



Universidad
Politécnica
de Cartagena

Campus
de Excelencia
Internacional

*Aplicación de la inteligencia artificial a la
defensa de un buque contra misiles de guía
de radiofrecuencia mediante señuelos*

Doctorado en Tecnologías Industriales

Autor: Ramón Touza Gil

Director: Javier Martínez Torres

Codirectores: María Álvarez Hernández

Javier Roca Pardiñas

Cartagena 2021

RESUMEN

Una de las situaciones más peligrosas a las que puede tener que enfrentarse un buque de guerra es a un ataque con misiles lanzados desde otros buques, aeronaves, submarinos o desde tierra. Además, dado el escenario actual, no es descartable que un grupo terrorista pueda adquirir misiles y emplearlos contra barcos que estén operando cerca de la costa, lo que aumenta su vulnerabilidad debido al escaso margen de reacción.

Uno de los medios que tiene el buque para su defensa son los señuelos, diseñados para engañar al misil enemigo. Sin embargo, para que su empleo sea efectivo es necesario obtener, de forma rápida, una solución de lanzamiento válida.

El propósito principal de esta tesis es mejorar la efectividad del lanzamiento de señuelos antimisil de un buque mediante la construcción de un modelo de inteligencia artificial/aprendizaje automático y de un gestor de soluciones basado en técnicas de decisión multicriterio, que proporcionen de forma inmediata, los datos necesarios para tomar la decisión de disparo.

Para abordar el objetivo anteriormente expuesto, ha sido necesario diseñar una metodología que, a partir de los datos aportados por un radar instrumental, permita automatizar el análisis estadístico y la generación de modelos de distribución de probabilidad más realistas de la superficie equivalente radar de un buque, que implementados en un simulador numérico de la defensa antimisil, logren mejorar los resultados de la simulación y obtener un conjunto de datos de entrenamiento fiable para la construcción de los modelos de inteligencia artificial.

ABSTRACT

One of the most dangerous situations a warship may have to face is an attack with missiles launched from other ships, aircraft, submarines or from land. Moreover, given the current scenario, it is not out of the question that a terrorist group could acquire missiles and use them against ships operating close to the coast, which increases their vulnerability due to the limited reaction margin.

One of the means available to the ship for its defense are decoys, designed to deceive the enemy missile. However, in order for their use to be effective, it is necessary to quickly obtain a valid launching solution.

The main purpose of this thesis is to improve the effectiveness of a ship's anti-missile decoy launch by develop an artificial intelligence/machine learning model and a solution manager based on multi-criteria decision making techniques that immediately provides the ship with the necessary data to make the firing decision.

To address the above objective, it has been necessary to design a methodology that, from the data provided by an instrumental radar, allows to automate the statistical analysis and the generation of more realistic probability density functions of a ship radar cross section, which, implemented in a numerical simulator of the anti-missile defense, can improve the simulation results and obtain a reliable training data set for the construction of artificial intelligence models.

A mi mujer y mis hijos Pablo y Catalina.

A mis padres y hermanos.

AGRADECIMIENTOS

Agradecer, en primer lugar a mi director de tesis, Javier Martínez su ayuda, apoyo y empuje durante estos años de trabajo que han hecho posible la culminación de esta tesis.

A mis codirectores, especialmente a María por la paciencia que ha tenido conmigo y por dejarse robar tiempo con mis tutorías.

Al Comandante-Director de la Escuela Naval Militar, Ignacio Cuartero Lorenzo, amigo y compañero, por todo su apoyo en estos últimos años.

Al jefe de Estudios, a los Jefes de los Departamentos 1 y 3 y a todos los oficiales de la Escuela Naval Militar, con un recuerdo especial a Juan Carlos el “Doctor” que nos ha dejado recientemente.

A Heitor Martínez, colaborador infatigable en el Gabinete de Investigación Operativa y a Luis Sánchez por su ayuda en el terreno electromagnético.

Al Centro de Medidas Electromagnéticas de la Armada y al Grupo de Antenas, Radar y Comunicaciones Ópticas de la Universidad de Vigo.

A mis antiguos compañeros del Centro Universitario de la Defensa, a Alicia correctora estilística de este trabajo, a Roberto Bellas, a Mila por dejarme participar en su grupo de investigación y a José M^a (Tyson) por sus aclaraciones a mis dudas electromagnéticas.

IN MEMORIAM

*A Francisco Javier Montojo Salazar (Monty), amigo,
compañero, científico y gran militar, fallecido en acto
de servicio el día 2 de marzo de 2018, en aguas de la
Antártida cuando trabajaba en el proyecto Galileo.*

ÍNDICE DE CONTENIDOS

CAPÍTULO 1. INTRODUCCIÓN.....	1
1.1. MOTIVACIÓN Y OBJETIVOS.....	1
1.2. UN POCO DE HISTORIA. LECCIONES APRENDIDAS.....	2
1.2.1. <i>La Segunda Guerra mundial. El primer misil</i>	2
1.2.2. <i>Después de la Segunda Guerra Mundial. El conflicto Árabe-Israelí</i>	3
1.2.3. <i>La Guerra de las Malvinas</i>	4
1.2.4. <i>Otros incidentes</i>	7
1.2.5. <i>Lecciones aprendidas</i>	9
1.3. ESTADO DEL ARTE DEL PROBLEMA.....	10
1.4. OBJETIVOS DE LA TESIS.....	15
1.5. METODOLOGÍA.....	16
1.6. APORTACIONES.....	19
1.7. ESTRUCTURA DE LA MEMORIA	21
CAPÍTULO 2. LA DEFENSA ANTIMISIL DE UN BUQUE.....	23
2.1. EL MISIL AMENAZA.....	23
2.1.1. <i>Sistemas y componentes</i>	24
2.1.2. <i>Clasificación de los misiles antibuque</i>	27
2.1.3. <i>Misiles antibuque de guía por radiofrecuencia</i>	28
2.2. MEDIOS Y FASES EN LA DEFENSA ANTIMISIL.....	31
2.2.1. <i>Señuelos</i>	31
2.2.2. <i>Lanzadores de señuelos</i>	33
2.2.3. <i>El proceso de la seducción de un misil antibuque mediante señuelos. Efecto centroide</i> 35	
2.2.4. <i>Fases en la defensa antimisil</i>	36
CAPÍTULO 3. MODELADO DE LA SUPERFICIE EQUIVALENTE RADAR.....	39
3.1. INTRODUCCIÓN.....	39
3.2. FUNDAMENTOS DEL SISTEMA RADAR	39
3.2.1. <i>Introducción</i>	39
3.2.2. <i>Diagrama de bloques del radar</i>	41
3.2.3. <i>Obtención de la distancia radar</i>	46
3.2.4. <i>El alcance máximo no ambiguo</i>	47
3.2.5. <i>Resolución en distancia</i>	48
3.2.6. <i>Discriminación angular</i>	50
3.2.7. <i>Celda de resolución</i>	51
3.2.8. <i>Forma simple de la ecuación radar</i>	52
3.2.9. <i>Frecuencias radar</i>	54
3.2.10. <i>Clasificación de los sistemas radares</i>	56
3.2.11. <i>El radar de un misil antibuque</i>	57
3.3. FUNDAMENTOS DE LA SUPERFICIE EQUIVALENTE RADAR	62
3.3.1. <i>Definición de superficie equivalente radar</i>	63
3.3.2. <i>Ecuación intuitiva de la superficie equivalente radar</i>	64

3.3.3.	<i>Unidades de medida de la superficie equivalente radar.....</i>	<i>66</i>
3.3.4.	<i>Dispersión.....</i>	<i>67</i>
3.3.5.	<i>Formas de medir la superficie equivalente radar.....</i>	<i>71</i>
3.3.6.	<i>Reducción de la superficie equivalente radar</i>	<i>75</i>
3.3.7.	<i>Propiedades estadísticas de la superficie equivalente radar</i>	<i>78</i>
3.4.	SEÑUELOS TIPO CHAFF. CARACTERÍSTICAS Y SUPERFICIE EQUIVALENTE	
RADAR.....		79
3.4.1.	<i>Materiales componentes</i>	<i>81</i>
3.4.2.	<i>Lanzamiento, despliegue, variación temporal de la RCS y persistencia</i>	<i>84</i>
3.5.	MODELADO DE LA SUPERFICIE EQUIVALENTE RADAR EN BLANCOS	
COMPLEJOS.....		85
3.5.1.	<i>Distribuciones de probabilidad relacionadas con el modelado de la RCS.....</i>	<i>87</i>
3.5.2.	<i>Contrastes de Bondad del ajuste.....</i>	<i>95</i>
3.5.3.	<i>Contraste de Wilcoxon de rangos con signos</i>	<i>97</i>
3.5.4.	<i>Aplicación de los contrastes de bondad del ajuste para muestras grandes</i>	<i>98</i>
3.6.	METODOLOGÍA PARA EL MODELADO DE LA RCS DE UN BUQUE. APLICACIÓN	
A UN CASO REAL		100
3.6.1.	<i>Datos obtenidos por el DIAR.....</i>	<i>100</i>
3.6.2.	<i>Preprocesado de los datos y análisis descriptivo y gráfico.</i>	<i>101</i>
3.6.3.	<i>Análisis inferencial. Estimación del modelo de probabilidad óptimo de la RCS</i>	<i>107</i>
3.6.4.	<i>Análisis de las marcaciones o aspectos anómalos en el modelo óptimo.....</i>	<i>110</i>
3.6.5.	<i>Conclusiones finales sobre el modelo óptimo de RCS.....</i>	<i>118</i>
 CAPÍTULO 4. MODELADO, SIMULACIÓN Y RESULTADOS DE LAS BATERÍAS DE EXPERIMENTOS 121		
4.1.	INTRODUCCIÓN.....	121
4.2.	PRINCIPIOS BÁSICOS DEL MODELADO Y LA SIMULACIÓN	121
4.2.1.	<i>Sistemas y modelos</i>	<i>122</i>
4.2.2.	<i>Tipos de modelos.....</i>	<i>124</i>
4.2.3.	<i>Modelos matemáticos</i>	<i>127</i>
4.2.4.	<i>Modelos estocásticos. Generación de números aleatorios</i>	<i>128</i>
4.2.5.	<i>Pasos en un estudio de simulación</i>	<i>132</i>
4.3.	EL SIMULADOR DEL LANZAMIENTO DE SEÑUELOS. DESCRIPCIÓN	134
4.3.1.	<i>El objeto buque.....</i>	<i>137</i>
4.3.2.	<i>El objeto misil.....</i>	<i>140</i>
4.3.3.	<i>El objeto señuelo.....</i>	<i>141</i>
4.3.4.	<i>Meteorología.....</i>	<i>143</i>
4.3.5.	<i>Modelo del algoritmo de guiado del misil. Efecto centroide.....</i>	<i>143</i>
4.4.	IMPLEMENTACIÓN DE UN NUEVO MODELO DE SUPERFICIE EQUIVALENTE	
RADAR EN ALSA		144
4.4.1.	<i>Generación de números aleatorios en C#.Net.....</i>	<i>145</i>
4.4.2.	<i>Generación de observaciones de variables aleatorias. Distribución Weibull.....</i>	<i>145</i>
4.5.	BATERÍAS DE EXPERIMENTOS Y RESULTADOS DE LA SIMULACIÓN	150
4.5.1.	<i>Escenarios</i>	<i>150</i>

4.5.2.	<i>Baterías de experimentos</i>	151
4.5.3.	<i>Cálculo de las réplicas necesarias</i>	152
4.5.4.	<i>Generación del conjunto de datos</i>	154
4.5.5.	<i>Análisis gráfico de los resultados de la simulación</i>	155
CAPÍTULO 5. IMPLEMENTACIÓN DE UN MODELO DE INTELIGENCIA ARTIFICIAL PARA LA SOLUCIÓN DE LANZAMIENTO		163
5.1.	INTRODUCCIÓN	163
5.2.	INTELIGENCIA ARTIFICIAL. DEFINICIÓN.	164
5.3.	APRENDIZAJE AUTOMÁTICO	167
5.3.1.	<i>Técnicas de aprendizaje automático</i>	168
5.3.2.	<i>El problema del lanzamiento de señuelos. Aprendizaje supervisado</i>	171
5.4.	ENTRENAMIENTO Y EVALUACIÓN EN APRENDIZAJE AUTOMÁTICO	173
5.4.1.	<i>Entrenamiento, validación y prueba del modelo</i>	173
5.4.2.	<i>Validación cruzada</i>	174
5.4.3.	<i>Métricas de evaluación del modelo</i>	174
5.4.4.	<i>Diagnóstico del modelo</i>	178
5.5.	MÁQUINAS DE VECTORES SOPORTE	180
5.5.1.	<i>Clasificadores de margen máximo</i>	181
5.5.2.	<i>Formulación dual de las SVM</i>	183
5.5.3.	<i>Clasificadores de margen suave</i>	184
5.5.4.	<i>Truco de kernel o kernel trick</i>	184
5.5.5.	<i>Máquinas de vectores soporte de regresión</i>	185
5.6.	REDES NEURONALES.....	187
5.6.1.	<i>Perceptrón multicapa</i>	190
5.6.2.	<i>Método de entrenamiento del MLP. Backpropagation</i>	193
5.6.3.	<i>Algoritmos de entrenamiento</i>	196
5.6.4.	<i>Tamaño y profundidad de la red y sobreaprendizaje</i>	198
5.7.	CONSTRUCCIÓN DE LOS MODELOS DE APRENDIZAJE AUTOMÁTICO PARA EL PROBLEMA DE LANZAMIENTO DE SEÑUELOS.....	201
5.7.1.	<i>Conjunto de datos de entrenamiento. Variables de entrada y de salida</i>	201
5.7.2.	<i>Paso#1. Normalización de los datos</i>	203
5.7.3.	<i>Paso#2. Diseño de los modelos del SVM y del MPL</i>	204
5.7.4.	<i>Paso#3. Entrenamiento, validación y test de todos los modelos de SVM y de MLP</i> ..206	
5.7.5.	<i>Paso#4. Determinación del modelo óptimo para cada variable de salida</i>	208
5.7.6.	<i>Paso#5. Entrenamiento de los modelos óptimos con número mayor de instancias para mejorar el ajuste del modelo, construcción de la solución final y test</i>	215
5.7.7.	<i>Ampliación de la solución final</i>	218
CAPÍTULO 6. EVALUACIÓN DE LAS SOLUCIONES DE LANZAMIENTO DE SEÑUELOS. EL GESTOR DE SOLUCIONES		221
6.1.	INTRODUCCIÓN	221
6.2.	EL PARADIGMA DE LA DECISIÓN MULTICRITERIO DISCRETA	222
6.2.1.	<i>El decisor y el analista</i>	224

6.2.2.	<i>El conjunto de elección</i>	224
6.2.3.	<i>Atributos y criterios</i>	224
6.2.4.	<i>La matriz de decisión o matriz decisional</i>	226
6.2.5.	<i>Cuantificación de las evaluaciones. La función de utilidad</i>	226
6.2.6.	<i>Métodos de construcción de funciones de utilidad</i>	228
6.2.7.	<i>Pasos en un problema de decisión multicriterio</i>	229
6.2.8.	<i>Elección del modelo de decisión multicriterio discreta</i>	230
6.3.	TEORÍA DE UTILIDAD MULTIATRIBUTO (MAUT)	232
6.4.	EL PROCESO DE ANÁLISIS JERÁRQUICO (AHP)	233
6.4.1.	<i>Axiomas básicos</i>	234
6.4.2.	<i>Metodología del proceso AHP</i>	235
6.4.3.	<i>Construcción de la estructura jerárquica del problema</i>	235
6.4.4.	<i>Construcción de las matrices de comparación por parejas</i>	236
6.4.5.	<i>Sintetización. Cálculo del vector de pesos y valoración de las alternativas</i>	238
6.4.6.	<i>Prueba de consistencia</i>	239
6.4.7.	<i>Determinar el orden de la prioridad global</i>	241
6.5.	CONSTRUCCIÓN DEL GESTOR DE SOLUCIONES	242
6.5.1.	<i>Jerarquía. Alternativas y criterios</i>	243
6.5.2.	<i>Pesos de los criterios. Matriz de comparación por parejas</i>	244
6.5.3.	<i>Valoración de las alternativas. Funciones de utilidad</i>	245
6.5.4.	<i>Cálculo del orden global</i>	248
6.6.	APLICACIÓN DE LA SOLUCIÓN A UN CASO DE USO	249
6.6.1.	<i>Conjunto de modelos/Gestor de soluciones vs simulador ALSA</i>	250
6.6.2.	<i>Análisis y visualización de la solución recomendada</i>	251
CAPÍTULO 7. CONCLUSIONES Y LÍNEAS FUTURAS DE INVESTIGACIÓN		255
7.1.	OBJETIVO NIVEL#3. METODOLOGÍA PARA MODELADO DE LA SUPERFICIE EQUIVALENTE RADAR	255
7.2.	OBJETIVO NIVEL#2. MEJORA DE LA SIMULACIÓN	256
7.3.	OBJETIVOS NIVEL#1. MEJORA DE LA SOLUCIÓN DE LANZAMIENTO DE SEÑUELOS. APLICACIÓN DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL	257
7.3.1.	<i>Mejora de la solución de lanzamiento</i>	257
7.3.2.	<i>Implementación de técnicas de IA/machine learning en ámbitos de decisión táctica</i> ..	258
7.4.	LÍNEAS FUTURAS DE INVESTIGACIÓN	258

LISTA DE FIGURAS

Figura 1-1. Seducción de un misil mediante señuelos (Huber, 2011)	2
Figura 1-2. Misil Henschel Hs 293. (Fuente: San Diego Air & Space Museum Archivos en flickr)	3
Figura 1-3. Patrullera de la clase Komar lanzando un misil Styx (Fuente: www.naval-encyclopedia.com)	4
Figura 1-4. Destructor HMS Sheffield momentos después del impacto del misil Exocet argentino (Fuente: www.theguardian.com)	5
Figura 1-5. Estado del buque Atlantic Conveyor al día siguiente del impacto (Fuente: www.thinkdefence.co.uk)	6
Figura 1-6. Portaaviones HMS Invincible (izquierda) y un avión Super-Etendard de la Armada Argentina (derecha) armando con un misil Exocet previo al ataque (Fuente: Royal Navy y Armada Argentina)	7
Figura 1-7. Fragata USS Stark después del impacto de los misiles (Fuente: www.history.navy.mil) ...	7
Figura 1-8. Corbeta INS Hanit de la María Israelí	8
Figura 1-9. Destructor USS Mason (Fuente: US Navy)	8
Figura 1-10. Integración de medios en ASMD (Fuente: MIT Lincoln Laboratory)	9
Figura 1-11. Pilares en una reacción antimisil	10
Figura 1-12. Configuración típica de cuatro lanzadores de señuelos en un buque de porte medio	11
Figura 1-13. Estado del arte y propuesta de modificación	15
Figura 1-14. Objetivos por niveles	16
Figura 1-15. Diagrama de bloques de la metodología de trabajo	18
Figura 2-1. Misil antibuque C-802 de fabricación china lanzado desde un buque iraní (Fuente: www.ausairpower.net)	24
Figura 2-2. Diferentes sistemas de un misil antibuque Exocet de fabricación francesa (Fuente: www.mbd-systems.com)	25
Figura 2-3. Sistema de guiado del misil y su relación con otros sistemas	26
Figura 2-4. Tipos de guía de misiles antibuque y algunos ejemplos de misiles	28
Figura 2-5. Típica configuración de un misil antibuque de guía por radiofrecuencia	29
Figura 2-6. Perfil típico de un misil antibuque de guía RF	29
Figura 2-7. Fase de búsqueda	30
Figura 2-8. Fase de ataque. Celda de resolución centrada en el blanco	31
Figura 2-9. Buque desplegando señuelos tipo chaff de seducción (Huber, 2011; Viau, D'Ágostino, & Cathala, 2014)	32

Figura 2-10. Buque lanzando bengalas (Schleijpen, 2012)	33
Figura 2-11. Despliegue (izquierda) e inflado (derecha) del señuelo pasivo tipo offboard FDS3 de la empresa IrvinGQ (Fuente: www.irvingcq.com).....	33
Figura 2-12. Diferentes lanzadores de señuelos (Fuentes: www.chemring.co.uk ; www.elbitsystems.com ; www.lacroix-defense.com ; www.leonardocompany.com)	34
Figura 2-13. Lanzadores MK-36 (izquierda) y dos miembros de la dotación del buque cargando señuelos (derecha) (Fuente: www.foronaval.com y Armada Española).....	34
Figura 2-14. Seducción del misil mediante efecto centroide.....	36
Figura 2-15. Cadena de la muerte o Kill chain (Galle, 2002)	36
Figura 2-16. Lanzamiento de un misil ESSM (izquierda) y Cañón CIWS Vulkan Phallax de la Marina de los EEUU (Fuentes: Armada Española, www.seaforces.org)	38
Figura 3-1. Esquema de bloques básico de un sistema radar	42
Figura 3-2. Lóbulos de radiación de una antena.....	43
Figura 3-3. Polarización horizontal y vertical.....	43
Figura 3-4. Ganancia de una antena direccional.....	44
Figura 3-5. Diferentes tipos de antenas: a) Radar de tiro DORNA; b) Radar de exploración aérea AN/SPS-49; c) Radar seeker del misil AS-10 Karen d) radar de navegación Sperry (Fuentes: www.buquesdeguerra.com , www.ausairpower.net , www.sperrymarine.com)	44
Figura 3-6. Forma de la onda. Tren de pulsos.....	47
Figura 3-7. Tren de pulsos de un radar	48
Figura 3-8. Resolución en distancia	48
Figura 3-9. Espectro de frecuencia y ancho de banda para un pulso sin codificar.....	49
Figura 3-10. Radar de compresión de pulsos chirp: a) forma del pulso; b) frecuencia de la onda transmitida; c) forma de la onda.....	50
Figura 3-11. Resolución angular $\Delta\theta$	51
Figura 3-12. Resolución angular (ΔRc)	51
Figura 3-13. Celda de resolución de un radar.	52
Figura 3-14. Radares de seguimiento: a) Radar STIR de la dirección de tiro MK-92; b) radar seeker del misil anti buque Brahmos (Fuentes: Armada Española y www.delhodefencereview.com)... ..	55
Figura 3-15. Designación de las bandas de frecuencia radar según IEEE y la denominación militar .	55
Figura 3-16. Radar Lanza. Antenas del radar primario y del secundario (fuente: www.indra.es)	56
Figura 3-17. Misil de origen ruso P-15 Termit (SS-N-2 “Styx” en código OTAN): a) vista del radar; b) misil en el momento de la carga en un buque (fuente: www.military-today.com).....	57
Figura 3-18. Diagrama de bloques de un seeker coherente y monopulso	58

Figura 3-19. Lóbulos generados por los cuatros cuadrantes de una antena monopulso	59
Figura 3-20. Seguimiento en distancia con puerta de distancia dividida: a) blanco centrado en distancia; b) blanco alejado en distancia.....	61
Figura 3-21. Principios de funcionamiento de la técnica de seguimiento monopulso: a) blanco centrado; b) blanco a la izquierda del eje de la antena; c) blanco por encima del eje de la antena	61
Figura 3-22. Típica forma de la superficie equivalente radar de un buque.....	66
Figura 3-23. Superficie equivalente radar de una esfera de radio r	69
Figura 3-24. Diferentes mecanismos de dispersión en un buque	70
Figura 3-25. Puerta de la maniobra de arriado de botes en un patrullero tipo BAM de la Armada. (Fuente: Armada Española).....	70
Figura 3-26. Forma del futuro misil antibuque y de crucero Perseus de la empresa MBDA (fuente: www.mbda-systems.com)	71
Figura 3-27. Configuración de medición a escala de RCS monoestática sobre un modelo de buque (Blanche, Neifeld, & Peyghambarian, 2017)	74
Figura 3-28. DIAR y el laboratorio móvil del Centro de Medidas Electromagnéticas (CEMEDEM) (fuente: Armada Española).....	75
Figura 3-29. Reducción de la RCS de un buque mediante el pintado con fibras RAM de la empresa Micromag. En rojo y en azul se representan la RCS del buque antes y después del pintado (García Tuñón et al., 2014)	77
Figura 3-30. Avión F-117 construido con tecnología stealth (fuente: www.lockheedmartin.com)	77
Figura 3-31. Destructor USS Zumwalt de la marina de los Estados Unidos construido con tecnología stealth (fuente: www.navy.mil)	78
Figura 3-32. Futura fragata F-110 de la Armada Española diseñada con tecnología stealth (fuente: www.navantia.es).....	78
Figura 3-33. Curvas teóricas de respuesta para tres conjuntos de dipolos resonantes a 6,0 (rojo); 8,0 (verde) y 10,0 (azul) GHz (Butters, 1982).....	81
Figura 3-34. Cartucho Mk36 tipo 1 (Fuente: www.chemring.co.uk).....	84
Figura 3-35. Variación de la RCS con el tiempo para a) chaff de hojas de aluminio 2x1; b) chaff de fibra de vidrio recubierto de aluminio. (+ polarización horizontal; × polarización vertical) (Butters, 1982).....	85
Figura 3-36. Swerling I y II. Buque visto como la suma de un determinado número de reflectores isotrópicos.	88
Figura 3-37. Forma de la distribución Swerling III para diferentes valores del parámetro μ	89
Figura 3-38. Swerling III y IV. Buque visto como un reflector isotrópico dominante y una serie de reflectores isotrópicos pequeños.....	90

Figura 3-39. Forma de la distribución Nakagami para diferentes valores de los parámetros μ y ω ...	91
Figura 3-40. Forma de la distribución log-normal para diferentes valores de los parámetros μ y σ ...	93
Figura 3-41. Forma de la distribución de Weibull para diferentes valores de los parámetros α y β ..	94
Figura 3-42. Relación entre distribuciones de probabilidad.....	95
Figura 3-43. Croquis de la evolución de un buque para caracterización de la RCS con DIAR	101
Figura 3-44. Secuencia de pasos en el preprocesado de los datos.....	102
Figura 3-45. Histograma para una marcación y frecuencia del buque ALFA.....	105
Figura 3-46. Gráfico polar de la RCS del buque ALFA para una frecuencia	106
Figura 3-47. Gráfico cartesiano de la RCS del buque ALFA para una frecuencia.....	106
Figura 3-48. Secuencia de pasos en el análisis inferencial de los datos. Estimación del modelo de probabilidad óptimo.....	107
Figura 3-49. Gráficas polares de la proporción de frecuencias en las que no se puede rechazar la hipótesis nula en el contraste de bondad del ajuste. Datos en escala lineal.....	111
Figura 3-50. Representación polar de los diferentes estadísticos de los p valores de las frecuencias. Datos en escala lineal.....	112
Figura 3-51. Número de marcaciones anómalas por frecuencia para la distribución de Weibull para los test Kolmogorov-Smirnov y Anderson-Darling.....	112
Figura 3-52. Secuencia del análisis de las marcaciones o aspectos anómalos en el modelo óptimo....	113
Figura 3-53. Proporción de frecuencias de no rechazo de la H_0 . a) Para la prueba KS b) Para la prueba AD	117
Figura 3-54. Histograma para una frecuencia de la marcación 180° del buque ALFA	118
Figura 4-1. Modelo del sistema de defensa antimisil del buque. Entidades, atributos y relaciones ...	123
Figura 4-2. Formas de estudiar un sistema.....	124
Figura 4-3. Modelo físico construido por la Marina Imperial Japonesa para planear el ataque a Pearl Harbor (fuente: www.historylink101.com)	125
Figura 4-4. Modelo físico de un buque en el Canal de Experiencias Hidrodinámicas de El Pardo (CEHIPAR) (Fuente: CEHIPAR)	126
Figura 4-5. Clasificación de los modelos matemáticos	127
Figura 4-6. Pasos en un estudio de simulación	134
Figura 4-7. Objetos de un escenario. Visualizador 2D	135
Figura 4-8 Esquema de la evolución de la simulación.....	137
Figura 4-9. Ejemplo de modelo estructural de buque	138
Figura 4-10. Características de la curva de evolución de un buque (izquierda) y estela dejada por un buque al ejecutar dos curvas completas (derecha)	139

Figura 4-11. Configuración de lanzadores de señuelos del buque de la simulación	140
Figura 4-12. Atributos del modelo buque para el estudio. Lanzadores, datos estructurales y forma de la RCS (no se incluye los valores de la RCS por cuestiones de confidencialidad).....	141
Figura 4-13. Atributos de la celda de resolución del radar seeker del misil.....	141
Figura 4-14. Celda de resolución de misil en 2D.....	144
Figura 4-15. Método de la transformación inversa.	147
Figura 4-16. Combinación de lanzadores y maniobras del buque	150
Figura 4-17. Batería de experimentos, escenarios y archivos de resultados	151
Figura 4-18. Marcación del misil y dirección del viento	151
Figura 4-19. Media del número de soluciones válidas por escenario para diferentes marcaciones (izquierda) y distancias (derecha) iniciales del misil	157
Figura 4-20. Media del número de soluciones válidas por escenario para diferentes marcaciones de viento (izquierda), para diferentes velocidades del viento (derecha/arriba) y diferentes velocidades del buque (derecha/abajo)	158
Figura 4-21. Media del número de soluciones válidas por escenario para cada lanzador	159
Figura 4-22. Histogramas: distancia de paso del misil, tiempo en celda y probabilidad de éxito	161
Figura 5-1. Enfoques de la inteligencia artificial según Russel y Norvig	164
Figura 5-2. Dominios de la inteligencia artificial	166
Figura 5-3. Técnicas de aprendizaje automático.....	168
Figura 5-4. Esquema básico de aprendizaje supervisado.....	169
Figura 5-5. Esquema básico de aprendizaje no supervisado (clustering)	170
Figura 5-6. Esquema básico de aprendizaje semisupervisado.....	171
Figura 5-7. Proceso para la obtención de la solución de lanzamiento.....	172
Figura 5-8. Proceso cíclico de la inteligencia artificial	172
Figura 5-9. Representación del método de validación cruzada	174
Figura 5-10. Matriz de confusión para un clasificador multiclase.....	175
Figura 5-11. Matriz de confusión para un problema de clasificación binaria.....	176
Figura 5-12. Ejemplo de curva ROC	177
Figura 5-13. Representación de infrajuste/sobreajuste para un modelo de regresión (Badillo et al., 2020)	179
Figura 5-14. Transformación del espacio de entrada mediante una función del kernel	180
Figura 5-15. Clasificadores de margen máximo	181
Figura 5-16. Hiperplano de separación, vectores soporte y margen	182

Figura 5-17. Hiperplano de regresión, vectores soporte, variables de holgura y margen ε – <i>insensitive</i>	186
Figura 5-18. Similitudes entre: a) neurona biológica y b) neurona artificial.....	188
Figura 5-19. Distintas arquitecturas: a) Red monocapa, b) Red multicapa totalmente conectada, c) Red recurrente	190
Figura 5-20. Nomenclatura utilizada en la definición matemática de una red neuronal.....	191
Figura 5-21. Ejemplo de parada temprana	200
Figura 5-22. Esquema de las acciones seguidas en el Paso#3.....	207
Figura 5-23. Comparativa de las medias de precisión (accuracy) para los distintos casos	209
Figura 5-24. Intervalos de confianza del 95% de la media de la precisión para las distintas topologías del MLP de 2 capas ocultas	209
Figura 5-25. Comparativa de las medias del error cuadrático medio (MSE) para los distintos casos.....	210
Figura 5-26. Intervalos de confianza del 95% de la media del MSE para las distintas topologías del MLP de 3 capas ocultas	211
Figura 5-27. Comparativa de las medias del error cuadrático medio (MSE) para los distintos casos.....	212
Figura 5-28. Intervalos de confianza del 95% de la media del MSE para las distintas topologías del MLP de 3 capas ocultas	212
Figura 5-29. Histograma de la probabilidad de éxito. Datos obtenidos de la simulación	213
Figura 5-30. Comparativa de las medias de precisión (accuracy) para los distintos casos	214
Figura 5-31. Intervalos de confianza del 95% de la media de la precisión para las distintas topologías del MLP de 1 capa oculta	215
Figura 5-32. Entrenamiento, construcción y prueba del conjunto de modelos.....	215
Figura 5-33. Solución final. Conjunto de modelos de perceptrón multicapa.....	216
Figura 5-34. Matrices de confusión de las variables de salida solución (izquierda) y probabilidad de éxito $>0,8$ (derecha).....	218
Figura 5-35. Ampliación de solución final.....	219
Figura 6-1. Matriz de decisión	226
Figura 6-2. Tipos de funciones de utilidad	227
Figura 6-3. Pasos en un problema de decisión multicriterio	230
Figura 6-4. Pasos del método AHP (García Cascales, 2009; Ho, 2008)	235
Figura 6-5. Jerarquía de elementos en un modelo AHP	236
Figura 6-6. Ejemplos de matrices de comparación por parejas para determinar el vector de pesos (izquierda) y asignar valores a las alternativas para un criterio (derecha)	237
Figura 6-7. Matriz de decisión	241

Figura 6-8. Matriz decisional en el método ideal	242
Figura 6-9. Matriz decisional en el método de la normalización o distributivo	242
Figura 6-10. Estructura jerárquica del problema.....	244
Figura 6-11. Vector de pesos de los criterios	245
Figura 6-12. Función de utilidad de la distancia de paso	246
Figura 6-13 Función de utilidad del tiempo en celda	247
Figura 6-14. Función de utilidad de la caída de rumbo.....	248
Figura 6-15. Salida del gestor de soluciones para un escenario.....	249
Figura 6-16. Secuencia del enfrentamiento	253
Figura 7-1 Secuencia de exposición de los objetivos alcanzados y conclusiones.....	255
Figura 7-2. Escora de un buque al realizar una caída de rumbo	259

LISTA DE TABLAS

Tabla 3-1. Características del seeker de un misil antibuque genérico (Knott et al., 2004; McEachron, 1997)	62
Tabla 3-2. Algunas medidas de RCS (O'Neil, 1991).....	67
Tabla 3-3. Comparación de las propiedades físicas de los diferentes tipos de chaff (Butters, 1982)...	82
Tabla 3-4. Intervalos de los tamaños de las muestras en caso de un contraste de hipótesis compuesto (Semenova & Khalin, 2018)	99
Tabla 3-5. Algunos intervalos para diferentes aspectos con su tamaño muestral.	103
Tabla 3-6. Matriz de muestras para diferentes aspectos y frecuencias.	104
Tabla 3-7. Marcaciones anómalas, su tamaño de la muestra y proporción de frecuencias en las que no se rechaza la hipótesis nula para los test de bondad de ajuste.....	114
Tabla 3-8. Máximos tamaños muestrales que no rechazan la hipótesis nula para KS y AD para proporción de frecuencias mayor de 0,85	116
Tabla 4-1. Valores de los atributos del señuelo	143
Tabla 4-2. Parámetros de configuración de las baterías de experimentos.....	152
Tabla 4-3. Errores en el muestreo tomados para las variables y resultados	153
Tabla 4-4. Datos de la matriz de las variables de entrada	154
Tabla 4-5. Datos de la matriz de las variables de salida	155
Tabla 4-6. Datos estadísticos descriptivos de las variables.....	160
Tabla 5-1. Funciones de kernel más comunes.	185
Tabla 5-2. Funciones de activación más habituales.....	192
Tabla 5-3. Variables de entrada del modelo	202
Tabla 5-4. Variables de salida o respuesta del modelo	203
Tabla 5-5. Cuadrícula de hiperparámetros de las SVM.....	204
Tabla 5-6. Topologías de MLP utilizadas en el análisis.....	206
Tabla 5-7. Métricas de evaluación de cada tipo de modelo	208
Tabla 5-8. Métricas de evaluación del conjunto de modelos.....	217
Tabla 6-1. Ejemplo de función de utilidad ordinal	228
Tabla 6-2. Escala de Saaty (T. Saaty, 1980)	237
Tabla 6-3. Tabla de índices de inconsistencia aleatoria media (T. Saaty & Vargas, 2001)	240
Tabla 6-4. Matriz de comparación por parejas. Vector de pesos	244
Tabla 6-5. Tabla de utilidades de la distancia de paso.....	246

Tabla 6-6. Tabla de utilidades del tiempo en celda.....	247
Tabla 6-7. Parámetros del escenario.....	250
Tabla 6-8. Salidas ordenadas del gestor de soluciones.....	251
Tabla 6-9. Resultados de la simulación.....	251
Tabla 6-10. Comparación de resultados.....	252

LISTA DE ACRÓNIMOS

AAM	Air to Air Missile
ADLA	Ayuda a la Decisión de Líneas de Acción
AHP	Analytic Hierarchy Process
ALSA	Algoritmo de Lanzamiento de Señuelos Armada
ANN	Artificial Neural Network
ARPECA	Armas de Pequeño Calibre
ASM	Air to Surface Missile
ASMD	Anti-Surface Missile Defense
AWACS	Airborne Warning and Control System
BAM	Buque de Acción Marítima
BMD	Balistic Missile Defense
BP	Backpropagation
Br	Babor
BR	Bayesian regularization
C2	Command & Control
CEHIPAR	Centro de Experiencias Hidrodinámicas de El Pardo
CEMEDEM	Centro de Medidas Electromagnéticas
CIWS	Close In Weapon System
CW	Continuos Wave
DBSCAN	Density Based Spatial Clustering of Applications with Noise
DIAR	Demostrador Instrumental de Alta Resolución
ELECTRE	ELimination Et Choix Traduisant la REalité
EM	Expectation-Maximization
EO	Electroóptico
Er	Estribor
ESSM	Evolved Sea Sparrow Missile
FN	False Negatives
FNN	Feedforward Neural Network
FP	False Positives
GD	Gradient Descent
GIMO	Gabinete de Investigación Operativa de la Armada
HCA	Hierarchical Clustering Analysis
HMS	Her Majesty Ship
IA	Inteligencia Artificial
IAM	Inconsistencia Aleatoria Media

IC	Índice de Consistencia
IEEE	Institute of Electrical and Electronic Engineers
IR	Infrarrojos
JUTAC	Junta de Táctica
KKT	Karusk-Kuhn-Tuker
KNN	K-nearest neighbors
LFG	Lagged Fibonacci Generator
LGC	Lineal Congruential Generators
LLSM	Least Squares Method
LM	Levenberg-Marquardt
MACBETH	Measuring Attractiveness by a Categorical Based Evaluation Technique
MAUT	Multi-Attribute Utility Theory
MAVT	Multi-Attribute Value Theory
MCP	Matriz de Comparación por Parejas
ML	Machine Learning
MLP	Multi Layer Perceptron
MOE	Measure Of Effectiveness
MTI	Moving Target Indicator
ORESTE	Organization, Rangement Et Synthese de donnes Relationnelles
OTAN	Organización del Tratado del Atlántico Norte
PRF	Pulse Repetition Frequency
PROMETHEE	Preference Ranking Organization METHod for Enrichment of Evaluations
PRP	Pulse Repetition Period
QUALITEX	Qualitative Flexible
RAM	Radar Absorbing Material
RC	Relación de Consistencia
RCS	Radar Cross Section
RF	Radiofrecuencia
RN	Royal Navy
ROE	Rule Of Engagement
S&A	Seguridad y Armado
SAM	Surface to Air Missile
SAR	Synthetic Aperture Radar
SER	Superficie Equivalente Radar
SGM	Segunda Guerra Mundial
SSM	Surface to Surface Missile

STC	Sensitive Time Control
SVM	Support Vector Machine
TAO	Tactical Action Officer
TP	True Positives
TN	True Negatives
TWT	Travelling Wave Tube
UK	United Kingdom
USM	Underwater to Surface Missile
USS	United States Ship

CAPÍTULO 1. INTRODUCCIÓN

1.1. MOTIVACIÓN Y OBJETIVOS

El misil es una de las amenazas más peligrosas a las que se puede tener que enfrentar un buque de guerra. En la actualidad, alrededor de setenta países disponen de misiles antibuque en sus arsenales, pudiendo ser lanzados desde plataformas aéreas, buques, submarinos o desde la costa.

Por otra parte, dado el actual escenario internacional con un incremento del terrorismo global, no es descartable que misiles caigan en manos de algún grupo terrorista y dado que las operaciones navales se desarrollan con más frecuencia en aguas cercanas a la costa, esta amenaza cobra especial relevancia, ya que los buques están expuestos a ataques desde tierra con reducido tiempo de reacción (Vego, 2014).

En paralelo con el cambio de la amenaza global, se ha incrementado el control que los gobiernos ejercen sobre las fuerzas militares desplegadas en las zonas de operaciones, dictando reglas de enfrentamiento (*rules of engagement: ROE's*) cada vez más restrictivas (Lord, 2006) y aunque todo comandante de buque tiene el inherente derecho de autodefensa, si no se desea una escalada de la tensión en la zona en conflicto, el empleo de la fuerza debe ser siempre proporcional. Por otra parte, la necesidad de evitar enfrentamientos amigo-amigo dificulta todavía más el empleo de las armas del buque a la hora de combatir un posible ataque de misiles.

Además de lo anteriormente expuesto, la defensa antimisil de un buque (*anti surface missile defense: ASMD*) es, desde el punto de vista táctico, una acción compleja donde las decisiones se deben tomar en segundos, sin margen para el error y en donde pueden llegar a emplearse todos los medios disponibles: medios *hardkill*¹ (misiles de largo, medio y corto alcance, cañones y armas de pequeño calibre) y medios *softkill*² (contramedidas electrónicas pasivas, activas y señuelos).

¹ Medios *hardkill* son todos aquellos que buscan la destrucción física del misil (misiles antimisil, cañones, etc.).

² Medios *softkill* buscan alterar el comportamiento del misil mediante contramedidas electrónicas, no son medios destructivos.

Capítulo 1. Introducción

Dentro de esta panoplia de medios, destacan los señuelos antimisil que son elementos pasivos que al ser lanzados por el buque, tratan de engañar o seducir al sistema de guía del misil atacante (ver Figura 1-1). Su empleo no implica el uso letal de la fuerza, siempre permitido por las reglas de enfrentamiento, por lo que adquieren especial importancia en el escenario actual. Además, son la última capa de defensa, por lo que constituyen un elemento esencial en caso de detección tardía del misil.

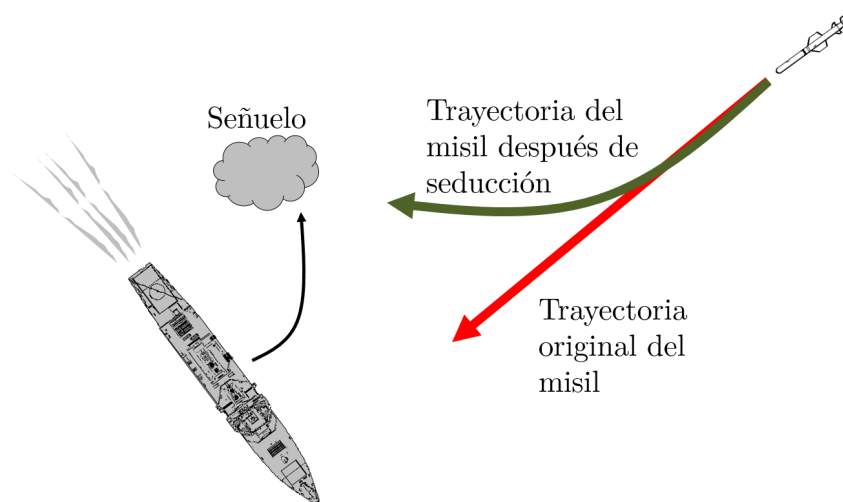


Figura 1-1. Seducción de un misil mediante señuelos (Huber, 2011)

1.2. UN POCO DE HISTORIA. LECCIONES APRENDIDAS

En este punto repasaremos de forma somera los hitos más importantes en relación a la defensa antimisil, los resultados obtenidos en diferentes enfrentamientos, las técnicas empleadas por los buques para su defensa e iremos desgranando las lecciones aprendidas.

1.2.1. La Segunda Guerra mundial. El primer misil

Quizás el primer misil de la historia fue el Henschel Hs 293 alemán, que se puede apreciar en la Figura 1-2. Fabricado durante la Segunda Guerra Mundial y lanzado desde aviones, con un alcance de unos 5 kilómetros, podemos considerarlo un verdadero misil, ya que disponía de un sistema de propulsión propio (motor cohete de combustible líquido) y un sistema de guía por radiocontrol desde la plataforma de lanzamiento. Aunque tuvo éxito al dañar o hundir más de 28 buques aliados, tenía el



Figura 1-2. Misil Henschel Hs 293. (Fuente: San Diego Air & Space Museum Archivos en flickr)

inconveniente de que debía ser guiado en modo visual desde la aeronave lanzadora, convirtiendo al avión en un blanco fácil.

Además, los aliados idearon un mecanismo para interferir, mediante perturbación electrónica, el sistema de guía por radiocontrol del misil, abriendo el camino a una de las formas para combatir a este tipo de amenaza: las contramedidas electrónicas.

1.2.2. Después de la Segunda Guerra Mundial. El conflicto Árabe-Israelí

Después de la Segunda Guerra Mundial (SGM) el misil empezó a formar parte de los arsenales de las principales naciones y comenzaron a utilizarse con profusión en diferentes conflictos.

