))
disp = ConfusionMatrixDisplay(confusion_matrix=cm, display_labels=['Radar_#1',
'Radar_#2', 'Radar_#3', 'Radar_#4', 'Radar_#5'])
disp.plot()
```

## ANEXO XIV

### Código del modelo de AI (*radar\_ml.ipynb*)

```
import matplotlib.pyplot as plt
import numpy as np
import pandas as pd
from tensorflow.keras import datasets, layers, models
from keras.layers import Dense, Flatten, Embedding, Conv1D, GlobalMaxPooling1D
from scipy.stats import truncnorm
from sklearn.model_selection import train_test_split
import tensorflow as tf
from sklearn.metrics import confusion_matrix, ConfusionMatrixDisplay
from tensorflow.keras.utils import to_categorical
from scipy import stats

# Simulation parameters
require_cols = [4,6,7,9] # columns to process
number_of_classes = 24 # number of radar classes
keep = [1,6,12,13,] # classes to keep
threshold = 3

# Load "Barrutia" dataset
from google.colab import drive
drive.mount('/content/drive')
radars_raw = pd.read_excel('/content/drive/MyDrive/BBDD.xlsx', sheet_name = 0,
    usecols = require_cols, skiprows=1, nrows=240, header=None, dtype=float)
#radars_raw.tail()
#radars_raw.hist(column=[6,7])

# Append "Chereguini" dataset
df = pd.read_excel('/content/drive/MyDrive/BBDD.xlsx', sheet_name = 1, usecols
    = require_cols, skiprows=1, nrows=239, header=None, dtype=float)
radars_raw = radars_raw.append(df, ignore_index=True)
#radars_raw.tail()
#df.hist(column=[6,7])

# Append "Rull" dataset
df = pd.read_excel('/content/drive/MyDrive/BBDD.xlsx', sheet_name = 2, usecols
    = require_cols, skiprows=1, nrows=237, header=None, dtype=float)
radars_raw = radars_raw.append(df, ignore_index=True)
#radars_raw.tail()
#df.hist(column=[6,7])
```

```

# Append "Salas" dataset
df = pd.read_excel('/content/drive/MyDrive/BBDD.xlsx', sheet_name = 3, usecols
    = require_cols, skiprows=1, nrows=240, header=None, dtype=float)
radars_raw = radars_raw.append(df, ignore_index=True)
#radars_raw.tail()
#df.hist(column=[6,7])

# Append "Descon" dataset
df = pd.read_excel('/content/drive/MyDrive/BBDD.xlsx', sheet_name = 4, usecols
    = require_cols, skiprows=1, nrows=120, header=None, dtype=float)
radars_raw = radars_raw.append(df, ignore_index=True)
#radars_raw.tail()
#df.hist(column=[6,7])

# Append "MaPita" dataset
df = pd.read_excel('/content/drive/MyDrive/BBDD.xlsx', sheet_name = 5, usecols
    = require_cols, skiprows=1, nrows=174, header=None, dtype=float)
radars_raw = radars_raw.append(df, ignore_index=True)
#radars_raw.tail()
#df.hist(column=[6,7])

# Append "Aduanas" dataset
df = pd.read_excel('/content/drive/MyDrive/BBDD.xlsx', sheet_name = 6, usecols
    = require_cols, skiprows=1, nrows=30, header=None, dtype=float)
radars_raw = radars_raw.append(df, ignore_index=True)
#radars_raw.tail()
#df.hist(column=[6,7])

# Append "CorvoMariño" dataset
df = pd.read_excel('/content/drive/MyDrive/BBDD.xlsx', sheet_name = 7, usecols
    = require_cols, skiprows=1, nrows=143, header=None, dtype=float)
radars_raw = radars_raw.append(df, ignore_index=True)
#radars_raw.tail()
#df.hist(column=[6,7])

# Append "Intermares" dataset
df = pd.read_excel('/content/drive/MyDrive/BBDD.xlsx', sheet_name = 8, usecols
    = require_cols, skiprows=1, nrows=75, header=None, dtype=float)
radars_raw = radars_raw.append(df, ignore_index=True)
#radars_raw.tail()
#df.hist(column=[6,7])

# Append "RioGuadalope" dataset
df = pd.read_excel('/content/drive/MyDrive/BBDD.xlsx', sheet_name = 9, usecols
    = require_cols, skiprows=1, nrows=105, header=None, dtype=float)
radars_raw = radars_raw.append(df, ignore_index=True)
#radars_raw.tail()
#df.hist(column=[6,7])

column_names = ['radar_type', 'pw', 'prf', 'n']

```

```
#column_names = ['radar_type', 'pw', 'prf', 'bw', 'n']
radars_raw.columns = column_names
radars_raw.dropna(inplace=True)
radars_raw['radar_type'] = radars_raw['radar_type'].astype('int')