El primer hundimiento con esta arma, después de la SGM, tuvo lugar en el año 1967 en el mar Mediterráneo (Shulte, 1994). El destructor israelí Eilat, en misión de patrulla, fue atacado con cuatro misiles Styx de origen soviético, lanzados por dos patrulleras egipcias de la clase Komar (ver Figura 1-3). Tres de los misiles impactaron en el buque lo que ocasionó su hundimiento. El buque, que solo disponía de artillería convencional de 4,5 pulgadas y 40mm, fue sorprendido y no reaccionó ante el ataque.




Figura 1-3. Patrullera de la clase Komar lanzando un misil Styx (Fuente: www.naval-encyclopedia.com)

Con las lecciones aprendidas de este hundimiento, la Marina Israelí se transformó en una flota de unidades más pequeñas, más maniobrables y con excelentes capacidades en contramedidas electrónicas activas y pasivas, así como señuelos antimisil.

Posteriormente, en el año 1973 en la Guerra Árabe-Israelí, la Marina Israelí tendría la ocasión de poner a prueba las soluciones adoptadas en relación a su capacidad antimisil. Los buques israelitas lograron, mediante señuelos y contramedidas electrónicas activas, engañar a más de cuarenta misiles Styx lanzados desde patrulleras sirias y egipcias. Indiscutiblemente, los resultados fueron más que aceptables.

1.2.3. La Guerra de las Malvinas

La Guerra de las Malvinas que tuvo lugar en el año 1982, fue el último conflicto aeronaval convencional, donde las lecciones aprendidas en la defensa antimisil sustentan la actual doctrina de la Organización del Tratado del Atlántico Norte (OTAN). Por ello, es interesante conocer las acciones de ataque y defensa llevadas a cabo en este campo durante las operaciones.

La Armada Argentina disponía tan solo de cinco misiles AM-39 Exocet, un tipo de misil de guía por radiofrecuencia de fabricación francesa con un alcance unas 30 millas náuticas que podían ser lanzados desde los aviones Super Étendard de reciente adquisición.



Figura 1-4. Destructor HMS Sheffield momentos después del impacto del misil Exocet argentino (Fuente: www.theguardian.com)

La primera misión argentina de ataque a la *Task Force* Británica se ejecutó el día cuatro de mayo. Dos aviones Super Etendard de la Armada Argentina armados cada uno de ellos con un misil Exocet, salieron de la base aeronaval de Rio Grande. Después de volar a muy baja altura y al estar a unas 30 millas de la fuerza británica, ascendieron, encendieron su radar, localizaron a la fuerza enemiga y lanzaron sus misiles. Uno de ellos localizó y adquirió al destructor HMS Sheffield, impactando por su través de estribor (ver Figura 1-4)

y sin que el buque reaccionase, mientras que el otro misil cayó a la mar por su proa (Armada Argentina, 1992; UK Royal Navy, 1982a). El impacto ocasionó un incendio de grandes proporciones, que no pudo ser controlado por la dotación que se vio obligada a abandonar el barco horas después.

El día 25 de mayo, tuvo lugar un segundo ataque por parte de la Armada Argentina. Otros dos aviones Super Etendard armados cada uno de ellos con un misil Exocet repitieron la misma misión siguiendo la misma táctica de vuelo bajo en silencio electromagnético, ascenso al llegar a la distancia de lanzamiento, localización mediante radar y disparo. El destructor HMS Ambuscade al detectar los misiles reaccionó con el lanzamiento de señuelos logrando engañarlos, aunque al sobrepasar a los señuelos, volvieron a entrar en modo de búsqueda y localizaron al mercante Atlantic Conveyor (que había sido reconvertido en plataforma auxiliar para operar con aeronaves y no disponía de sistemas de autoprotección), lo adquirieron y lo impactaron (ver Figura 1-5). Debido a los daños y el incendio provocado por los misiles, la dotación abandonó el buque horas después.

El barco transportaba, entre otro material, los helicópteros para realizar los movimientos de las Fuerzas Terrestres Británicas que debido a esta pérdida tuvieron que realizar todos sus movimiento a pie en las islas. Las pérdidas en material supusieron

Capítulo 1. Introducción

un duro revés para la Fuerza Británica (Armada Argentina, 1992; UK Royal Navy, 1982b).



*Figura 1-5. Estado del buque Atlantic Conveyor al día siguiente del impacto
(Fuente: www.thinkdefence.co.uk)*

El último de los misiles Exocet se utilizó en una misión conjunta el 30 de mayo, en donde nuevamente dos aviones Super Etendard de la Armada Argentina, uno de ellos con el misil y el otro de apoyo radar, junto con cuatro aviones A-4 Skyhawk de la Fuerza Aérea Argentina armados con bombas, planearon una misión de ataque al portaaviones HMS Invencible (ver Figura 1-6). La misión se ejecutó de forma similar a las anteriores; al estar al alcance de la Fuerza Británica se lanzó el misil y detrás de él, siguiendo su estela, atacaron los cuatro A-4. Aunque los pilotos argentinos aseguraron que el misil impactó en el portaaviones, los británicos informaron que dicho misil fue seducido por señuelos de la fragata HMS Avenger y se perdió (Armada Argentina, 1992; Fuerza Aérea Argentina, 1998).

En el conflicto de las Malvinas, se puso de manifiesto la letalidad de los misiles anti-buque, lo que dio lugar a un cambio en la doctrina OTAN en lo concerniente a las tácticas antimisil. Por otra parte, otras de las conclusiones obtenidas, y que a día de hoy siguen plenamente vigentes, fueron en relación al empleo de señuelos, considerándose un elemento vital en la defensa del buque ante ataques de misiles (Department of the Navy, 1983).



Figura 1-6. Portaaviones HMS Invincible (izquierda) y un avión Super-Etendard de la Armada Argentina (derecha) armando con un misil Exocet previo al ataque (Fuente: Royal Navy y Armada Argentina)

1.2.4. Otros incidentes

Otro incidente reseñable fue el ataque a la fragata norteamericana USS Stark, un buque del mismo tipo que nuestras fragatas de la clase Santa María. El día 17 de mayo de 1987, en misión de patrulla por el Golfo Pérsico, durante la guerra Irán-Irak, un avión Mirage F-1 iraquí lanzó sobre el buque dos misiles Exocet que impactaron en la banda de babor, ocasionando la muerte de 37 marineros (ver Figura 1-7). La fragata, a pesar de los avisos previos de un avión de alerta temprana (*airborne warning and control system*: AWACS) y aunque detectó al avión hostil en su sistema radar, no lo consideró una amenaza y por lo tanto no reaccionó al ataque (US Navy, 1987).



Figura 1-7. Fragata USS Stark después del impacto de los misiles (Fuente: www.history.navy.mil)



Figura 1-8. Corbeta INS Hanit de la María Israelí.

Un caso más reciente fue el ocurrido el 14 de julio de 2006 con la corbeta israelí Hanit, que fue atacada por un misil C-802 de origen chino, lanzado desde la costa por un grupo del Ala Militar de Hezbollah. El buque que contaba con un moderno sistema de defensa, no reaccionó al ataque y fue impactado por el misil que le causó diversos daños y la muerte de varios miembros de la dotación.

La Inteligencia Naval Israelí había informado previamente de la imposibilidad de que Hezbollah dispusiese de misiles antibuque, por lo que el barco no tenía alisado su sistema de defensa (Ben & Scott, 2006).

Por último, hay que destacar el incidente ocurrido en octubre del 2016 en el estrecho de Bad el-Mandeb, donde el destructor USS Mason de la Marina de los Estados Unidos (ver Figura 1-9), fue atacado en tres ocasiones por misiles lanzados por el grupo rebelde yemení Houthi. El buque reaccionó empleando misiles antiaéreos y señuelos, evitando el impacto (Vaughan, Eisenstadt, & Knights, 2020).



Figura 1-9. Destructor USS Mason (Fuente: US Navy)

1.2.5. Lecciones aprendidas

A la vista de lo expuesto anteriormente, queda fuera de toda duda la peligrosidad de los misiles antibuque, siendo esta amenaza omnipresente en la mayoría de los escenarios en los que tiene que operar un buque de guerra. Es evidente que una buena preparación del buque, tanto en lo relativo a los medios técnicos como al adiestramiento de la dotación, es un factor determinante en su defensa ante esta amenaza.

Casos recientes como el del destructor USS Mason, corroboran que la defensa antimisil de un buque deben realizarse integrando soluciones *hardkill* y *softkill*, donde los señuelos (también denominados chaff o decoys cómo veremos más adelante) deben jugar un papel más en el conjunto de medios de defensa (ver Figura 1-10).

Es evidente que una integración estrecha de todos los medios disponibles mejora el rendimiento general del buque en ASMD. Sin embargo, el empleo de todos los sistemas individuales en una estrategia defensiva única, requiere una evaluación de la amenaza y asignación de armas (*Threat Evaluation Weapon Allocation: TEWA*), eficaz y cada vez más automatizada (Johansson & Falkman, 2009; Paradis, Benaskeur, Oxenham, & Cutler, 2005).




Figura 1-10. Integración de medios en ASMD (Fuente: MIT Lincoln Laboratory)

Por otra parte, las estadísticas relativas a incidentes de ataques con misiles desde la SGM (Shulte, 1994), nos demuestran que el empleo de señuelos es una herramienta eficaz en la defensa antimisil del buque, por lo que todas las acciones relativas a

incrementar la rapidez y mejorar su solución de lanzamiento, redundará en un incremento en la capacidad de defensa del barco y por lo tanto en su supervivencia.

Por consiguiente, se puede concluir que la supervivencia del buque en una reacción antimisil se fundamenta en los tres pilares que se muestran en la Figura 1-11: una buena preparación y adiestramiento, una eficaz y rápida evaluación y asignación de armas y un rápido y preciso lanzamiento de señuelos.

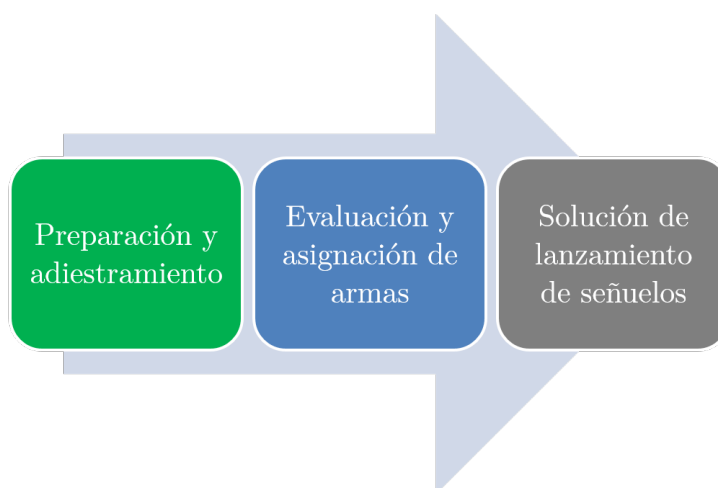


Figura 1-11. Pilares en una reacción antimisil

1.3. ESTADO DEL ARTE DEL PROBLEMA

Los misiles antibuque actuales podemos clasificarlos, según su sistema de guía en: de radiofrecuencia (RF), de infrarrojos (IR), electroópticos (EO) o duales (combinación de las anteriores). Para defenderse de ellos, se pueden utilizar distintos tipos de señuelos: bengalas³ y humos para los de guía IR y electroóptica respectivamente, chaff⁴ para los de guía de radiofrecuencia o una combinación de los anteriores para los de guía dual.

En este trabajo nos centraremos exclusivamente en la defensa contra misiles de guía de radiofrecuencia, ya que este tipo de arma representa el 80% de los misiles antibuque en servicio en el mundo (Cai & Zhang, 2009).

³ Las bengalas generan una fuente de calor mayor que la que proporciona el buque.

⁴ El chaff genera un eco radar en el misil más atractivo que el buque.

Capítulo 1. Introducción

Con el uso de señuelos, tal y como se observa en la Figura 1-1, se pretende engañar al misil y que centre su sistema de guía en un blanco falso, este proceso es lo que se conoce en términos de táctica naval como seducción. Sin embargo, su empleo no es trivial; para que sea eficaz, el buque debe reaccionar inmediatamente y escoger uno de los lanzadores que están situados en diferentes posiciones (ver Figura 1-12) y en ocasiones simultanear el lanzamiento con una caída de rumbo para mejorar la eficacia. Esta combinación de lanzador y cambio de rumbo, se conoce como solución de lanzamiento.




Figura 1-12. Configuración típica de cuatro lanzadores de señuelos en un buque de porte medio

En una acción real contra un misil atacante, el tiempo del que dispone el buque quizás no llegue a un minuto, por lo que la solución de lanzamiento de los señuelos debe estar previamente planeada para todos o la mayoría de los posibles escenarios en los que pueda llegar a encontrarse el barco.

La solución antes citada se obtiene mediante técnicas de simulación numérica y se fundamenta en la interacción de tres modelos: buque, señuelo y misil. Estos interactúan en un escenario que viene dado por un viento, una velocidad del buque y una distancia y marcación del misil atacante. Cada uno de los modelos implicados en la simulación son caracterizados por una serie de atributos o características que van a afectar a la solución de lanzamiento.

El modelo del buque se caracteriza fundamentalmente por sus dimensiones, datos cinemáticos, posición de los lanzadores de señuelos y su superficie equivalente radar (RCS). Aunque en el capítulo 3 definiremos la RCS de una manera formal, de forma coloquial podemos considerarla como el tamaño del buque visto por el radar del misil. Es por lo tanto un factor clave en la seducción, ya que una RCS baja hará que el buque sea poco visible por el radar buscador del misil y facilitará su seducción mediante señuelos.

El modelo de señuelo se caracterizará por sus datos de despliegue: distancia, altura, tiempo de despliegue, velocidad de caída, diámetro de la nube que se forma y por su superficie equivalente radar. La RCS del señuelo también es un dato sumamente importante ya que deberá tener un valor suficientemente alto en relación a la RCS del buque para engañar al misil.

El modelo misil es el tercer móvil de la simulación y se caracteriza por su cinemática y las características de su radar buscador o *seeker*.

Además de los tres modelos mencionados, a cada uno de los posibles escenarios hay que sumarle el viento, ya que es un factor clave en el movimiento de los señuelos. Así, simulando un número elevado de escenarios se generan las reacciones preplaneadas que se implementarán en el buque mediante una tabla de soluciones.

Actualmente, para la generación de las tablas de lanzamiento se emplea el simulador ALSA (Algoritmo de Lanzamiento de Señuelos Armada) que utiliza modelos deterministas de la superficie equivalente radar del buque y de los señuelos, por lo que los resultados obtenidos no tienen en cuenta el efecto de centelleo⁵ que se produce en el radar buscador del misil atacante. Además, aunque la tabla de soluciones implementada en el buque contempla un número elevado de escenarios, no puede abarcarlos todos, tampoco puede contemplar cualquier tipo de misil, ni realizar una evaluación o análisis de la solución.

Por otra parte, en el ámbito del espectro electromagnético, la Armada junto con el Grupo de Antenas, Radares y Comunicaciones Ópticas de la Universidad de Vigo, ha desarrollado en el campo de las medidas de RCS, el Demostrador Instrumental de

⁵ Este efecto ocasiona la fluctuación de la señal que recibe el radar del misil del buque y del señuelo. Se tratará con más detalle en los próximos capítulos.

Capítulo 1. Introducción

Alta Resolución (DIAR), que ha sustituido al antiguo radar de instrumentalización Libra, y que ha aumentado extraordinariamente nuestra capacidad de caracterización de la RCS de buques y señuelos, permitiendo disponer de más y mejores medidas. Existe, por lo tanto, un extraordinario margen de mejora en el modelado de la RCS y por consiguiente, también una gran capacidad de mejora en la simulación del lanzamiento de señuelos contra misiles de guía de radiofrecuencia.

Otro aspecto a considerar en el campo militar, es la irrupción de la inteligencia artificial (IA). Esta tecnología se refiere a la capacidad de las máquinas para realizar tareas que normalmente requieren inteligencia humana, tales como: reconocer patrones, aprender de la experiencia, obtener conclusiones, hacer predicciones, actuar, etc., ya sea de forma digital o como software inteligente detrás de sistemas físicos autónomos.

La IA ya está transformando a empresas e industrias y se espera que a corto plazo tenga un impacto en todos los ámbitos de las Fuerzas Armadas (FAS), incluyendo su implementación en los buques de la Flota, en tareas de protección de la Fuerza, en la formación, en la logística, en las operaciones del ciberespacio, etc.

Aquellos países que puedan aprovechar y explotar el potencial de la IA más rápidamente, garantizando al mismo tiempo un fuerte compromiso con la ética y la seguridad de la IA, obtendrán una ventaja militar significativa. La ventaja bélica decisiva en esta nueva era competitiva será para aquellos que integren y adapten esta tecnología de vanguardia para crear conceptos operativos innovadores con rapidez y agilidad. Actualmente, en el ámbito naval y en el terreno militar, tanto a nivel nacional como de la OTAN, se está investigando en qué áreas puede ayudar esta tecnología disruptiva a mejorar las operaciones, se están elaborando estrategias e iniciativas y diferentes estudios y trabajos, de los que podemos descartar:

- A nivel nacional organismos vinculados a Defensa como el Instituto Español de Estudios Estratégicos (IEEE) o el Centro Superior de Estudios de la Defensa Nacional (CESEDEM) han realizado trabajos sobre los usos militares de la IA en la robótica, ciberdefensa, reconocimiento de imágenes, análisis de grandes volúmenes de datos del campo de batalla, etc. (CESEDEN, 2018; De la Fuente Chacón, 2019; IEEE, 2019).
- Un aspecto importante a señalar es la nueva Estrategia de Tecnología e Innovación para la Defensa (ETID-2020), promulgada por la Secretaria de Estado

Capítulo 1. Introducción

de Defensa, donde se pretende que la inteligencia artificial juegue un papel esencial como palanca en la transformación digital de las FAS.

- Actualmente la empresa Indra junto con la Armada Española están desarrollando el proyecto Soprene. Se trata de un proyecto I+D+i que emplea redes neuronales y otras técnicas de IA, para mejorar el mantenimiento predictivo en los buques (Lamas, 2018). Existen también otros proyectos en ejecución relacionados con el conocimiento del entorno marítimo y de reconocimiento de imágenes en donde se están aplicando también técnicas de inteligencia artificial.
- A nivel internacional, la Royal Navy ha creado el Centro Nelson para la gestión del dato y desarrollo y la aplicación de técnicas de IA al ámbito naval. De la misma manera, el Ministerio de Defensa francés ha publicado el documento *Artificial Intelligence In Support of Defence*, donde establece las principales directrices de actuación en este ámbito (Ministère des Armées, 2019).
- Todo lo concerniente a los sistemas autónomos, tanto de superficie, submarinos como aéreos, también es un campo donde se están llevando a cabo proyectos de investigación sobre la aplicación de la IA, tal y como se muestran en los informes del Mando Aliado de Transformación de la OTAN y del *NATO Naval Armaments Group* (Gamer & Isaksson, 2018; JCGUAS, 2021).
- Otra área de investigación es la relativa a la defensa contra misiles balísticos (*ballistic missile defense: BMD*), donde se han realizado estudios que combinan simulación y aprendizaje automático (Weaver, 2008).
- También el empleo de técnicas de inteligencia artificial en el campo de la guerra electrónica, puede suponer un salto cualitativo fundamentalmente en la detección e identificación de señales electromagnéticas (Vandervelde, 2017).

A colación de todo lo expuesto anteriormente, el estado actual del proceso de obtención de las soluciones de lanzamiento de señuelos antimisil, puede ser objeto de diferentes mejoras implementando nuevos modelos de superficie equivalente radar en la simulación e implementado técnicas de inteligencia artificial/aprendizaje automático o *machine learning* (ML) que sustituyan el actual sistema de tablas y reglas preplaneadas (ver Figura 1-13).

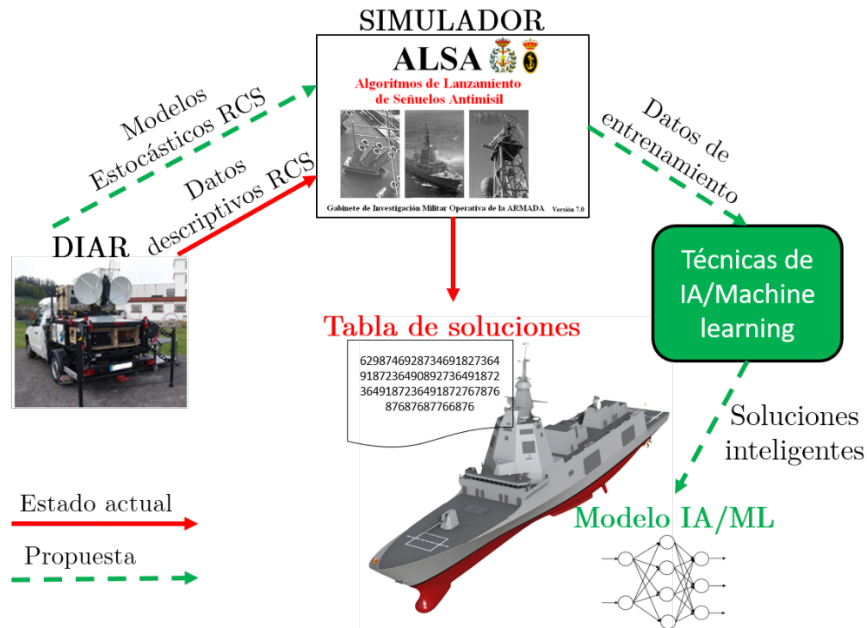


Figura 1-13. Estado del arte y propuesta de modificación

1.4. OBJETIVOS DE LA TESIS

Con esta Tesis se pretenden alcanzar los siguientes objetivos, que se han dividido en tres niveles (ver Figura 1-14):

Objetivos nivel#1.

- (1) Mejorar la efectividad del lanzamiento de señuelos antimisil de un buque mediante la construcción de un modelo de inteligencia artificial y de un gestor de soluciones basado en técnicas de decisión multicriterio. El producto alcanzado debe ser implementable a bordo.
- (2) Obtener conclusiones sobre la metodología empleada en el estudio, para que sirva como prueba de concepto con el objeto de determinar la posibilidad de implementar técnicas de inteligencia artificial/aprendizaje automático en los buques de la Armada en ámbitos de la decisión táctica, tales como la evaluación de la amenaza y asignación de armas y otros procesos que apoyen al oficial táctico en la toma de decisiones.

Objetivo nivel#2

Mejorar la simulación de la defensa antimisil de un buque y en general la simulación del empleo de la Fuerza Naval en un escenario electromagnético complejo,

implementando nuevos modelos de RCS, más realistas que simulen el efecto centelleo o *glint*. Los resultados de la simulación de la defensa antimisil deben servir como conjunto de entrenamiento para el modelo de inteligencia artificial señalado en el primer objetivo del nivel#1.

Objetivo nivel#3

Generar una metodología que permita automatizar el análisis de los datos obtenidos de las medidas RCS de buques y señuelos y que nos permita generar modelos estocásticos de superficie equivalente radar más precisos y realistas. Estos modelos son los que se utilizarán en el objetivo del nivel#2.

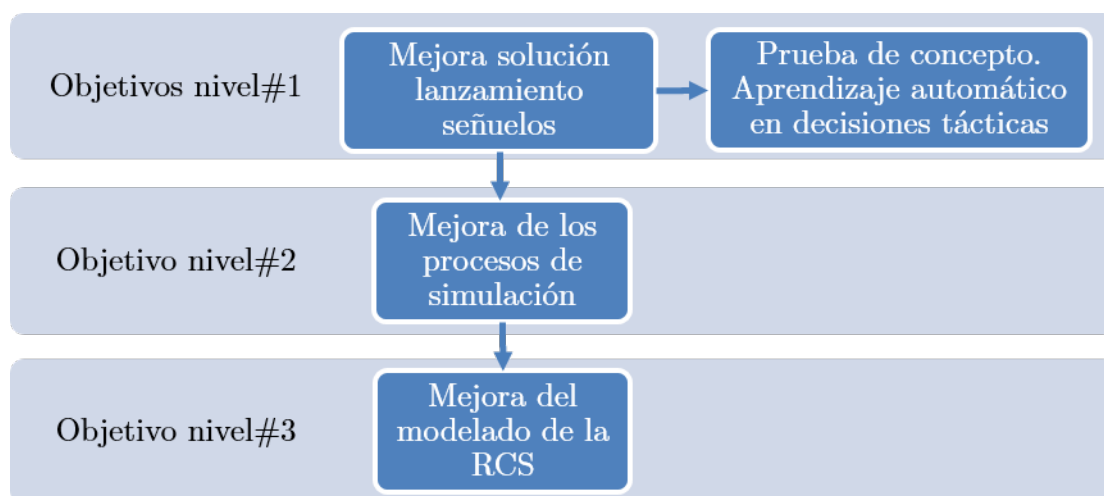


Figura 1-14. Objetivos por niveles

1.5. METODOLOGÍA

Esta investigación, mediante la integración de diferentes áreas científicas y tecnológicas, aborda un problema real en el ámbito de la Armada. Para ello, se integran distintas disciplinas tales como técnicas estadísticas, modelización numérica, análisis de decisiones e inteligencia artificial.

A continuación, y con el propósito de facilitar al lector la comprensión de este trabajo, se resumen las fases en las que se ha desarrollado el estudio.

Fase#1.- Modelado de la Superficie Equivalente Radar

El modelado de la RCS se ha realizado aplicando técnicas de estadística inferencial a los datos reales obtenidos por el radar de instrumentación DIAR. Para obtener un modelo de forma automática se ha seguido la siguiente metodología:

Capítulo 1. Introducción

- Determinar las posibles distribuciones de probabilidad que puede modelar la RCS de un buque.
- Realizar una limpieza y análisis gráfico de los datos.
- Modificar las diferentes técnicas de bondad del ajuste, para que puedan aplicarse a un gran volumen de datos y determinar qué distribución de probabilidad presenta un mejor ajuste.

Esto nos permite obtener un modelo más realista de la RCS de buques y señuelos e implementarlo en simulaciones de reacciones antimisil.

Para los trabajos de este punto, se han tomado como referencias algunos de los estudios realizados hasta la fecha sobre este tema (Dowdy, 1991; K. Kim, Kim, Kim, & Cho, 2012; Swerling, 1997).

Fase#2.- Simulación numérica

Básicamente en esta Fase se siguieron los siguientes pasos:

- Se implementó el modelo de superficie equivalente radar de la Fase#1 en la simulación de lanzamiento de señuelos.
- Se diseñó una batería de experimentos con los parámetros de configuración de nuestro marco experimental y se ejecutaron una serie de simulaciones para obtener un conjunto de datos suficientes para abordar la siguiente fase.

Todos los datos y soluciones de la simulación contenidas en este trabajo son SIN CLASIFICAR, ya que los parámetros de configuración del buque, misil y señuelos empleados son ficticios u obtenidos de fuentes abiertas.

Fase#3.- Construcción de un modelo de inteligencia artificial

La siguiente Fase se centró en construir un modelo de inteligencia artificial, que entrenado a partir del conjunto de datos obtenidos en la Fase#2, fuese capaz de predecir las posibles soluciones de lanzamiento de señuelos en cualquier escenario. Para ello, se han seguido las siguientes etapas: determinación del modelo óptimo, entrenamiento y análisis.

Fase#4.- Generación de un Gestor de Soluciones

Dado que para un mismo escenario pueden existir varias posibles soluciones, es necesario determinar cuál es la mejor. Las salidas procedentes del modelo de IA, se gestionan fundamentalmente mediante técnicas de decisión multicriterio para tener una lista ordenada de soluciones válidas.

A modo esquemático, en la Figura 1-15 se ha incluido un diagrama de bloques del proceso básico del trabajo, donde se puede apreciar de manera general las Fases y la metodología a emplear.

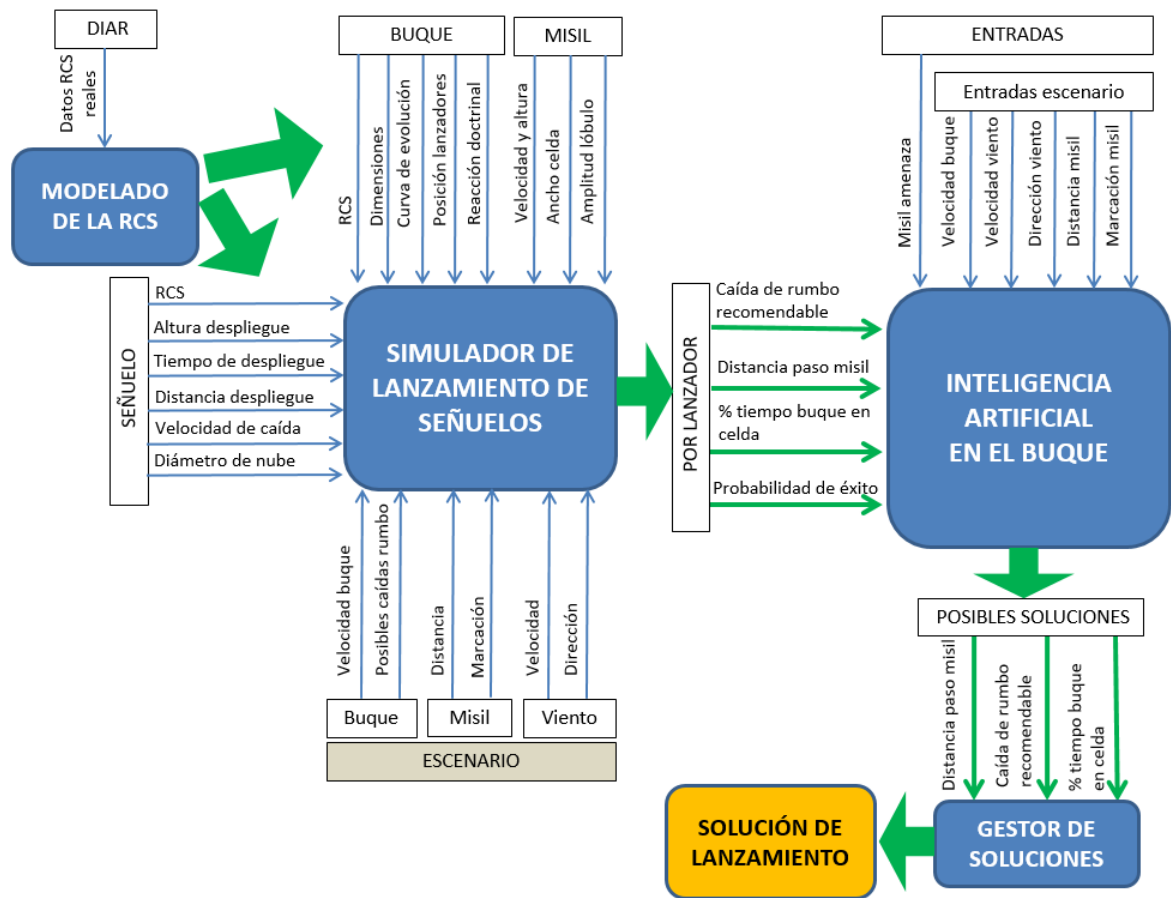


Figura 1-15. Diagrama de bloques de la metodología de trabajo

1.6. APORTACIONES

Las aportaciones más significativas de esta investigación son las siguientes:

- Mejora de las soluciones de lanzamiento de señuelos mediante la implementación de un modelo de IA/*machine learning* y por lo tanto, un aumento de la probabilidad de supervivencia del buque en caso de ataque de misil.
- Constatación de que el uso combinado de los simuladores navales actuales, técnicas de IA/*machine learning* y métodos de decisión multicriterio, nos permite construir modelos que mejoran y automatizan los procesos operativos a bordo, lo que permitiría apoyar a la toma de las decisiones tácticas, reducir la dotación y ahorrar costes.
- La metodología diseñada es de aplicación a los buques de las Armada y los resultados pueden ser implementados directamente en las unidades y a bajo coste.

Los antecedentes y contribuciones al conocimiento de este trabajo, a modo de publicaciones, se pueden concretar en los siguientes puntos:

En el campo de la simulación en el ámbito naval:


- Touza, R., Martínez, J., González-Cela, G., Roca, J. Bellas, R., Rodríguez, J., González, A. (2018). *Mejora de la simulación de la reacción antimisil de un buque de superficie con chaff*. Comunicación oral. XXXVII Congreso de Estadística e Investigación Operativa y las XI Jornadas de Estadística Pública.



Se expuso la capacidad de mejora en la simulación de lanzamiento de señuelos, mediante la implementación de un nuevo modelo estocástico de superficie equivalente radar del buque, generado a partir de un volumen grande de datos, procedente de un radar instrumental.

- Bellas, R., Martínez, J., Rivera, I., Touza, R., Gómez, M., Carreño, R. (2020). *Analysis of Naval Ship Evacuation Using Stochastic Simulation Models and Experimental Data Sets*. CMES-Computer Modeling in Engineering & Sciences, 122(3), 971–995.

Capítulo 1. Introducción



En este artículo se expone el modelado de un portaaviones, la simulación de la situación de evacuación del buque en la mar y el posterior análisis estadístico de los resultados, para poder determinar el tiempo que se tarda en abandonar el barco y determinar los puntos críticos de aglomeración en los flujos de personas.

En el campo de la inteligencia artificial/*machine learning*:

- Touza, R., Martínez, J., Álvarez, M., Roca, J. (2020). *Obtaining antimissile decoy launch solution from a ship using machine learning techniques*. International journal of interactive multimedia and artificial intelligence.

IJIMAI
journal

En este artículo se expone la metodología empleada para desarrollar un modelo de *machine learning* que resuelve el problema del lanzamiento de señuelos en una reacción antimisil y su aplicación a un caso de uso.

En el campo de la decisión multicriterio:

- González-Cela, G., Bellas, R., Martínez, J., Touza, R., Carreño, R. (2018). *Optimal Design of Spanish Navy F-110 Frigates Combat Information Center*. Naval Engineers Journal, 130-1, 121-132.
- González-Cela, G., Bellas, R., Carreño, R., Martínez, J., Touza, R., González-Gil, A., Gómez, M., González, D. (2018). *A Framework for Integrating Human Factor in the Early Etages of Ship Design: Application to the Mess Halls of a Surface Combatant*. Journal of Ship Production and Design, 36-1, 1-13.



Estos artículos muestran una metodología para la aplicación de técnicas de simulación numérica, junto con métodos de decisión multicriterio discreta, como el proceso de análisis jerárquico o *analytic hierarchy process* (AHP), para reducir la subjetividad en la toma de decisiones relativas a problemas presentados en el ámbito naval.

1.7. ESTRUCTURA DE LA MEMORIA

Este documento comienza, con una explicación detallada del problema táctico del lanzamiento de señuelos y los factores que deben tenerse en cuenta. Los siguientes capítulos siguen la misma estructura que la metodología de la investigación, reseñada en el punto 1.5, exponiendo en cada uno de ellos, el contenido y resultados de cada una de las fases del trabajo. A modo de resumen, los capítulos que se incluyen en esta memoria son los siguientes:

1. **La reacción antimisil con señuelos.** En este capítulo se realiza una descripción técnica del misil antibuque, sus características principales y su modo de funcionamiento. Se exponen también los medios de defensa del buque ante esta amenaza, centrándose en el empleo de los señuelos.
2. **Modelado de la superficie equivalente radar.** Inicialmente, se exponen los principios de funcionamiento del radar y se define el concepto de superficie equivalente radar. A continuación, se detalla la metodología empleada para la modelización de la RCS y además, se realiza una breve exposición del marco teórico-matemático de las técnicas estadísticas empleadas.
3. **Simulación numérica y análisis de los resultados.** Se realiza una breve descripción metodológica de los pasos realizados en esta fase, se expone cómo se implementan los nuevos modelos de superficie equivalente radar en el simulador de lanzamiento de señuelos y se construye el conjunto de datos o *dataset* necesario para poder entrenar al modelo de inteligencia artificial.
4. **Construcción de un modelo de inteligencia artificial.** Se define la inteligencia artificial desde diferentes enfoques y se describen las técnicas de aprendizaje automático que se han empleado en este trabajo: máquinas de vectores soporte y redes neuronales. Posteriormente, y aplicando directamente los datos obtenidos de la simulación, se expone la metodología para la elección del modelo óptimo de IA, el algoritmo empleado para su entrenamiento, el análisis de su comportamiento y los resultados finales.
5. **Implementación de un Gestor de Soluciones.** En este capítulo se describe cómo se ha seleccionado la mejor solución de lanzamiento aplicando técnicas de decisión multicriterio.

Capítulo 1. Introducción

Finalmente, en el último capítulo se recogen las conclusiones más relevantes del trabajo y posibles líneas futuras de investigación.

CAPÍTULO 2. LA DEFENSA ANTIMISIL DE UN BUQUE

En este capítulo expondremos toda aquella información esencial que permitirá comprender a qué tipo de amenaza se enfrenta un buque ante un ataque de misiles y qué acciones puede ejecutar para su defensa.

En primer lugar, se describen las características más importantes de un misil antibuque, ya que es la información básica que proporcionará la visión necesaria para comprender las acciones que debe emprender un barco en la defensa contra este tipo de arma. Para finalizar, se enumeran las fases habituales en el enfrentamiento contra un misil y en concreto las reacciones con señuelos.

2.1. EL MISIL AMENAZA

Un misil es un ingenio capaz de alcanzar el objetivo e inutilizarlo, a pesar de los factores aleatorios y de maniobrabilidad del blanco (ver Figura 2-1). Para ello, debe ser capaz de modificar su trayectoria y, en el caso de un blanco móvil, disponer de suficiente movilidad para adaptarse a sus maniobras evasivas.

La maniobrabilidad del misil consume energía debido a la resistencia del aire, lo que se traduce en una pérdida de velocidad. Para evitar esta pérdida de velocidad y obtener un buen margen de maniobrabilidad el misil debe estar dotado de un sistema de propulsión (Cucharero, 1995).

La función de los misiles es alcanzar y destruir o dejar inoperativo el blanco objetivo y es precisamente el tipo de blanco el que va a determinar sus características, esto es, un misil diseñado contra buques tendrá unas características específicas para combatir este tipo de blancos, que serán diferentes a las que debe tener un misil antiaéreo. Sin embargo, de forma general, todo misil deberá tener:

- Suficiente velocidad y maniobrabilidad para interceptar el blanco.
- Una aceptable *envelope* (distancia y altitud) dentro de las cuales es efectivo.
- Capacidad de ser lanzado cuando se necesite y con un tiempo de reacción satisfactorio.
- Capacidad de infligir al blanco el suficiente daño.



Figura 2-1. Misil antibuque C-802 de fabricación china lanzado desde un buque iraní
(Fuente: www.ausairpower.net)

2.1.1. Sistemas y componentes

Como se señaló en el apartado anterior, las características de un misil vendrán dadas fundamentalmente por el tipo de blanco para el que fue diseñado, pero en términos generales la configuración de cualquier misil se puede decir que consta de (ver Figura 2-2):

- Una estructura aerodinámica.
- Un sistema de propulsión.
- Un sistema de control.
- Una cabeza de combate.
- Un sistema de guiado.

La estructura aerodinámica es la que contiene, soporta y protege la cabeza de combate y sus componentes asociados, durante el lanzamiento y su trayectoria hasta el blanco.

La estructura del misil estará condicionada por el tipo de la cabeza de combate, las características de la sección de guiado y los requerimientos de precisión. Debe ser aerodinámica para obtener un rendimiento óptimo de vuelo, buscando siempre la re-

ducción del efecto de frenado, la eficacia de la sustentación y del control y la estabilidad del vuelo. Además, debe soportar elevadas cargas de maniobra en vuelo y esfuerzos por calentamiento debido a las altas velocidades.




Figura 2-2. Diferentes sistemas de un misil antibuque Exocet de fabricación francesa (Fuente: www.mbda-systems.com)

El sistema de propulsión provee la potencia o energía necesaria para propulsar o mover el misil hacia el blanco. Dentro del sistema de propulsión podemos encontrar reactores térmicos (estatorreactores o turborreactores) y motores cohetes de combustible sólido o líquido o mixto.

Es habitual que los misiles antibuque dispongan de un motor cohete de combustible sólido para acelerar al misil en el momento del lanzamiento. Al alcanzar cierta velocidad entra en funcionamiento un motor térmico, que le propulsa en la trayectoria de vuelo hasta el objetivo. Este es el caso de los misiles Exocet, Harpoon o Styx.

El sistema de control mantiene al misil en la trayectoria de vuelo deseada por medio de los mecanismos estabilizadores y de sustentación. Está formado por los alerones y timones y debe ser capaz de mantener la estabilidad del misil durante todo el vuelo, compensando los cambios en el centro de presión debido a las variaciones de la velocidad y del centro de gravedad por la disminución en el peso del misil al ir consumiendo su combustible.

La cabeza de combate es el agente destructor y tiene como misión ocasionar el daño al blanco, por lo que la naturaleza del objetivo condicionará su diseño. Toda cabeza de combate dispone generalmente de:

Capítulo 2. La defensa antimisil de un buque

Un mecanismo de seguridad y armado (S&A) para evitar la detonación accidental y prematura de la cabeza de combate, hasta que el misil esté a una determinada distancia del buque propio y bajo ciertas premisas.

Una carga útil que constituye el agente destructor, y que puede estar formada por una carga de alto explosivo, metralla prefragmentada o una combinación de ambas.

Una espoleta encargada de activar la carga útil, que deberá actuar en el instante en que la trayectoria del misil cause el mayor daño al blanco. En el caso de misiles antibuque, la espoleta no detonará la cabeza de combate hasta que el misil no haya penetrado dentro de la estructura del buque, para así infligir el mayor daño posible.

El sistema de guía es el grupo de componentes que mide la posición del misil con respecto al blanco y modifica la trayectoria de vuelo para corregir los errores para llevarlo a la interceptación con el objetivo.

Lógicamente los sistemas de guía y control están íntimamente ligados entre sí, ya que el sistema de control recibe las órdenes del sistema de guía. El autopiloto es la interfaz entre ambos sistemas (ver Figura 2-3), controla los accionadores eléctricos de las aletas, es el responsable de mantener estabilizado el misil y gobierna la trayectoria dependiendo de las órdenes de la sección de guiado (Yanushevsky, 2008).

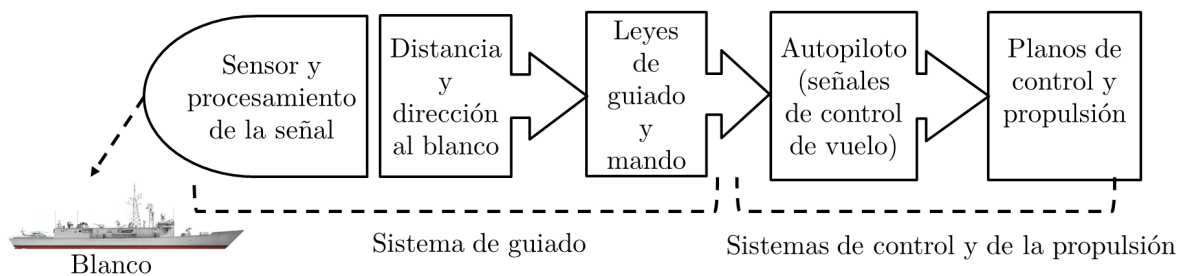


Figura 2-3. Sistema de guiado del misil y su relación con otros sistemas

Capítulo 2. La defensa antimisil de un buque

2.1.2. Clasificación de los misiles antibuque

La primera clasificación que podemos realizar de los misiles es en función de la plataforma lanzadora y del tipo de blanco para el que fueron diseñados. Obteniendo las siguientes denominaciones:

- Misil Superficie-Superficie (*Surface to Surface Missile: SSM*).
- Misil Superficie-Aire (*Surface to Air Missile: SAM*).
- Misil Aire-Superficie (*Air to Surface Missile: ASM*).
- Misil Aire-Aire (*Air to Air Missile: AAM*).
- Misil Submarino-Superficie (*Underwater to Surface Missile: USM*).

Como podemos observar de la anterior clasificación, un misil antibuque podrá ser del tipo SSM, ASM o USM, es decir, podrá ser lanzado desde una plataforma de superficie, aérea o submarina.

Además de los tipos anteriores, podemos clasificar los misiles en función de otros criterios: alcance, velocidad, empleo táctico, etc. Sin embargo, la clasificación más importante para el problema que nos ocupa, es la realizada en función de su sistema de guía, ya que para diferentes sistemas de guiado, tendremos que utilizar diferentes tipos señuelos.

Así, según este criterio y como se aprecia en la Figura 2-4, los misiles antibuque los podemos clasificar en guía de radiofrecuencia (RF), de infrarrojos (IR), electróptica (EO) o dual (Siouris, 2004). Siendo estos últimos una combinación de dos tipos de guías normalmente RF-IR o RF-EO, donde el misil comienza habitualmente guiado por radiofrecuencia y a cierta distancia del blanco conmuta una guía IR o EO.

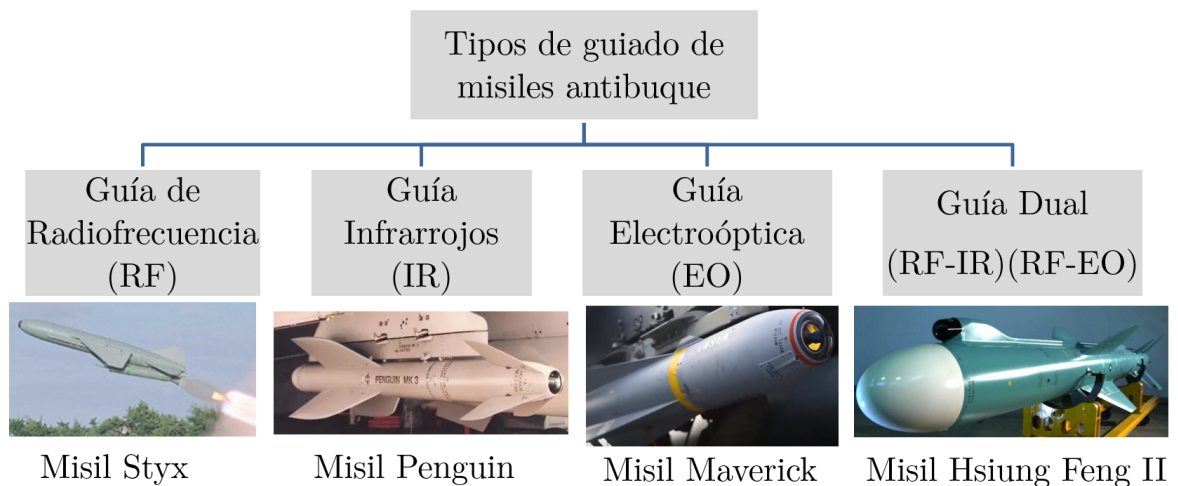


Figura 2-4. Tipos de guía de misiles antibuque y algunos ejemplos de misiles

2.1.3. Misiles antibuque de guía por radiofrecuencia

Tal y como se expuso en el capítulo anterior, en este trabajo nos centraremos en la defensa contra los misiles de guía de radiofrecuencia, por lo que expondremos a continuación sus características principales y su funcionamiento básico.

Este tipo de misiles está formado por los sistemas expuestos en el punto 2.1.1, con la peculiaridad de que la guía la proporciona un radar buscador o *seeker*, que será el responsable de localizar y seguir al blanco hasta su impacto (ver Figura 2-5). En el próximo capítulo expondremos con detalle el funcionamiento de estos tipos de radares, ya que su conocimiento es un elemento esencial para poder engañar al misil mediante señuelos.

Los misiles antibuque de guía RF pueden tener un alcance de más de 100 millas náuticas y habitualmente son transónicos o supersónicos, pudiendo alcanzar estos últimos velocidades de hasta 3 mach. Suelen medir entre 4 y 6 metros de longitud, tienen un peso que oscila entre 500 y 700 kg y transportan una carga de combate de unos 100 kg.

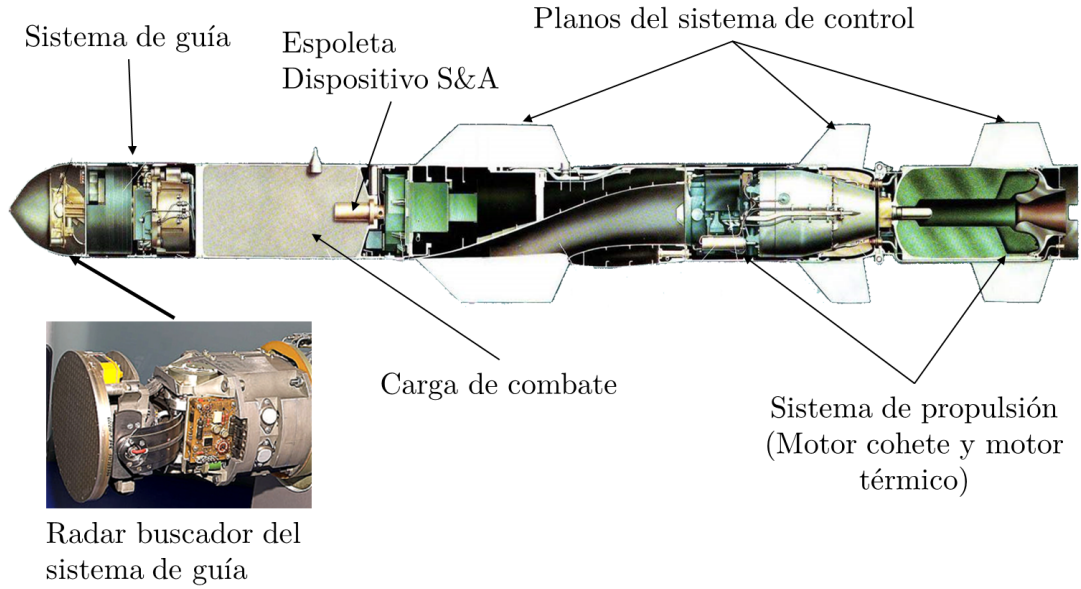


Figura 2-5. Típica configuración de un misil antibuque de guía por radiofrecuencia

En general, la secuencia de lanzamiento y el vuelo del misil hasta el impacto o interceptación con el buque blanco, puede resumirse en las siguientes fases (ver Figura 2-6).

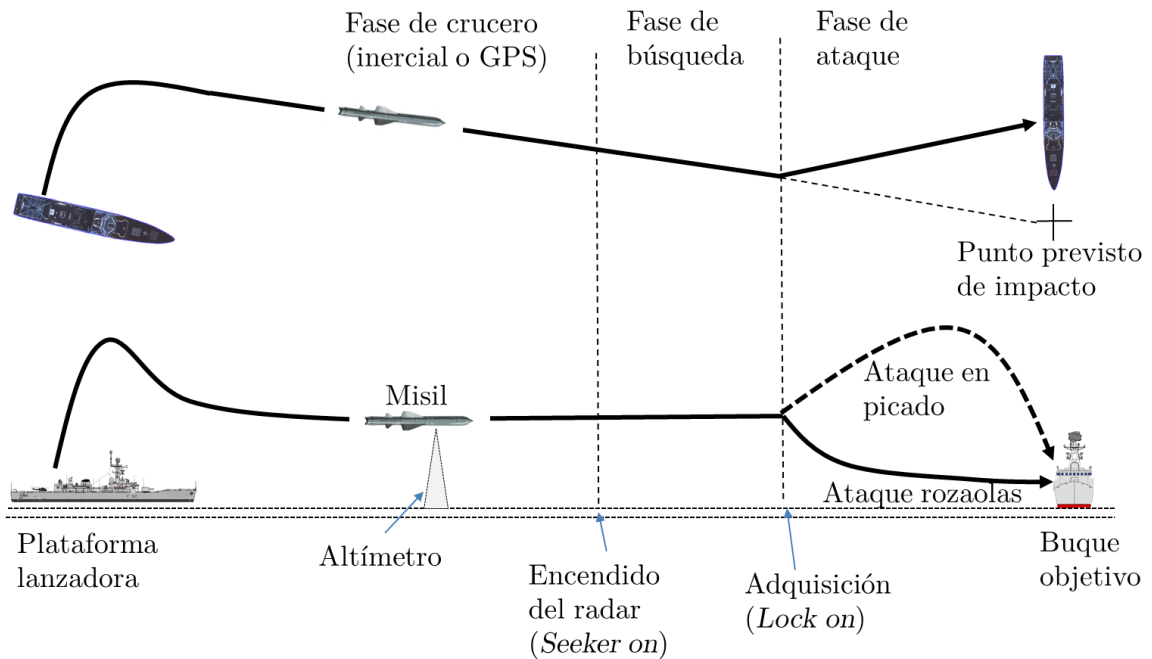


Figura 2-6. Perfil típico de un misil antibuque de guía RF

Pre-lanzamiento. Antes de efectuar el fuego, desde la plataforma de lanzamiento, se le introduce al misil la posición del blanco (punto previsto de impacto) y a continuación se efectúa el disparo.

Fase de crucero. Una vez efectuado el lanzamiento, el misil estabiliza su vuelo y comienza la denominada fase de crucero. En esta fase, el guiado se realiza mediante un sistema de navegación inercial o GPS, mantiene su radar *seeker* apagado y solo transmite con un radar altímetro, que le permite conocer en todo momento la altura respecto de la superficie de la mar.

Fase de búsqueda. A una determinada distancia del blanco, enciende el radar buscador (*seeker on*), y comienza la fase de búsqueda. Esta fase es esencial, ya que el misil no puede predecir los movimientos del objetivo durante el tiempo vuelo, por consiguiente, es muy poco probable que el sistema de guía detecte el objetivo inmediatamente y por lo tanto, debe realizar una búsqueda, en un área relativamente grande, para cubrir completamente la posible dispersión de la posición del objetivo. Para ello, la antena del radar del misil, realiza un movimiento rápido para que la celda de resolución⁶ realice una exploración completa del área (ver Figura 2-7).

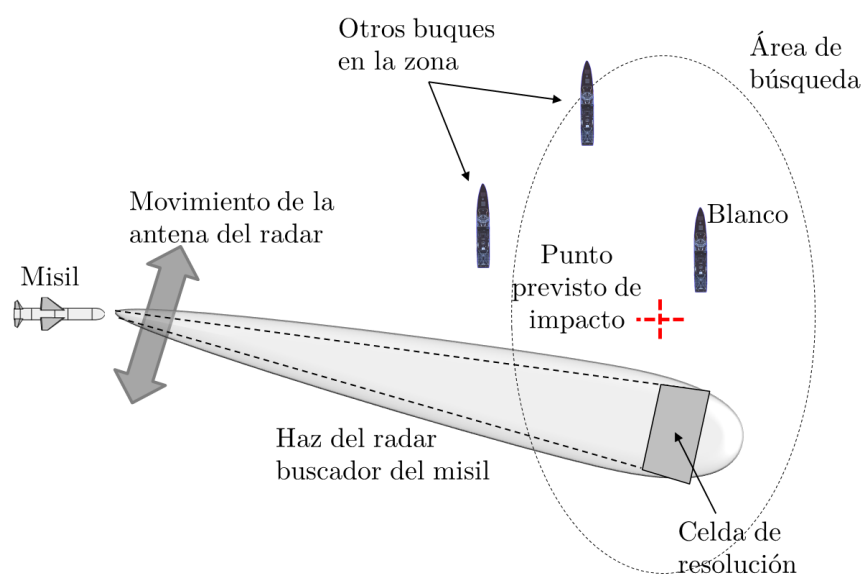


Figura 2-7. Fase de búsqueda

⁶ La celda de resolución del radar es el volumen de espacio, dentro del cual tiene capacidad para detectar objetos. Esta cuestión se verá con más detalle en el próximo capítulo.

Capítulo 2. La defensa antimisil de un buque

Una vez que el misil encuentra un blanco, cesa la búsqueda, si el computador del sistema de guía lo clasifica como blanco válido, centra el objetivo en la celda de resolución (*lock on*) y comienza la fase de ataque (ver Figura 2-8). En esta fase, el sistema de guía gobierna el misil hasta la interceptación del blanco, mediante los datos de distancia y ángulo proporcionados por el radar. La altura de vuelo en el ataque es variable, pudiendo encontrarnos misiles de ataque en picado o ataque rozaolas, siendo los más peligrosos estos últimos.




Figura 2-8. Fase de ataque. Celda de resolución centrada en el blanco

En los perfiles de ataque rozaolas, la altura final del misil depende del estado de la mar. En este caso, un misil tendría que volar a una altura de aproximadamente tres veces más que el nivel medio de la mar. Por ejemplo, para un estado de la mar 4 la altura de la ola es de aproximadamente 4 pies, por lo que tendría que tener una altura de vuelo de 4 m para estar razonablemente seguro en su trayectoria hacia el blanco (D. A. James, 1986).

2.2. MEDIOS Y FASES EN LA DEFENSA ANTIMISIL

Para la defensa antimisil, un buque de guerra puede disponer de diferentes medios. Sin embargo, y dado que este trabajo se centra en el estudio de lanzamiento de señuelos pasivos, nos ceñiremos en describir estos últimos.

2.2.1. Señuelos

Un señuelo es cualquier artefacto consumible que, empleado contra los medios RF, IR o EO de exploración y de guía de armas del enemigo, sirve para, atrayendo la atención

Capítulo 2. La defensa antimisil de un buque

de dichos medios, impedir o dificultar que realicen sus tareas o inducirles a adoptar como blanco el que el señuelo representa. Aunque existen muchos tipos, todos buscan imitar las características del buque y ser más atractivos que él para la cabeza buscadora del misil al que pretenden engañar.

La clasificación generalmente aceptada, que atiende no solo al tipo de material sino también a la complejidad del señuelo, es la siguiente:

- **Chaff.** Es un señuelo de material reflectante a la radiofrecuencia, que consiste en tiras o dipolos de fibra de vidrio metalizada, muy livianos, cortados a la longitud adecuada y que son utilizados para engañar a los misiles de guía por RF. Existen diferentes tipos de chaff, diseñados específicamente para las diferentes fases de un ataque con misiles: chaff de confusión (chaff C), chaff para distracción (chaff D) y chaff para seducción (chaff S).

El chaff de seducción (ver Figura 2-9), que es objeto de este trabajo, se despliega a muy corta distancia del buque, y es el que se utiliza en la fase de ataque del misil, cuando ha adquirido al blanco (*lock on*). La solución de lanzamiento de este tipo de señuelos no es trivial, ya que su trayectoria debe pasar por dentro de la celda de resolución del misil y el buque debe maniobrar para crear el suficiente viento relativo para separar el señuelo del barco.



Figura 2-9. Buque desplegando señuelos tipo chaff de seducción (Huber, 2011; Viau, D'Agostino, & Cathala, 2014)



Figura 2-10. Buque lanzando bengalas (Schleijpen, 2012)

- **Bengalas y humos.** Son señuelos utilizados contra misiles de guía por infrarrojos y electroópticos. Suelen formar una nube incandescente o una antorcha que imita la radiación IR del buque o una cortina de humo que enmascara al blanco (ver Figura 2-10).
- **Engaños o *Offboard decoys*.** En esta categoría podemos encontrar señuelos activos, pasivos reflectantes (ver Figura 2-11) o una combinación de ambos. En general, su uso es contra misiles de guía RF y pueden ser remolcados, a la deriva o autopropulsados.




Figura 2-11. Despliegue (izquierda) e inflado (derecha) del señuelo pasivo tipo *offboard FDS3* de la empresa *IrvingQ* (Fuente: www.irvingcq.com)

En este trabajo, nos centraremos en la búsqueda de las soluciones de lanzamiento de los señuelos tipo chaff de seducción (chaff S), que como se mencionó anteriormente, son los que se emplean en la defensa contra misiles de guía RF durante la fase de ataque.

2.2.2. Lanzadores de señuelos

Para el lanzamiento de los señuelos tipo chaff o bengalas, existen en el mercado diferentes morteros o lanzadores, por ejemplo, el Sylena de la compañía francesa Lacroix, el Centurion de la inglesa Chemring, el DESEAVAR de la israelí Elbit o el italiano OTO ODLS de la compañía Leonardo (ver Figura 2-12).



Figura 2-12. Diferentes lanzadores de señuelos (Fuentes: www.chemring.co.uk; www.elbitsystems.com; www.lacroix-defense.com; www.leonardocompany.com)

En la Armada Española, los buques montan el lanzador *Super Rapid Bloom Offboard Countermeasures* (SRBOC) MK-36. Se trata de un sistema de 6 tubos fijos, no orientables, montando por cada buque cuatro o seis lanzadores en función del tamaño de barco. En la Figura 2-13, se pueden observar a la izquierda los dos lanzadores de la banda de babor de una fragata de la clase “Álvaro de Bazán” y a la derecha, dos miembros de la dotación cargando un señuelo.



Figura 2-13. Lanzadores MK-36 (izquierda) y dos miembros de la dotación del buque cargando señuelos (derecha) (Fuente: www.foronaval.com y Armada Española)

2.2.3. *El proceso de la seducción de un misil antibuque mediante señuelos. Efecto centroide*

Una vez expuestas las funcionalidades de un señuelo y desde dónde se efectúa el lanzamiento, en este apartado, se describirá cómo el señuelo de tipo chaff S engaña o seduce a un misil de guía RF, ya que este procedimiento será la base fundamental para obtener la solución de lanzamiento.

El proceso o mecanismo de la seducción, está diseñado para emplearlo en la fase de ataque del misil, es decir cuando ha adquirido al blanco. El proceso, consiste básicamente, en desplegar una nube o nubes de señuelos con una superficie equivalente radar suficiente para que, por efecto del viento y de la velocidad del buque, la celda de resolución de seguimiento del misil quede centrada sobre el señuelo y alejada del buque. El proceso de la seducción utiliza lo que se denomina en terminología naval el efecto centroide (Galle, 2002; Galle, Heemskerk, & Van Ewijk, 1999; Sun, 2019).

En la Figura 2-14, se puede observar en cinco pasos el mecanismo de seducción de un misil de guía RF mediante este efecto, que podemos resumir de la siguiente forma:

- Paso#1. El buque está dentro de la celda de resolución del misil. El centro de la celda está sobre la parte del buque que ofrece una mayor superficie equivalente radar al misil.
- Paso#2. El buque ha reaccionado con un lanzamiento de señuelos, y parte de ellos quedan dentro de la celda de resolución del misil. El centro de la gravedad de la superficie equivalente radar o centroide, está ahora desplazado hacia los señuelos, por lo que el centro de la celda de resolución se desplaza en la misma dirección.
- Paso#3. Los señuelos se mueven por acción del viento hacia el buque, desplazando el centro de la celda de resolución del misil.
- Paso#4. Los señuelos siguen moviéndose por acción del viento, alejándose del buque y continúan desplazando la celda de resolución.

Paso#5. Los señuelos se alejan progresivamente del buque por acción del viento, y si tienen la superficie equivalente radar suficiente, serán capaces de liberar al buque de la celda de resolución del misil.




Figura 2-14. Seducción del misil mediante efecto centroe

2.2.4. Fases en la defensa antimisil

Para entender cómo defenderse de un ataque de un misil, es necesario describir lo que se conoce como la cadena de la muerte del enemigo o *kill chain* (ver Figura 2-15), donde figuran las fases del ataque, desde la detección del buque blanco hasta el enfrentamiento o lanzamiento del misil (Scott, 2016).




Figura 2-15. Cadena de la muerte o *Kill chain* (Galle, 2002)

Capítulo 2. La defensa antimisil de un buque

El lanzamiento de un misil por parte de una unidad hostil comienza con una primera detección de la fuerza naval propia. A continuación, la unidad hostil debe clasificar dicha fuerza, esto es, estimar el tipo, número, tamaño y lo más importante, la identidad de la primera detección, para confirmar de manera efectiva que se trata de la fuerza oponente. Posteriormente, debe identificar el blanco a atacar, realizar el seguimiento para determinar sus datos cinemáticos y por último, proceder al enfrentamiento o lanzamiento del misil.

En la defensa contra un misil, el buque atacado utilizará, si es posible, todos los medios disponibles *hardkill* y *softkill*. Así, lo habitual es aplicar una defensa por capas (D. Kim & Ryoo, 2009; Townsend, 1999), siendo las fases típicas de una reacción antimisil las siguientes:

- Despliegue de chaff distracción (chaff D). Se trata de desplegar una serie de señuelos a cierta distancia del buque, justo antes del lanzamiento del misil o durante su fase de búsqueda. Se persigue que el misil ya no adquiera la unidad propia y ataque a un señuelo.
- Lanzamiento de misiles de largo/medio alcance (por ejemplo, misiles SM-2), para intentar destruir al misil a cierta distancia del buque.
- Lanzamiento de misiles de corto alcance (por ejemplo, misiles *Evolved Sea Sparow Missile*: ESSM) (ver Figura 2-16), para intentar destruir al misil antes de que alcance al buque.
- A continuación, si el misil ha travesado todas las barreras y continúa con el buque centrado en su sistema de guía, es necesario realizar un despliegue de señuelos o chaff de seducción (Chaff S).

A diferencia de los señuelos de distracción, los señuelos de seducción se emplean cuando el misil ya ha localizado y adquirido al buque y está en la fase final de ataque. Tal y como se expuso anteriormente, el empleo de este tipo de señuelos es más complejo, y para que sea eficaz, el buque debe reaccionar inmediatamente, escoger uno de los 4 o 6 lanzadores o morteros que están situados en diferentes posiciones y en ocasiones simultanear el lanzamiento con una caída de rumbo para mejorar la eficacia. Precisamente, este es el objetivo de esta tesis: obtener la mejor solución de lanzamiento de señuelos en esta etapa en la defensa contra un misil antibuque de guía RF.

Capítulo 2. La defensa antimisil de un buque

- Simultáneamente, el buque reaccionará con otros medios *hardkill* de defensa próxima, tales como cañones, CIWS (*close in weapon system*) (ver Figura 2-16) y armas de pequeño calibre (ARPECA).



Figura 2-16. Lanzamiento de un misil ESSM (izquierda) y Cañón CIWS Vulkan Phallax de la Marina de los EEUU (Fuentes: Armada Española, www.seaforces.org)

CAPÍTULO 3. MODELADO DE LA SUPERFICIE EQUIVALENTE RADAR

3.1. INTRODUCCIÓN

La medida de la detectabilidad del buque por parte del radar buscador de un misil, viene dada por la superficie equivalente radar (SER), sección recta radar o *radar cross section* (RCS) del barco. Una reducida RCS dificultará la búsqueda y seguimiento del objetivo del misil y en el caso de emplear señuelos en la defensa mejorará su eficacia (Galle et al., 1999). Por lo tanto, el conocimiento preciso de la RCS de un navío de combate es esencial.

En este capítulo, describiremos el primer objetivo de este trabajo consistente en generar un modelo preciso de superficie equivalente radar del buque y del señuelo, a partir de un número finito de observaciones obtenidas de un radar de instrumentación. Para alcanzar este objetivo, comenzaremos exponiendo los fundamentos y la ecuación simplificada de un sistema radar, para posteriormente, describir las características especiales del radar buscador o *seeker* de los misiles antibuque de guía activa. Todo ello, nos permitirá poner en contexto el concepto de superficie equivalente radar, su comportamiento, aplicación a un buque y a un señuelo y la forma de medición.

Posteriormente, expondremos los principios básicos de estadística necesarios para comprender la metodología desarrollada para el modelado de la RCS y finalmente, detallaremos las diferentes etapas de dicho procedimiento y la aplicaremos a un caso de un buque real para demostrar su validez.

3.2. FUNDAMENTOS DEL SISTEMA RADAR

3.2.1. *Introducción*

El radar (término derivado del acrónimo *Radio Detection And Ranging*) es un sensor electromagnético diseñado para la detección y localización de objetos reflectantes, tales como aeronaves, buques, vehículos terrestres, formaciones meteorológicas o terreno (Skolnik, 2008).

Capítulo 3. Modelado de la superficie equivalente radar

El radar se fundamenta en las ecuaciones de Maxwell que describen los fenómenos electromagnéticos y que fueron demostradas en 1886 por el físico alemán Heinrich Hertz. El ingeniero alemán Christian Hülsmeier fue el primero que puso en práctica estos principios físicos y diseñó un dispositivo de detección para evitar colisiones de buques en la mar. En 1922 el italiano Guglielmo Marconi desarrolló un aparato similar (Espejo, 2011; Rahman, 2019).

El primer experimento satisfactorio de detección a distancia tuvo lugar en 1924, cuando el físico británico Edward Victor Appleton utilizó el eco de las ondas de radio para determinar la altura de la ionosfera. Posteriormente, los físicos norteamericanos Gregory Breit y Merle Antony Tuve llegaron de forma independiente a los mismos resultados para la ionosfera al usar la técnica de radioimpulsos que más tarde se incorporó a todos los sistemas radar (Rahman, 2019).

Sin embargo, no fue hasta el año 1935 cuando Robert Watson-Watt construyó el primer radar operativo de la historia. Su diseño consiguió que en el año 1938 entrase en servicio la primera cadena de radares en la costa este y sur de la isla de Gran Bretaña, para la defensa aérea de las Islas Británicas. Durante la contienda, los británicos Henry Boot y John T. Randall inventaron y desarrollaron el magnetrón que ocasionó el desarrollo de radares en longitudes de onda más pequeñas, posibilitando la detección de blancos más pequeños mediante antenas más reducidas, lo que permitió montar los sistemas radar en buques, aeronaves y submarinos. Durante la segunda guerra mundial, los alemanes también diseñaron sus propios sistemas radar, aunque los ingleses y estadounidenses mantuvieron durante todo el conflicto la superioridad técnica en este campo (Espejo, 2011; Rahman, 2019; Skolnik, 1981).

Los avances introducidos en los sistemas radar desde la postguerra hasta nuestros días, han sido numerosos, desarrollando mejoras en la transmisión, en la recepción e incluyendo el procesado digital de la señal. Todo esto ha dado lugar a nuevas tecnologías como los radares de compresión de pulsos, radares de apertura sintética (*synthetic aperture radar: SAR*), técnicas de seguimiento radar, contramedidas electrónicas radar, radares *phase array*, radares MTI (*moving target indicator*), etc. (Rahman, 2019).

El funcionamiento del radar se puede resumir de la forma siguiente (Richards, Scheer, & Holm, 2015; Skolnik, 2008):

Capítulo 3. Modelado de la superficie equivalente radar

- Mediante una antena, el radar radia energía electromagnética que se propaga en el espacio.
- Parte de la energía radiada es interceptada por el objeto reflectante, denominado blanco, situado a cierta distancia del radar.
- La energía interceptada por el blanco se vuelve a re-irradiar en todas las direcciones.
- Parte de la energía re-irradiada por el blanco, que denominaremos eco, retorna al radar y se recibe por la antena.
- La energía recibida se amplifica por un receptor, se procesa la señal y el radar determina si existe un eco del blanco, proporcionando su localización y en ocasiones otra información, como la velocidad del blanco.

3.2.2. Diagrama de bloques del radar

El funcionamiento de un radar de pulsos típico puede describirse con la ayuda del esquema de bloques que se muestra en la Figura 3-1, donde observamos que de forma general, un sistema radar lo podemos dividir en cinco subsistemas (Skolnik, 2008):

- Transmisor.
- Antena.
- Receptor.
- Procesado y explotación de la información.
- Controlador.

El subsistema transmisor es el encargado de generar la señal de radiofrecuencia y básicamente está formado por un transmisor o amplificador de radiofrecuencia y un modulador. Inicialmente, los transmisores estaban formados por tubos electrónicos tales como magnetrones y tubos de onda progresiva (*travelling wave tube: TWT*), que están siendo sustituidos por transmisores de estado sólido (Rahman, 2019).

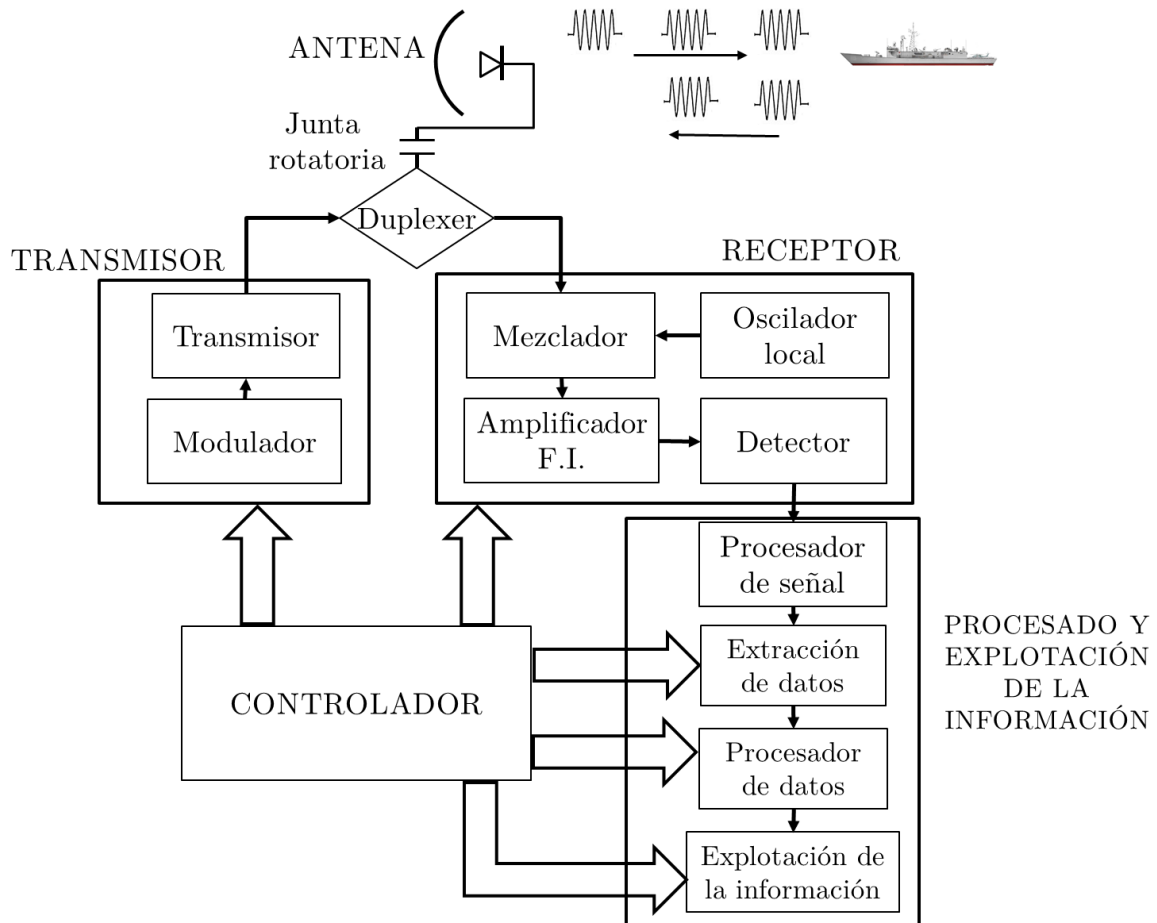


Figura 3-1. Esquema de bloques básico de un sistema radar

La antena o antenas tienen como objetivo acoplar la energía entre el medio exterior y las líneas de transmisión del radar. La onda generada por el transmisor va hacia la antena por la línea de transmisión y desde la antena es radiada al espacio. En recepción, la antena recoge la energía del eco de blanco y la envía al receptor. Las características más importantes de la antena son (Skolnik, 2008):

- **Lóbulo de radiación.** Es deseable, en toda antena, que disponga de un haz principal de radiación estrecho para obtener una buena resolución angular y lóbulos laterales pequeños para evitar falsos ecos (Figura 3-2).

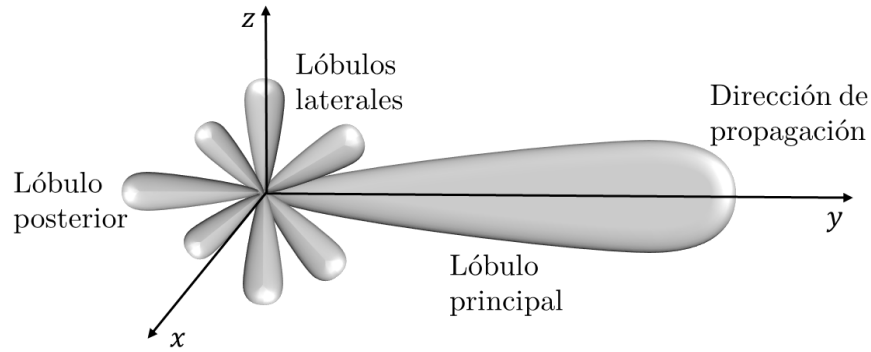


Figura 3-2. Lóbulos de radiación de una antena

- **Polarización.** La onda electromagnética está formada por un campo magnético (\vec{B}) y un campo eléctrico (\vec{E}) con 90° de desfase entre ellos, definiendo la dirección de la polarización como la dirección del vector campo eléctrico (Skolnik, 2008). Los radares usualmente trabajan con polarización lineal, que puede ser horizontal (H) o vertical (V) (ver Figura 3-3) utilizando habitualmente la siguiente nomenclatura:

HH: transmisión y recepción con polarización horizontal.

VV: transmisión y recepción con polarización vertical.

HV: transmisión con polarización horizontal y recepción con polarización vertical (polarización cruzada).

VH: transmisión con polarización vertical y recepción con polarización horizontal (polarización cruzada).

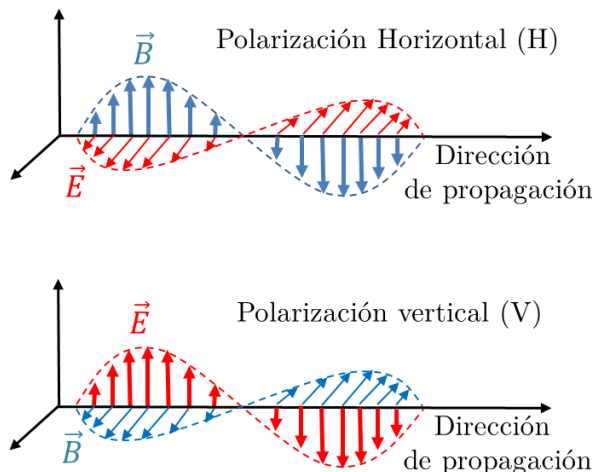


Figura 3-3. Polarización horizontal y vertical

También existen otros tipos de polarización como la circular y elíptica.

- **Ganancia de la antena (G).** Es una medida del incremento de potencia radiada en la dirección del blanco comparado con la potencia que hubiese radiado una antena isotrópica (ver Figura 3-4).

- **Área o apertura efectiva (A_e)** Es el área equivalente de una antena de apertura A_e que recogiese toda la energía disponible en su superficie.

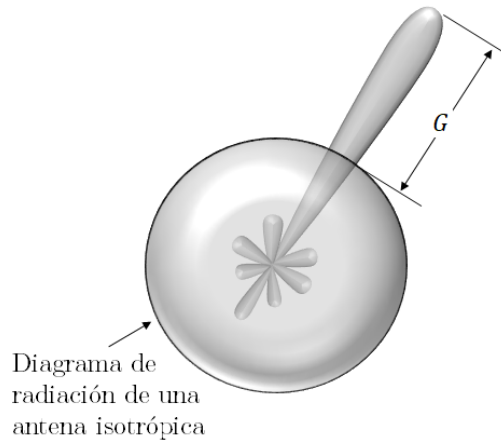


Figura 3-4. Ganancia de una antena direccional

Normalmente se emplea una sola antena para transmitir y recibir, por lo que el receptor debe ser protegido de la alta potencia del transmisor, realizando esta función el duplexer. El duplexer sirve también para canalizar los ecos recibidos hacia el receptor y no hacia el transmisor (Skolnik, 2008). La forma de la antena dependerá de la función y del tipo de radar (ver Figura 3-5).




Figura 3-5. Diferentes tipos de antenas: a) Radar de tiro DORNA; b) Radar de exploración aérea AN/SPS-49; c) Radar seeker del misil AS-10 Karen d) radar de navegación Sperry (Fuentes: www.buquesdeguerra.com, www.ausairpower.net, www.sperrymarine.com)

El subsistema receptor es el responsable de la detección de las señales reflejadas por el objetivo o blanco. A grandes rasgos, es un receptor superheterodino clásico. La entrada en el receptor puede ser una etapa mezcladora, en donde el mezclador y el oscilador local convierten la señal de radiofrecuencia a una frecuencia intermedia, posteriormente un amplificador de frecuencia intermedia maximiza la relación señal

Capítulo 3. Modelado de la superficie equivalente radar

ruido y por último el detector extrae el pulso de modulación para ser enviado al subsistema de procesado y explotación de la información (Rahman, 2019; Skolnik, 1981).

Las características de las señales recibidas, la existencia de señales parásitas y la necesidad de extraer distintas informaciones automáticamente, dan lugar a que el receptor del radar se convierta en un conjunto complejo, que en todo caso deberá tener las siguientes características:

- **Sensibilidad.** Es la capacidad de detectar blancos en presencia de ruido. La medida de esa capacidad viene dada por la mínima señal discernible, esto es, la mínima amplitud de señal eco que puede ser identificada como tal en presencia de ruido.
- **Ganancia.** Es el aumento o amplificación que experimenta la señal eco antes de su entrega al subsistema de explotación de la información; la amplificación se puede llevar a cabo en radiofrecuencia, frecuencia intermedia y videofrecuencia y ha de ser tal que la amplitud de la señal de vídeo entregada a la unidad indicadora sea del orden de decenas de voltios.
- **Rango dinámico.** Expresa el margen de los niveles de señales a la entrada del receptor en que este funciona correctamente. Por debajo está limitado por la sensibilidad del receptor y por arriba por la distorsión o saturación del receptor. El receptor requiere tener rangos dinámicos elevados, ya que debe tener la capacidad para detectar ecos tan distintos como los que origina una montaña a corta distancia o un pequeño avión a varios centenares de millas.

En el subsistema de procesado y explotación de la información, a partir de las señales suministradas por el receptor y tras separar las señales procedentes de los blancos deseados del resto de señales, se determina la posición y velocidad de los blancos y se presentan estos datos al usuario o en el caso del radar de un misil se envían al computador del sistema de guía. Básicamente, este subsistema incluye los siguientes cuatro elementos: el procesador de señal, el extractor de datos, el procesador de datos y la explotación de la información.

- El procesador de señal determina la presencia o no de blancos. Para lo cual debe eliminar las señales no deseadas, denominadas *clutter* (ecos del suelo, mar, nubes, chaff, interferencias electrónicas producidas por el enemigo u otras interferencias).

Capítulo 3. Modelado de la superficie equivalente radar

- El extractor de datos se encarga, a partir de los datos suministrados por el procesador de señal, de calcular la información de interés como: la distancia, marcación, elevación y velocidad del blanco.
- El procesador de datos, gestiona la información procedente del extractor de datos, realizando varias funciones como: detección automática de blancos, aplicar filtros Kalman (Ramachandra, 2000) para efectuar el seguimiento automático de blancos, etc.
- La explotación de la información viene dada por el tipo de radar y la función que realiza. En el caso de un radar de un misil, la explotación de la información se realiza por el sistema de guía que a partir de la información recibida del procesador de datos genera las órdenes a los planos de control para controlar el vuelo del misil. En otro tipo de radares, lo habitual es que la explotación se realice mediante una consola o pantalla donde se presente al operador la información del modo más amigable posible para su correcta interpretación.

Todos los subsistemas antes mencionados están gestionados por un controlador donde radica la inteligencia del sistema. En los sistemas más sofisticados puede llegar a ser un ordenador central e incluso algunas funciones específicas pueden ser realizadas por uno o varios microprocesadores dedicados. El tamaño y velocidad del controlador están determinados por el tipo de radar y por lo tanto por el grado de complejidad.

3.2.3. Obtención de la distancia radar

La forma más simple de la señal radar consiste en una serie de pulsos rectangulares equiespaciados o tren de pulsos, cada uno de ellos de una duración muy pequeña (τ) y modulados a través de una frecuencia portadora (f_o) (Figura 3-6). El sistema determina la distancia a un blanco u objeto midiendo el tiempo T_R , entre la transmisión de un pulso y la recepción de su retorno. Este tiempo es igual a $2R/c$ donde c es la velocidad de la luz en el medio y R la distancia al blanco (Knott, Shaeffer, & Tuley, 2004; Richards et al., 2015). Por lo tanto, podemos calcular el alcance o distancia radar con la siguiente ecuación, donde el factor numérico 2 del denominador, es debido a que el pulso debe realizar un recorrido de ida y vuelta al blanco u objeto desde el transmisor:

$$R = \frac{cT_R}{2} \quad (3-1)$$




Figura 3-6. Forma de la onda. Tren de pulsos

3.2.4. El alcance máximo no ambiguo

En la configuración de un tren de pulsos, tal y como se observa en la Figura 3-7, es necesario que entre pulso y pulso haya tiempo suficiente para recibir el eco, de manera que se pueda identificar cada eco como resultante del último pulso enviado. Si el tiempo entre pulsos (T_p) es demasiado corto, entonces el eco de un blanco lejano pero detectable, llegará después de la emisión de un pulso posterior al que le originó y podría asociarse incorrectamente con el citado pulso posterior.

La distancia a partir de la cual puede ocurrir esta anomalía se denomina alcance máximo no ambiguo, y viene dado por la siguiente expresión (Knott et al., 2004; Richards et al., 2015).

$$R_{Unamb} = \frac{cT_p}{2} = \frac{c}{2f_p} \quad (3-2)$$

donde T_p es el periodo de repetición de pulsos (*pulse repetition period*: PRP) y f_p es la frecuencia de repetición de pulsos (*pulse repetition frequency*: PRF). Ambos parámetros están relacionados de la siguiente forma:

$$T_p = \frac{1}{f_p} = \frac{1}{PRF} \quad (3-3)$$

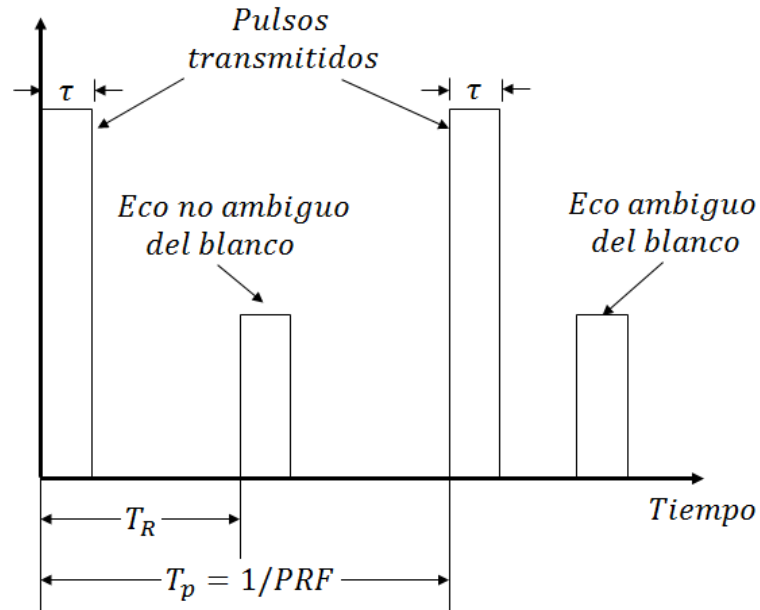


Figura 3-7. Tren de pulsos de un radar

3.2.5. Resolución en distancia

La resolución o discriminación en distancia (ΔR) de un sistema radar es la mínima distancia entre dos blancos situados en la misma dirección, para la cual el sistema tiene la capacidad de detectarlos como ecos separados (ver Figura 3-8) (Knott et al., 2004; Richards et al., 2015).

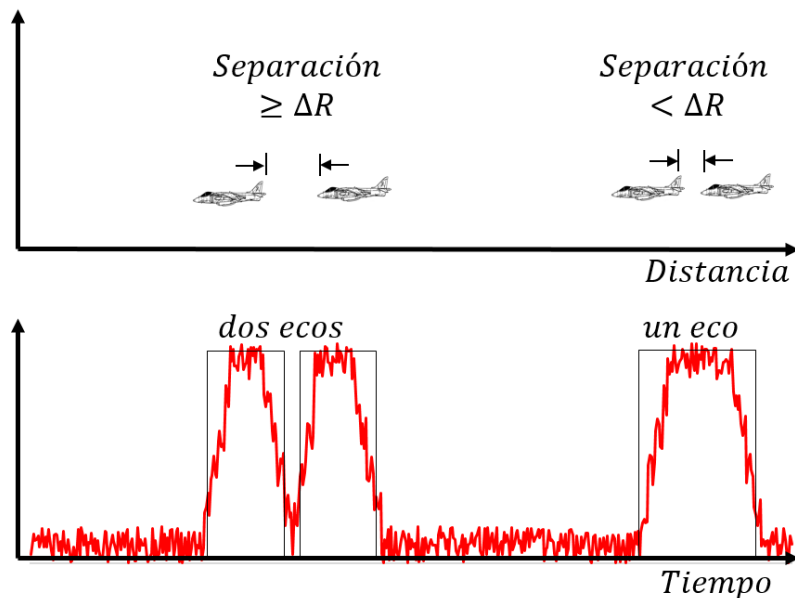


Figura 3-8. Resolución en distancia

Capítulo 3. Modelado de la superficie equivalente radar

Para el cálculo de ΔR , partiremos de un radar típico que utiliza una onda continua modulada por un tren de pulsos. Un ejemplo, ya mencionado antes, es el de una onda cuadrada con una anchura de pulso (τ) y una frecuencia (f_0). En este caso, en donde el pulso no está codificado, la resolución en distancia o discriminación en distancia, es función del ancho del pulso (τ) y de la velocidad de la luz en el medio (c), según la relación:

$$\Delta R = c\tau/2 \tag{3-4}$$

A pesar de lo expresado en el párrafo anterior, es habitual expresar la resolución en distancia en términos del ancho de banda (*bandwidth: BW*) de la forma de onda transmitida (Richards et al., 2015). En el dominio de frecuencia las señales transmitidas y recibidas tienen componentes espectrales centrados en la frecuencia de funcionamiento f_0 con una forma de onda del tipo $\text{sen } x/x$, donde el ancho de banda se mide sobre los puntos de -3dB , que en el caso del radar pulsado, tal y como se aprecia en la Figura 3-9, viene dado por $BW = 1/\tau$, por lo que si sustituimos este valor en (3-4) obtenemos:

$$\Delta R = c/2BW \tag{3-5}$$

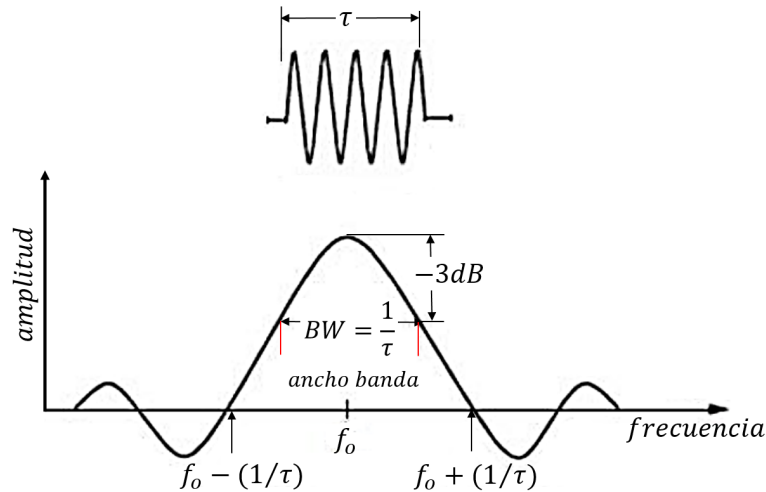


Figura 3-9. Espectro de frecuencia y ancho de banda para un pulso sin codificar

Si se desea una determinada resolución en distancia es necesario disminuir el ancho de pulso. Sin embargo, para la detección de un blanco es necesario que la energía reflejada por el blanco supere la señal ruido ambiente. Así pues, para una determinada potencia de pico (P_t) o potencia de un pulso individual y un alcance máximo no ambiguo, un pulso pequeño implica menos energía radiada por unidad de tiempo o

potencia promedio (P_{av}). Por ello, se utilizan técnicas de codificación intrapulso para proporcionar una mejor discriminación en distancia, mientras se mantiene un ancho de pulso suficiente para conseguir una elevada potencia promedio (Richards et al., 2015).