# Keep classes
radars_raw = radars_raw[radars_raw['radar_type'].isin(keep)]
print(radars_raw)

# Remove outliers from pw
radars = pd.DataFrame()
for radar_type in range(1,number_of_classes):
    reextracted = radars_raw[radars_raw['radar_type'] == radar_type]
    z = np.abs(stats.zscore(reextracted['pw']))
    radarz = reextracted[(z < threshold)]
    radars = radars.append(radarz, ignore_index=True)

print('Original:', radars_raw.shape)
print('Filtered:', radars.shape)

# Remove outliers from prf
radars_raw = radars
radars = pd.DataFrame() # empty radars
for radar_type in range(1,number_of_classes):
    reextracted = radars_raw[radars_raw['radar_type'] == radar_type]
    z = np.abs(stats.zscore(reextracted['prf']))
    radarz = reextracted[(z < threshold)]
    radars = radars.append(radarz, ignore_index=True)

print('Original:', radars_raw.shape)
print('Filtered:', radars.shape)

# Remove outliers from n
radars_raw = radars
radars = pd.DataFrame() # empty radars
for radar_type in range(1,number_of_classes):
    reextracted = radars_raw[radars_raw['radar_type'] == radar_type]
    z = np.abs(stats.zscore(reextracted['n']))
    radarz = reextracted[(z < threshold)]
    radars = radars.append(radarz, ignore_index=True)

print('Original:', radars_raw.shape)
print('Filtered:', radars.shape)

#hist = radars.hist(column=['pw','prf'])
# get labels
labels = radars['radar_type']
# get features from radar dataframe deleting radar_type column before
```

```

features = radars.drop('radar_type', 1)
training_data, test_data, training_labels, test_labels = train_test_split(features, labels, test_size=0.2, random_state=1)

#print(training_data.shape)
#print(training_labels.shape)
#print(test_data.shape)
#print(test_labels.shape)
display_labels= ['BAR_B_L', 'BAR_B_S', 'BAR_A_L', 'BAR_A_S'] # 1-4
display_labels+=['CHE_B_L', 'CHE_B_S', 'CHE_A_L', 'CHE_A_S'] # 5-8
display_labels+=['RUL_B_L', 'RUL_B_S', 'RUL_A_L', 'RUL_A_S'] # 9-12
display_labels+=['SAL_B_L', 'SAL_B_S', 'SAL_A_L', 'SAL_A_S'] # 13-16
display_labels+=['DESCON'] # 17
display_labels+=['MAPITA-I', 'MAPITA-II'] # 18-19
display_labels+=['ADUANAS'] # 20
display_labels+=['CORVOMARIÑO'] # 21
display_labels+=['INTERMARES'] # 22
display_labels+=['RIOGUADALOPE'] # 23
label_list = labels.value_counts().sort_index()

for i,label in label_list.items():
    print(display_labels[i-1],':',label)

# Model definition
model = models.Sequential()

model.add(Dense(32, input_dim=3, activation='relu'))
model.add(Dense(16, activation='relu'))
model.add(Dense(number_of_classes, activation='softmax'))

#model.add(Dense(128, activation='relu', input_dim=5))
#model.add(Dense(256, activation='relu'))
#model.add(Dense(128, activation='relu'))
#model.add(Flatten())
#model.add(Dense(number_of_classes, activation='softmax'))

#model.add(Dense(number_of_classes, input_dim=5, activation='softmax'))

model.summary()

model.compile(optimizer='adam',
              loss=tf.keras.losses.SparseCategoricalCrossentropy(from_logits=True),
              metrics=['accuracy'])

plt.plot(history.history['accuracy'], label='accuracy')
plt.plot(history.history['val_accuracy'], label='val_accuracy')
plt.xlabel('Epoch')
plt.ylabel('Accuracy')
plt.ylim([0.1, 1.0])

```

```
plt.legend(loc='lower right')

test_loss, test_acc = model.evaluate(test_data, test_labels, verbose=2)

# Prediction for one radar
data = [[0.2, 500, 35]]
radar_to_predict = pd.DataFrame(data, columns=['pw', 'prf', 'n'])
pred_radar = model.predict(radar_to_predict)
print(pred_radar)
index = np.argmax(pred_radar)
print(display_labels[index])

pred_radar = np.round(pred_radar).astype(int)
print(pred_radar)

# Prediction for test_data
predictions = model.predict(test_data)
predictions = np.round(predictions).astype(int)

test_labels = to_categorical(np.asarray(test_labels), dtype="uint8")

cm = confusion_matrix(test_labels.argmax(axis=1), predictions.argmax(axis=1))

disp = ConfusionMatrixDisplay(confusion_matrix=cm, display_labels=display_labels)
disp.plot(xticks_rotation=90)
```