Para proporcionar un mayor ancho de banda, obtener así una buena discriminación en distancia y simultáneamente mantener un ancho de pulso con cierto tamaño, se utilizan técnicas que se denominan de compresión de pulsos. Algunos de los radares de compresión de pulsos que nos podemos encontrar son los chirp y los barker. Su funcionamiento se basa en modular la señal portadora, dicha modulación puede ser de forma lineal en frecuencia (radares chirp) o en fase (radares barker).




Figura 3-10. Radar de compresión de pulsos chirp: a) forma del pulso; b) frecuencia de la onda transmitida; c) forma de la onda

En concreto, la modulación chirp consiste en modular en frecuencia la señal transmitida en cada pulso. Básicamente se trata de cambiar la frecuencia instantánea del oscilador que se utiliza para la transmisión, casi siempre un oscilador local cuya salida es posteriormente amplificada por un tubo de ondas progresivas o un conjunto de transistores de potencia. En la Figura 3-10 se puede apreciar la forma de los pulsos y el ancho de banda en un radar de compresión de pulsos tipo chirp.

3.2.6. Discriminación angular

La discriminación o resolución angular ($\Delta\theta$) es la mínima separación en acimut de dos blancos iguales situados a la misma distancia del radar, para que sean detectados como dos ecos distintos (ver Figura 3-11). Depende fundamentalmente del ancho del lóbulo de radiación y por lo tanto del tipo de antena del sistema. En general, para un radar simple podemos establecer como medida de resolución angular al ancho del lóbulo para los puntos de mitad de potencia ($-3dB$).




Figura 3-11. Resolución angular ($\Delta\theta$)

También podemos definir la resolución angular (ΔR_c) como la mínima distancia entre dos blancos situados a la misma distancia del radar para sean detectados como dos ecos diferentes (ver Figura 3-12). En este caso esta resolución depende de la distancia al blanco y viene dada por $\Delta R_c \approx R\theta$, donde θ es el ancho del lóbulo de radiación a la mitad de potencia ($-3dB$) (Richards et al., 2015).




Figura 3-12. Resolución angular (ΔR_c)

3.2.7. Celda de resolución

La celda de resolución es el mínimo espacio que deben estar separados dos blancos para que sean detectados como dos ecos diferentes. En el cálculo de la celda resolución (Figura 3-13) intervienen los parámetros vistos anteriormente: discriminación en distancia (ΔR) y discriminación angular ($\Delta\theta$). En un radar tridimensional 3D, la discriminación angular será tanto en elevación ($\Delta\theta_e$), como en azimut ($\Delta\theta_{Az}$) (Rahman, 2019).

Tal y como se expuso en el capítulo anterior, el tamaño de la celda de resolución del radar del misil, es un factor clave en la seducción mediante señuelos, por lo que su conocimiento es esencial para poder calcular las soluciones de lanzamiento.




Figura 3-13. Celda de resolución de un radar.

3.2.8. Forma simple de la ecuación radar

La ecuación radar relaciona el alcance radar con las características del transmisor, el receptor, la antena, el medio de propagación y la superficie equivalente del blanco. Además, sirve como herramienta para comprender los fundamentos teóricos del radar y las cuestiones básicas de diseño (Knott et al., 2004; Rahman, 2019; Skolnik, 2008).

Para una potencia de transmisión del radar P_t y una antena isotrópica⁷, la densidad de potencia (S_{iso}), en vatios por unidad de área, a una distancia R del radar es igual a la potencia de transmisión dividida por el área de una esfera imaginaria de radio R :

$$S_{iso} = \frac{P_t}{4\pi R^2} \quad (3-6)$$

Sin embargo, los sistemas radar utilizan antenas directivas para radiar la potencia P_t en una dirección determinada. Por ello, se utiliza el parámetro de ganancia de la antena (G), que tal y como lo definimos anteriormente, es una medida del incremento de la densidad de potencia radiada a la distancia del objeto, respecto de la producida en ese mismo punto por una antena isotrópica que transmite la misma potencia. Así, obtenemos que la densidad de potencia (S) en un blanco situado a la distancia R y radiada por una antena con ganancia G viene dada por:

$$S = \frac{P_t G}{4\pi R^2} \quad (3-7)$$

El blanco intercepta una porción de la potencia incidente y la refleja en varias direcciones. La relación entre la cantidad de potencia interceptada por el blanco y reflejada

⁷ Una antena isotrópica es aquella que radia uniformemente en todas las direcciones.

Capítulo 3. Modelado de la superficie equivalente radar

en la misma dirección del radar depende de la superficie equivalente radar del propio blanco (σ) y está definida en la siguiente ecuación:

$$S_{eco} = \frac{P_t G}{4\pi R^2} \frac{\sigma}{4\pi R^2} \quad (3-8)$$

donde S_{eco} es la densidad de potencial de radiación en la antena del radar asociada al eco producido por el blanco.

La superficie equivalente radar tiene unidades de área, y se puede interpretar como el área ideal equivalente de un material perfectamente reflector, es decir un conductor perfecto, colocado de manera perpendicular a la dirección de propagación que produjese el mismo eco.

La antena del radar captura una porción de la potencia del eco del blanco, por lo que si llamamos A_e al área efectiva de la antena, la potencia recibida del eco (P_r) es la siguiente:

$$P_r = \frac{P_t G}{4\pi R^2} \frac{\sigma}{4\pi R^2} A_e = \frac{P_t G \sigma A_e}{(4\pi)^2 R^4} \quad (3-9)$$

Ahora, denominaremos alcance máximo radar (R_{max}) a la distancia a partir de la cual el blanco no puede ser detectado y que ocurre cuando la potencia recibida del eco (P_r) es igual a la mínima señal detectable (S_{min}). Obtenemos así, a partir de la ecuación (3-9), la forma fundamental de la ecuación radar, que vendrá dada por:

$$R_{max} = \sqrt[4]{\frac{P_t G \sigma A_e}{(4\pi)^2 S_{min}}} \quad (3-10)$$

Por otra parte, se puede relacionar la ganancia y el área efectiva de la antena de la siguiente forma:

$$G = \frac{4\pi A_e}{\lambda^2} \quad (3-11)$$

donde λ es la longitud de onda de la señal electromagnética, que a su vez está relacionada con la frecuencia de transmisión (f_0), mediante $\lambda = c/f_0$.

Capítulo 3. Modelado de la superficie equivalente radar

Dado que habitualmente los radares utilizan la misma antena para recepción y transmisión, podemos sustituir la ecuación (3-11) en (3-10) y obtener las dos siguientes ecuaciones radar:

$$R_{max} = \sqrt[4]{\frac{P_t G^2 \lambda^2 \sigma}{(4\pi)^3 S_{min}}} \quad (3-12)$$

$$R_{max} = \sqrt[4]{\frac{P_t A_e^2 \sigma}{4\pi \lambda^2 S_{min}}} \quad (3-13)$$

Las expresiones que acabamos de enunciar son tan solo versiones simplificadas de la ecuación radar, ya que hay otros factores que afectan al alcance y que no están contenidos en ellas. Por ello, este modelo no describe exactamente el rendimiento práctico de un sistema, obteniendo en la realidad alcances máximos menores a lo predichos por ellas. Sin embargo, para el marco de este trabajo, su precisión es suficiente ya que nos permite determinar la influencia de la superficie equivalente radar del blanco en las prestaciones de un sistema radar.

3.2.9. Frecuencias radar

Los sistemas radar pueden trabajar en una amplia banda de frecuencias de transmisión, siendo la finalidad para la que ha sido diseñado, el factor que va a determinar dicha frecuencia de trabajo.

Los radares navales de navegación trabajan en frecuencias sobre los 9 GHz, mientras que radares de seguimiento de blancos, como direcciones de tiro y radares buscadores o *seeker* de misiles, funcionan en frecuencias entre 10,0 – 20,0 GHz con anchos de pulsos más pequeños y antenas de tamaño más reducido (ver Figura 3-14).

Hay que reseñar que para frecuencias altas, cómo el caso de los radares de misiles, se pueden emplear antenas más pequeñas que siguen manteniendo una buena discriminación angular y en distancia. Sin embargo, tienen el inconveniente de que se verán más influenciados por las condiciones meteorológicas, disminuyendo su alcance.




Figura 3-14. Radares de seguimiento: a) Radar STIR de la dirección de tiro MK-92; b) radar seeker del misil anti buque Brahmos (Fuentes: Armada Española y www.delhidedefencereview.com)

Con el desarrollo inicial de los sistemas radar y para mantener la confidencialidad, se empezó a designar las frecuencias de trabajo con un código de letras: L, S, C, etc. Esta forma comenzó a hacerse habitual hasta que el año 1976 el *Institute of Electrical and Electronic Engineers* (IEEE) estandarizó su uso mediante el documento IEEE 521-1976, que fue actualizado en el año 1984 y modificado posteriormente en 2002 mediante la publicación IEEE 521-2002, actualmente en vigor. También existe otra nomenclatura de las bandas de frecuencia utilizada en el ámbito militar, que también emplea letras para designar las diferentes bandas, aunque su denominación y márgenes son diferentes. Ambas nomenclaturas se encuentran recogidas en la Figura 3-15.

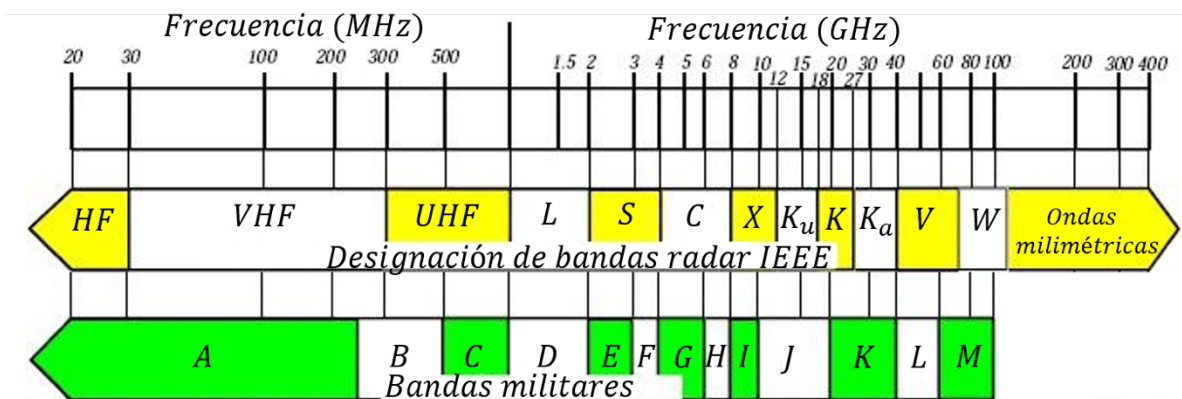


Figura 3-15. Designación de las bandas de frecuencia radar según IEEE y la denominación militar

3.2.10. Clasificación de los sistemas radares

Los sistemas radar los podemos clasificar según su: funcionamiento, finalidad, número de antenas y forma de la onda.

Según su funcionamiento, los podemos clasificar en radar primario o radar secundario (ver Figura 3-16). El radar primario son los que hemos tratado hasta ahora, es decir emite una señal electromagnética, esta se refleja en el blanco, el sistema recibe el eco y calcula la distancia, acimut y velocidad del objeto. En los radares secundarios el blanco va equipado con un transpondedor, que cuando recibe una señal codificada del radar secundario interrogador, se activa y devuelve un pulso codificado conteniendo una serie de información, como identificación, altura, fallo de comunicaciones, etc.



Figura 3-16. Radar Lanza. Antenas del radar primario y del secundario (fuente: www.indra.es)

El sistema radar se pueden clasificar, según su finalidad, en radares de búsqueda o radares de seguimiento. El radar de búsqueda explora una zona del espacio para detectar blancos, mientras que en el radar de seguimiento la antena apunta constantemente al blanco, por ejemplo en el caso de una dirección de tiro para obtener de forma instantánea sus leyes de movimiento.

Según el número de antenas, podemos clasificar los sistemas radar en monoestático, biestático o multiestático. Los radares monoestáticos son aquellos que disponen de una sola antena receptora y transmisora, mientras que en los biestáticos o multiestáticos, dichas antenas pueden estar separadas grandes distancias.

Por último podemos clasificar los sistemas radar según la forma de onda en radar de pulsos o radar de onda continua (CW). Los primeros corresponden al radar clásico en

Capítulo 3. Modelado de la superficie equivalente radar

donde se transmite periódicamente un pulso, mientras que, el radar de onda continua transmite continuamente y por lo tanto habitualmente utiliza dos antenas.

3.2.11. El radar de un misil antibuque

Una vez expuestos los principios básicos de funcionamiento de un radar, estamos en condiciones de profundizar en el caso concreto de los radares que portan los misiles antibuque de guía activa (ver Figura 3-17).




Figura 3-17. Misil de origen ruso P-15 Termit (SS-N-2 “Styx” en código OTAN): a) vista del radar; b) misil en el momento de la carga en un buque (fuente: www.military-today.com)

Tal y como se expuso en el capítulo 2, el radar o *seeker* de un misil activo, es un radar de búsqueda y seguimiento. Al llegar a cierta distancia de la zona del objetivo, realiza una búsqueda en un área centrada en la posición prevista del buque, introducida previamente al lanzamiento, cuando localiza un blanco válido, se fija sobre él e inicia el seguimiento, manteniendo constantemente apuntada la antena sobre el objetivo para el guiado del misil, hasta que se produzca el impacto.

Este tipo de radar es monoestático y trabaja habitualmente en las bandas X , K_u o K , aunque algunos países están comenzando desarrollos en la banda superior K_a . Otras características de estos sistemas son su baja potencia de pico, debido por una parte a lo limitado del volumen disponible y a la necesidad de ser detectado lo más tarde posible por los equipos de guerra electrónica de los buques. También requieren una elevada precisión, por lo que tiene una PRF alta y una muy buena resolución en distancia y angular.

Aunque este sistema es un radar pulsado, debido a sus peculiaridades de funcionamiento, presenta algunas diferencias respecto a lo descrito en el punto 3.2.2 sobre radares convencionales. Por ello, expondremos aquí los fundamentos de un *seeker* de última generación del tipo coherente, con seguimiento monopulso y antena giroestabilizada (Das, 2005), cuyo diagrama básico de bloques es el que se muestra en la Figura 3-18 y en donde se observan los siguientes subsistemas (Babu, Toppo, Patel, & Kumar, 2013; Pérez Martínez, 2011):

- Transmisor.
- Receptor.
- Procesado de la información.
- Antena y su controlador.
- Procesador del radar o *seeker*.

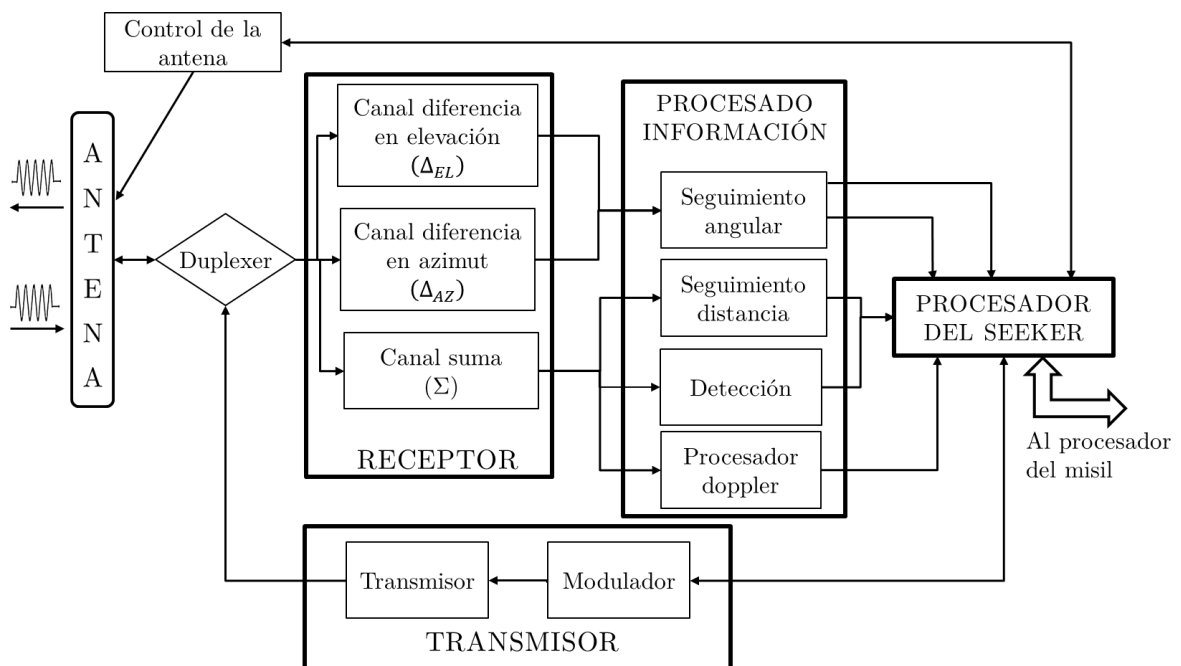


Figura 3-18. Diagrama de bloques de un *seeker* coherente y monopulso

En la fase de búsqueda del misil, la estructura de los subsistemas transmisor y receptor del radar *seeker*, no varían substancialmente de los empleados en los radares primarios. Aunque debido a la naturaleza especial de estos radares, el subsistema de procesado de la información tendrá ciertas diferencias ya que tendrá que determinar si la

detección de un contacto, corresponde a un blanco válido para iniciar la fase de ataque.

Sin embargo, la diferencia fundamental respecto a otro tipo de radares radica en la fase de ataque. Una vez que el radar ha detectado e identificado al blanco, éste debe ser aislado del resto mediante una puerta muy estrecha y realizar el seguimiento en

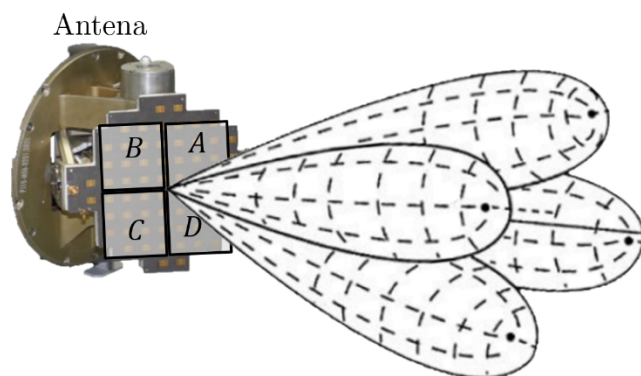


Figura 3-19. Lóbulos generados por los cuatros cuadrantes de una antena monopulso

lazo cerrado, en acimut y en distancia. Este tipo de radares emplean, tanto para detección como para seguimiento, la técnica monopulso⁸. Para ello, la antena está dividida en cuatro cuadrantes (*A, B, C y D*), de tal forma que generan cuatro lóbulos como los que se observan en la Figura 3-19 (Peebles, 1998).

En este tipo de técnica, para conocer la posición del blanco se calcula su desplazamiento respecto de los cuatro cuadrantes, es decir, se medirá la señal recibida en cada cuadrante, de forma que cuando el blanco esté sobre el eje de la antena se recibirá la misma señal en cada uno de ellos. Para realizar esta tarea, el receptor dispone de tres canales: canal de diferencia en elevación, canal de diferencia en acimut y canal suma, donde se forman las siguientes señales en función de la señal recibida por cada cuadrante:

$$\text{Canal diferencia en elevación: } \Delta_{EL} = (A + B) - (C + D)$$

$$\text{Canal diferencia en acimut: } \Delta_{AZ} = (A + D) - (B + C)$$

$$\text{Canal suma: } \Sigma = (A + B + C + D)$$

Las señales suma (Σ), diferencia en elevación (Δ_{EL}) y diferencia el azimuth (Δ_{AZ}) del receptor se utilizan en el subsistema de procesamiento de la información en los circuitos

⁸ El nombre de monopulso a esta técnica se debe a que solamente es necesario un pulso para determinar la dirección del blanco.

Capítulo 3. Modelado de la superficie equivalente radar

de detección, procesamiento doppler, seguimiento en distancia y seguimiento angular. En los siguientes párrafos pasaremos a describir cómo funcionan estos circuitos.

Los circuitos de detección contienen los elementos para determinar, a partir de la señal Σ , la existencia o no de un blanco válido dentro de la celda de resolución del misil, incluyendo habitualmente también la posibilidad de identificar fuentes de perturbación electrónica o *jamming*.

Las primeras generaciones de misiles antibuque, montaban radares no coherentes, ya que la elevada superficie equivalente radar del buque objetivo, suponía que el eco de la señal reflejada proporcionaba la suficiente discriminación sobre el *clutter*, incluso para escenarios con mal estado de la mar. Sin embargo, la inclusión de tecnologías de reducción de superficie equivalente radar en los buques de guerra, ha traído consigo que los misiles tengan la necesidad de mejorar la discriminación con estados de la mar muy adversos. Por ello, los radar *seeker* más modernos incluyen un circuito de procesamiento doppler de la señal (Hodgson & Lee, 2003; Skolnik, 2008).

Los circuitos de seguimiento en distancia y de seguimiento angular, son los que determinan continuamente la posición del blanco en la celda de resolución del radar. Para el seguimiento en distancia se utiliza la señal suma Σ del receptor y se emplea habitualmente la técnica de puerta de distancia dividida, dicha técnica utiliza dos puertas de distancia: puerta anterior o *early gate* y puerta posterior o *late gate* (ver Figura 3-20). El voltaje de salida de la puerta anterior es positivo y el de la puerta posterior es negativo. Las salidas de las dos puertas se suman y se origina una señal error que se usa para centrar las puertas por medio de un sistema de control por realimentación. Cuando la señal error es cero, las puertas de distancia están centradas sobre el pulso y si la energía de la señal eco que contiene la puerta anterior es menor que la de la puerta posterior, se genera un voltaje de salida negativo y por tanto una señal error negativa que tiende a centrar la las puertas (Hannen, 2014; Mahafza, 2000).




Figura 3-20. Seguimiento en distancia con puerta de distancia dividida: a) blanco centrado en distancia; b) blanco alejado en distancia

La técnica monopulso en seguimiento angular se ilustra en la Figura 3-21, donde los cuatro cuadrantes *A*, *B*, *C* y *D* corresponden a los cuatro lóbulos de la antena y el círculo representa la señal del eco del blanco. Cuando el blanco está centrado sobre el eje de seguimiento de la antena (Figura 3-21a), los cuatro cuadrantes reciben la misma energía y por lo tanto la señal error que se genera es nula. En el caso de que el blanco esté desplazado en acimut (Figura 3-21b) y en elevación (Figura 3-21c), se generan en el receptor las señales diferencia en elevación (Δ_{EL}) y diferencia el azimut (Δ_{AZ}), que son procesadas por el subsistema de procesamiento de la información para generar las señales error de lazo de cerrado para el seguimiento angular del blanco.




Figura 3-21. Principios de funcionamiento de la técnica de seguimiento monopulso: a) blanco centrado; b) blanco a la izquierda del eje de la antena; c) blanco por encima del eje de la antena

Capítulo 3. Modelado de la superficie equivalente radar

Por último, describiremos de forma somera las funciones del subsistema de control de la antena y del procesador del *seeker*. El primero de ellos, tiene como objetivo garantizar el apuntamiento de la antena al blanco y mantenerla estabilizada, mientras que el procesador del *seeker* es el responsable de controlar el funcionamiento de los subsistemas y asegura la correcta realización de las tareas y pautas programadas. Además, tiene un enlace con el procesador del misil, por el cual recibe órdenes y envía información.

En la siguiente tabla se han presentado los márgenes típicos de los parámetros de funcionamiento de un radar *seeker* de un misil antibuque y que utilizaremos para su modelado en el simulador.

Tabla 3-1. Características del *seeker* de un misil antibuque genérico (Knott et al., 2004; McEachron, 1997)

Parámetro del <i>seeker</i>	Márgenes habituales de trabajo
Potencia	5 – 40 W
Frecuencia de transmisión	Bandas X, K_u o K
Ancho de banda	0,5 MHz – 2,5 MHz
Ganancia de la antena	20 dB – 35 dB
Tipo de seguimiento	monopulso
Ancho del haz para $\pm 3dB$	3° – 5°
Ancho de la puerta de distancias	0,2 μs – 0,9 μs

3.3. FUNDAMENTOS DE LA SUPERFICIE EQUIVALENTE RADAR

En el punto anterior, al enunciar la ecuación radar, vimos la influencia de la superficie equivalente radar en las prestaciones del sistema. De forma coloquial, podemos decir que la superficie equivalente radar, o *radar cross section* (RCS) es una medida de cómo de detectable es un blanco con un radar.

Capítulo 3. Modelado de la superficie equivalente radar

Por lo tanto, no es extraño que uno de los requisitos de los buques de la Armada sea el disponer de una RCS lo más reducida posible. Este requisito persigue, desde el punto de vista operativo, dos fines: disminuir la distancia máxima de detección de los radares del enemigo sobre el buque propio, esto es, mejorar el factor de ventaja y por otro lado, hacer más eficaces las contramedidas electrónicas activas y pasivas (señuelos).

Otro aspecto importante es que la RCS propia debe ser perfectamente conocida, ya que ello nos permitirá modelar de forma realista las simulaciones de escenarios navales electrónicamente complejos y obtener conclusiones sobre el empleo táctico del buque, como el caso del lanzamiento de señuelos ante el ataque de un misil de guía radar. Por otra parte, el conocimiento de la RCS permitirá aplicar diferentes técnicas para su reducción.

En definitiva, una superficie equivalente radar reducida y controlada, proporciona una mayor eficiencia operativa y por lo tanto incrementa la capacidad de supervivencia del buque (Galle et al., 1999).

3.3.1. Definición de superficie equivalente radar

Podemos encontrarnos varias definiciones de superficie equivalente radar, incluso podríamos afirmar que existen tantas definiciones como autores han escrito sobre el tema, por lo que tomaremos las siguientes como referencia para este trabajo.

- La superficie equivalente radar es una medida de las características de reflexión radar de un blanco. Es igual a la potencia reflejada por estereorradián en la dirección del radar dividida por la densidad de potencia que es interceptada por el blanco (NAWCWD, 2013).
- La superficie equivalente radar de un blanco es un área ficticia que, interceptando una parte de la potencia incidente y reflejada en todas las direcciones, produce un eco en el radar igual al del blanco (Skolnik, 1981).
- La superficie equivalente radar es una medida de la potencia reflejada en una dirección cuando el blanco es iluminado por una onda incidente (Knott et al., 2004).
- Desde un punto de vista más formal, podemos tomar la definición del *IEEE Estándar Radar Definitions* que establece que: «la sección radar de un objeto

Capítulo 3. Modelado de la superficie equivalente radar

se define como 4π veces el cociente entre la potencia dispersada por el objeto en la dirección del radar por unidad de ángulo sólido y la potencia por unidad de superficie de la onda plana que incide sobre dicho objeto desde una dirección dada».

$$\sigma = \lim_{R \rightarrow \infty} 4\pi R^2 \frac{|E^s|^2}{|E^i|^2} \quad (3-14)$$

donde E^s es la intensidad del campo eléctrico dispersado y E^i es la intensidad del campo eléctrico incidente.

La medida de la RCS está normalizada respecto a la densidad de potencia del campo incidente. Con esta normalización se elimina la influencia de la distancia de forma que se obtiene una descripción de la RCS que es independiente de la distancia entre el blanco y el radar (Pérez-Ojeda, 2007).

3.3.2. Ecuación intuitiva de la superficie equivalente radar

También podemos definir la superficie equivalente radar como la superficie de un reflector perfecto que envía hacia el radar la misma densidad de potencia que el objeto iluminado (Knott et al., 2004). Esta definición nos permitirá llegar de forma más intuitiva a la formulación formal (3-14) realizada por el *IEEE Estándar Radar Definitions*.

Consideremos que la densidad de potencia incidente en el blanco situado a cierta distancia del radar es $P_i \text{ W/m}^2$. La potencia interceptada por el blanco está relacionada con la superficie equivalente radar (σ) medida en metros al cuadrado, de la forma siguiente $\sigma P_i \text{ W}$. Si asumimos que esta potencia interceptada por el blanco es dispersada uniformemente en todas las direcciones, es decir en los 4π estereoradianes del espacio, entonces la densidad de potencia dispersada (P_s) vendrá dada por la siguiente ecuación:

$$P_s = \frac{\sigma P_i}{4\pi R^2} \text{ W/m}^2 \quad (3-15)$$

donde R es la distancia del blanco al radar.

Capítulo 3. Modelado de la superficie equivalente radar

Si despejamos ahora la superficie equivalente radar (σ) obtenemos la siguiente ecuación:

$$\sigma = 4\pi R^2 \frac{P_s}{P_i} \text{ m}^2 \quad (3-16)$$

donde observamos que la superficie equivalente radar corresponde a la relación entre la densidad de potencia dispersada y la densidad de potencia reflejada.

Ahora, sabiendo que la densidad de potencia de una onda electromagnética es proporcional al cuadrado de campo eléctrico, llegamos a la ecuación (3-14) que se puede expresar de la forma:

$$\sigma = 4\pi R^2 \frac{|E^s|^2}{|E^i|^2} = 4\pi R^2 \frac{|B^s|^2}{|B^i|^2} \quad (3-17)$$

donde E y B corresponden a los campos eléctrico y magnético de la onda electromagnética y los superíndices i y s al campo incidente y campo dispersado.

Volviendo a la ecuación (3-9), podemos expresar la potencia recibida por el radar (P_r) de la forma siguiente:

$$P_r = \frac{P_t G \sigma A_e}{(4\pi)^2 R^4} = \frac{\left(\frac{P_t G}{4\pi R^2}\right) \sigma}{4\pi R^2} A_e \quad (3-18)$$

Observamos en la ecuación anterior, que el primer término del numerador es la densidad de potencia incidente sobre el blanco, que al multiplicarla por la superficie equivalente radar (σ), obtenemos la potencia interceptada por el blanco y reflejada en todas las direcciones. A una distancia R del blanco, se obtiene una densidad de potencia en la antena receptora (P_r) que es capturada por el área efectiva de la antena A_e . Por lo que se desprende, que la superficie equivalente radar es una medida de la potencia dispersada en una dirección dada cuando el blanco es iluminado por una onda incidente (Pérez-Ojeda, 2007).

Una vez vista la definición formal de la RCS, hay que mencionar que existen una serie de factores que van a condicionar su valor y que básicamente son los siguientes (Galle et al., 1999; Pérez-Ojeda, 2007):

Capítulo 3. Modelado de la superficie equivalente radar

- Orientación angular relativa del blanco con el transmisor y el receptor.
- Geometría y composición de los materiales del blanco.
- Frecuencia o longitud de onda de trabajo del radar.
- Polarización el transmisor y del receptor.
- Condiciones ambientales (conductos y multitrayecto).

En la Figura 3-22 se puede observar la representación en un gráfico polar, de la típica forma de la superficie equivalente de un buque, para una determinada frecuencia y polarización, donde podemos apreciar lo fuertemente dependiente que la RCS es de la orientación angular respecto del radar.

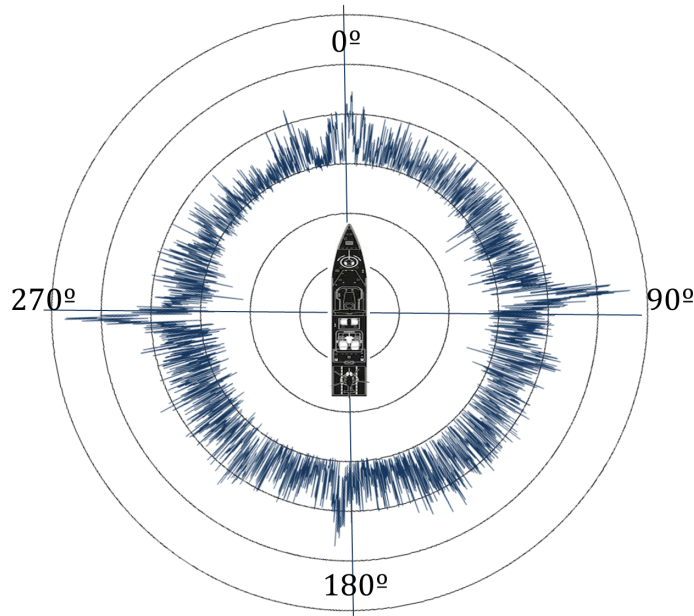


Figura 3-22. Típica forma de la superficie equivalente radar de un buque

3.3.3. Unidades de medida de la superficie equivalente radar

La unidad de medida de la superficie equivalente radar es el metro al cuadrado (m^2). Sin embargo, para blancos grandes, como el caso de los buques, en los que se pueden obtener valores mayores de $10^5 m^2$, se suele emplear una escala logarítmica, utilizándose como valor de referencia $\sigma_{ref} = 1 m^2$:

$$\sigma_{dBsm} = \sigma_{dBm^2} = 10 \log_{10} \left(\frac{\sigma_{m^2}}{\sigma_{ref}} \right) = 10 \log_{10} \left(\frac{\sigma_{m^2}}{1} \right) \quad (3-19)$$

En la Tabla 3-2 figuran los valores aproximados de la superficie equivalente radar de algunos objetos. Estos valores deben tomarse tan solo como una indicación ya que proceden de fuentes que pueden no ser precisas y además la RCS puede variar en función de la frecuencia, aspecto del blanco y otros factores.

Tabla 3-2. Algunas medidas de RCS (O'Neil, 1991).

Objeto	σ_{m^2}	σ_{dBsm}
Insecto	0,001	-30
Pájaro grande	0,1	-10
Misil antibuque	0,03	-15
Bombardero	3	5
Patrullero (200 Ton)	300	25
Fragata/destructor (4000 Ton)	15 000	45
Crucero (9000 Ton)	100 000	50
Portaaviones (94 000 Ton)	3 000 000	65

3.3.4. *Dispersión*

Un objeto expuesto a una onda electromagnética dispersa la energía incidente en todas las direcciones. Esta distribución espacial de energía se denomina dispersión y al objeto se le denomina dispersor. Es importante comprender estos mecanismos de dispersión electromagnética en un buque, para poder así determinar de forma precisa la superficie equivalente radar y poder reducirla de forma eficaz.

En primer lugar debemos tener en cuenta que la RCS depende, entre otros factores, de la frecuencia de la onda incidente. Por ello, se definen tres regímenes o regiones de dispersión electromagnética (Rayleigh, Mie o de resonancia y óptica o de alta frecuencia), en las cuales la RCS es claramente diferente, siendo estas tres regiones función

Capítulo 3. Modelado de la superficie equivalente radar

de las dimensiones del blanco en relación con la longitud de onda de la señal incidente (Knott et al., 2004).

Si la longitud de onda (λ) es grande comparada con las dimensiones del blanco (L), es decir $L/\lambda \ll 1$, nos encontramos en la llamada región de Raleigh. En esta región la RCS es proporcional a la cuarta potencia de la frecuencia, donde los detalles de la forma del objeto no son importantes.

Cuando las dimensiones del objeto son parecidas al orden de la longitud de onda $L/\lambda \sim 1$, nos encontramos en la región de Mie o de resonancia. La geometría completa es importante, incluso los pequeños detalles. En esta región la RCS presenta un comportamiento oscilatorio.

Cuando la longitud de onda incidente es mucho menor que el tamaño del blanco $L/\lambda \gg 1$ nos encontramos en la región óptica o de alta frecuencia. En esta región el campo dispersado es muy dependiente del ángulo y la RCS no es tan dependiente de la longitud de onda incidente. En el caso de este estudio, nos moveremos siempre en esta región ya que las frecuencias de trabajo de los radares de los misiles antibuque están en la banda X y superiores, por lo que el tamaño del buque será siempre mucho mayor que la longitud de onda incidente.

En la Figura 3-23 se puede apreciar la RCS normalizada de una esfera de radio r en las tres regiones. Se puede observar que la normalización está realizada respecto al área de la sección máxima de la esfera, es decir en el eje de ordenadas se representa el término $\sigma/\pi r^2$ (Rahman, 2019).

En caso de blancos simples, tales como una esfera, cilindro o una superficie plana, la RCS se puede determinar analíticamente. Además, los mecanismos de dispersión de estas formas simples son útiles para deducir los procesos de dispersión de los blancos complejos.




Figura 3-23. Superficie equivalente radar de una esfera de radio r

Un buque es un objeto complejo y presenta diferentes mecanismos de dispersión, que proporcionan una comprensión básica del proceso físico subyacente de la dispersión y que resumiremos a continuación (Baussard, Rochdi, & Khenchaf, 2011; Knott et al., 2004) (ver Figura 3-24). Algunos mecanismos son dominantes en comparación con otros y también dependientes del ángulo de aspecto del objetivo (Khan, Duan, & Sherbaz, 2012).

Retorno especular. Esta es la forma más significativa de reflexión en la región óptica, la superficie actúa como un espejo para el pulso del radar incidente. La mayor parte de la energía del radar incidente se refleja de acuerdo con la ley de la reflexión especular, es decir, el ángulo de reflexión es igual al ángulo de incidencia.

Ondas de superficie (*Traveling waves*). Se producen en casos en que la dirección de incidencia es casi rasante sobre la superficie. Esta energía se dispersa si se topa con cualquier tipo de discontinuidad. La terminación brusca de la estructura de propagación da lugar a una radiación en sentido contrario, que puede producir un eco importante.

Reflexiones múltiples. Este caso ocurre cuando al onda reflejada, sufre otras reflexiones con otras superficies. En algunos casos su contribución en la RCS es mucho mayor que la debida a la primera reflexión.

Difracción en puntas, vértices y bordes. La onda que incide en una superficie muy afilada o un borde se dispersa en lugar de seguir la ley de la reflexión especular.




Figura 3-24. Diferentes mecanismos de dispersión en un buque

Cavidades. Las cavidades pueden absorber, reflejar o dispersar toda la energía incidente en función de sus propiedades de resonancia. Las típicas cavidades que nos podemos encontrar en un buque son las escotillas, la puerta del hangar o estructuras abiertas en la superestructura. En la Figura 3-25, se puede observar la puerta de la maniobra de arriado de botes en un buque de acción marítima (BAM) de la Armada para reducir la RCS del barco.



Figura 3-25. Puerta de la maniobra de arriado de botes en un patrullero tipo BAM de la Armada. (Fuente: Armada Española)

Creeping waves. Este fenómeno aparece en superficies de curvatura suave. La onda incidente no se refleja, se propaga alrededor de la superficie del objeto y regresa al radar. Por ello, los misiles antibuque y de crucero de última generación tienden a no usar fuselaje en forma de tubo (ver Figura 3-26).



Figura 3-26. Forma del futuro misil antibuque y de crucero Perseus de la empresa MBDA (fuente: www.mbda-systems.com)

Difracción en discontinuidades. Se producen principalmente en discontinuidades en la superficie tales como: cambios de material, soldaduras, ranuras, abolladuras, agujeros, vértices y en cualquier otro tipo de discontinuidad. Todas ellas son una fuente de eco.

3.3.5. Formas de medir la superficie equivalente radar

Las medidas de un barco pueden realizarse con dos objetivos fundamentales (Pérez-Ojeda, 2007)

- Medidas globales, donde se trata de obtener el valor de la RCS en función del aspecto, frecuencia y polarización.
- Medidas de precisión para identificar y localizar de los denominados puntos calientes o *hot-spot*.

Prácticamente existen tres métodos para medir la superficie equivalente de un blanco complejo, tal y como es el caso de un buque:

- Técnicas de predicción mediante ordenador.
- Medidas con modelos a escala.
- Medidas a escala real.

Técnicas de predicción mediante ordenador

Dentro de estas técnicas nos encontramos los métodos exactos, los métodos numéricos y los métodos de alta frecuencia.

Los métodos exactos buscan una solución analítica a la RCS resolviendo las ecuaciones Maxwell y están restringidos a objetos simples y pequeños medidos en la región de Rayleigh y en la región de resonancia o Mie.

Los métodos numéricos de baja frecuencia obtienen la RCS de blancos complejos mediante cálculo numérico por ordenador, para ello se realiza una discretización, tanto de las ecuaciones de Maxwell, como de la superficie del blanco. El inconveniente de estos métodos es que requieren un alto coste computacional.

Por otra parte, existen los métodos de alta frecuencia o aproximados, utilizados para blancos complejos medidos en la región óptica, es decir, cuando el blanco es mucho mayor que la longitud de onda incidente, que es el margen de frecuencias más habitual de los radares. La utilización de los métodos de alta frecuencia se basa en la descomposición del blanco en una serie de centros de eco, de los que se conoce una solución analítica o bien una solución numérica, los campos reflejados hacia el radar se calculan para cada centro de eco por separado y se obtiene el campo total como la suma de los campos reflejados. Las técnicas que utilizan estas aplicaciones son habitualmente: óptica geométrica y óptica física (Khan et al., 2012; J. Rius, 1991).

Los métodos de alta frecuencia son los utilizados por la mayoría del software comercial para la estimación de la RCS de blancos complejos como aeronaves, buques, etc. Dentro de este campo podemos citar como más relevantes las aplicaciones: GRECO, EPSILON, POFACETS 4.2, FEKO, CADRCS, NewFANSANT, EMC Studio/EMCoS Antenna VLab o CTS (Díaz Charris & Gómez Torres, 2017; J. M. Rius, Ubeda, & Heldring, 2018).

Las mejoras en la capacidad de computación están permitiendo un auge de los métodos numéricos y por lo tanto una mayor precisión en el cálculo de la RCS. Como ejemplo podemos citar el algoritmo Multilevel Fast Multipole Algorithm-Fast Fourier Transform (MLFMA-FFT), desarrollado por la Universidad de Vigo (J. M. Taboada et al., 2010; Jose Manuel Taboada, Araujo, Basteiro, Rodriguez, & Landesa, 2013).

Medidas con modelos a escala

Si se desea medir la RCS de un determinado blanco (σ) se puede realizar una medida a escala de la RCS de un modelo (σ_m). Básicamente, este método se basa en la linealidad de las ecuaciones de Maxwell, lo cual implica que el campo dispersado por un blanco real puede ser determinado por la misma medida sobre un modelo a escala. Para ello es necesario mantener una proporción fija de longitud de onda a la dimensión lineal del blanco (Sinclair, 1948). Si denotamos por λ a la longitud de onda de la frecuencia a la que queremos medir la RCS en el blanco real, D a la dimensión lineal del blanco real y D_m a la dimensión lineal del modelo, tenemos que la longitud de onda de la frecuencia necesaria para la medición λ_m , deberá cumplir que $\lambda_m = p \lambda$, donde $p = D_m/D$ es el factor de escala del modelo.

El objetivo del modelado es la medición de la RCS del blanco (σ), que tal y cómo definimos en el punto 3.3.1, es el área de un reflector isotrópico que devolvería a la antena receptora del radar una señal igual a la del objetivo, formalmente obtenida por la ecuación (3-14):

$$\sigma = \lim_{R \rightarrow \infty} 4\pi R^2 \frac{|E^s|^2}{|E^i|^2} \quad (3-20)$$

En la ecuación anterior, podemos observar que la RCS del blanco depende del cuadrado de la relación del campo dispersado e incidente. Por ello, a partir de la RCS de modelo σ_m y del factor de escala p , tenemos que $\sigma = p^2 \sigma_m$ (Waldman, Fetterman, Goodhue, Bryant, & Temme, 1980).

Si tenemos un buque tipo fragata de 145 metros de eslora⁹ y queremos obtener su RCS para una frecuencia de 9 GHz, mediante un modelo de 1,5 metros, necesitamos una frecuencia de medida de 0,87 THz que se genera mediante el uso de láseres (Iwaszczuk, Heiselberg, & Jepsen, 2007).

⁹ La eslora es la medida de un buque en el sentido longitudinal.




Figura 3-27. Configuración de medición a escala de RCS monoestática sobre un modelo de buque (Blanche, Neifeld, & Peyghambarian, 2017)

Medidas a escala real

Los métodos anteriores de predicción por ordenador y las medidas con modelos a escala, no dejan de ser medidas aproximadas que deben ser confirmadas por medidas reales con el buque, una vez construido con todos sus elementos.

Las medidas a escala real se realizan mediante un radar instrumental que generalmente puede cubrir un rango de frecuencia de 1,0 a 20 GHz o incluso de 0,1 a 40 GHz. Además, tiene la capacidad de cambiar entre un conjunto de antenas que corresponden a bandas individuales dentro de este rango (Odendaal, Botha, & Joubert, 2007).

A menudo este radar puede transmitir y recibir a través de cada uno de los dos canales de polarización en cada antena y efectúa estas mediciones mientras realiza un seguimiento continuo del buque, que a su vez, ejecuta una curva de evolución hasta completar los 360° de caída de rumbo, para presentar todos los ángulos de aspecto al radar.

El resultado de una medición típica de un objetivo con un radar de este tipo, es una gran cantidad de datos que deben procesarse para su análisis y visualización.

En la Armada Española, la caracterización de la superficie equivalente radar se realiza a escala real. Para ello, hasta el año 2018 se disponía del sistema Libra (García-Tuñón, Obelleiro, Rodríguez, Pérez-Ojeda, & Sanjuan, 2010), equipo que ha sido sustituido

Capítulo 3. Modelado de la superficie equivalente radar

por el Demostrador Instrumental de Alta Resolución (DIAR) (ver Figura 3-28), que permite caracterizar la firma radar de diferentes blancos (buques, vehículos terrestres y chaff) y cuyas funciones principales son: generar y recibir señal de radiofrecuencia en la banda X, medir el eco radar del blanco, es decir su RCS, y su perfil de alta resolución con capacidad de representación de imagen radar. También permite generar y emular distintos tipos de señales en banda X y realizar el procesado de la señal. Además, el sistema es capaz de realizar el seguimiento del blanco de forma automática, recoger y grabar los datos y presentar las medidas en tiempo cuasi-real.

El nuevo radar instrumental DIAR, permite la toma de un mayor volumen de datos que su predecesor Libra, lo cual nos permitirá generar un modelo preciso de la RCS de los buques y los señuelos.



Figura 3-28. DIAR y el laboratorio móvil del Centro de Medidas Electromagnéticas (CEMEDEM) (fuente: Armada Española).

3.3.6. Reducción de la superficie equivalente radar

En los buques, aviones y todo tipo de vehículos militares es de vital importancia reducir lo más posible su superficie equivalente radar. En el caso concreto de un buque, una RCS pequeña permitirá retrasar su detección radar por parte del enemigo y mejorar la eficacia de las contramedidas activas y los señuelos. En definitiva reduce la vulnerabilidad del buque y por consiguiente aumenta su supervivencia.

El nuevo concepto de buque *stealth* o buque furtivo es un término que incluye todas aquellas tecnologías encaminadas a la reducción de la firma de infrarrojos, reducción de la forma acústica y reducción de la superficie equivalente radar.

Capítulo 3. Modelado de la superficie equivalente radar

Para reducir la RCS, existen las cuatro siguientes técnicas, de las cuales solo las dos últimas son las utilizadas hoy en día (Khan et al., 2012; Knott et al., 2004):

- Cancelación pasiva.
- Cancelación activa.
- Materiales absorbentes radar o *radar-absorbing material* (RAM).
- Control de las formas del objeto o *shaping*.

La **cancelación pasiva** se basa en intentar que la onda reflejada tenga una amplitud y fases invertidas respecto a la onda incidente para que ambas se cancelen entre sí. Presenta el problema de ser compleja, incluso para objetos pequeños y se ha descartado para su uso operativo.

En la **cancelación activa** el blanco debe radiar, en el momento exacto, una señal con una amplitud y fase que cancele la onda incidente. Esto implica que el blanco tiene que conocer el ángulo de incidencia de la señal, su intensidad, frecuencia y forma de onda. El principal inconveniente es que su funcionamiento es muy crítico, si no se realiza correctamente, el sistema es contraproducente ya que generará una señal que alertará al enemigo.

Los **materiales absorbentes** (RAM) reducen la energía reflejada mediante diferentes técnicas de absorción (Miacci & Rezende, 1988). Los materiales tradicionales se fabrican dispersando partículas electromagnéticas en un material base. Estas partículas van desde partículas metálicas a nanotubos de carbono, pasando por las ferritas. Otros materiales comercialmente disponibles son las espumas de poliuretano impregnadas con partículas de carbono, siliconas y neoprenos con carbono, pinturas con fibras de carbono, polímeros conductores, composites de fibra de vidrio y fibra de carbono.

En la actualidad, también existen materiales compuestos de pequeños circuitos que resuenan, y por tanto, absorben la energía incidente (Micromag, n.d.). En concreto la empresa española Micromag dispone de este tipo de tecnología entorno a fibras propietarias fabricadas en sus instalaciones en España que, mezcladas con pintura, producen una significativa reducción de la RCS, tal y como se refleja en la Figura 3-29, donde se observa una reducción de aproximadamente 10 dBsm en un patrullero de la Armada.




Figura 3-29. Reducción de la RCS de un buque mediante el pintado con fibras RAM de la empresa Micromag. En rojo y en azul se representan la RCS del buque antes y después del pintado (García Tuñón et al., 2014)

El **control de las formas del objeto o *shaping*** es quizás la técnica más ampliamente utilizada para reducir RCS. Se fundamenta en orientar las superficies y los bordes del objeto para desviar la energía dispersada en direcciones alejadas del radar. La aplicación de esta técnica se puede apreciar en las aeronaves y buques militares de última generación (ver Figura 3-30 y Figura 3-31).



Figura 3-30. Avión F-117 construido con tecnología *stealth* (fuente: www.lockheedmartin.com)



Figura 3-31. Destructor USS Zumwalt de la marina de los Estados Unidos construido con tecnología stealth (fuente: www.navy.mil)

En los buques, esta tecnología tiene un gran potencial y hay una serie de acciones en el diseño tales como: construir los costados del casco con un determinado ángulo hacia fuera, construir los costados de la superestructura con un ángulo hacia dentro, diseñar mástiles integrados, evitar diedros y triedros, montar equipos sobre cubierta con formas que reflejen la mínima señal posible, esconder pescantes de botes y elementos de maniobra y eliminar candeleros y otros accesorios de cubierta. Los últimos buques de la Armada ya incorporan este tipo de consideraciones en el diseño, siendo las futuras fragatas de la clase F-110 un claro ejemplo de ello (ver Figura 3-32).



Figura 3-32. Futura fragata F-110 de la Armada Española diseñada con tecnología stealth (fuente: www.navantia.es)

3.3.7. Propiedades estadísticas de la superficie equivalente radar

En todo sistema radar siempre hay un movimiento relativo entre el radar y el blanco. Imaginemos el caso de un misil de guía radar activa que se aproxima a un buque

objetivo, tanto el buque como el misil tendrán ciertos movimientos de guiñada, balance y cabezada, por lo que existirá un movimiento relativo misil-blanco, lo cual ocasionará pequeños cambios en el aspecto presentado por parte del buque al sistema radar del misil.

Un buque es un blanco complejo y por lo tanto está formado por un número elevado de dispersores. Esto implica que al ocurrir estos pequeños cambios en el aspecto del barco, ocasionan que el centro aparente de las dispersiones del blanco, que está siendo seguido por el radar del misil, fluctúe de un punto a otro. Se produce por lo tanto una fluctuación o centelleo de la RCS del buque que se conoce como efecto *glint*. Estas fluctuaciones de la RCS pueden ser rápidas o lentas en función del tamaño del blanco, su forma y del movimiento relativo respecto del radar (Maffet, 1989).

Este efecto *glint* es de suma importancia en el caso del modelado del radar de un misil antibuque, ya que ocasiona variaciones en la posición del centroide de seguimiento del misil (Cucharero, 1995; Yanushevsky, 2008). Este efecto, se puede analizar estadísticamente como un proceso estocástico, modelarlo mediante variables aleatorias y simularlo mediante funciones de probabilidad obtenidas experimentalmente.

No todos los blancos presentan fluctuaciones en la RCS. Aquellos blancos cuya RCS se modela mediante una constante independientemente del aspecto presentado al radar se denomina blancos no fluctuantes o blancos Marcum. Una esfera es típico caso de este tipo de blancos.

3.4. SEÑUELOS TIPO CHAFF. CARACTERÍSTICAS Y SUPERFICIE EQUIVALENTE RADAR

El chaff es un tipo de señuelo empleado contra misiles de guía radar, que consiste en una serie de filamentos conductores que se cortan para formar dipolos, para que resuenen a unas determinadas frecuencias. Los principales factores que determinan la RCS del grupo o la nube de dipolos, son los siguientes (Butters, 1982; Žák, Vach, & Dvořáček, 2016):

- La longitud de los dipolos.
- La cantidad de dipolos contenidos en el cartucho chaff.
- El material del que están hechos los dipolos.

Capítulo 3. Modelado de la superficie equivalente radar

En cuanto a la longitud de cada dipolo, su medida óptima está en la mitad de la longitud de onda de la señal a la que se pretende que resuene. Sin embargo, en la práctica esta longitud es ligeramente inferior, debido a que la velocidad de propagación de las ondas electromagnéticas es menor en el dipolo que en espacio libre.

La RCS máxima de un dipolo viene dada por la relación en metros al cuadrado $\sigma_{max} \approx 0,856 \lambda^2$. Sin embargo, dado que el dipolo puede tener una orientación aleatoria en 4π estereorradianes, obtenemos que la RCS media vendrá determinada por la expresión $\bar{\sigma} \approx 0,172 \lambda^2$ (Butters, 1982; Hannen, 2014; Zak, Gregor, Dvoracek, & Papez, 2018).

Además, si consideramos que cada cartucho chaff contiene N dipolos, la RCS máxima y media de los señuelos vendrán dadas por las siguientes expresiones (Hannen, 2014).

$$\sigma_{max} \approx 0,856N \lambda^2 \quad (3-21)$$

$$\bar{\sigma} \approx 0,172N \lambda^2 \quad (3-22)$$

Por lo que es deseable que un cartucho chaff tenga el mayor número de dipolos posibles para generar la mayor RCS.

Tal y como se ha expuesto anteriormente, los dipolos chaff están diseñados para resonar a una frecuencia concreta, donde logran su máxima RCS. No obstante, en la práctica se puede comprobar que la nube chaff genera RCS hasta el cuarto armónico de la frecuencia de diseño (Butters, 1982).

Por otra parte, la carga de dipolos de un chaff puede contener diferentes conjuntos de dipolos, con cortes distintos para aumentar el ancho de banda de funcionamiento del señuelo. Sin embargo, dado que en un cartucho chaff, el espacio disponible para la carga es limitado, es evidente que un aumento del ancho de banda de trabajo trae consigo una disminución de la RCS global del señuelo, ya que el número N de dipolos para cada frecuencia necesariamente disminuye. En la Figura 3-33 se puede observar la respuesta teórica, en términos de RCS, de un chaff formado por un conjunto de tres tipos de dipolos con diferentes cortes, donde se aprecian los máximos de RCS y la respuesta hasta el cuarto armónico de cada uno de los conjuntos (Butters, 1982).




Figura 3-33. Curvas teóricas de respuesta para tres conjuntos de dipolos resonantes a 6,0 (rojo); 8,0 (verde) y 10,0 (azul) GHz (Butters, 1982)

3.4.1. Materiales componentes

En las fases de diseño y fabricación de un chaff, deben tenerse en cuenta una serie de aspectos para maximizar la RCS del cartucho y por lo tanto, van a condicionar el material con que se elaboren los dipolos. Un resumen de los factores son los que figuran a continuación:

- Seleccionar el material conductor de recubrimiento con pequeña resistencia a la RF.
- Diseñar los dipolos para que se orienten al azar en la nube y presenten, tanto dispersión en polarización vertical, como en polarización horizontal.
- Disminuir el diámetro del dipolo para aumentar el número que pueden cargarse en un cartucho chaff.
- Diseñar un sistema de despliegue de manera que la nube chaff se forme lo más rápido posible y alcance la máxima RCS de diseño en el menor tiempo.
- Disminuir la probabilidad de formación de lo que se denomina nidos, que es el término utilizado para describir la situación en la que grupos de cientos de dipolos se adhieren o se enredan entre sí y no se despliegan correctamente al generar la nube, lo que ocasiona una reducción de la RCS del cartucho.

Capítulo 3. Modelado de la superficie equivalente radar

- Seleccionar un material de recubrimiento de modo que los filamentos no se doblen cuando se dispersen en el aire.

A la vista de las características deseables de un señuelo chaff, analizaremos qué ventajas e inconvenientes presentarán los materiales disponibles para su fabricación, entre lo que nos podemos encontrar básicamente los siguientes y cuyas características se han incluido en la Tabla 3-3 (Butters, 1982; Det 8 ACC TRSS. US Air Force, 2000).

- Nylon recubierto de plata
- Papel de aluminio
- Fibras de vidrio recubiertas de aluminio.

Tabla 3-3. Comparación de las propiedades físicas de los diferentes tipos de chaff (Butters, 1982)

Tipo	Sección de los filamentos (μm)	Densidad del material (kg/m^3)	Velocidad de caída (m/s)	Número de dipolos por unidad de volumen referida a nylon-plata
Fibra de vidrio-aluminio	25	2 550	0,3	10,97
Nylon-plata	90	1 300	0,6	1
Lámina de aluminio 2×1	50×25	2 700	0,40 – 0,45	4,31
Lámina de aluminio 4×1	100×25	2 700	0,50 – 0,55	2,15
Lámina de aluminio 2×1/2 V – doblado	200×25	2 700	0,50 – 0,55	1,84

Uno de los materiales utilizado para confeccionar dipolos, es el nylon recubierto con plata. Este tipo de material presenta varios inconvenientes como su elevado costo. Además, su diámetro no puede ser más pequeño que $90 \mu\text{m}$, lo que implica que el número de dipolos para un determinado cartucho chaff sea menor que para otros materiales, y por lo tanto ocasiona una RCS menor. También tienden a caer de forma horizontal, por lo que la mayor reflectividad se presenta en polarización horizontal y muy poca en polarización vertical. Por contrapartida, es el material que presenta menos tendencia a formar nidos y tiene una baja densidad y buena robustez (Butters, 1982).

Capítulo 3. Modelado de la superficie equivalente radar

Las láminas de aluminio es otro material utilizado, cuyo proceso de fabricación consiste en el corte de una hoja de aluminio, para obtener los filamentos o dipolos. El grosor de los filamentos viene dado por el grosor de la propia lámina, que suelen ser de 12,7 μm o 25 μm , mientras que la configuración de la máquina de corte determina el ancho del dipolo generalmente de 50 μm , 100 μm o 200 μm . En general, podemos encontrarnos con los siguientes tipos de filamentos de aluminio:

- Grosor: 25 μm , ancho: 50 μm (denominación: hoja de aluminio 2×1).
- Grosor: 25 μm , ancho: 100 μm (denominación: hoja de aluminio 4×1).
- Grosor: 12,7 μm , ancho: 200 μm (denominación: hoja de aluminio $8 \times 1/2$ V-doblado).

El proceso de corte hace que se coloquen series regulares de giros trenzados en la longitud del filamento. Esto le confiere distintos movimientos de vuelo de los dipolos y por lo tanto distintas polarizaciones. Por otra parte, su velocidad de caída es más baja que la velocidad del nylon recubierto de plata, por lo que su permanencia en el aire es mayor. Sin embargo, también hay que tener en cuenta que debido a esta baja velocidad, necesita más tiempo para formar una nube efectiva (Butters, 1982).

El material más utilizado en aplicaciones navales es la fibra de vidrio recubierta de aluminio. Los dipolos de este material son de sección cilíndrica con un diámetro pequeño de aproximadamente 25 μm , lo que maximiza la cantidad de dipolos que contiene el cartucho chaff. Debido a la sección cilíndrica, su vuelo es básicamente horizontal, y por lo tanto la polarización es fundamentalmente horizontal, aunque debido a imperfecciones en su superficie presenta un grado de reflexión mayor en polarización vertical que los otros materiales. Su baja velocidad de caída, le permite tener una mayor permanencia de la nube. Además, en comparación con otros materiales presenta un coste inferior (Butters, 1982; Pouliguen, 1993).

También se pueden emplear otros materiales como filamentos de poliéster revestido de cobre, filamentos de vidrio revestidos de zinc, carbono recubierto de metal o fibras de grafito, carburo de silicio recubierto o boro. Sin embargo, no se usan generalmente debido a su costo y problemas de fabricación (Butters, 1982).

3.4.2. Lanzamiento, despliegue, variación temporal de la RCS y persistencia

En el mercado existen diferentes tipos de cartuchos chaff navales, conteniendo cada artefacto entre 10 kg y 15 kg de dipolos. En la Figura 3-34, se puede observar el corte de un típico cartucho, en concreto se trata del modelo Mk36 tipo 1 de la empresa Chemring, donde se puede apreciar la distribución de los paquetes que contienen a los dipolos.



Figura 3-34. Cartucho Mk36 tipo 1 (Fuente: www.chemring.co.uk)

Quizás los factores de diseño más importantes del cartucho son el tiempo necesario para desplegar el chaff con el máximo valor de RCS y la persistencia de la nube. Veremos estos dos parámetros sobre dos tipos de chaff: de hojas de aluminio 2×1 y de fibra de vidrio recubierta de aluminio

En la Figura 3-35 se puede observar la respuesta en función del tiempo de la RCS ocasionada por el despliegue de chaff de hojas de aluminio (Figura 3-35a) y de fibra de vidrio recubierta de aluminio (Figura 3-35b). La RCS que se presenta en la figura, es relativa a la respuesta máxima de cada carga útil medida en polarización horizontal. Ambas nubes se despliegan con el mismo lanzador naval, utilizando el mismo volumen de chaff, empaquetado a la densidad de embalaje normal para cada material y la frecuencia de medición es la misma para ambos tipos.

En las dos figuras a) y b) se muestran los tiempos para lograr la RCS máxima, que para el caso de las hojas de aluminio es de 40 s y para la fibra de vidrio aluminizada es de 100 s. En todo caso, los sistemas navales están diseñados para lograr la RCS mínima requerida dentro de aproximadamente 10 s después del disparo (Butters, 1982) .

En cuanto a la persistencia de la nube, el material de aluminio tiene una persistencia más pequeña debido a la mayor tasa de caída, mientras que las nubes de dipolos de fibra de vidrio aluminizado son muy persistentes, pudiendo ser de horas, dependiendo

de las condiciones climáticas locales, con poco viento y en presencia de corrientes térmicas.

Otra diferencia significativa entre ambas figuras, es la desigualdad de respuesta de polarización horizontal y vertical, mayor en el caso de dipolos de fibra de vidrio aluminizado.




Figura 3-35. Variación de la RCS con el tiempo para a) chaff de hojas de aluminio 2x1; b) chaff de fibra de vidrio recubierto de aluminio. (+ polarización horizontal; × polarización vertical) (Butters, 1982)

3.5. MODELADO DE LA SUPERFICIE EQUIVALENTE RADAR EN BLANCOS COMPLEJOS

Tal y como se ha expuesto en el punto 3.3.7, la superficie equivalente radar de un blanco, debido a su fluctuación como consecuencia del efecto *glint*, puede considerarse como una variable aleatoria y por lo tanto modelarse mediante una función de probabilidad. En relación a este aspecto hay una amplia bibliografía, que ha pasado a formar parte de la teoría radar y cualquier publicación técnica sobre los fundamentos radar o los principios de la superficie equivalente radar tratan ampliamente este tema.

Los primeros trabajos relativos a esta cuestión, fueron realizados por Minoru Nakagami a principios del año 1940 que estudió, desde el punto de vista estadístico, las fluctuaciones en la intensidad de las ondas electromagnéticas de alta frecuencia (Nakagami, 1960). Sin embargo, no fue hasta el año 1954 en que Peter Swerling comenzó a estudiar la fluctuación de la superficie equivalente radar, dando lugar a las distribuciones de probabilidad Swerling I, II, III y IV, basadas en distribuciones chi-cuadrado (χ^2) y que dio lugar a una extensa teoría sobre este asunto que todavía es de aplicación en el análisis de los sistemas radar (Swerling, 1960, 1965).

Capítulo 3. Modelado de la superficie equivalente radar

Contemporáneamente, Walter Weinstock investigó modelos de RCS para misiles y satélites, concluyendo que aquellos que estaban basados en la distribución chi-cuadrado daban una pobre representación de las colas (Weinstock, 1964).

A estos trabajos, siguieron otros autores (Huynen, McNolty, & Hansen, 1975; McNolty & E., 1974) que continuaron la última línea de Swerling. Posteriormente, Perter Swerling retomó los trabajos de 1965 e introdujo la distribución lognormal como una nueva forma de modelado de la RCS en buques (Swerling, 1997). Recientemente, otros estudios introducen diferentes distribuciones de probabilidad como la Weibull, lognormal o gamma para modelar el efecto de centelleo de la RCS (De Maio, Farina, & Foglia, 2004; Dowdy, 1991; Sandhu & Saylor, 1985; Wang, Shao, & Hu, 2015).

A la vista de la cantidad de bibliografía existente y de la importancia de disponer de un conocimiento exacto de la RCS de los buques de guerra, en este trabajo se pretende crear una metodología para que a partir de los datos de medida experimentales, nos permita modelar de la forma más precisa posible la superficie equivalente radar de un buque, y poder emplear dicho modelo en simuladores numéricos de escenarios navales.

Dado que la RCS se puede modelar como una variable aleatoria, la metodología a emplear seguirá las siguientes fases, que aplicaremos a un caso real:

- Obtención de datos y tratamiento inicial.
- Cálculo de medidas estadísticas y análisis gráfico.
- Obtención de la función de densidad que mejor se ajuste a los datos obtenidos.

En este punto, para comprender la metodología que se ha desarrollado, empezaremos por presentar los modelos de probabilidad más generales, de los que se derivarán los modelos de probabilidad específicos que emplearemos para representar la RCS en la simulación. Seguiremos con la descripción de los métodos de bondad del ajuste que utilizaremos y las modificaciones introducidas para analizar un volumen grande de datos.

3.5.1. Distribuciones de probabilidad relacionadas con el modelado de la RCS

Los modelos de superficie equivalente radar, derivan básicamente de las cinco distribuciones de probabilidad siguientes:

- Distribución exponencial.
- Distribución gamma.
- Distribución chi-cuadrado o χ^2 .
- Distribución de Rayleigh.
- Distribución normal.

En este estudio, para tratar de modelar la RCS, trabajaremos a priori con las siguientes distribuciones de probabilidad, que describiremos a continuación:

- Familia de distribuciones de Swerling.
- Distribución de Nakagami o distribución-m.
- Distribución lognormal.
- Distribución Weibull.

Primera generación. Familia de distribuciones de Swerling

Los modelos de Swerling se utilizan para describir las propiedades estadísticas de la superficie equivalente radar de objetos complejos y son de particular importancia en la tecnología radar. De acuerdo con estos modelos, la RCS de un objeto se basa en la función de probabilidad chi-cuadrado con una serie de grados de libertad específicos. Hay cinco modelos diferentes de Swerling (Swerling, 1960):

Swerling I

Este caso describe un objeto, cuya magnitud de la señal reflejada es relativamente constante durante el tiempo de permanencia del lóbulo de radiación de la antena del radar sobre el blanco. La superficie equivalente radar es constante pulso a pulso, pero varía independientemente de escaneo a escaneo, se trata por lo tanto de modelar una fluctuación lenta de la RCS.

Capítulo 3. Modelado de la superficie equivalente radar

Tiene la forma de una función de densidad de probabilidad chi-cuadrado con dos grados de libertad y viene dada por la siguiente ecuación, donde μ es la media o esperanza matemática de la variable aleatoria.

$$f(x) = \frac{1}{\mu} e^{\left(\frac{-x}{\mu}\right)} \quad (3-23)$$

Se puede apreciar que la función Swerling I es la función exponencial $Exp\left(\frac{1}{\mu}\right)$, y un caso particular de la función de densidad gamma cuando $\alpha = 1$.

Swerling II

El objetivo de la distribución de Swerling II, es similar a Swerling I, usando la misma ecuación, excepto que los valores de RCS cambian más rápido y varían adicionalmente de pulso a pulso. Ambas funciones, consideran al blanco como un número grande reflectores isotrópicos iguales distribuidos en una superficie. En la Figura 3-36 podemos observar de forma gráfica esta abstracción del modelo Swerling.




Figura 3-36. Swerling I y II. Buque visto como la suma de un determinado número de reflectores isotrópicos.

Los casos I y II de Swerling se aplican a un objeto que se compone de muchos dispersores independientes de áreas aproximadamente iguales. Sin embargo, en el caso II de Swerling no hay una antena del típico radar rotatorio, sino que está enfocada a un radar de seguimiento, lo que corresponde a nuestro caso, para un misil en la fase de ataque, donde su radar *seeker* está centrado sobre el blanco.

Swerling III

Modela la fluctuación de la RCS en los diferentes barridos de un radar, es decir una fluctuación lenta de la RCS. La distribución tiene la forma de una distribución chi-cuadrado pero con cuatro grados de libertad y corresponde a una distribución gamma para los parámetros $\alpha = 2$ y $\beta = \mu/2$. Por lo tanto, sigue la siguiente función de densidad de probabilidad:

$$f(x) = \frac{4x}{\mu^2} e^{\left(\frac{-2x}{\mu}\right)} \quad (3-24)$$

donde μ corresponde a la media o esperanza matemática de la variable aleatoria.

En la Figura 3-37 se puede apreciar la forma de esta función de probabilidad, para diferentes valores del parámetro μ .




Figura 3-37. Forma de la distribución Swerling III para diferentes valores del parámetro μ

Swerling IV

Los casos III y IV modelan un objeto con una gran superficie de dispersión con varias otras pequeñas superficies dispersoras. Se considera, por lo tanto, un reflector isotrópico dominante que está superpuesto por una pluralidad de pequeños reflectores. En la Figura 3-38, podemos observar este concepto aplicado a un buque.




Figura 3-38. Swerling III y IV. Buque visto como un reflector isotrópico dominante y una serie de reflectores isotrópicos pequeños

Las distribuciones IV y III de Swerling tienen la misma función de densidad. Aunque la Swerling IV corresponde a la modelización de la RCS de pulso a pulso, es decir el caso correspondiente a un radar de seguimiento. Modela por lo tanto la RCS percibida por un misil que ya ha localizado al blanco y está centrado en su objetivo, ya que en esta situación la potencia recibida por el misil variará pulso a pulso.

Swerling V

El caso V es un valor de referencia relativo a una RCS constante, también conocida como Swerling 0 o de Marcun. Describe una idealización del blanco sin fluctuación, se trata por lo tanto de un modelo determinista.

Distribución de Nakagami o Nakagami-m

La distribución de Nakagami o la distribución-m es un modelo de probabilidad relacionado con la distribución gamma. Tiene dos parámetros: el parámetro de forma $m > 1/2$ y el parámetro de apuntamiento $\Omega > 0$, siendo la función de densidad para $x > 0$ la siguiente:

$$f(x) = \frac{2m^m}{\Gamma(m)\Omega^m} x^{2m-1} e\left(-\frac{m}{\Omega}x^2\right) \quad (3-25)$$

Mediante el método de máxima verosimilitud, se obtienen los parámetros de la función:

$$m = \frac{E^2[X^2]}{V(X^2)} \quad (3-26)$$

$$\Omega = E[X^2] \quad (3-27)$$

La forma, para diferentes valores de los parámetros, es la que se muestra en la Figura 3-39.




Figura 3-39. Forma de la distribución Nakagami para diferentes valores de los parámetros μ y ω

La distribución de Nakagami es un caso particular de la función gamma $Y \sim G(\alpha, \beta)$ cuando $\alpha = m$, $\beta = \Omega/m$ y se realiza el cambio de variable $Y = X^2$.

Puede modelar cambios rápidos en la superficie equivalente radar para frecuencias entre 200 y 4000MHz y largas distancias (Mcnoilty & Hansen, 1974) y aunque el radar

de un misil antibuque funciona en un margen de frecuencias más elevado, generalmente en las bandas I y J militar, estudiaremos también en este trabajo, la bondad del ajuste de la RCS a esta distribución, para determinar su comportamiento.

Distribución log-normal o logonormal

La distribución log-normal, normal logarítmica o Ley de Galton-Mac Aliester es una distribución de probabilidad de una variable aleatoria continua cuyo logaritmo está normalmente distribuido.

Una variable aleatoria se distribuye de forma log-normal si es la resultante de un número elevado de causas independientes, con efectos positivos cada una de ellas de poca importancia con respecto a las demás e independientes, que se componen de manera multiplicativa de manera que $Y = X_1 X_2 \dots X_n$.

En este caso, el logaritmo de Y seguirá una distribución normal. Es decir, si X es una variable aleatoria con una distribución normal, entonces e^x tiene una distribución log-normal. La base de una función logarítmica no es importante, ya que $\log_a X$ está distribuida normalmente si y solo si $\log_b X$ está distribuida normalmente, solo se diferencian en un factor constante. La función de densidad es:

$$f(x) = \frac{1}{x\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{\ln x - \mu}{\sigma}\right)^2} \quad (3-28)$$

donde σ y μ son la desviación típica y la media del logaritmo de la variable.

Las medidas características más importantes son:

$$E[X] = e^{\mu + \sigma^2/2} \quad (3-29)$$

$$V(X) = (e^{\sigma^2} - 1)e^{2\mu + \sigma^2} \quad (3-30)$$

A continuación, en la Figura 3-40, se muestran los gráficos de la función de distribución y de la función de densidad para diferentes valores de la media y de la desviación típica.




Figura 3-40. Forma de la distribución log-normal para diferentes valores de los parámetros μ y σ

Distribución de Weibull.

La distribución de Weibull corresponde a una variable aleatoria continua cuya función de densidad es la siguiente (Weibull, 1951):

$$f(x) = \begin{cases} \frac{\beta}{\alpha} \left(\frac{x}{\alpha}\right)^{\beta-1} e^{-\left(\frac{x}{\alpha}\right)^\beta} & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases} \quad (3-31)$$

Tiene dos parámetros: el parámetro de escala $\alpha > 0$ y el parámetro de forma $\beta > 0$. Se puede observar que para $\beta = 1$ la distribución es una exponencial y por lo tanto una Swerling I/II. De la misma manera, si $\beta = 2$ obtenemos la distribución de Rayleigh.

Las medidas características más importantes de la distribución de Weibull son:

$$\mu = \alpha \Gamma\left(1 + \frac{1}{\beta}\right) \quad (3-32)$$

$$\sigma^2 = V(X) = \sigma^2 \left[\Gamma\left(1 + \frac{2}{\beta}\right) - \Gamma^2\left(1 + \frac{1}{\beta}\right) \right] \quad (3-33)$$

donde $\Gamma(\cdot)$ es la función gamma de Euler.

En la Figura 3-41, se puede apreciar la forma de la distribución para diferentes valores de los parámetros de escala y de forma.




Figura 3-41. Forma de la distribución de Weibull para diferentes valores de los parámetros α y β

A la vista de lo expuesto en los puntos anteriores, analizaremos como posibles modelos de RCS las distribuciones de probabilidad Swerling II, Swerling IV, Nakagami, log-normal y Weibull. En la Figura 3-42, se puede observar a modo de resumen de los apartados anteriores, las distribuciones objeto de este estudio, marcadas en gris, y su relación con otras distribuciones de probabilidad básicas.

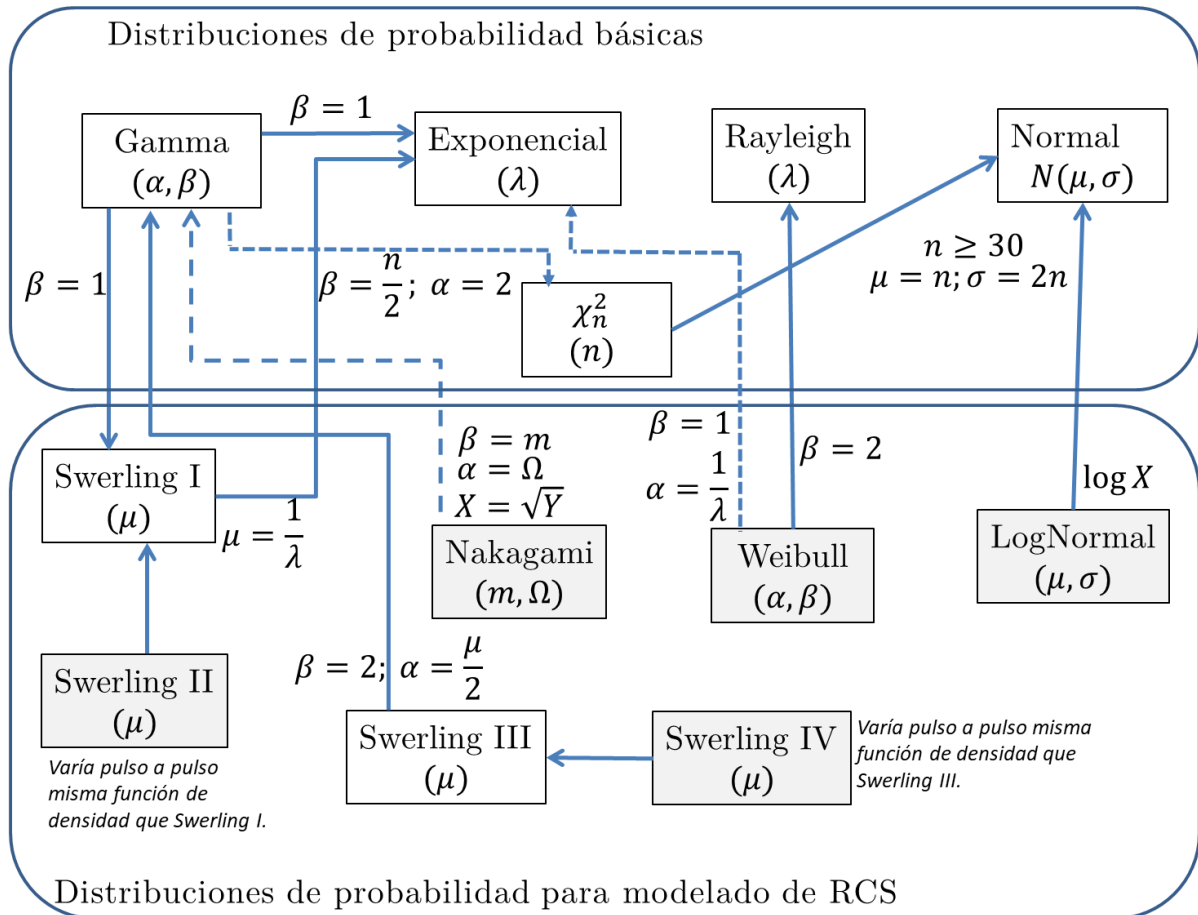


Figura 3-42. Relación entre distribuciones de probabilidad

3.5.2. Contrastes de Bondad del ajuste

A partir de los datos reales de las mediciones de la superficie equivalente radar, será necesario determinar la distribución de probabilidad o el modelo de probabilidad de donde provienen, es decir, contrastar si los datos tomados se ajustan a alguno de los modelos de RCS previamente establecidos.

Este tipo de problemas son los que se abordan mediante los contrastes de bondad del ajuste, cuya hipótesis nula (H_0) e hipótesis alternativa (H_1) son las siguientes:

H_0 : Los datos siguen una distribución especificada

H_1 : Los datos no siguen una distribución especificada

Para nuestro estudio utilizaremos el contraste de Kolmogorov-Smirnov y el contraste de Anderson-Darling. Se ha descartado el test de la χ^2 ya que los dos anteriores son pruebas más eficientes para el caso de variables continuas (Stephens, 1974).

Test de Kolmogorov-Smirnov

El test de Kolmogorov-Smirnov (KS) está especialmente diseñado para contrastar la bondad del ajuste a distribuciones continuas, es un test no paramétrico y de distribución libre.

Para entender el mecanismo de este contraste, es necesario utilizar la función de distribución empírica. Así, dada una muestra $X_1, X_2, X_3, \dots, X_n$ de tamaño n , procedente de una población F . Su función de distribución empírica (F_n), es aquella que asigna a cada número real (x) la frecuencia relativa de observaciones menores o iguales que x . Matemáticamente tenemos que (Cao et al., 2001; Vélez & García, 1993):

$$F_n(x) = \frac{\text{Número de observaciones } X_i < x}{n} = \frac{1}{n} \sum_{i=1}^n 1_{(-\infty, x]}(X_i) \quad (3-34)$$

La función de distribución empírica no es más que una función escalonada no decreciente, construida a partir de la muestra, que vale cero en todo punto a la izquierda de todos los datos muestrales y que en cada dato da un salto de magnitud igual a la fracción de datos iguales a ese valor. Cuando no hay repeticiones se trata de saltos de amplitud $1/n$.

El contraste de Kolmogorov-Smirnov está basado en la distribución del estadístico (D_n) que representa la máxima discrepancia en vertical entre la función de distribución empírica y teórica (Cao et al., 2001; Vélez & García, 1993).

$$D_n = \sup_{x \in \mathbb{R}} |F_n(x) - F(x)| \quad (3-35)$$

Siempre que la distribución de partida sea correcta el estadístico D_n es de distribución libre, es decir su distribución en el muestreo no depende de la población F . La distribución de D_n se conoce como distribución K de Kolmogorov, está tabulado y presente en los paquetes estadísticos y MATLAB. La hipótesis relativa a la forma de la distribución especificada, se rechaza si el estadístico de prueba D_n , es mayor que el valor crítico obtenido en la tabla correspondiente.

Test Anderson-Darling

La prueba de Anderson-Darling (T. W. Anderson & Darling, 1952, 1954; D'Agostino & Stephens, 1986) se usa para probar si una muestra de datos proviene de una población con una distribución específica. Es una modificación del test de Kolmogorov-Smirnov (KS), aunque le da más peso a las colas que dicha prueba, es decir, tienen más peso las diferencias en los valores extremos de la distribución que los valores ubicados en el rango medio. Por ello, se recomienda su aplicación para distribuciones con colas pronunciadas.

El test de Anderson-Darling, se considera una mejora al test de Kolmogorov-Smirnov y está disponible en algunos paquetes estadísticos y en MATLAB.

Para construir el test, partimos de una muestra $X_1, X_2, X_3, \dots, X_n$, ordenada y de tamaño n . A partir de ella, el estadístico A^2 de la prueba de Anderson-Darling se define como:

$$A^2 = -n - S \quad (3-36)$$

donde

$$S = \sum_{i=1}^n \frac{(2i-1)}{n} [\ln F(X_i) + \ln(1 - F(X_{n+1-i}))] \quad (3-37)$$

siendo F la función de distribución acumulada de la distribución especificada.

3.5.3. Contraste de Wilcoxon de rangos con signos

Esta prueba estadística se utiliza para realizar contrastes de hipótesis sobre la mediana (M_e) del tipo:

$$H_0: M_e \geq m_o$$

$$H_1: M_e < m_o$$

donde m_o es el valor de la mediana que quiere contrastar.

Este test se fundamenta en el estadístico T de Wilcoxon (Sheldon, 2004; Vélez & García, 1993; Wilcoxon, 1945). Para su cálculo, se parte de una muestra aleatoria simple $X_1, X_2, X_3, \dots, X_n$ de tamaño n y se siguen los siguientes pasos:

- Se calculan las diferencias $d_i = X_i - m_o \forall i = 1, 2, \dots, n$.
- Se ordenan de menor a mayor los valores absolutos de las diferencias $|d_1|, |d_2|, \dots |d_n|$.
- Se establece, lo que se denomina, el rango r correspondiente a cada diferencia, de forma que $r(|d_i|)$ es el puesto que ocupa $|d_i|$ en la ordenación del paso anterior.

En el caso de haber empate, se asigna un rango promedio a todas las diferencias empatadas. Así, si la menor diferencia observada aparece en tres ocasiones, a las que corresponderían rangos 1, 2 y 3. Su promedio es 2, que asignamos a cada una de las tres observaciones.

- El estadístico T es la suma de los rangos de las observaciones mayores que m_o y se define como:

$$T = \sum_{i=1}^n I_i r(|d_i|) \tag{3-38}$$

$$I_i = \begin{cases} 0 & \text{si } d_i < 0 \\ 1 & \text{si } d_i > 0 \end{cases}$$

Para determinar el resultado del contraste, existe una tabla de valores del estadístico T que se puede aproximar, para tamaños muestrales grandes, a una distribución normal estándar (Cao et al., 2001; Hollander & Wolfe, 1999).

El contraste de Wilcoxon también está disponible en algunos paquetes estadísticos y en MATLAB.

3.5.4. Aplicación de los contrastes de bondad del ajuste para muestras grandes

Tal y como se ha expuesto anteriormente, para determinar qué modelo de probabilidad se ajusta mejor a la RCS de un buque, utilizaremos pruebas no paramétricas de bondad del ajuste sobre los datos proporcionados por el DIAR. Por otra parte, hay que reseñar que el volumen de datos que proporciona este equipo es elevado, por lo que se han tenido que aplicar estos contrastes para tamaños muestrales grandes, en ocasiones en conjuntos de más de 1000 datos.

Capítulo 3. Modelado de la superficie equivalente radar

Los intentos de utilizar los clásicos test no paramétricos (Kolmogorov-Smirnov y Anderson-Darling) para tamaños muestrales grandes, como en el caso que nos ocupa, pueden producir fallos por sobreajuste, es decir, tender a rechazar la hipótesis nula incluso cuando esta es cierta. Esto no implica que las pruebas convencionales no sean de aplicación a este tipo de situaciones, pero es necesario adaptarlas a este tipo de problemas (Kunte & Gore, 1992; Lin, Lucas, & Shmueli, 2013).

Así, para abordar este problema, utilizaremos el algoritmo propuesto por A. Semnova y D. Khalin, para poder aplicar los test de bondad del ajuste a muestras grandes. Los autores abordan esta problemática mediante técnicas de simulación de Montecarlo y establecen un procedimiento para estos casos (Semenova & Khalin, 2018).

Básicamente, el algoritmo consiste en dividir la muestra inicial de tamaño grande en submuestras, aplicarle las pruebas clásicas de bondad del ajuste a cada submuestra por separado y a continuación decidir si existen evidencias para rechazar o no la hipótesis nula del modelo. El proceso que se ha seguido en este trabajo es el siguiente:

- a) Dividir la muestra grande en submuestras cuyo tamaño muestral se tomará teniendo en cuenta las recomendaciones del trabajo de A. Semnova y D. Khalin y que están contenidas en la Tabla 3-4. Hay que reseñar que el número de submuestras no afecta significativamente a los resultados del test.

Tabla 3-4. Intervalos de los tamaños de las muestras en caso de un contraste de hipótesis compuesto (Semenova & Khalin, 2018)

Prueba de bondad del ajuste	Kolmogorov-Smirnov (KS)	Anderson-Darling (AD)
Tamaño mínimo	250	750
Tamaño máximo	550	2500

- b) Calcular los p valores para cada una de las submuestras.
- c) Calcular la media, mediana y primer y tercer cuartil de los p -valores de las submuestras, lo que nos permitirá realizar un análisis descriptivo inicial.
- d) A partir de los resultados del paso anterior, decidir si existen evidencias estadísticas para rechazar o no la hipótesis nula de los test de bondad del ajuste. En

este punto la metodología de A. Semnova y D. Khalin recomienda tomar la decisión en función del valor del primer cuartil de los p valores, comparándolo con el nivel de significación deseado.

En nuestro caso, introduciremos una variante en la toma de la decisión. Aplicaremos un procedimiento más restrictivo, utilizando el contraste no paramétrico de los rangos con signo de Wilcoxon, en el que tratemos de contrastar si existen o no evidencias estadísticas para rechazar la hipótesis nula de que la mediana de los p-valores obtenidos es igual o menor de 0,05, es decir asumiremos en todo momento un nivel de confianza del 95%.

3.6. METODOLOGÍA PARA EL MODELADO DE LA RCS DE UN BUQUE. APLICACIÓN A UN CASO REAL

En los puntos anteriores de este capítulo hemos expuesto los conceptos generales de la superficie equivalente radar, la forma de medirla en el ámbito de la Armada, su carácter estocástico, las diferentes funciones de densidad para su modelado y algunos conceptos estadísticos necesarios para abordar este trabajo.

En este apartado, describiremos la secuencia de pasos para obtener un modelo de probabilidad de la superficie equivalente radar de un buque, a partir de los datos experimentales obtenidos por el radar instrumental DIAR. Además, implementaremos esta metodología mediante scripts de MATLAB, a un caso real utilizando las mediciones de un buque, que denominaremos ALFA por cuestiones de seguridad de la información, obtenidas en el periodo de pruebas del DIAR.

3.6.1. Datos obtenidos por el DIAR

Para obtener los datos de la RCS de un buque en todos sus aspectos mediante el DIAR, el barco debe realizar una evolución completa de 360° en aproximadamente 10 minutos. En la Figura 3-43 se presenta un croquis de la evolución del buque en la caracterización de la RCS, así como dos posiciones ejemplo (Posición A y Posición B) relativas a las mediciones para los aspectos de 120° y 0° respectivamente.

El DIAR realiza las mediciones por trazas, correspondiendo cada traza a las medidas en un aspecto o marcación del buque en diferentes frecuencias.

Capítulo 3. Modelado de la superficie equivalente radar

En el caso real del buque ALFA, sobre el que aplicaremos la metodología descrita en este punto, disponemos de 99 927 trazas con 61 puntos de frecuencias diferentes por traza. Por lo tanto, tendremos datos de RCS de 61 frecuencias distintas, para una polarización dada, cada aproximadamente $360^\circ/99927 = 0,003^\circ$ de aspecto o marcación.

Las 61 frecuencias se agrupan en un ancho de banda de 200 MHz, lo que supone un salto de 3,27 MHz entre frecuencias.




Figura 3-43. Croquis de la evolución de un buque para caracterización de la RCS con DIAR

3.6.2. Preprocesado de los datos y análisis descriptivo y gráfico.

La metodología para modelar la RCS de un buque comienza con un preprocesado de los datos y un análisis descriptivo y gráfico. Esta parte del proceso se llevará siguiendo los pasos que se indican en la Figura 3-44.

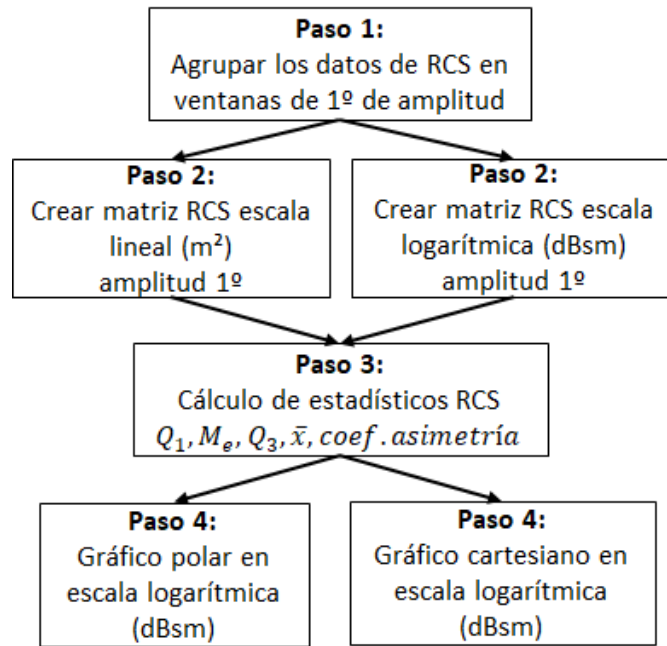


Figura 3-44. Secuencia de pasos en el preprocesado de los datos

Paso#1. Agrupar los datos de los diferentes aspectos en ventanas de 1º de amplitud

Tal y como se expuso en el punto 3.3.7, en todo sistema radar siempre hay un movimiento relativo entre el radar y el buque objetivo. Esto implica que al ocurrir estos pequeños cambios en el aspecto del barco, ocasionan que el centro aparente de las dispersiones del blanco, que está siendo seguido por el radar, fluctúe de un punto a otro y produce un centelleo en la RCS del buque que se conoce como efecto *glint*.

Para modelar este efecto, se ha utilizado la capacidad del DIAR para obtener medidas de RCS cada aproximadamente 0,003º. Así, para cada frecuencia, se han agrupado las medidas en ventanas de 1º de amplitud, lo que nos permite disponer por cada grado de un tamaño muestral suficiente para aplicar las técnicas estadísticas correspondientes y modelar este efecto.

En la Tabla 3-5, se pueden apreciar tres ventanas para 0º, 180º y 359º de aspecto y los tamaños de la muestra obtenidos para cada una de las 61 frecuencias para el buque ALFA del estudio.

Tabla 3-5. Algunos intervalos para diferentes aspectos con su tamaño muestral.

Aspecto del buque (marcación)	Intervalo de amplitud de 1°	Tamaño de la muestra (para cada una de las 61 frecuencias)
0°	(359,5°-000,5°]	193
...
180	(179,5°-181,5°]	886
...
359°	(358,5°-359,5°]	653

A efectos de determinar la amplitud de ventana para agrupar los datos de RCS, se deben tener en cuenta las variaciones naturales en el rumbo, balance y cabezada del buque y del misil en vuelo. Sin embargo, no hay datos exactos sobre estos parámetros, ya que dependerá de multitud de factores: tipo de buque, tipo de misil, estado de la mar, viento, adiestramiento del timonel, huelgos en el servomecanismo del timón o sistemas del gobierno del misil, ruido en el sistema de guía del misil, etc.

En un barco el error de navegación para un timonel inexperto y en malas condiciones meteorológica podemos cifrarlo de forma gruesa en $\pm 2^\circ$ (amplitud 4°) (Moreu & Martínez, 1987), sin embargo, no existen datos para otras situaciones, ni reglas que determine de forma precisa el error de navegación.

Por todo lo anterior, se han tomado ventanas de 1° de amplitud ($\pm 0.5^\circ$), de forma que su tamaño sea suficientemente pequeño para que sea menor que la suma de la totalidad de los errores de binomio buque/misil.

Paso#2. Crear matrices de datos en escala lineal y escala logarítmica

Tal y como se expuso en el punto 3.3.3, las medidas de RCS se puede expresar en escala lineal (m^2) o logarítmica (dBsm), por lo que realizaremos el análisis estadístico previo sobre ambas y el modelado en la escala lineal.

Para nuestro caso de aplicación, crearemos dos matrices, una para los datos en escala lineal y otra para los datos en escala logarítmica, ambas de idénticas dimensiones (360 marcaciones \times 61 frecuencias), que contienen en cada celda la muestra de datos obtenida de su correspondiente ventana de 1° de amplitud. Los tamaños muestrales obtenidos son variables en función del aspecto oscilando entre 64 y 1166 datos.

Capítulo 3. Modelado de la superficie equivalente radar

En la Tabla 3-6 se aprecia la composición de estas matrices de muestras, con el detalle de los tamaños muestrales para los aspectos 0° , 180° y 359° .

Tabla 3-6. Matriz de muestras para diferentes aspectos y frecuencias.

Marcación	Frecuencia 1	...	Frecuencia 61
0°	1×193	...	1×193
...
180°	1×886	...	1×886
...
359°	1×653	...	1×653

Paso#3. Calcular diferentes medidas estadísticas descriptivas

Para cada escala, aspecto y frecuencia se calculan la media, mediana, primer cuartil, tercer cuartil y coeficiente de asimetría.

Del análisis gráfico de los datos del buque ALFA, se observa que los histogramas de los datos de la RCS, en todos los aspectos y frecuencias, tienen una forma similar. En la Figura 3-45 se ha incluido el histograma para una marcación y frecuencia, junto con las formas de las distintas distribuciones teóricas de probabilidad empleadas en este estudio. Podemos observar la clásica fuerte asimetría positiva en los datos, que se ha encontrado en todas las marcaciones y frecuencias.

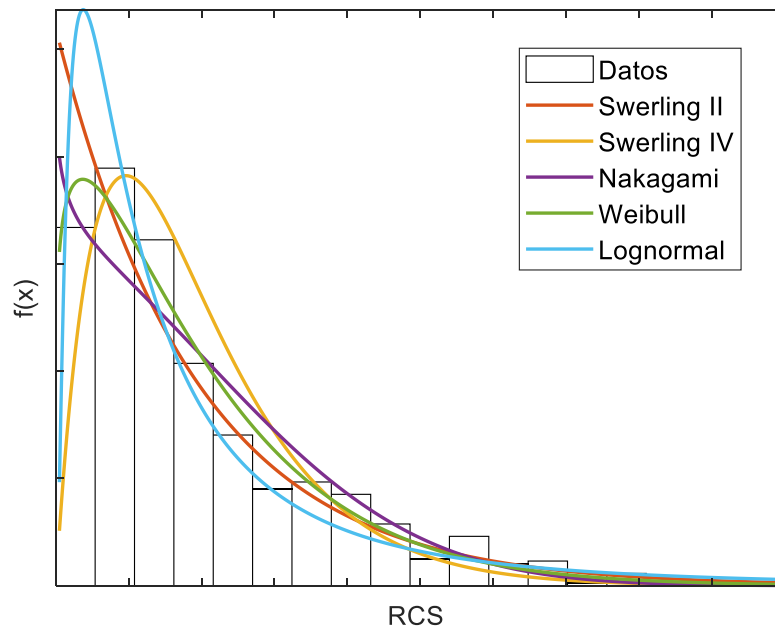


Figura 3-45. Histograma para una marcación y frecuencia del buque ALFA.

Paso#4. Construir un gráfico polar y un gráfico cartesiano de la RCS

En este paso se construyen los clásicos gráficos polar y cartesiano de la RCS, que junto con los estadísticos anteriores, nos indicarán la forma de la RCS en los 360° grados de marcación. Aplicando este paso a los datos reales de una frecuencia medida del buque ALFA, obtenemos las gráficas de la Figura 3-46 y la Figura 3-47, donde se han representado los valores de la media, mediana, primer cuartil y tercer cuartil y en las que podemos observar la forma clásica de la RCS de un buque, con puntos calientes en los traveses del buque (marcaciones 90° y 270°) y por la popa (marcación 180°)¹⁰.

¹⁰ Se omiten los valores de RCS en la escala por seguridad de la información.




Figura 3-46. Gráfico polar de la RCS del buque ALFA para una frecuencia




Figura 3-47. Gráfico cartesiano de la RCS del buque ALFA para una frecuencia

3.6.3. Análisis inferencial. Estimación del modelo de probabilidad óptimo de la RCS

Los siguientes pasos están encaminados a la aplicación de técnicas de estadística inferencial para determinar, para cada grado de aspecto y para cada frecuencia, el modelo o función de densidad que se ajuste a los datos muestrales.

Tal y como se expuso en el punto 3.5.1, se han tenido en cuenta como posibles modelos de RCS, las distribuciones de probabilidad Swerling II, Swerling IV, Nakagami, lognormal y Weibull, de entre las cuales se seleccionará el modelo de probabilidad óptimo.

Los pasos de esta fase de la metodología están resumidos en la Figura 3-48.

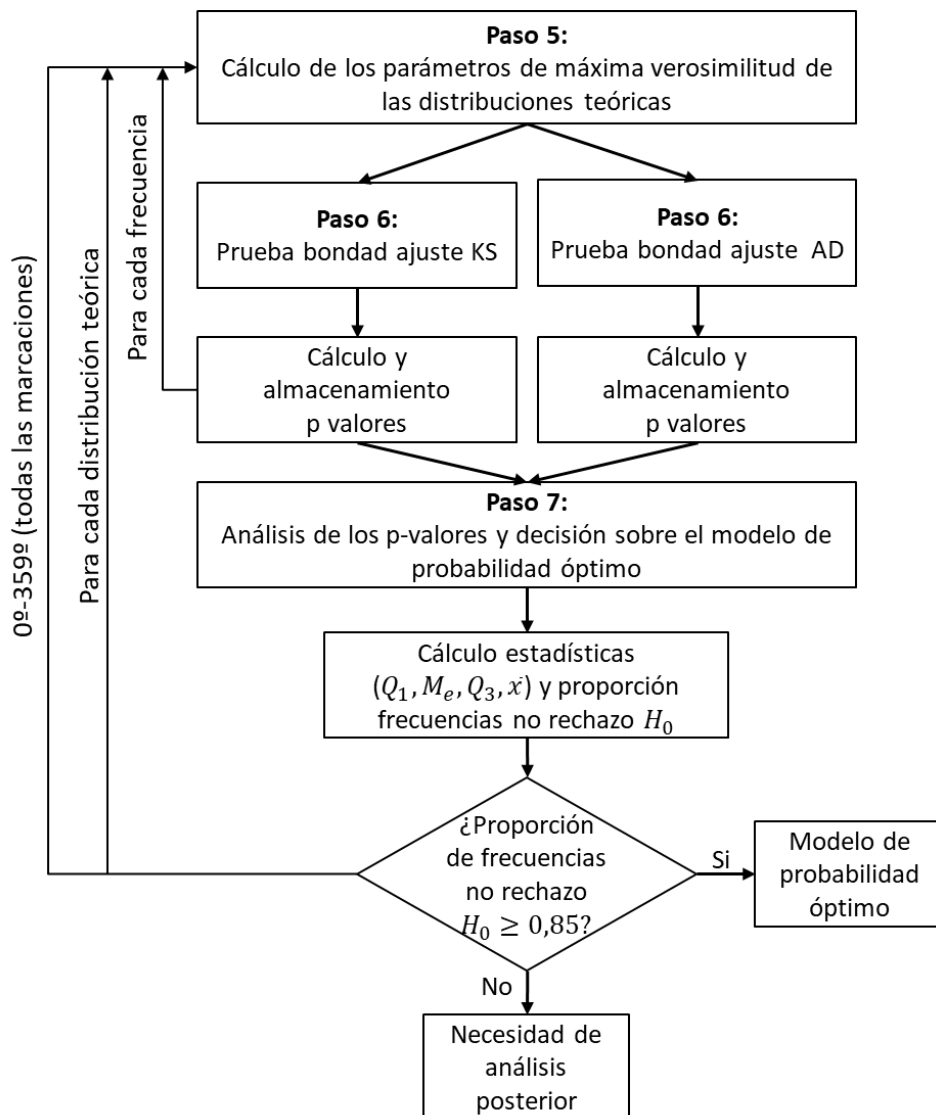


Figura 3-48. Secuencia de pasos en el análisis inferencial de los datos. Estimación del modelo de probabilidad óptimo

Paso#5. Calcular los parámetros de máxima verosimilitud

A partir de las matrices de datos calculamos, para cada grado y cada para frecuencia, los parámetros de máxima verosimilitud correspondientes a las cinco distribuciones de probabilidad señaladas anteriormente.

Paso#6. Contrastes de bondad del ajuste

Una vez obtenidos los valores de máxima verosimilitud de los parámetros de las cinco distribuciones teóricas de probabilidad, debemos analizar cómo es el ajuste de estas distribuciones a los datos reales.

Para este estudio, tal y como se ha descrito en el punto 3.5.2, se han utilizado el contraste de Kolmogorov-Smirnov (KS) y el contraste de Anderson-Darling (AD). En este paso, se obtienen los p valores de ambos contrastes o pruebas, para cada distribución teórica de probabilidad, para cada marcación y para cada frecuencia.

En el caso del buque ALFA, se obtiene una matriz de tres dimensiones [360 marcaciones \times 10 (2 pruebas: KS y AD \times 5 distribuciones) \times 61 frecuencias], que contiene todos los p valores de las pruebas y que será necesario analizar en pasos posteriores.

Paso#7. Análisis de los p valores y decisión sobre el modelo de probabilidad óptimo

El análisis de los p valores se realiza sobre la matriz del punto anterior, y cuyo objetivo es determinar el modelo de probabilidad óptimo para cada marcación del buque.

Elaboración de estadísticas

Se calcula para cada tipo de distribución de probabilidad y cada grado de marcación, la media, mediana, primer cuartil y tercer cuartil de los p valores de toda la trama de frecuencias.

También se obtiene, para cada marcación, la proporción de frecuencias en las que el p valor sea igual o superior a 0,05. Es decir, se contabilizarán las frecuencias en las que no existan evidencias estadísticas suficientes para rechazar la hipótesis nula (H_0 : los datos siguen una distribución especificada).

Así para cada modelo de distribución de probabilidad, obtendremos una matriz tridimensional de dimensiones 360 marcaciones \times 5 (media, mediana, Q_1 , Q_3 y proporción de no rechazo H_0) \times 2 pruebas KS y AD.

Toma de decisión del modelo

Para la toma de la decisión sobre cuál es la distribución de probabilidad óptima a adoptar, representamos en diagramas polares de marcaciones, las proporciones de frecuencias en las que el p valor sea igual o superior a 0,05. Es decir, se toma un nivel de confianza del 95%.

Con los datos del buque ALFA, se han obtenido las gráficas de proporciones de la Figura 3-49, donde podemos observar que el modelo que presenta un mejor ajuste es el correspondiente a la distribución Weibull, donde en prácticamente todas de marcaciones se obtiene una proporción de frecuencias de no rechazo de la hipótesis nula de más de 0,85.

Para cada marcación o aspecto, se ha tomado como válido el modelo de probabilidad analizado, si el rechazo de la hipótesis nula se produce en menos de 10 frecuencias, lo que supone una proporción de no rechazo igual o mayor de 0.85. Se asume el peor de los casos posibles, en donde las 10 frecuencias anómalas estén agrupadas, lo que supone un ancho de banda de 32,7 MHz, que no se considera suficiente para un cambio en la RCS del buque.

En la Figura 3-50 se presentan en un diagrama polar los valores de los diferentes estadísticos de los p valores, donde podemos apreciar dos zonas de anomalías centradas en las marcaciones 0° y 180° , donde la proporción de no rechazo baja hasta 0,6885 en la zona de proa y a 0,2623 en la zona de popa. Por lo tanto será necesario realizar un análisis más detallado en estos aspectos.

Comprobación de no existencia de frecuencias anómalas

Antes de continuar con el análisis de las marcaciones anómalas, es necesario comprobar que no existen frecuencias o grupos de frecuencias que no respondan al modelo óptimo, de forma repetitiva, en un número elevado de marcaciones. Este aspecto, no puede detectarse con los análisis anteriores, por lo se realizará un estudio gráfico, representando en un diagrama de barras, para cada frecuencia, el número de marcaciones cuyo p valor sean inferior a 0,05.

Capítulo 3. Modelado de la superficie equivalente radar

En el análisis del buque ALFA, se ha elaborado el gráfico de la Figura 3-51, donde se puede comprobar que tan solo 6 frecuencias presentan anomalías en más de 5 marcaciones, siendo el peor caso el correspondiente a la frecuencia nº 4, donde se contabilizan 11 marcaciones anómalas que corresponden tan solo al 3% del total.

Por lo tanto, se puede descartar la existencia de frecuencias de comportamientos anómalos en un conjunto elevado de aspectos del buque.

3.6.4. Análisis de las marcaciones o aspectos anómalos en el modelo óptimo

La aplicación de la metodología en el buque ALFA, determinó que la distribución de probabilidad que mejor se ajusta a la RCS es una función Weibull. Sin embargo, se observó que existen dos zonas de anomalías centradas en marcación 0° y en marcación 180° .

Los siguientes pasos consistirá en analizar, desde el punto de vista estadístico, los motivos de estas anomalías, para tratar de determinar si estas se producen en aspectos donde el tamaño de la muestra es grande y por lo tanto, tal y como expuso en el punto 3.5.4, pueden producirse fallos por sobreajuste en los test de bondad del ajuste. Para llevar a cabo este análisis, se procederá según la secuencia que se indica en la Figura 3-52.

Capítulo 3. Modelado de la superficie equivalente radar

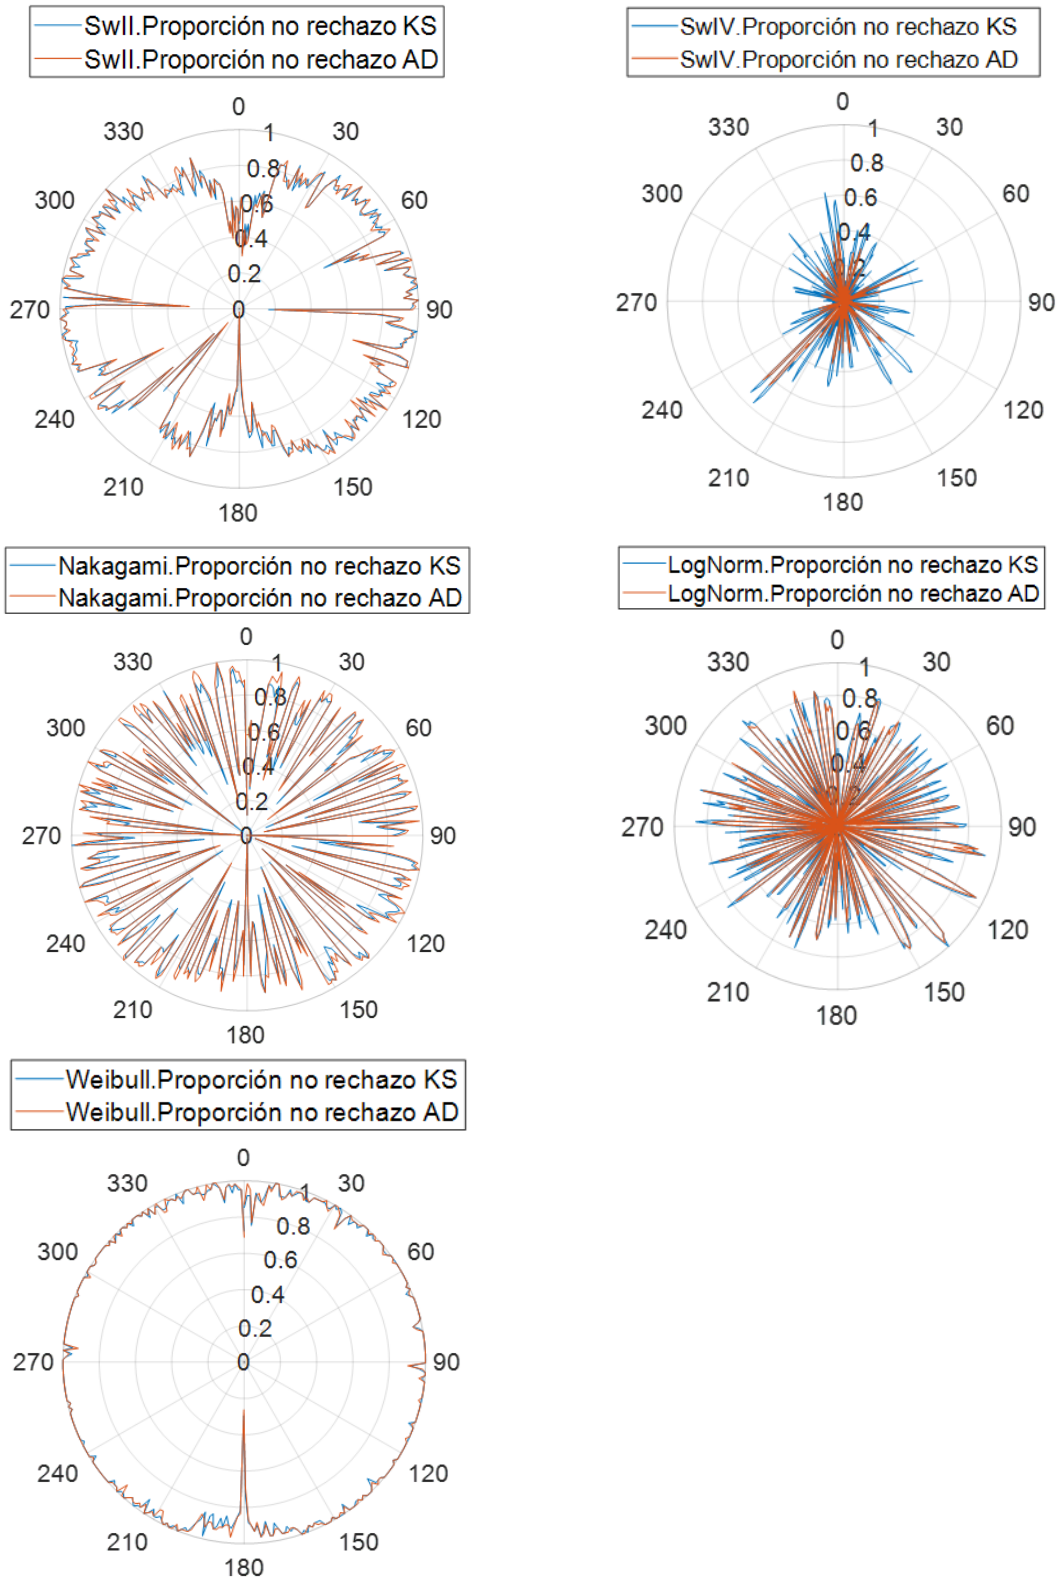


Figura 3-49. Gráficas polares de la proporción de frecuencias en las que no se puede rechazar la hipótesis nula en el contraste de bondad del ajuste. Datos en escala lineal

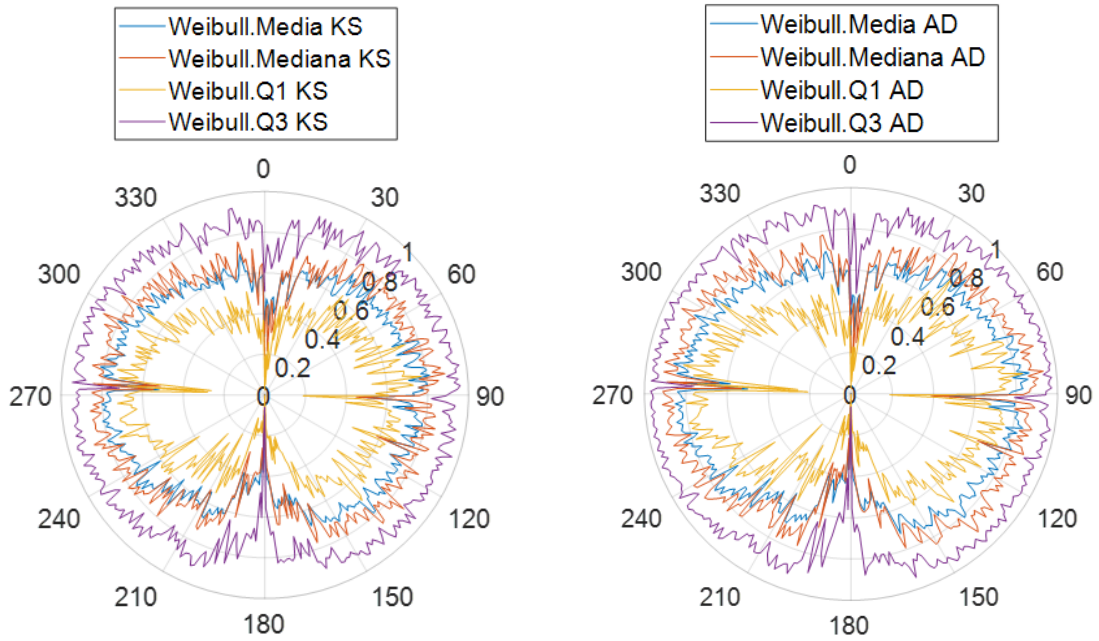


Figura 3-50. Representación polar de los diferentes estadísticos de los p valores de las frecuencias. Datos en escala lineal




Figura 3-51. Número de marcaciones anómalas por frecuencia para la distribución de Weibull para los test Kolmogorov-Smirnov y Anderson-Darling

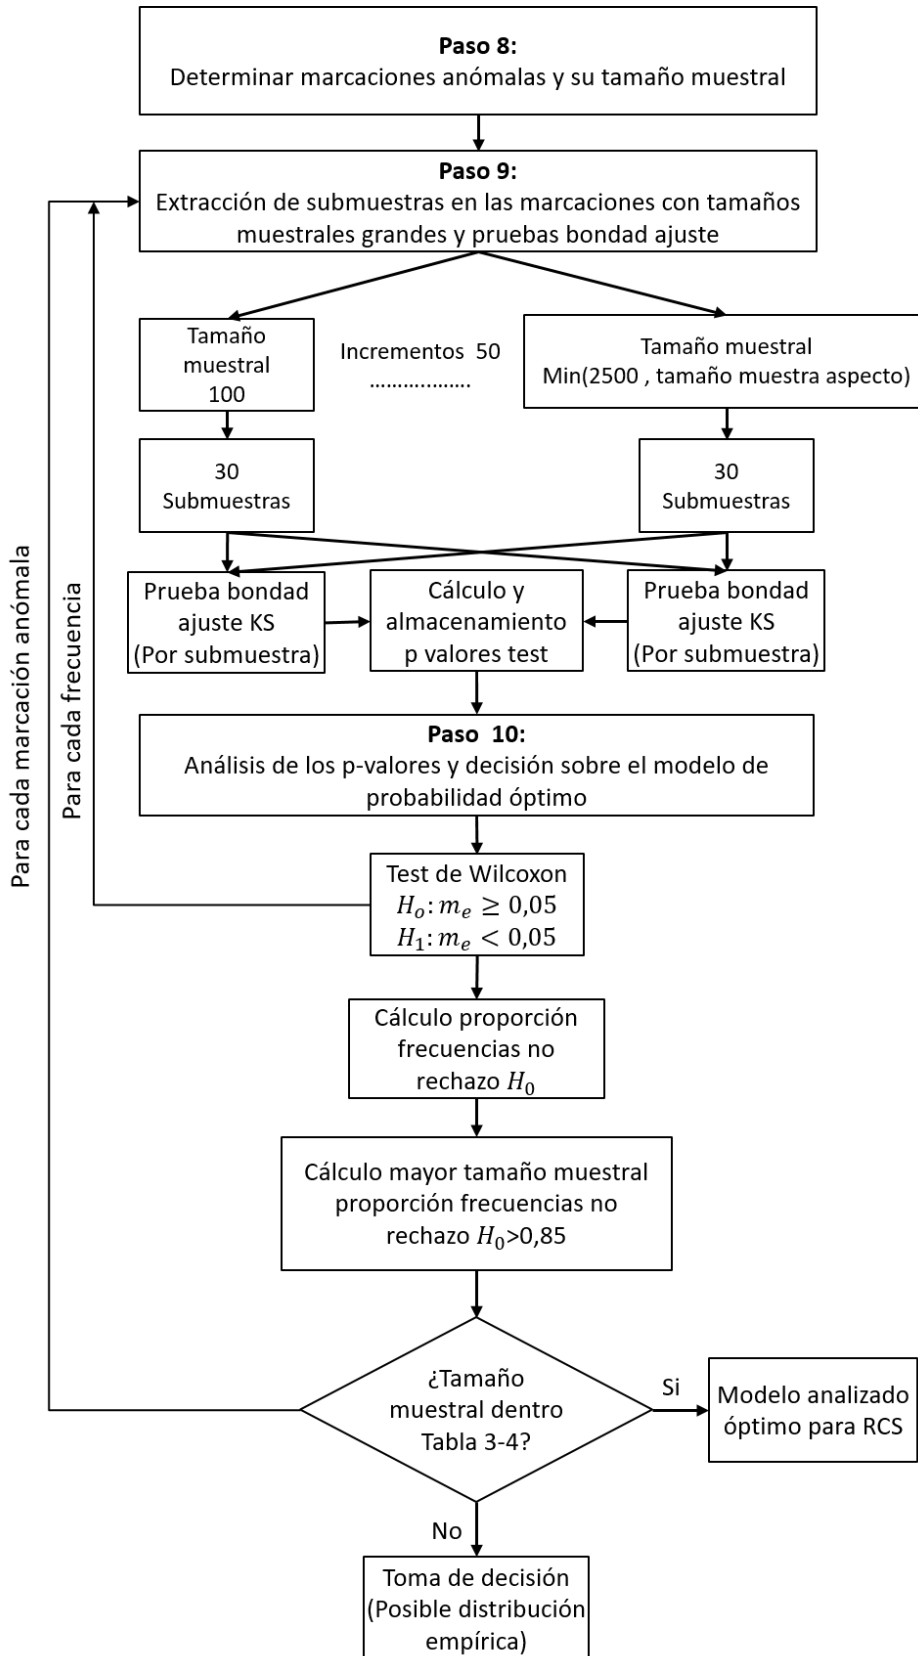


Figura 3-52. Secuencia del análisis de las marcaciones o aspectos anómalos en el modelo óptimo

Paso#8. Determinar las marcaciones anómalas y su tamaño muestral

Este paso de la metodología, tiene por objetivo determinar cuáles son los aspectos o marcaciones del buque que presentan anomalías, sus tamaños muestrales y así poder determinar si se trata de muestras grandes que pueden estar distorsionando las pruebas de bondad del ajuste.

Se busca aquellas marcaciones cuya proporción de frecuencias en las que el p valor sea igual o superior a 0,05, sea menor que 0,85 y dentro de este grupo y acorde con lo fijado en la Tabla 3-4, aquellas cuyo tamaño muestral sea superior a 550 datos (correspondiente al tamaño máximo para el test KS).

Para el buque ALFA, se han encontrado las marcaciones anómalas, con los tamaños muestrales y proporciones que figuran en la Tabla 3-7, en donde podemos apreciar que existen cinco marcaciones que cumplen los requisitos fijados en el párrafo anterior y por lo tanto, son las que se analizan en los pasos siguientes.

Tabla 3-7. Marcaciones anómalas, su tamaño de la muestra y proporción de frecuencias en las que no se rechaza la hipótesis nula para los test de bondad de ajuste

Marcación	Tamaño muestral	Proporción frecuencias de no rechazo KS	Proporción frecuencias de no rechazo AD
3	689	0,7541	0,7705
179	886	0,7377	0,6885
180	790	0,2951	0,2623
181	110	0,8197	0,8361
359	653	0,7213	0,6885

Paso#9. Extracción de submuestras en las marcaciones anómalas con tamaños muestrales grandes y realización de contrastes de bondad del ajuste

A continuación, en cada una de las marcaciones o aspectos anómalos con tamaño muestral grande y en cada una de las frecuencias obtenemos, mediante remuestreo,

Capítulo 3. Modelado de la superficie equivalente radar

30 submuestras de diferentes tamaños. Estas submuestras se generarán con tamaños desde 100, con incrementos de 50, hasta el mínimo entre el 2500 y el tamaño muestral de la marcación.

Una vez construidas todas las submuestras, se ejecutarán sobre todas ellas las pruebas de bondad del ajuste de Kolmogorov-Smirnov y Anderson-Darling de los modelos de probabilidad óptimos determinados en el Paso#7 y de estas pruebas, se obtendrán los p valores para su posterior análisis.

Al aplicar este procedimiento al buque ALFA, las pruebas de bondad del ajuste de las marcaciones anómalas se han limitado a la distribución de probabilidad Weibull, ya que en el paso anterior, se concluyó que el modelo óptimo correspondía a esta distribución.

Paso#10. Análisis estadístico de los p valores de las marcaciones anómalas y decisión final

En este último paso, se realiza un análisis estadístico los p valores obtenidos en el punto anterior, para determinar el modelo de probabilidad óptimo en las marcaciones anómalas y se toma la decisión sobre el modelo definitivo de la RCS del buque.

Sobre los p valores correspondientes a los test KS y AD de cada marcación anómala, aplicaremos el mismo método de análisis, que consistirá en lo siguiente:

Test de Wilcoxon

Para cada frecuencia y por cada tamaño muestral, determinaremos si tenemos evidencias estadísticas para afirmar que la mediana de las 30 submuestras es menor de 0,05. Es decir, realizaremos el siguiente contraste de hipótesis para la mediana mediante el test de Wilcoxon o de los rangos:

$$\begin{aligned}H_0: M_e &\geq 0,05 \\H_1: M_e &< 0,05\end{aligned}$$

Toma de decisión para marcaciones anómalas

Se calcula para cada tamaño de las submuestras, la proporción de frecuencias para las que no se rechaza la hipótesis nula anterior y se determina cuál es el mayor tamaño que cumple que dicha proporción sea mayor o igual a 0,85.

Capítulo 3. Modelado de la superficie equivalente radar

Si el tamaño muestral del punto anterior está dentro de los valores máximo y mínimo de la Tabla 3-4 se tomará el modelo que estamos analizando como válido para dicha marcación. En el caso de que ninguno de los modelos de probabilidad previstos se ajuste a los datos experimentales, se tomará la decisión en función del modelo obtenido en las marcaciones adyacentes o se elaborará una distribución empírica.

Para el caso del buque ALFA, una vez completadas las acciones de este paso, se obtuvo la Tabla 3-8, donde están contenidos los tamaños muestrales máximos de las submuestras en los que se consigue una proporción de no rechazo de la hipótesis nula en todas las frecuencias mayor de 0,85.

Tabla 3-8. Máximos tamaños muestrales que no rechazan la hipótesis nula para *KS* y *AD* para proporción de frecuencias mayor de 0,85

Marcación	Máximo tamaño muestral (KS)	Máximo tamaño muestral (AD)
3	650	700
179	650	650
180	350	300
359	450	650

Observando los resultados de la tabla anterior, observamos que los tamaños muestrales para el contraste Kolmogorov-Smirnov están dentro de márgenes fijados en la Tabla 3-4, por lo que desde el punto de vista de este test, podemos dar como óptima para estas marcaciones la distribución Weibull.

Caso aparte son los resultados del contraste Anderson-Darling, donde los máximos tamaños muestrales no están dentro de los intervalos de la Tabla 3-4. Sin embargo, si exceptuamos la marcación 180°, en el resto de marcaciones anómalas los tamaños muestrales están cerca de los valores mínimos establecidos en la citada tabla.

Para la toma de la decisión final sobre el modelo óptimo de RCS del buque ALFA, volvemos a representar en diagramas polares con las correcciones obtenidas en el análisis de las marcaciones anómalas (ver Figura 3-53), las proporciones de frecuencias

en las que el p valor del contraste de bondad del ajuste de la distribución Weibull sea igual o superior a 0,05.

De la observación de la gráfica de la Figura 3-53a, podemos concluir que según el contraste de KS, la distribución Weibull modela de forma correcta la RCS del buque ALFA en todas las marcaciones. Cabe destacar que solamente la marcación 181 obtiene una proporción inferior a 0,85, con un valor igual a 0,8197.

Por otra parte, en cuanto al contraste de AD, cuyos resultados se presentan en la gráfica de la Figura 3-53b, se puede apreciar que las cuatro marcaciones anómalas analizadas (3° , 179° , 180° , 359°) siguen presentando valores fuera de los márgenes establecido en la metodología. Sin embargo, dados los tamaños muestrales próximos al mínimo AD requerido y a los resultados de las marcaciones adyacentes podemos asumir la distribución Weibull como el mejor modelo que se ajusta a los datos.

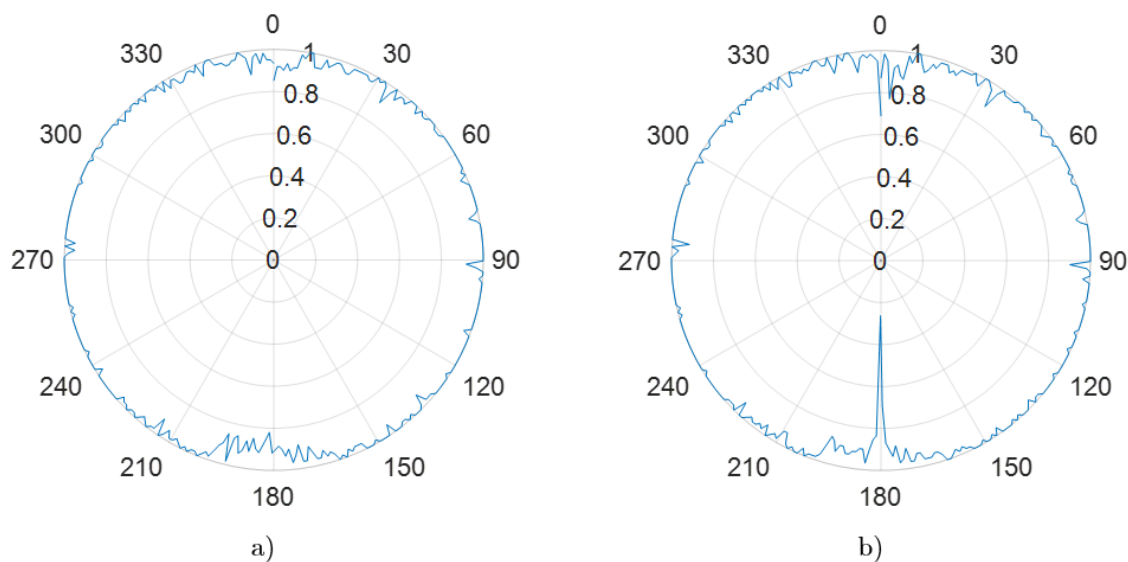


Figura 3-53. Proporción de frecuencias de no rechazo de la H_0 . a) Para la prueba KS
b) Para la prueba AD

Además, para apoyar la decisión de adoptar la distribución de Weibull, también como el modelo óptimo en la marcación crítica de 180° , se analizó gráficamente el comportamiento en todas las frecuencias, para este aspecto, obteniendo histogramas similares al representado en el Figura 3-54, en los que se puede observar la coincidencia gráfica entre el histograma y la teórica distribución de Weibull.




Figura 3-54. Histograma para una frecuencia de la marcación 180° del buque ALFA

A la vista de los resultados del buque ALFA, podemos concluir que la distribución de densidad de probabilidad Weibull es el modelo que mejor se ajusta para todas las marcaciones y frecuencias. Con ello, y con los parámetros obtenidos en el Paso#5, queda perfectamente modelada la RCS del barco.

3.6.5. Conclusiones finales sobre el modelo óptimo de RCS

La distribución Weibull es la que consigue un mejor ajuste de la RCS del buque en todas las frecuencias y marcaciones, mejorando el comportamiento respecto a las clásicas distribuciones Swerling.

La ventana de 1° de amplitud para el modelado del efecto *glint*, nos ofrece suficiente precisión para la mayoría de los marcos experimentales del ámbito de la simulación de una fuerza naval en un escenario electromagnético complejo. Sin embargo, dada la capacidad de análisis del DIAR, sería factible reducir la ventana a 0,5° de amplitud o incluso inferior. También sería factible lograr una precisión mayor, si las mediciones se realizan con una evolución más lenta del buque, logrando así aumentar el número de tramas en la caracterización de la RCS.

Para determinar el modelo de probabilidad de la RCS de un señuelo tipo chaff, se puede seguir la metodología antes citada. Sin embargo, debido a la reciente incorporación del DIAR, no existe todavía datos de medidas de señuelos, por lo que para

Capítulo 3. Modelado de la superficie equivalente radar

modelar su RCS, se seguirá lo expuesto en los trabajos de la Tesis de Pérez-Ojeda (Pérez-Ojeda, 2007), en donde establece que pueden modelarse mediante una distribución Swerling II.

CAPÍTULO 4. MODELADO, SIMULACIÓN Y RESULTADOS DE LAS BATERÍAS DE EXPERIMENTOS

4.1. INTRODUCCIÓN

El objetivo del modelado y simulación del lanzamiento de señuelos es conseguir un conjunto de datos suficientemente grande, para poder entrenar un modelo de inteligencia artificial que obtenga las soluciones de lanzamiento para cualquier escenario en el que pueda encontrarse un buque en la mar. Para este estudio, utilizaremos el simulador Algoritmo de Lanzamiento de Señuelos Armada (ALSA), que a la vista de los resultados del capítulo anterior, le introduciremos una serie de modificaciones para mejorar los modelos de superficie equivalente radar.

En este capítulo empezaremos exponiendo, de forma breve, los principios básicos del modelado y la simulación, y describiremos el funcionamiento básico del simulador ALSA y los objetos que interactúan en él. Esta descripción se realizará de forma somera, para que el lector pueda comprender el desarrollo de este trabajo, pero no se efectuará una descripción detallada por cuestiones de confidencialidad. En esta primera parte, se describirá también cómo se ha implementado en el simulador el nuevo modelo de RCS basado en una distribución de probabilidad Weibull.

Para terminar el capítulo, se presenta la configuración de las baterías de experimentos realizadas en el simulador, que nos han permitido obtener el conjunto de soluciones de lanzamiento para un número elevado de escenarios. Además, se describe el conjunto de datos que utilizaremos para entrenar un modelo de inteligencia artificial y se analiza gráficamente cuál ha sido el comportamiento de los resultados de la simulación.

4.2. PRINCIPIOS BÁSICOS DEL MODELADO Y LA SIMULACIÓN

El término simulación, de una forma general, se refiere a un conjunto de técnicas y métodos que utiliza un ordenador con un software apropiado, para imitar el comportamiento de un sistema real.

Una vez que hemos hecho una primera aproximación al concepto de simulación, estamos en condiciones de dar una definición más formal y aunque existen innumerables podemos citar las siguientes:

- La simulación es la imitación de la operación de un proceso o sistema del mundo real a lo largo de un periodo de tiempo, para describir y analizar su comportamiento (Banks, 1998).
- La simulación es una técnica de resolución de problemas siguiendo en el tiempo los cambios de un modelo de un sistema (Gordon, 1969).
- La simulación es el proceso de diseñar un modelo de un sistema real y realizar experimentos con él, con la finalidad de comprender el comportamiento del sistema o evaluar nuevas estrategias de funcionamiento del sistema (Shannon, 1975)
- La simulación es una técnica numérica para conducir experimentos en una computadora digital. Estos experimentos comprenden ciertos tipos de relaciones matemáticas y lógicas, las cuales son necesarias para describir el comportamiento y la estructura de sistemas complejos del mundo real a través de largos periodos de tiempo (Naylor, Balintfy, Burdick, & Chu, 1966).

La simulación es una de las técnicas más utilizadas en la investigación operativa, en donde se ha aplicado en infinidad de áreas, como el diseño y análisis de sistemas de producción, desarrollo de políticas de inventarios, diseño de sistema de comunicaciones, diseño y operación de sistemas de transporte como aeropuertos, puertos, metro, etc., análisis de sistemas económicos o financieros, etc.

En el ámbito militar, al igual que el ámbito civil, las técnicas de simulación se han utilizado extensamente en la toma de decisiones en diferentes campos: elaboración de tácticas de combate, diseño de cadenas logísticas, evaluación de nuevos sistemas de armas, gestión de personal, etc. (Farris & Stuckey, 2000; Mcintosh & Kerry, 2018).

4.2.1. *Sistemas y modelos*

En las definiciones que acabamos de ver en el punto anterior, aparecen una serie de conceptos, tales como, sistema y modelo, que será necesario definir de forma conveniente para comprender de forma clara de concepto de simulación.

Podemos definir un sistema como una colección de objetos o entidades que interactúan entre sí y cuyas propiedades se quieren estudiar. En la práctica, lo que consideremos como sistema va a depender de los objetivos del estudio concreto que queremos realizar (Law & Kelton, 2000; Moller & Struth, 2013). Por ejemplo, en nuestro caso, el objetivo de estudio es determinar la mejor reacción con señuelos de un buque ante un ataque de misil, por lo que nuestro sistema estará formado por las entidades u objetos: buque, señuelo, misil y viento, que interactuarán entre sí.

Por otra parte, de forma general, podemos definir un modelo como una representación de un sistema desarrollada para un propósito específico. El modelo representa a las entidades u objetos del sistema, sus atributos o características y sus interacciones, en definitiva se pretende describir un cierto fenómeno o proceso (Aracil & Gordillo, 2005; Moller & Struth, 2013; Urquía, 2005). Por tanto, el modelo recogerá solo aquellos aspectos que sean relevantes para el marco experimental en cuestión.

Volviendo de nuevo al sistema de nuestro estudio, en la Figura 4-1 se puede observar el esquema del modelo de defensa antimisil de un buque, donde se han incluido los objetos: buque, señuelo, viento y misil, sus características o atributos y las relaciones básicas de interacción entre ellos.

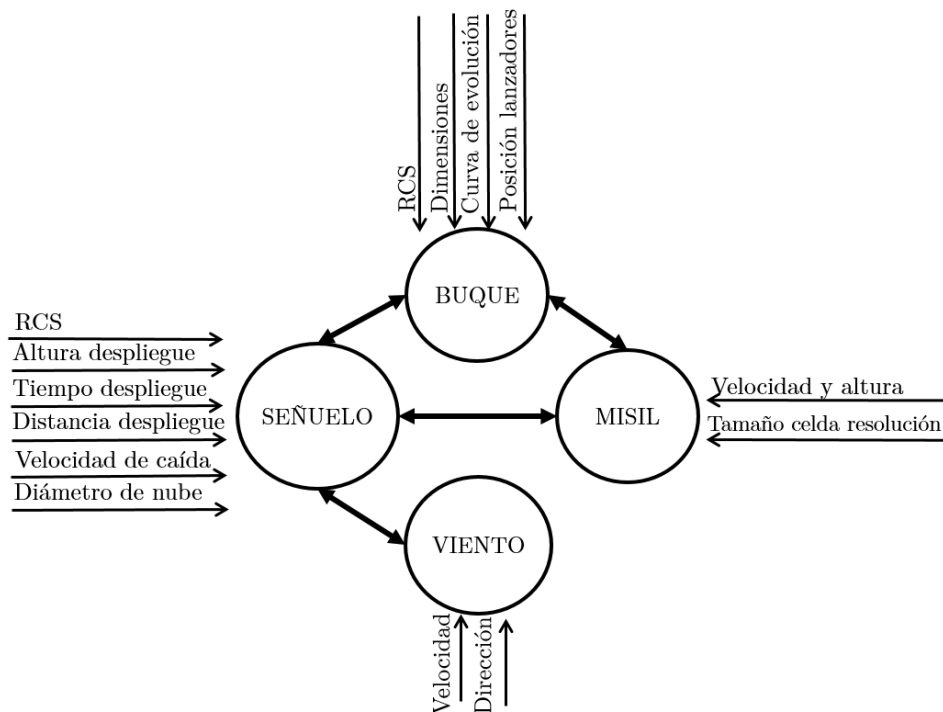


Figura 4-1. Modelo del sistema de defensa antimisil del buque. Entidades, atributos y relaciones

4.2.2. Tipos de modelos

El procedimiento para conocer el comportamiento de un sistema es lo que se denomina experimentación, que se basa en la realización de experimentos que los podemos definir como los procesos de extraer datos de un sistema sobre el cual se ha ejercido una acción externa (Shannon, 1975; Urquía, 2005).

Tal y como podemos observar en la Figura 4-2, la experimentación de un sistema se puede realizar de varias formas que detallaremos a continuación.

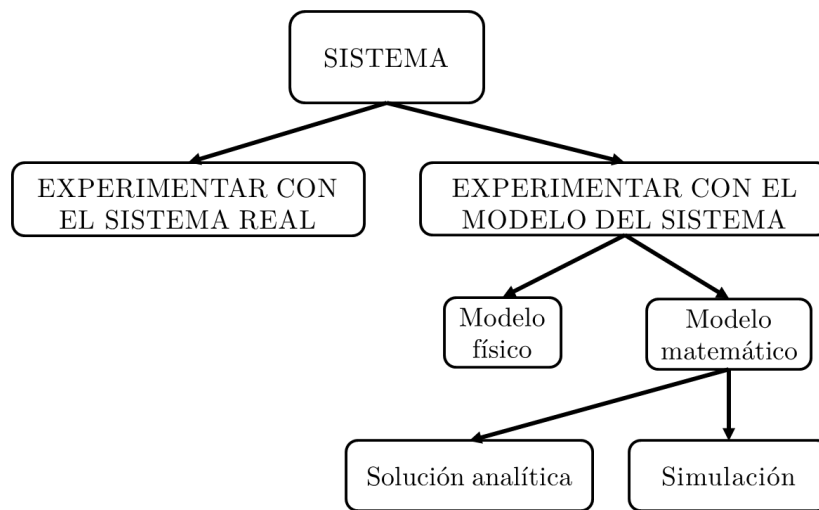


Figura 4-2. Formas de estudiar un sistema

Experimentar con el sistema real o experimentar con un modelo del sistema.

Si es posible y la relación coste/eficacia nos lo permite, experimentar directamente con el sistema real presenta indudables ventajas, ya que se pueden cambiar los valores de las variables de entrada al sistema y ver lo que ocurre en las salidas, con la seguridad de que las soluciones obtenidas son válidas (Law & Kelton, 2000). Sin embargo, esto frecuentemente no es posible por muchas circunstancias: el sistema puede que no exista todavía, los experimentos pueden ser de un coste económico elevado, puede tratarse de experimentos destructivos o peligrosos, el tiempo para realizar el experimento pudiera ser excesivo, el rango de las variables que se desea probar no están accesibles en el sistema, etc.

Por lo anteriormente expuesto, habitualmente es necesario construir un modelo que nos permita estudiar el comportamiento del sistema real. Sin embargo, el uso de un modelo implica que, a priori, desconocemos si sus salidas reflejan de forma precisa las

Capítulo 4. Modelado, simulación y resultados de las baterías de experimentos

salidas del sistema que estamos estudiando. Necesitamos, por lo tanto, validar el modelo, es decir, de alguna manera necesitamos comprobar que el modelo construido se comporta, para nuestro marco experimental, como se comportaría el sistema real. Esta cuestión de la validación es un aspecto importante de la simulación y la trataremos con más detalle en los próximos puntos.

Modelo físico o modelo matemático

Un modelo físico o modelo icónico, es una recreación o una maqueta del sistema real, donde se ha realizado una reducción de su tamaño, manteniendo constante las relaciones dimensionales básicas, aunque hay que reseñar que este tipo de modelos no tienen una gran incidencia en los estudios de investigación operativa (Law & Kelton, 2000). En la Figura 4-3, podemos observar el modelo físico de la Base Naval de Pearl Harbour de la Flota Norteamericana del Pacífico, construido por la Marina Imperial Japonesa y utilizado para elaborar su plan de ataque en la Segunda Guerra Mundial.

En la actualidad y como ejemplos de este tipo de modelos, podemos citar los modelos de aeronaves, que se prueban en túneles de viento o los modelos de buques, como el de la Figura 4-4, que se prueban en canales de experiencias hidrodinámicas.



Figura 4-3. Modelo físico construido por la Marina Imperial Japonesa para planear el ataque a Pearl Harbor (fuente: www.historylink101.com)



Figura 4-4. Modelo físico de un buque en el Canal de Experiencias Hidrodinámicas de El Pardo (CEHIPAR) (Fuente: CEHIPAR)

Sin embargo, la mayoría de los modelos construidos son modelos matemáticos. En ellos, las relaciones entre las variables que pueden ser observadas del sistema (distancias, velocidades, flujos, etc.) están descritas mediante relaciones lógicas y cuantitativas (Urquía, 2005).

Solución analítica o simulación

Una vez que hemos construido un modelo matemático, debemos determinar si las relaciones matemáticas del modelo son sencillas y pueden resolverse analíticamente. Habitualmente, en la mayoría de las situaciones la solución por medios analíticos no es factible y debe estudiarse con ayuda del ordenador, aplicando métodos numéricos. Este experimento numérico realizado sobre el modelo matemático, recibe el nombre de simulación (Law & Kelton, 2000; Urquía, 2005).

Para el caso de estudio de la defensa antimisil de un buque, emplearemos un modelo matemático donde, debido a su complejidad, será necesario emplear técnicas de simulación para su análisis.

4.2.3. Modelos matemáticos

Existen diferentes clasificaciones de los modelos matemáticos, atendiendo a diferentes criterios. En la Figura 4-5 se presenta la clasificación que describiremos a continuación:

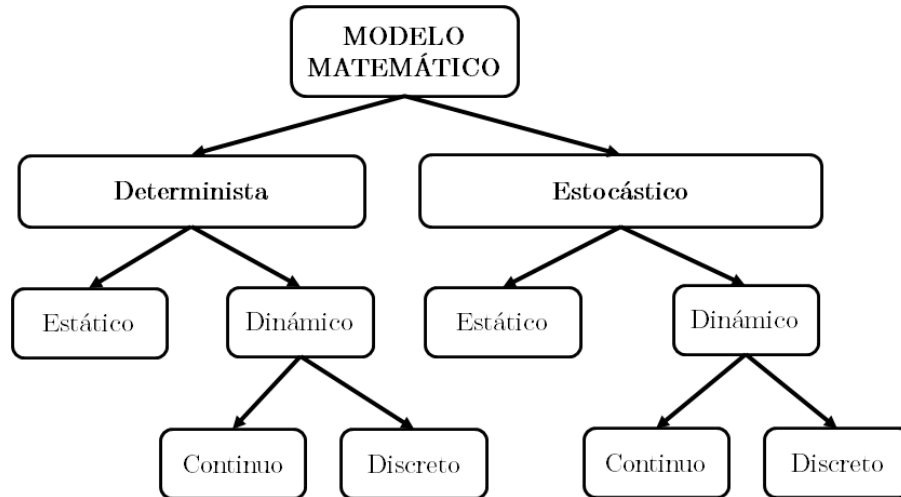


Figura 4-5. Clasificación de los modelos matemáticos

Modelo determinista frente a estocástico

Si un modelo no contiene ningún componente aleatorio o estocástico se conoce como determinístico. En un modelo determinístico la salida es determinada una vez que se especifican las relaciones, cantidades y entradas. Para una misma entrada se produce siempre la misma salida (Law & Kelton, 2000; Urquía, 2005).

Sin embargo, lo más habitual es que los sistemas tengan ciertos componentes aleatorios de entrada, representados mediante modelos de probabilidad (por ejemplo, la mayoría de los sistemas de colas e inventarios). Los modelos de simulación estocásticos producen salidas que son aleatorias y deben ser tratadas mediante técnicas de estadística inferencial (Law & Kelton, 2000; Urquía, 2005).

Modelo estático frente a dinámico

Un modelo estático es una representación de un sistema en un instante determinado o uno que representa un sistema en el cual el tiempo no juega ningún papel. Podemos citar como ejemplo de simulaciones estáticas, los modelos Monte Carlo (Shannon, 1975; Urquía, 2005). De otro lado, los modelos dinámicos representan sistemas que evolucionan con el tiempo (Aracil & Gordillo, 2005).

Modelos Continuos frente a discretos

Los modelos continuos se ocupan de sistemas cuyo comportamiento cambia continuamente con el tiempo. Estos modelos suelen utilizar ecuaciones diferenciales para describir las interacciones entre los diferentes elementos del sistema (Taha, 2012).

Los modelos discretos tienen que ver principalmente con el estudio de líneas de espera con el objetivo de determinar medidas como el tiempo de espera promedio y la longitud de la cola. Estas medidas cambian sólo cuando un cliente entra o sale del sistema. Los instantes en que ocurren los cambios en puntos discretos específicos del tiempo (eventos de llegada y salida), originan el nombre simulación de evento discreto (Taha, 2012).

Los modelos de tiempo continuo son una idealización, ya que al simular mediante un ordenador un modelo de tiempo continuo, debe discretizarse el eje temporal a fin de evitar el problema de los infinitos cambios en el valor de los estados. Esta discretización constituye una aproximación, con su error asociado, que transforma el modelo de tiempo continuo en un modelo de tiempo discreto.

El modelo del simulador de defensa antimisil, empleado en este estudio, es un modelo matemático, estocástico y dinámico. Además, discretiza el eje temporal del modelo de tiempo continuo con un intervalo de discretización Δt , que es configurable por usuario.

4.2.4. Modelos estocásticos. Generación de números aleatorios

En este punto expondremos la teoría básica sobre generadores de números aleatorios, ya que esta cuestión es el núcleo mismo de la simulación estocástica (Banks, 1998). Además, para la implementación del nuevo modelo aleatorio de RCS en el simulador ALSA, deberemos tenerla en cuenta para asegurar, de una manera formal, la robustez de su comportamiento.

En toda simulación de un sistema o proceso que tenga un componente aleatorio, será necesario construir un modelo numérico para generar muestras independientes de variables aleatorias a partir de determinadas distribuciones de probabilidad. Estas observaciones de una variable aleatoria, se obtienen a partir de números aleatorios de una distribución uniforme $U(0,1)$ (Shadkam & Aghaie, 2010).

Existen dos grandes grupos de generadores de números aleatorios: los generadores físicos y los generadores aritméticos. Los primeros son dispositivos físicos que emplean

fuentes externas, como ruido eléctrico, desintegración de material radioactivo, etc. Sin embargo, en este trabajo, nos centraremos en el grupo de generadores aritméticos que son los implementados en los ordenadores.

Los métodos de generación aritméticos son secuenciales, es decir, cada número se determina a partir de uno o varios de sus predecesores mediante un algoritmo determinista (dichos números no son aleatorios, ni impredecibles). Conocido el algoritmo generador, se puede predecir la secuencia, por ello se denominan números pseudo aleatorios (Banks, 1998). Así de una manera formal, podemos utilizar la definición enunciada por L'Ecuyer (L'Ecuyer, 1990, 1997):

Definición. Un generador de números pseudo aleatorios es una estructura $\mathcal{G} = (X, x_0, T, U, g)$, donde X es un conjunto finito de estados, $x_0 \in X$ es el estado inicial (semilla), la aplicación $T: X \rightarrow X$ es la función de transición, U es el conjunto finito de posibles observaciones, y $g: X \rightarrow U$ es la función de salida.

Básicamente, la secuencia de funcionamiento de los generadores de números aleatorios es la misma. Se escoge una semilla inicial x_0 y a partir de ella, mediante una relación de recurrencia $x_n = T(x_{n-1})$ se genera una sucesión de números x_n . Cada uno de estos valores proporciona un número pseudo aleatorio u_n definido a través de alguna relación $u_n = g(x_n)$. Como X es finito, la sucesión de estados es periódica, es decir en algún instante, para algún valor $j > i$, sucederá que $x_j = x_i$, y a partir de ese momento, $x_{j+k} = x_{i+k}$ y por lo tanto, $u_{j+k} = u_{i+k}$, para todo $k \geq 0$. Definimos, entonces el periodo como el menor entero $\rho > 0$, tal que, para algún entero $\tau \geq 0$, se verifica que $x_{\rho+k} = x_k$, para todo $k \geq \tau$ (L'Ecuyer, 1997).

A veces, en la práctica, la semilla es un valor fijo, lo que significa que se elimina completamente la aleatoriedad. En otros casos, algunos sistemas determinan la semilla leyendo el reloj del ordenador (L'Ecuyer, 1990).

Desde el punto de vista práctico de la simulación, un buen generador de números aleatorios debe tener las siguientes propiedades (Law & Kelton, 2000):

- La sucesión de valores debe asemejarse a una sucesión de realizaciones independientes de una variable aleatoria uniforme $U(0,1)$.
- El generador debe ser rápido y no requerir grandes capacidades de memoria interna.

- En simulación, los resultados deben ser reproducibles, es decir, que comenzando con la misma semilla debe ser capaz de reproducir la misma secuencia. Esto nos puede permitir depurar fallos del modelo o simular diferentes alternativas del modelo en las mismas condiciones obteniendo una comparación más precisa.
- El generador debe permitir la generación de varias secuencias separadas de números aleatorios, para poder dedicar una secuencia diferente para cada fuente del modelo.

Según Zeeb (Zeeb & Burns, 1997), las tres clases de generadores de números pseudo aleatorios más populares son las siguientes:

- Generadores congruenciales lineales (*lineal congruential generators*: LCG).
- Generadores de Fibonacci retardados (*lagged fibonacci generator*: LFG).
- Generadores combinados.

En este punto, describiremos de forma resumida estos generadores, centrándonos en el generador de Fibonacci que es el utilizado por el simulador ALSA. Además, también expondremos las características principales del generador de Mersenne-Twister, que es el que utiliza por defecto MATLAB.

Generadores congruenciales lineales

Los generadores congruenciales lineales fueron introducidos por Lehmer (Lehmer, 1951) y se han venido utilizando frecuentemente en simulación. Se obtiene la secuencia de números aplicando (Knuth, 1998; Tezuka, 1995):

$$X_{n+1} = (a \cdot X_n + c) \bmod m, \quad n \geq 0 \quad (4-1)$$

donde:

m	es el divisor	$(m > 0)$
a	es el multiplicador	$(0 \leq a < m)$
c	es el incremento	$(0 \leq c < m)$
X_0	es el valor inicial (semilla)	$(0 \leq X_0 < m)$

X_{n+1} es el resto de la división $a \cdot X_n + c$ por m , por lo tanto $0 \leq X_{n+1} \leq m - 1$ y para obtener números en el intervalo $[0,1)$ es necesario dividirlos por m .

Las series de números generados tienen un periodo de m , donde normalmente es de 2^{32} o 2^{64} , que en ocasiones puede ser muy corto, aunque son generadores que ocupan poca memoria (Dibble & Turner, 2014).

En función del valor de c , los generadores congruenciales lineales se pueden clasificar en:

- Mixtos, cuando $c > 0$
- Multiplicativos, cuando $c = 0$

Generadores de Fibonacci retardados

La forma de estos generadores se fundamentan en una recurrencia del tipo (S. L. Anderson, 1990; Green, Smith, & Klem, 1959; Zeeb & Burns, 1997):

$$X_n = (X_{n-r} \text{ op } X_{n-s}) \text{ mod } m \quad (4-2)$$

donde las posibles operaciones (*op*) pueden ser:

+	suma
-	resta
×	multiplicación
⊕	O exclusivo

Los valores más usados de (r, s) son: (17,5); (55,24); (127,97); (607,273) y (1 279,418).

En caso de emplear las operaciones suma y resta, se suelen denominar generador de números aleatorios aditivos y sustractivos de Knuth. Estos generadores tienen una gran rapidez de cálculo, ya que no requiere realizar operaciones de multiplicación y un periodo largo de hasta $2^r - 1$ (Knuth, 1998).

Generadores combinados

Por parte de algunos autores (Marsaglia, 1985) se han propuesto métodos para combinar dos o más generadores congruenciales lineales para mejorar las propiedades estadísticas, el problema de estos algoritmos es que aumentan el costo computacional de la generación de números.

Generador Mersenne-Twister

El generador Mersenne-Twister se desarrolló en 1997 por Matsumoto y Nishimura (Matsumoto & Nishimura, 1998). Actualmente, se ha convertido en uno de los más empleados, siendo el generador por defecto en muchos programas, por ejemplo, en Python (Phyton, 2020), Excel (Mélard, 2014; Microsoft, n.d.) y MATLAB. Se trata de un generador congruencial matricial lineal, que tiene un periodo extremadamente largo de $2^{19937} - 1$ y una equidistribución $U(0,1]$ en 623 dimensiones.

4.2.5. Pasos en un estudio de simulación

De forma general y a grandes rasgos, los siguientes pasos, son los que deberían seguirse en cualquier estudio de simulación (Banks, 1998; Shannon, 1998; Urquía, 2005) (ver Figura 4-6):

- **Formulación del problema.** Definir claramente los objetivos del estudio y cuál es su propósito, es decir, por qué estamos estudiando este problema y qué preguntas esperamos responder. Se deben determinar los límites y restricciones que se utilizarán para definir el sistema o proceso y qué aspectos de la realidad constituyen el sistema del proyecto. Es posible que el problema deba reformularse una vez iniciados los estudios de simulación.
- **Planificación del proyecto.** Estimar los recursos necesarios para llevar a cabo el proyecto de simulación: medios *hardware* de computación, recursos *software*, personal, presupuesto, etc.
- **Formulación del modelo conceptual.** Desarrollar un modelo preliminar ya sea gráficamente, mediante diagramas de bloque o diagramas de flujo del proceso, o en pseudocódigo para definir los componentes, las variables descriptivas de entrada, interacciones que constituyen el sistema, las variables de salida y las medidas de efectividad (*measure of effectiveness*: MOE).

- **Preparación de los datos de entrada.** Identificación y recopilación de los datos de entrada necesarios para construir el modelo.
- **Traducción del modelo.** Codificar el modelo en un lenguaje de simulación apropiado para el sistema del estudio.
- **Verificación.** Confirmar que el modelo opera en la forma que el analista pretende. Es decir, el simulador realiza correctamente las tareas para las cuales ha sido programado.
- **Validación.** Comprobar que los resultados del modelo son creíbles y representan el comportamiento del sistema real.
- **Diseño del experimento.** Diseñar un experimento que proporcione la información necesaria para poder contestar a las preguntas planteadas en el paso 1. En el caso de un simulador estocástico, será necesario determinar el número de réplicas para acotar el error en los resultados.
- **Experimentación.** Ejecutar el experimento diseñado en el paso anterior.
- **Análisis e interpretación.** Inferir conclusiones a partir de los datos obtenidos de las medidas de eficacia de la simulación.
- **Documentación e implementación de resultados.** Presentar los resultados y las conclusiones de la forma más adecuada, documentar el modelo para su posterior reutilización y tomar las acciones oportunas a partir de los resultados obtenidos.

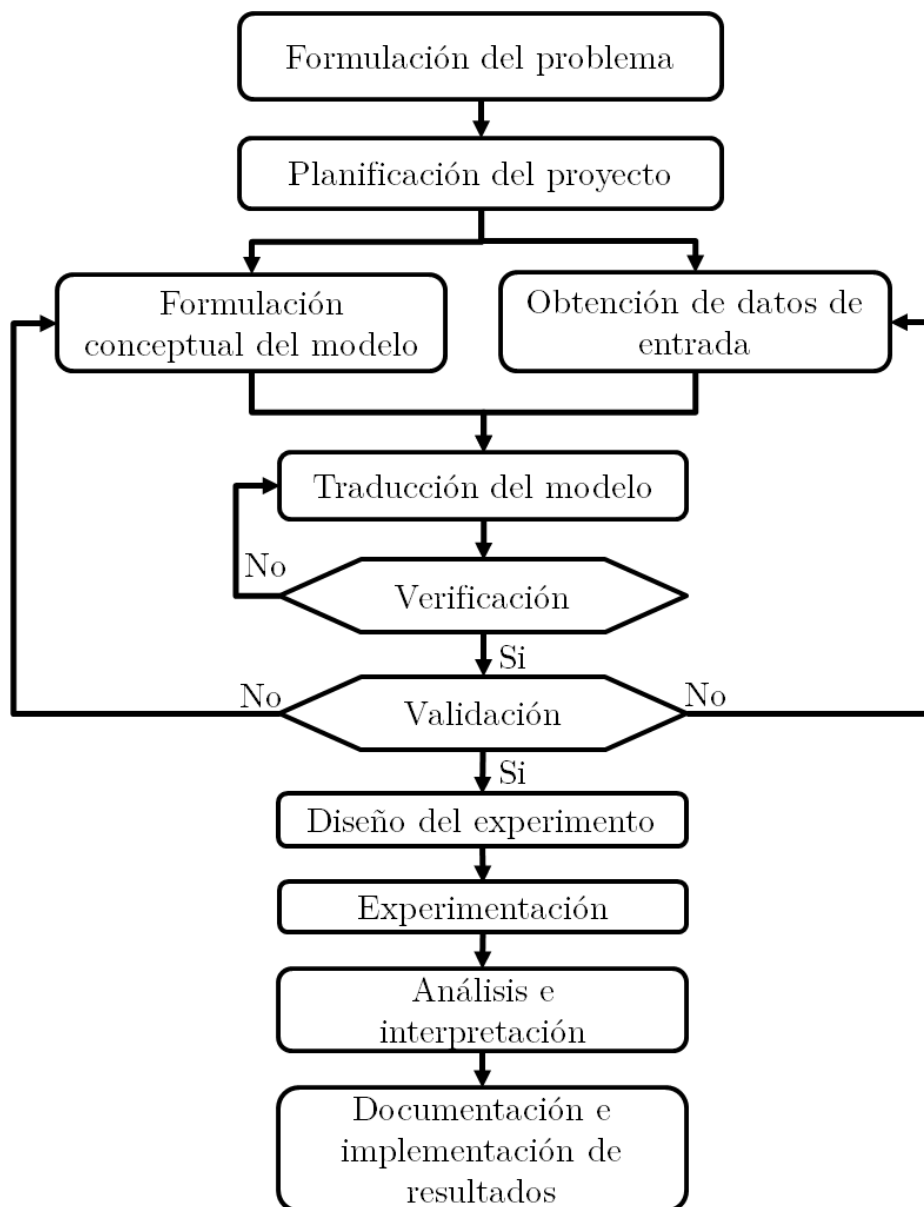


Figura 4-6. Pasos en un estudio de simulación

4.3. EL SIMULADOR DEL LANZAMIENTO DE SEÑUELOS. DESCRIPCIÓN

Para este trabajo se ha utilizado el Algoritmo de Lanzamiento de Señuelos Armada (ALSA), cuya función es simular un escenario en el que un buque reacciona con señuelos ante un ataque de misil. ALSA es una aplicación informática, desarrollada en lenguaje C#, formada en su núcleo o *kernel*, por un simulador que coordina la interacción de tres objetos o instancias: buque, señuelo y misil. Dichas instancias, se relacionan en un escenario que viene dado por un viento, una velocidad del buque y una distancia y marcación o ángulo del misil atacante. Cada uno de los objetos implicados

en la simulación son caracterizados por una serie de atributos o características que van a afectar a la solución de lanzamiento. En la Figura 4-7, se muestra el visualizador 2D de la aplicación, donde se aprecian los objetos de la simulación en un escenario.

El programa simula la capacidad del buque para engañar al misil, obtiene la información sobre la efectividad de los señuelos frente al ataque y determina cuál de las posibles soluciones de lanzamiento optimiza las medidas de efectividad definidas previamente. Para ello, la aplicación toma los datos de entrada mediante ficheros de configuración y genera los resultados en diversos formatos configurables por el usuario.

Básicamente, el simulador realiza su tarea estableciendo las condiciones iniciales del escenario y evolucionando el estado de los objetos en función de sus respectivos datos cinemáticos, de forma que en cada iteración el tiempo avanza un diferencial definible en el fichero de configuración de la simulación. La simulación concluye cuando el misil ha impactado en el buque o al desaparecer el peligro, es decir se aleja del barco objetivo.

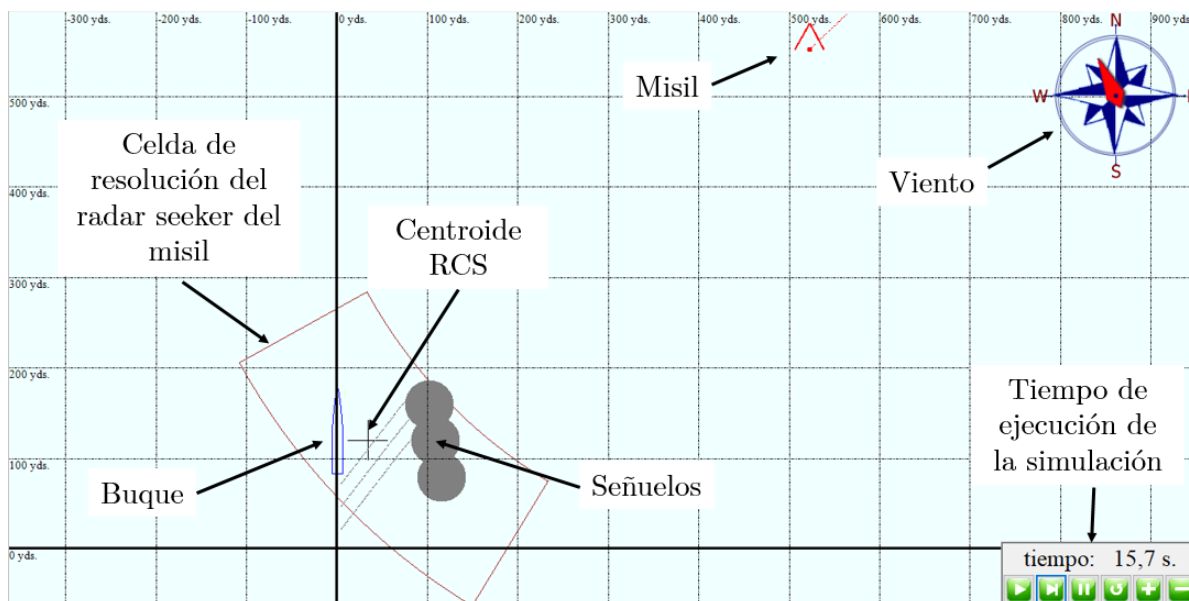


Figura 4-7. Objetos de un escenario. Visualizador 2D

Los diferentes archivos de configuración proveen al simulador de los atributos y los parámetros cinemáticos y geográficos propios de los distintos objetos que forman parte de un escenario y de la información relativa al proceso de la simulación, como el diferencial de tiempo a emplear en cada caso.

Capítulo 4. Modelado, simulación y resultados de las baterías de experimentos

En general y de forma esquemática, la Figura 4-8 muestra la evolución de la simulación durante la ejecución de un escenario, que a grandes rasgos podemos resumir de la forma siguiente:

- 1) El simulador parte de una definición de un escenario, fijando el tipo de buque, de señuelos y de misil que intervendrán en la simulación.
- 2) A partir de la definición del escenario, se cargan todos los objetos (buque, misil y señuelos) con los atributos contenidos en los ficheros de configuración.
- 3) Se establecen las condiciones iniciales del escenario (velocidad del buque, marcación y distancia al misil y viento).
- 4) Se ejecuta el primer o siguiente paso de simulación.
- 5) Se mueve el buque, según su movimiento asociado y se estudia si se ha de lanzar en ese instante de simulación algún señuelo y si se produce el lanzamiento, se añade a la lista de señuelos del simulador.
- 6) Se mueve la amenaza. El radar del misil estudia el estado del escenario, determina el blanco a atacar y se dirige hacia él para interceptarlo.
- 7) Se mueven todos los señuelos presentes en el escenario.
- 8) Se evalúan las condiciones de fin de simulación:
 - La condición de fin de simulación se alcanza cuando el misil impacta en el blanco o se produzca un aumento de la distancia misil/buque respecto al paso de simulación anterior. Si se alcanza el final de la simulación, se pasa a evaluar los resultados obtenidos.
 - Si no se cumplen las condiciones anteriores, se ejecuta el siguiente paso de simulación (punto 4).

Una vez vista de forma general el funcionamiento del simulador, pasaremos a describir de forma somera los distintos objetos que lo forman.

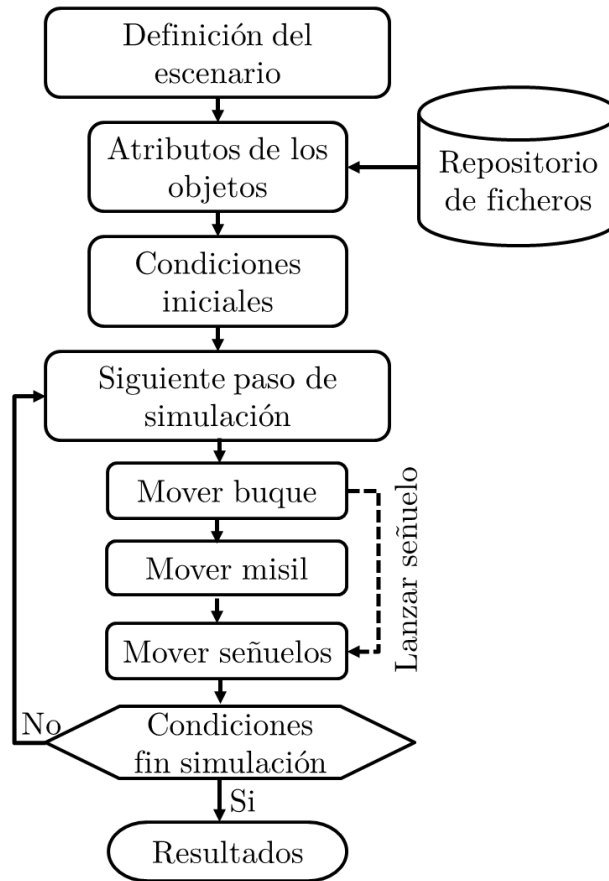


Figura 4-8 Esquema de la evolución de la simulación

4.3.1. El objeto buque

La configuración de los buques en ALSA viene dada por las características propias del escenario y los atributos del buque.

En el escenario se especifica el tipo de buque y sus condiciones cinemáticas de rumbo y velocidad. Mientras que los atributos, que dependen del tipo de buque específico que se empleará en la simulación, se definen dentro de un archivo propio asociado al tipo de buque y son independientes del escenario.

Las características que se definen en el escenario van a determinar las acciones realizadas por cada buque, pero su comportamiento, cómo realiza o ejecuta dichas acciones, así como los efectos que tiene sobre el resto del escenario, viene determinado por sus atributos.

El programa utiliza la configuración fijada para el escenario para situar el buque, que será movido de acuerdo a los parámetros iniciales especificados al configurar el escenario y teniendo en cuenta los atributos, obtenidos del archivo asociado a cada tipo de buque. Estos atributos son los siguientes:

- Modelo estructural.
- Características de evolución.
- Lanzadores de señuelos que posee, posición en el buque y señuelos cargados en ellos.
- Superficie equivalente radar.

El modelo estructural del buque, define las dimensiones del casco (eslora, manga y francobordo), altura de mástiles y tamaños de las superestructuras (ver Figura 4-9).




Figura 4-9. Ejemplo de modelo estructural de buque

Las características de evolución, vienen determinadas por las curvas de evolución del buque y las tablas de aceleración y desaceleración. La colección de curvas de evolución de un buque están confeccionadas a diferentes velocidades y diferentes ángulos de timón o de caña y tienen las siguientes características (ver Figura 4-10)(Barbudo, 2004):

- Avance: distancia entre el punto de caída inicial (A) y el punto más alejado de la curva medido en sentido longitudinal al rumbo inicial (R_i).
- Traslado o apartamiento: separación lateral entre el rumbo inicial y cualquier punto de la curva.

- Diámetro táctico: traslado correspondiente al rumbo opuesto al rumbo inicial.
- Diámetro final: el correspondiente al final de la curva, cuando ésta tiende a ser una circunferencia.

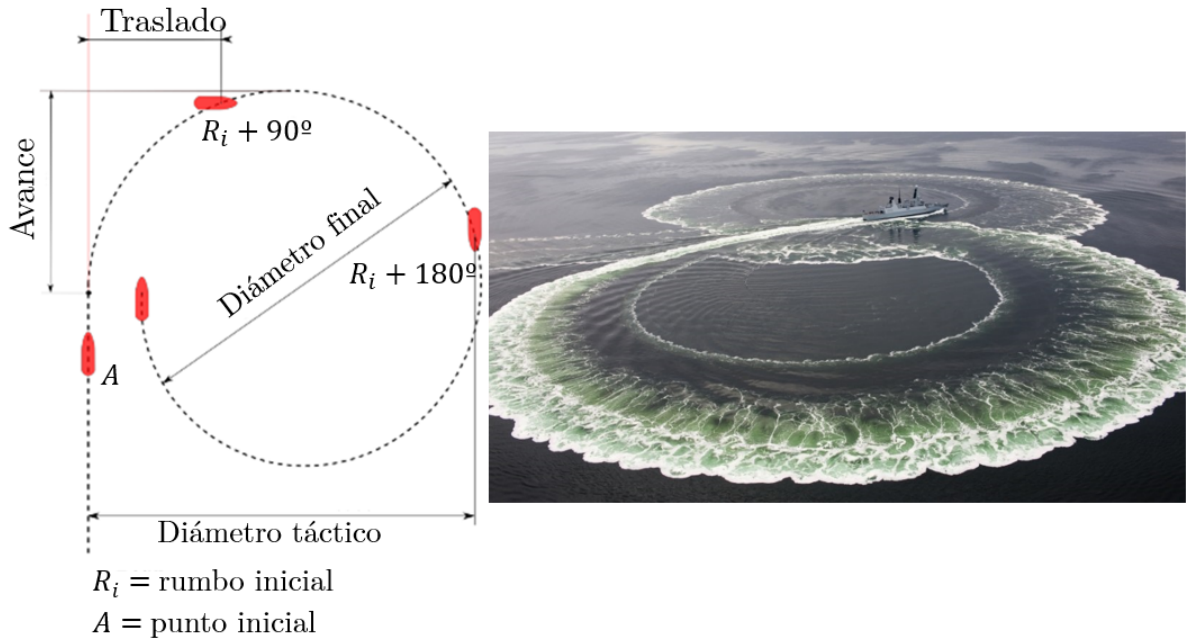


Figura 4-10. Características de la curva de evolución de un buque (izquierda) y estela dejada por un buque al ejecutar dos curvas completas (derecha)

El número de lanzadores de señuelos es otro de los atributos del buque, de los cuales es necesario especificar su posición respecto a un sistema de coordenadas y la marcación o ángulo respecto a la línea de crujía (eje longitudinal del buque). En la Figura 4-11 se puede observar la típica configuración de cuatro lanzadores para un buque de tipo medio.

Para este estudio se ha construido un modelo ficticio de buque de tamaño pequeño/medio, con cuatro lanzadores de señuelos y cuyos atributos se han incluido en la Figura 4-12. Hay que reseñar, que aunque la RCS se ha creado de forma aleatoria, y por lo tanto, no corresponde a ningún buque de la Armada, los valores que se han generado han sido coherentes con un buque moderno y la forma es la típica, con valores de pico o puntos calientes en los traveses, popa y proa. Tampoco aquí se incluyen los valores de la RCS por cuestiones de confidencialidad.




Figura 4-11. Configuración de lanzadores de señuelos del buque de la simulación

4.3.2. El objeto misil

La definición de los misiles dentro del escenario se realiza de forma similar a como se definen los buques.

De esta manera se indica en el escenario el tipo de misil empleado y su posición inicial desde el buque por marcación y distancia.

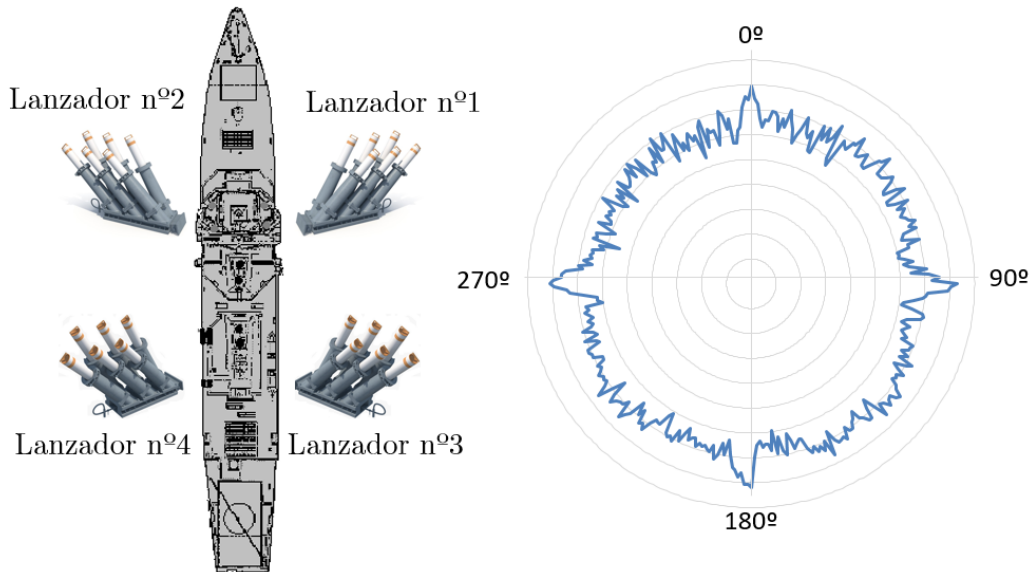
El resto de los parámetros son los atributos propios del misil y se definen en un fichero aparte, asociado al tipo de misil empleado. Sus características o atributos vienen dados por:

- La altura de vuelo.
- La velocidad de vuelo.
- Los atributos del radar seeker.

En relación con el radar buscador o *seeker*, sus atributos vienen dados por los parámetros de configuración de la celda de resolución, que tal y como se expuso en el punto 3.2.7, son los siguientes (ver Figura 4-13):

- Ancho de la celda o puerta de distancias (ΔR).
- Ancho del haz en acimut o apertura angular horizontal de la celda ($\Delta\theta_{AZ}$).
- Ancho del haz en elevación o apertura angular en elevación de la celda ($\Delta\theta_e$).

En este trabajo se ha modelado un misil antibuque transónico y rozaolas. Además para configurar los atributos de la celda de resolución del radar *seeker*, se han tomado los valores medios de la Tabla 3-1, implementado una apertura angular horizontal y en elevación de 4° y un ancho de la puerta de distancias de $5,5 \mu s$ equivalente a 165 m.



Datos estructurales:

Eslora: 100 m; Manga: 11 m; Francobordo: 6 m
 Superestructura: Longitud: 50 m; Ancho: 11 m; Alto: 6 m

Figura 4-12. Atributos del modelo buque para el estudio. Lanzadores, datos estructurales y forma de la RCS (no se incluye los valores de la RCS por cuestiones de confidencialidad)




Figura 4-13. Atributos de la celda de resolución del radar seeker del misil

4.3.3. El objeto señuelo

Los señuelos van a ser asignados a la simulación, en un momento determinado, a través del buque como plataforma lanzadora. ALSA dispone de una serie de archivos de configuración de los señuelos, que contienen los atributos de cada uno de los tipos disponibles. Entre las características propias para cada señuelo están las siguientes:

- El tiempo de vuelo, desde el lanzamiento hasta que comienza el despliegue.

Capítulo 4. Modelado, simulación y resultados de las baterías de experimentos

- La distancia de despliegue contada desde el buque.
- La altura de despliegue.
- La velocidad de caída.
- Su tamaño una vez desplegado (radio de la esfera).
- La superficie equivalente radar.

Los señuelos se modelan como bolas esféricas, considerando que mantienen su forma sin deformación una vez desplegados y que se apagan cuando se hunden completamente en el agua. Podemos describir su movimiento en 5 fases:

Fase #0. Dentro del lanzador.

Fase#1. Lanzamiento.

Fase#2. Despliegue/activación.

Fase#3. Periodo de efectividad.

Fases#4. Apagado.

Durante la Fase#0 el señuelo se considera una parte más del buque, y se trata como tal. En cada paso de simulación, al propagar el movimiento del buque, únicamente la simulación comprueba si hay que efectuar un lanzamiento de señuelos. En las Fases#1, 2 y 3 el objeto se trata como un objeto dependiente del escenario, al mismo nivel que un buque o un misil, y puede afectar a otras instancias. Finalmente, en la Fase#4 el señuelo deja de afectar a los demás elementos, y por lo tanto, deja de contabilizarse en la simulación, quedando únicamente almacenados sus datos para el procesado final.

Para este trabajo se ha modelado un señuelo tipo chaff con los parámetros contenidos en la Tabla 4-1, obtenidos de fuentes abiertas y de los valores generales de la Tabla 3-3. En concreto, se ha utilizado como base del modelo el chaff Mk36 type1 de la empresa Chemring Countermeasures (Chemring countermeasures, 2013).

Tabla 4-1. Valores de los atributos del señuelo

Atributo	Valor
Tiempo de vuelo	3,5
Distancia de despliegue	145 m
Altura de despliegue	90 m
Velocidad de caída	0,5 m/s
Radio de la esfera	10 m
Superficie equivalente radar	15 000 m ²

4.3.4. Meteorología

El simulador implementa un sencillo modelo meteorológico capaz de suministrar información relativa a la velocidad y dirección del viento, que se mantendrán invariantes durante el tiempo de simulación del escenario.

4.3.5. Modelo del algoritmo de guiado del misil. Efecto centroide

En el punto 2.2.3 se describió el proceso o mecanismo de la seducción del misil mediante señuelos, denominado efecto centroide, donde la superficie equivalente radar del buque y del señuelo juega un papel fundamental para el engaño del misil.

El efecto centroide es el que utiliza ALSA y en general los simuladores navales, para modelar el algoritmo de guiado de un misil (Ayling, Butters, Millwood, & Walmsley, 2008; Z. S. Li, Sun, Xu, Du, & Xu, 2009). Este mecanismo analiza la señal de RCS y fija el centro de la celda de resolución del misil, en el punto medio de toda la energía recibida, tanto en distancia (R), en marcación (θ_{AZ}) y elevación (θ_e).

Así, el centro de la celda en distancia ($R_{centroid}$), en marcación ($\theta_{AZ-centroid}$) y en elevación ($\theta_{e-centroid}$) respecto al misil, viene dada por las siguientes ecuaciones:

$$R_{centroid} = \frac{\int_{R_{min}}^{R_{max}} RCS(R) \cdot R \cdot dR}{\int_{R_{min}}^{R_{max}} RCS(R) \cdot dR} \quad (4-3)$$

$$\theta_{AZ-centroid} = \frac{\int_{\theta_{AZ_{min}}}^{\theta_{AZ_{max}}} RCS(\theta_{AZ}) \cdot \theta_{AZ} \cdot d\theta_{AZ}}{\int_{\theta_{AZ_{min}}}^{\theta_{AZ_{max}}} RCS(\theta_{AZ}) \cdot d\theta_{AZ}} \quad (4-4)$$

$$\theta_{e-centroid} = \frac{\int_0^{\Delta\theta_e} RCS(\theta_e) \cdot \theta_e \cdot d\theta_e}{\int_0^{\Delta\theta_e} RCS(\theta_e) \cdot d\theta_e} \quad (4-5)$$

donde los valores de R_{max} , R_{min} , $\theta_{AZ_{max}}$ y $\theta_{AZ_{min}}$, tal y como se puede observar en la Figura 4-14, se obtienen a partir de los atributos ancho de la puerta de distancias (ΔR) y apertura angular horizontal ($\Delta\theta_{AZ}$). El valor $\Delta\theta_e$ corresponde al parámetro de apertura angular en elevación de la celda.

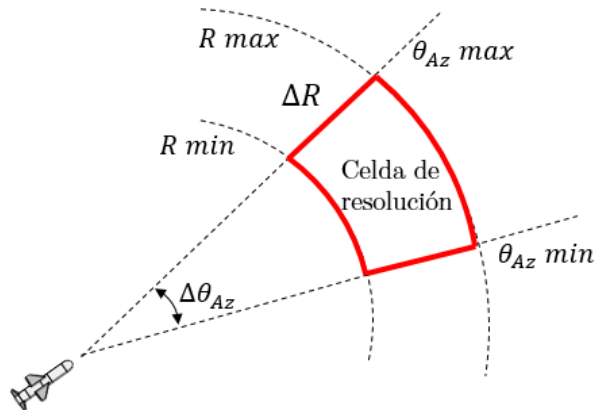


Figura 4-14. Celda de resolución de misil en 2D

4.4. IMPLEMENTACIÓN DE UN NUEVO MODELO DE SUPERFICIE EQUIVALENTE RADAR EN ALSA

Para la implementación en el simulador de lanzamiento de señuelos ALSA de un nuevo modelo estocástico de RCS basado en una distribución Weibull, ha sido necesario modificar su código fuente, que como se expuso en el punto 4.3 está programado en C#.NET. Con este objetivo, se analizó el generador de números aleatorios imple-

mentado en este lenguaje de programación y se añadieron las líneas de código necesarias para generar observaciones de una variable aleatoria de distribución de probabilidad Weibull.

4.4.1. Generación de números aleatorios en C#.Net

En simulación, cuando se trabaja con modelos estocásticos, es imprescindible conocer el algoritmo generador de números aleatorios, para poder conocer su funcionamiento, sus ventajas y limitaciones, por lo que estudiaremos qué tipo implementa la plataforma C#.NET.

C# es un lenguaje orientado a objetos y se ejecuta en el ecosistema de .NET, que es un sistema de ejecución virtual denominado *Common Language Runtime* (CLR) con un conjunto unificado de bibliotecas de clases. Esto significa que todos los servicios disponibles en la plataforma .NET aparecen para C# como clases nativas, por lo que pueden utilizarse directamente (Charte, 2002). Una de ellas es la clase *System.Random()*, que es un generador de números pseudo aleatorios.

La implementación actual de la clase *Random()* se basa en un generador de Fibonacci retardado, en concreto se trata de una modificación del algoritmo generador de números aleatorios sustractivos de Knuth, que utiliza unos valores de $(r, s) = (55, 34)$, por lo que según lo expuesto en el punto 4.2.4, tendrá un periodo largo de $2^{55} - 1$.

Además, esta clase permite al usuario especificar una semilla personalizada o utilizar *Environment.TickCount* como predeterminado, que es un número entero de 32 bits, que contiene el tiempo en milisegundos que transcurrió desde la última vez que se inició el equipo. Esta propiedad de la clase se ha utilizado para evitar que diferentes réplicas de un mismo escenario, se ejecuten con la misma secuencia de números pseudo aleatorios.

4.4.2. Generación de observaciones de variables aleatorias. Distribución Weibull

Existen varios métodos para generar observaciones de variables aleatorias, entre los que podemos citar (Reza & García, 1996):

- Método de la transformación inversa.
- Método de convolución.

- Método de aceptación y rechazo.
- Método directo.

Para seleccionar el método óptimo, entre los arriba mencionados, existen una serie de criterios que deben tenerse en cuenta para la toma de la decisión (Law & Kelton, 2000; Urquía, 2005):

- **Exactitud.** Es evidentemente deseable que el método seleccionado proporcione observaciones de la variable aleatoria con la mejor aproximación posible a la distribución de probabilidad deseada. Indiscutiblemente, se producirán inexactitudes en la generación de números aleatorios, existirán limitaciones de precisión en el ordenador que ejecuta la simulación, etc., por lo que, todo ello, deberá tenerse en cuenta y determinar si el resultado es válido para nuestro marco experimental.
- **Eficiencia.** Un factor clave, sobre todo en simulaciones muy pesadas, es que el algoritmo sea de ejecución rápida y que no necesite un elevado espacio de memoria.
- **Complejidad.** Es deseable que el algoritmo sea conceptualmente sencillo y fundamentalmente su programación en el código del simulador no resulte compleja.
- **Robustez.** El algoritmo debería ser eficiente para cualquier valor admisible de los parámetros de la distribución de probabilidad.

En nuestro caso, se ha utilizado el método de la transformación inversa, por lo que pasaremos, en primer lugar, a describir el marco teórico del método y posteriormente, expondremos las razones que han llevado a la elección de este procedimiento y describiremos cómo se ha realizado su implementación en el simulador ALSA.

Con la aplicación de este método, se consiguen generar observaciones de la variable aleatoria X con función de distribución conocida $F(x)$, que es una función continua y estrictamente creciente para todos los valores de x , tales que $0 < F(x) < 1$. El método consiste en los siguientes pasos:

- Generar un número pseudo aleatorio $u \in U[0,1]$.

- Devolver $x = F^{-1}(u)$, donde F^{-1} es la función inversa de la función de distribución $F(x)$. Así podemos definir la función inversa como:

$$F^{-1}(u) = \inf\{x: F(x) \geq u\}, \forall 0 \leq u \leq 1 \quad (4-6)$$

donde se observa que la función anterior, devuelve para un valor $u \in [0,1]$, el valor de la variable X que primero acumula una probabilidad mayor o igual a u (ver Figura 4-15).

Este método, permite de forma sencilla aplicarse también a distribuciones truncadas al intervalo $[a, b]$, aplicando los siguientes pasos (Law & Kelton, 2000):

- Generar un número pseudo aleatorio $u \in U[0,1]$.
- Calcular:

$$v = F(a) + (F(b) - F(a)) \cdot u \quad (4-7)$$

- Devolver $x = F^{-1}(v)$




Figura 4-15. Método de la transformación inversa.

Generación de observaciones de una distribución de Weibull

Para nuestro caso, ha sido necesario generar observaciones procedentes de una distribución de Weibull de la que se conocen, mediante estimadores de máxima verosimilitud, los parámetros de escala $\alpha > 0$ y de forma $\beta > 0$. Para generar dichas observaciones, se ha utilizado el método de la transformación inversa, por las siguientes razones:

- La distribución de Weibull permite el cálculo directo de la inversa de la función de distribución.
- El algoritmo requiere sólo un número aleatorio para cada observación generada.
- Utiliza poca capacidad de almacenamiento, ya que no necesita almacenar la tabla de la función de distribución.
- Para nuestro experimento, permite generar observaciones para cualquier combinación de los parámetros α y β .
- La implementación del algoritmo en código C# es sencilla, mediante unas pocas líneas de código.

Así, a partir de la función de densidad de una variable aleatoria X con distribución de Weibull $X \sim W(\alpha, \beta)$ descrita en el punto 3.5.1, se obtiene su función de distribución $F(x)$ y su función inversa:

$$F(x) = \begin{cases} 0 & \text{si } x < 0 \\ 1 - e^{-(x/\alpha)^\beta} & \text{si } x \geq 0 \end{cases} \Rightarrow F^{-1}(u) = \alpha[-\ln(1-u)]^{1/\beta} \quad (4-8)$$

Aplicando este método, se han implementado en el simulador 360 distribuciones de Weibull diferentes, para generar observaciones independientes de la superficie equivalente radar para cada grado de marcación del buque $[0^\circ, 359^\circ]$, quedando así modelada la RCS del barco de forma realista.

Para implementar la generación estocástica de los datos de RCS del señuelo en la simulación, se ha utilizado el mismo método. Partiendo de la función de densidad de la distribución Swerling II de media μ , descrita en el punto 3.5.1, se obtiene la función de distribución y a continuación su función inversa:

$$F(x) = \begin{cases} 0 & \text{si } x < 0 \\ 1 - e^{-x/\mu} & \text{si } x \geq 0 \end{cases} \Rightarrow F^{-1}(u) = -\mu \ln(1 - u) \quad (4-9)$$

En este caso, al considerarse el señuelo una esfera, solamente se ha implementado una función para todas las marcaciones.

Generación de observaciones de una distribución empírica

En la metodología para el modelado de la superficie equivalente radar en blancos complejos diseñada en el capítulo anterior, se establece que en caso de no adecuarse ninguna distribución de probabilidad conocida a los datos, debería utilizarse distribuciones empíricas. Por consiguiente, es necesario arbitrar un método para la generación de observaciones en este caso.

En esta situación, pueden generarse observaciones de una distribución empírica, con observaciones individuales x_1, x_2, \dots, x_n , de la siguiente forma (Law & Kelton, 2000; Urquía, 2005):

- Generar un número pseudo aleatorio $u \in [0,1]$.
- Ordenar de forma creciente los datos de las observaciones individuales $x_{(1)}, x_{(2)}, \dots, x_{(i)}, \dots, x_{(n)}$, donde $x_{(i)}$ representa la observación en el puesto i .
- Obtener:

$$x = x_{(i)} + (p - i + 1) \cdot (x_{(i+1)} - x_{(i)}) \quad (4-10)$$

donde:

$$\begin{aligned} p &= (n - 1) \cdot u \\ i &= [p] + 1 \end{aligned} \quad (4-11)$$

y donde $[p]$ representa el mayor entero que es menor o igual que el número real p .

4.5. BATERÍAS DE EXPERIMENTOS Y RESULTADOS DE LA SIMULACIÓN

4.5.1. Escenarios

El escenario es la unidad básica de la simulación en ALSA y está compuesto por:

- Un misil amenaza definido por su tipo y por la posición inicial, esta última dada por la marcación y la distancia al blanco.
- Un buque definido también por su tipo y por su velocidad.
- Una serie de señuelos que serán lanzados por el buque y están definidos por su tipo.
- Unas condiciones atmosféricas, que vienen dadas por una velocidad y dirección del viento.

Los tipos de misiles, buques y señuelos están modelados en los ficheros de configuración de cada uno de ellos, que contienen sus atributos, que a su vez son características globales independientes del escenario concreto que se esté ejecutando.




Figura 4-16. Combinación de lanzadores y maniobras del buque

En un escenario se ejecutan todas las posibles reacciones del buque ante el misil amenaza, para determinar cuáles son válidas. Siendo las posibles reacciones todas aquellas combinaciones entre los lanzadores y las posibles caídas de rumbo.

En nuestro trabajo, se ha modelado un buque con cuatro lanzadores y se fijaron tres posibles maniobras en el momento del lanzamiento: mantenerse a rumbo, caer a estribor 30° o caer a babor 30°. Por lo que el número total de posibles soluciones son: 4 lanzadores x 3 maniobras = 12 soluciones (ver Figura 4-16).

4.5.2. Baterías de experimentos

ALSA dispone también de lo que se denomina baterías de experimentos, en las que se ejecutan sucesivos escenarios, donde se va variando secuencialmente ciertos parámetros de la simulación, dentro de un margen e intervalo de variación previamente fijado (ver Figura 4-17). Estos parámetros variables son los siguientes:

- La velocidad del buque (V_{buque}).
- La posición inicial del misil: marcación (B_{misil}) y distancia (D_{misil}).
- El viento: dirección (B_{viento}) y velocidad (V_{viento}).

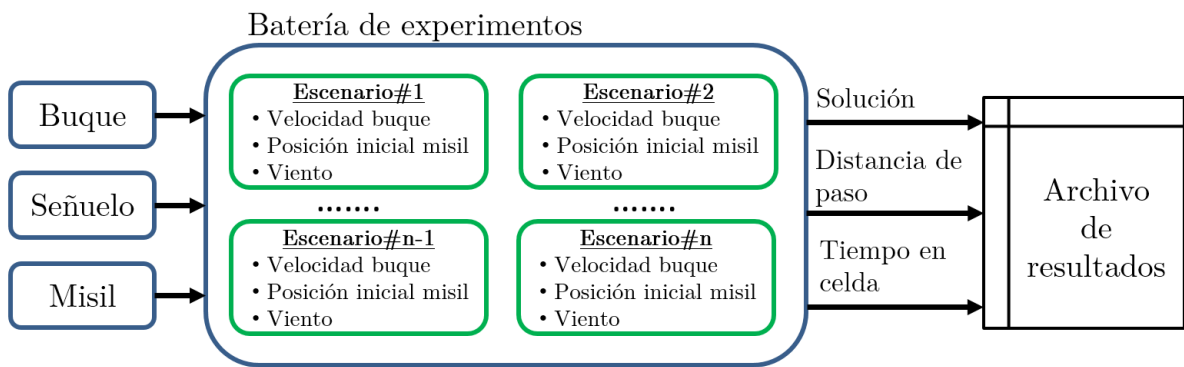


Figura 4-17. Batería de experimentos, escenarios y archivos de resultados

En la Figura 4-18 se puede observar gráficamente cómo se miden las variables marcación inicial del misil y dirección del viento.

De la ejecución de una batería de experimentos, para cada posible solución (combinación de lanzador y maniobra), se almacenan los parámetros de los escenarios y las siguientes medidas de eficacia:




Figura 4-18. Marcación del misil y dirección del viento

- Solución. Si ha habido impacto del misil o no.
- Distancia de paso. Mínima distancia de paso entre el misil y el buque cuando no ha habido impacto.
- Tiempo en celda. Proporción del tiempo del escenario en el que el buque ha estado dentro de la celda de resolución del misil.

Para este estudio, se ha configurado en el simulador la batería de experimentos con los datos que figuran en la Tabla 4-2, lo que da lugar a un total de 186 624 escenarios, que al disponer de 12 posibles soluciones por escenario, se obtienen un conjunto total de 2 239 488 instancias.

Tabla 4-2. Parámetros de configuración de las baterías de experimentos

Parámetros del escenario	Valores
Velocidad del buque (V_{buque})	10, 15, 20 nudos
Velocidad del viento (V_{viento})	0, 10, 20, 30 nudos
Dirección del viento (B_{viento})	[0°-355°] saltos 5°
Distancia inicial del misil (D_{misil})	5000, 10000, 15000 yardas
Marcación inicial del misil (B_{misil})	[0°-355°] saltos 5°

4.5.3. Cálculo de las réplicas necesarias

La implementación en ALSA de un modelo de RCS basado en distribuciones de probabilidad, implica que se ha incluido un componente estocástico al sistema y por lo tanto producirá salidas aleatorias. Es por ello, que una réplica de cada escenario es insuficiente para obtener conclusiones válidas, y por consiguiente, es necesario aplicar técnicas de muestreo para determinar cuál es el número mínimo de ellas que deben realizarse, para alcanzar un grado de confianza determinado en los datos de salida.

Dado que no existía una fuerte restricción en el tiempo disponible, se realizaron 30 réplicas piloto de la batería de experimentos y posteriormente se comprobó si estas eran suficientes para acotar el error de la media en las variables de salida del sistema.

Para realizar estos cálculos, se programó un script en MATLAB que analizase de forma automática los valores estadísticos de las réplicas en las 2 239 488 instancias, correspondientes a las tres variables de salida expuestas en el punto anterior:

- Variable binaria. Solución: Impacto/fracaso:0; No impacto/éxito: 1.
- Variable real: Distancia de paso.
- Variable real: Tiempo en celda.

Al tener la muestra piloto un tamaño grande (30 réplicas), para obtener el mínimo número de réplicas necesarias (n), se aplicaron las siguientes ecuaciones basadas en la distribución normal (Rodríguez Osuna, 2001, 2005; Spiegel & Stephens, 2009):

$$n \cong \frac{z^2 S^2}{e^2} \text{ (para las variables reales)} \quad (4-12)$$

$$n \cong \frac{z^2 pq}{e^2} \text{ (para la variable binaria)} \quad (4-13)$$

donde S^2 y pq corresponden a la varianza muestral de las variables reales y binaria respectivamente, e es el error en el muestreo y z es el valor de la variable $N(0,1)$. Para todas las variables se ha tomado un valor de $z = 1,65$; equivalente a un nivel de significación de $\alpha = 0,1$ o lo que es lo mismo, un nivel de confianza del 90%.

Los errores en el muestreo utilizados y los resultados del valor de n obtenidos para todas las instancias se incluyen en la Tabla 4-3, donde se puede observar que el tamaño muestral de 30 es suficiente para acotar el error de la media en los términos fijados.

Tabla 4-3. Errores en el muestreo tomados para las variables y resultados

Variable	Error en el muestreo (e)	Valor más alto de n en todas las instancias
Solución	0,1	29
Distancia de paso	50 yardas	11
Tiempo en celda	0,1	27

4.5.4. Generación del conjunto de datos

Una vez finalizadas todas réplicas de la batería de experimentos, fue necesario generar el conjunto de datos o *dataset* que sirviese para el entrenamiento de un modelo de inteligencia artificial, encargado de obtener las soluciones de lanzamiento de señuelos.

Para ello, se generaron dos matrices o conjuntos de datos: una matriz de variables de entrada y una matriz de variables de salida. De tal forma que en cada una de ellas, cada fila representase a una muestra o instancia, es decir, una posible solución de un escenario determinado.

Tal y como se expuso en el punto 4.5.2, al ejecutarse un total de 186 624 escenarios, con 12 posibles soluciones por escenario, se obtienen un conjunto total de 2 239 488 instancias, que es número de filas de las matrices del *dataset*.

En la **matriz de las variables de entrada** se incluyen los datos del escenario, el lanzador utilizado en la reacción y la maniobra o cambio de rumbo ejecutado (ver Tabla 4-4).

Tabla 4-4. Datos de la matriz de las variables de entrada

Datos	Unidades
Velocidad del buque (V_{buque})	Nudos
Velocidad del viento (V_{viento})	Nudos
Dirección del viento (B_{viento})	Grados
Distancia inicial del misil (D_{misil})	Yardas
Marcación inicial del misil (B_{misil})	Grados
Lanzador empleado (L)	1, 2, 3 o 4
Caída de rumbo o maniobra del buque (C)	30°Br, 0°, 30°Er

La **matriz de variables de salida** contiene los siguientes datos (ver Tabla 4-5):

- **Solución.** Especifica si para ese escenario y con esa reacción del buque se consigue seducir al misil (no impacto/éxito = 1) o no (impacto/fracaso = 0). Este valor de la variable se marcará como 1 (no impacto), si existe al menos una réplica exitosa en la instancia.
- **Distancia de paso.** Es la media de la distancia de paso de la instancia, contabilizando solo aquellas réplicas con éxito en la solución (no impacto).
- **Tiempo en celda.** Es la media del tiempo en celda, tomando solo aquellas réplicas de la instancia con éxito en la solución (no impacto).
- **Probabilidad de éxito.** del misil. Contabiliza la proporción de soluciones exitosas del total de las 30 réplicas de la instancia, lo cual nos dará una estimación de la probabilidad de éxito de la reacción.

En las simulaciones llevadas a cabo en el estudio para el buque, misil y señuelo ficticios, el 63% del total de reacciones fueron éxitos (no impacto) y en todos los escenarios simulados se ha obtenido al menos una solución válida.

Tabla 4-5. Datos de la matriz de las variables de salida

Datos	Unidades
Solución (S)	Binario
Distancia de paso (D_{paso})	Yardas
Tiempo en celda (T_{celda})	Proporción del tiempo total del escenario (sin unidades)
Probabilidad de éxito ($P_{éxito}$)	Probabilidad. Sin unidades

4.5.5. Análisis gráfico de los resultados de la simulación

Una vez obtenidos los resultados de la simulación y construido el *dataset* o conjunto de datos, se realizó un análisis gráfico de las soluciones catalogadas como éxito (no

impacto). Esto permitió obtener una visión más clara del problema y además servir como información inicial para elaborar las funciones de utilidad que se implementaron en el gestor de soluciones, que se expone en el próximo capítulo.

En concreto se realizó un análisis gráfico de los siguientes parámetros y variables de salida:

- Marcación y distancia inicial del misil.
- Marcación y velocidad del viento y velocidad del buque
- Lanzador empleado.
- Distancia de paso del misil, tiempo en celda y probabilidad de éxito de la solución.

Marcación y distancia inicial del misil

Para estos dos parámetros, se construyeron las gráficas de la Figura 4-19, en donde la escala radial en el gráfico polar y el eje de ordenadas en el diagrama de barras, muestra la media de las soluciones alcanzadas por escenario para cada marcación/distancia inicial del misil. Señalar que, como se expuso anteriormente, el número máximo de soluciones posibles por escenario es de 12.

Para el caso de las marcaciones del misil, se observa en la gráfica de la izquierda que se pierde eficacia en la proa, popa, través de babor y de estribor, que coincide con los picos o punto calientes de la RCS del buque.

En la gráfica de la derecha se puede apreciar que mejora el ratio de soluciones por escenario a medida que aumenta la distancia inicial del misil, es decir, una reacción lo más temprana posible y presentar un aspecto con la menor RCS, mejorará la eficacia de los señuelos.

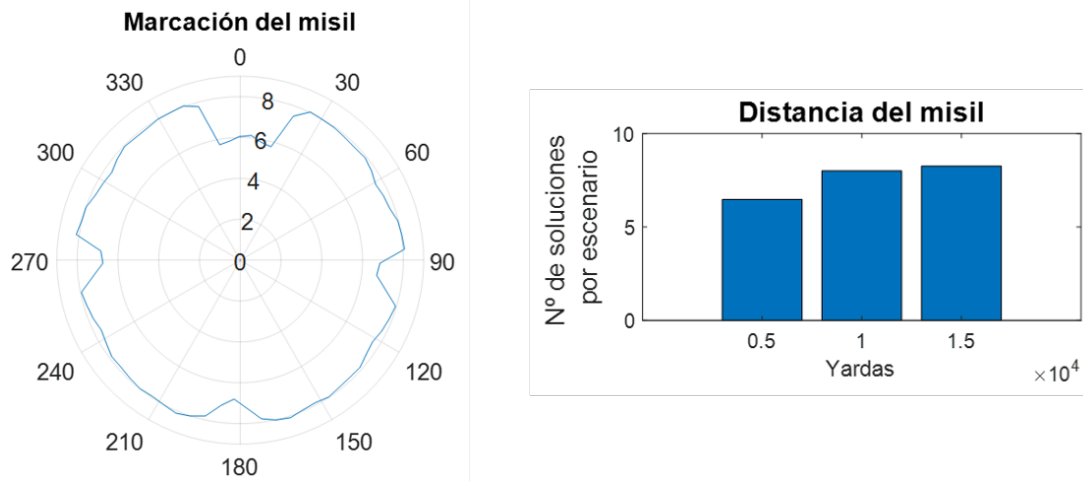


Figura 4-19. Media del número de soluciones válidas por escenario para diferentes marcaciones (izquierda) y distancias (derecha) iniciales del misil

Marcación y velocidad del viento y velocidad del buque

Según se aprecia en la gráfica de la Figura 4-20, aumentan los ratios de soluciones válidas por escenario con valores altos de la velocidad del viento y marcaciones proeles. Así mismo, también se consiguen mejoras al incrementar la velocidad del buque.

Todos estos factores están relacionados. Los vientos proeles, junto con una alta velocidad del buque, generan mayores vientos relativos¹¹, lo que ocasiona que la velocidad de alejamiento señuelo/buque sea mayor y por lo tanto se consigue un mayor número de soluciones válidas por escenario.

Por consiguiente, el escenario ideal corresponde a aquel que tenga un viento de alta intensidad con marcación proel, pudiendo el buque aumentar la efectividad incrementando su velocidad, todo ello encaminado conseguir el mayor viento relativo posible.

¹¹ El viento relativo es el que percibimos a bordo de un barco navegando. Siempre se encuentra más cerca de la proa que el viento real al ser la suma vectorial del viento real con el vector velocidad el buque.

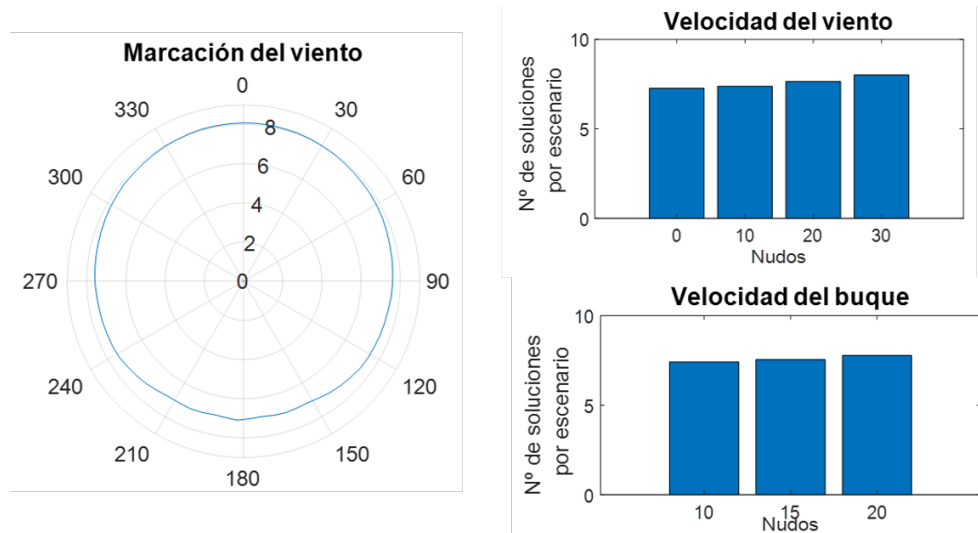


Figura 4-20. Media del número de soluciones válidas por escenario para diferentes marcaciones de viento (izquierda), para diferentes velocidades del viento (derecha/arriba) y diferentes velocidades del buque (derecha/abajo)

Lanzadores empleados

Para analizar con qué lanzadores se han obtenido un mayor número de soluciones, se construyó el diagrama de barras de la Figura 4-21, donde en el eje de abscisas figuran los lanzadores del buque y en el eje de ordenadas la media del número de soluciones por escenario y lanzador. Hay que reseñar que para cada lanzador, el máximo número de soluciones por escenarios es de tres, correspondientes a las opciones: caídas de rumbo a babor o estribor o no efectuar caída de rumbo.

Se observa que los lanzadores proeles n^o 1 y 2, son los que alcanzan un mayor número de soluciones. Esto está relacionado con lo expuesto en el apartado anterior en relación con el viento relativo.

Dicho viento es el que genera el movimiento aparente señuelo/buque y se encuentra más cerca de la proa que el viento real. Esto ocasiona que, generalmente una reacción con lanzadores proeles permitirá al señuelo desfilarse de proa a popa del buque, otorgarle más probabilidades de posicionarse dentro de la celda de resolución del misil y por lo tanto de completar con éxito la seducción.




Figura 4-21. Media del número de soluciones válidas por escenario para cada lanzador

Distancia de paso del misil, tiempo en celda y probabilidad de éxito de la solución

Para estas variables de salida del simulador se ha realizado un análisis gráfico mediante los correspondientes histogramas (ver Figura 4-22) y un somero análisis descriptivo (ver Tabla 4-6).

Para la distancia de paso del misil, podemos apreciar en su histograma una fuerte asimetría positiva, con el pico entorno a las 200 yardas (2 esloras del buque). Por otra parte, de los datos estadísticos es destacable que en el 25% de las soluciones la distancia de paso del misil ha sido menor de 169 yardas.

Asimismo, en la variable proporción del tiempo en celda se aprecia, en los datos estadísticos y en el histograma, una distribución simétrica y platicúrtica de los datos.

En la variable probabilidad de éxito, los datos obtenidos presentan una asimetría negativa muy pronunciada, donde el 90% de las soluciones tienen una probabilidad de éxito mayor de 0,8.

Tabla 4-6. Datos estadísticos descriptivos de las variables

	Distancia de paso del misil (yardas)	Proporción de tiempo en celda	Probabilidad de éxito
Media (\bar{x})	474	0,4943	0,8970
Primer cuartil (Q_1)	169	0.3153	0,8667
Mediana (M_e)	351	0,4965	0,9333
Tercer cuartil (Q_3)	652	0,6627	0,9666

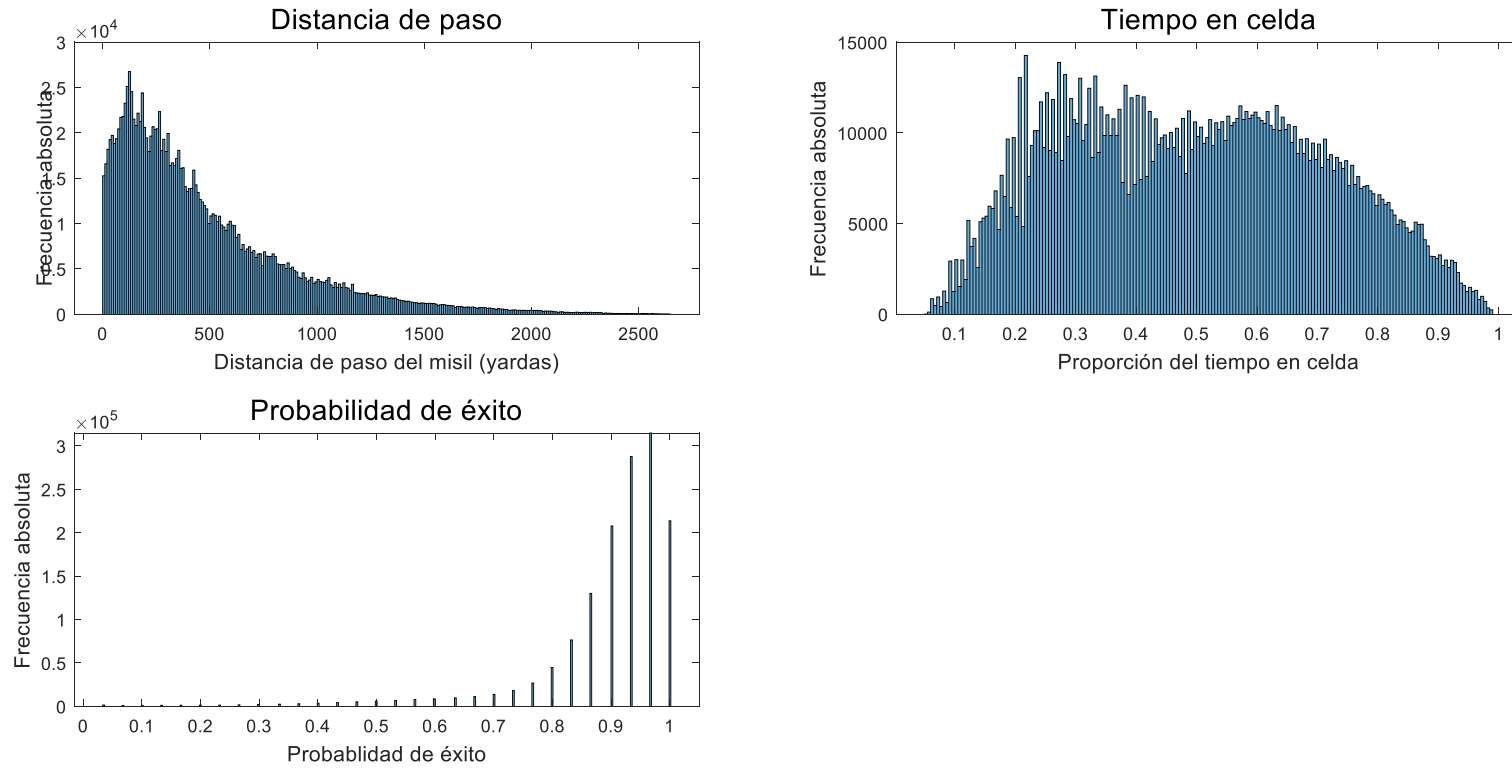


Figura 4-22. Histogramas: distancia de paso del misil, tiempo en celda y probabilidad de éxito

CAPÍTULO 5. IMPLEMENTACIÓN DE UN MODELO DE INTELIGENCIA ARTIFICIAL PARA LA SOLUCIÓN DE LANZAMIENTO

5.1. INTRODUCCIÓN

A partir de los datos obtenidos en la simulación descrita en el capítulo anterior, construiremos un modelo de inteligencia artificial (IA) que pueda ser implementado en el buque y obtenga las soluciones de lanzamiento de señuelos en cualquier escenario posible. Así, para la implementación del modelo que resuelva el problema, se han seguido las siguientes premisas:

- Deberá obtener una solución lo más precisa posible.
- Deberá obtener la solución de lanzamiento en el menor tiempo posible.
- Deberá obtener todas las soluciones existentes para un escenario y además calcular otra información relevante como la distancia de paso del misil respecto del buque y el tiempo que el misil tendrá fijado en su radar al buque hasta que se transfiera a los señuelos.
- Deberá ser implementable en el buque sin esfuerzo.
- Deberá ser escalable, es decir deberá contemplar a posibilidad de obtener las reacciones de lanzamiento para varios tipos de misiles.

En este capítulo, comenzaremos definiendo la inteligencia artificial desde diferentes enfoques y cuáles son sus ramas o dominios, describiremos diferentes aspectos, formas de entrenamiento y métricas de evaluación de un modelo del aprendizaje automático y a continuación expondremos, de manera formal, las técnicas que se han empleado en este trabajo: máquinas de vectores soporte y redes neuronales.

Posteriormente, y aplicando directamente los datos disponibles obtenidos de la simulación, describiremos la secuencia de pasos realizados para resolver el problema de la selección del modelo óptimo de IA, como se efectuó su entrenamiento, cuál es la solución final alcanzada y su comportamiento.

A la finalización de esta fase del trabajo debemos estar en condiciones de aplicar un gestor de soluciones a las salidas del modelo de IA escogido, para ordenar las soluciones del escenario, obtener la mejor solución posible y presentarle al usuario final la información evaluada.

5.2. INTELIGENCIA ARTIFICIAL. DEFINICIÓN.

El término Inteligencia Artificial (*artificial intelligence*: AI), fue acuñado por John McCarthy, en su propuesta para la Conferencia de Dartmouth de 1956, considerada como la primera conferencia sobre inteligencia artificial.

Hoy en día existen multitud de definiciones de inteligencia artificial. El propio McCarthy definió la AI como la ciencia y la ingeniería de hacer máquinas inteligentes, E. Rich (Rich, 1983) la define como el estudio que trata de hacer que los ordenadores hagan cosas que los humanos hacemos mejor.

Sin embargo, quizás la definición más exhaustiva de la inteligencia artificial es la recogida por Russel y Norvig (Russel & Norvig, 2010), que abordan esta cuestión desde cuatro enfoques diferentes y que veremos a continuación.

En la Figura 5-1 se observan estos cuatro enfoques de la inteligencia artificial dispuestas en dos dimensiones: las definiciones superiores están relacionadas con los procesos de pensamiento y razonamiento, mientras que las inferiores se ocupan del comportamiento humano. Las definiciones de la izquierda se centran en los rasgos que nos hacen humanos y las de la derecha se enfocan en lo que se denomina la racionalidad, considerando que un sistema es racional si hace lo correcto (Russel & Norvig, 2010).

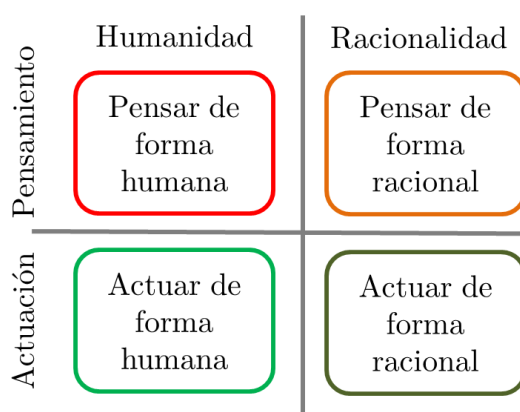


Figura 5-1. Enfoques de la inteligencia artificial según Russel y Norvig

Pasemos a definir con más detalle cada una de estas cuatro aproximaciones a la definición de la IA.

- **Los sistemas que piensan de forma humana** automatizan actividades como la toma de decisiones, la resolución de problemas y el aprendizaje.

Este enfoque ha dado lugar a la ciencia cognitiva, campo interdisciplinar que reúne modelos computacionales de la IA y técnicas experimentales de la psicología para construir teorías comprobables y precisas de la mente humana.

- **Los sistemas que actúan de forma humana** son computadoras que realizan tareas de forma similar a como lo hacen las personas.

Este es el enfoque del Test de Turing (Turing, 1950), por el que una inteligencia artificial pasaría el test cuando después de un tiempo realizándole preguntas un interrogador humano experimentado, la IA es capaz de engañarle haciéndole pensar que es humano o bien éste no es capaz de determinar si se trata o no de un computador. En este caso la computadora necesitaría poseer las siguientes capacidades:

- Procesamiento del lenguaje natural para permitirle comunicarse con éxito en inglés (o en algún otro idioma humano).
 - Representación del conocimiento para almacenar la información proporcionada antes o durante el interrogatorio.
 - Razonamiento automatizado para usar la información almacenada para responder preguntas y sacar nuevas conclusiones.
 - Aprendizaje automático para adaptarse a las nuevas circunstancias y para detectar y extrapolar patrones.
- **Los sistemas que piensan de forma racional** intentan emular el pensamiento lógico racional de los humanos. En este campo se investiga cómo lograr que las máquinas puedan percibir, razonar y actuar en consecuencia.

El desarrollo de la lógica formal a finales del siglo XIX y principios del XX, proporcionó una notación precisa para las afirmaciones y las relaciones entre ellas. En 1965, existían programas que podían, con tiempo y memoria suficiente, tomar una descripción de un problema en notación lógica y encontrar la solución

al problema si existe (si no hay solución, el programa podría nunca dejar de buscarla). La llamada tradición logicista dentro de la inteligencia artificial espera basarse en tales programas para crear sistemas inteligentes.

- **Los sistemas que actúan de forma racional** idealmente, son aquellos que tratan de imitar de manera racional el comportamiento humano.

De la misma manera que no hay una sola definición, tampoco hay consenso en cuanto a las ramas en las que podemos dividir la inteligencia artificial. No obstante podemos considerar los siguientes dominios como las principales disciplinas (ver Figura 5-2): aprendizaje automático (*machine learning*), aprendizaje profundo (*deep learning*), sistemas expertos, optimización, robótica, representación de conocimiento, procesamiento del lenguaje natural y visión artificial. Sin embargo, estas ramas no son compartimentos estancos, sino que existen ciertas relaciones entre ellas, por ejemplo, las redes neuronales convolucionales para reconocimiento de imágenes forman parte del aprendizaje automático, aprendizaje profundo y visión artificial.

En este estudio nos centraremos exclusivamente en la rama del aprendizaje automático o *machine learning*, ya que son las técnicas que se han empleado en la generación de los modelos para la solución del problema de lanzamiento de señuelos.

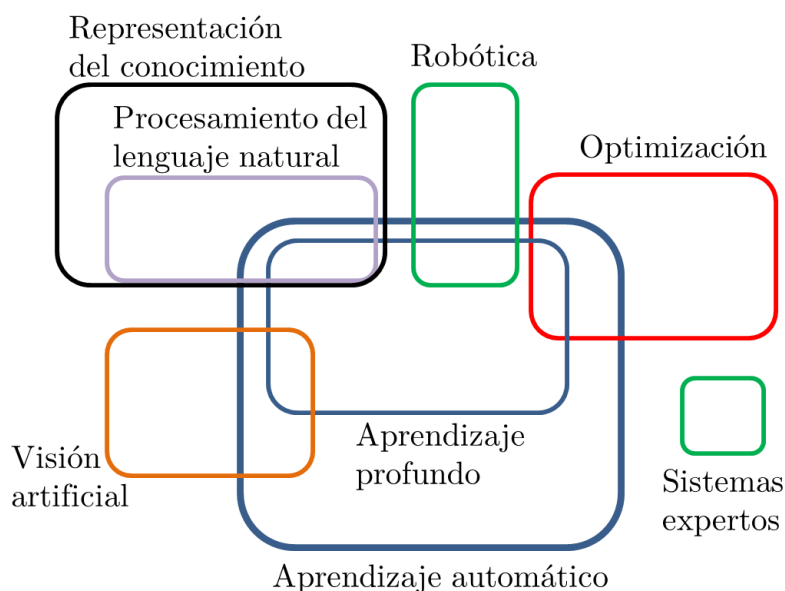


Figura 5-2. Dominios de la inteligencia artificial

5.3. APRENDIZAJE AUTOMÁTICO

En inteligencia artificial, podemos definir el aprendizaje como el procedimiento, por el cual, un ordenador es capaz de mejorar su capacidad de resolver un problema mediante la adquisición de conocimiento a través de la experiencia (Mitchell, 1997).

El aprendizaje automático o *machine learning* (ML) es una rama de la inteligencia artificial que está diseñada para aprender a realizar tareas que hasta ahora solo las realizaban los humanos, de tal forma que son capaces de aprender de los datos, que intrínsecamente contienen la información de la experiencia.

Los algoritmos de aprendizaje automático utilizan métodos computacionales para aprender obteniendo información directamente de los datos, sin depender de una ecuación predeterminada como modelo, mejoran su rendimiento de forma adaptativa a medida que aumenta el número de muestras disponibles para el aprendizaje y son capaces de encontrar patrones naturales, generando conocimiento y proporcionando apoyo en la toma de decisiones y predicciones. En definitiva, es la técnica, que de alguna manera, permite a un ordenador programarse a sí mismo para resolver un problema.

Es evidente, que para que el aprendizaje automático sea correcto, es decir, que sea capaz de generalizar a partir de ejemplos concretos, es necesario disponer de un volumen de datos suficientemente grande que denominaremos conjunto de entrenamiento o *dataset*. Si el conjunto de entrenamiento no es suficiente, estaríamos expuestos a que errores o ruido en los datos ocasionen un resultado poco fiable (Berzal, 2019b).

Hoy en día es una tecnología que nos permite analizar y obtener información de grandes volúmenes de datos, automatizar y eliminar tareas repetitivas mediante el aprendizaje, realizar mejores predicciones en diferentes ámbitos, reconocimiento de imágenes, procesamiento del lenguaje natural, etc. Concluyentemente, es ya una herramienta esencial de apoyo a la decisión en la industria y en la empresa civil, en campos tan variados como la logística, la gestión de personal, la medicina, la seguridad o las finanzas.

Indiscutiblemente, el potencial de la IA y en concreto del aprendizaje automático es enorme, sin embargo, en el ámbito militar y en concreto en la Armada está poco desarrollado, por lo que es necesario empezar a abrir campos de aplicación en el terreno militar y aprovechar las capacidades que ofrece para mejorar el apoyo a la

decisión, tanto en el ámbito operativo de la Fuerza, como el logístico (Horowitz, Kahn, & Mahoney, 2020; Lesinski & Corns, 2018).

5.3.1. Técnicas de aprendizaje automático

El aprendizaje automático utiliza cuatro grandes enfoques (ver Figura 5-3):

- Aprendizaje supervisado.
- Aprendizaje no supervisado.
- Aprendizaje semisupervisado.
- Aprendizaje por refuerzo.

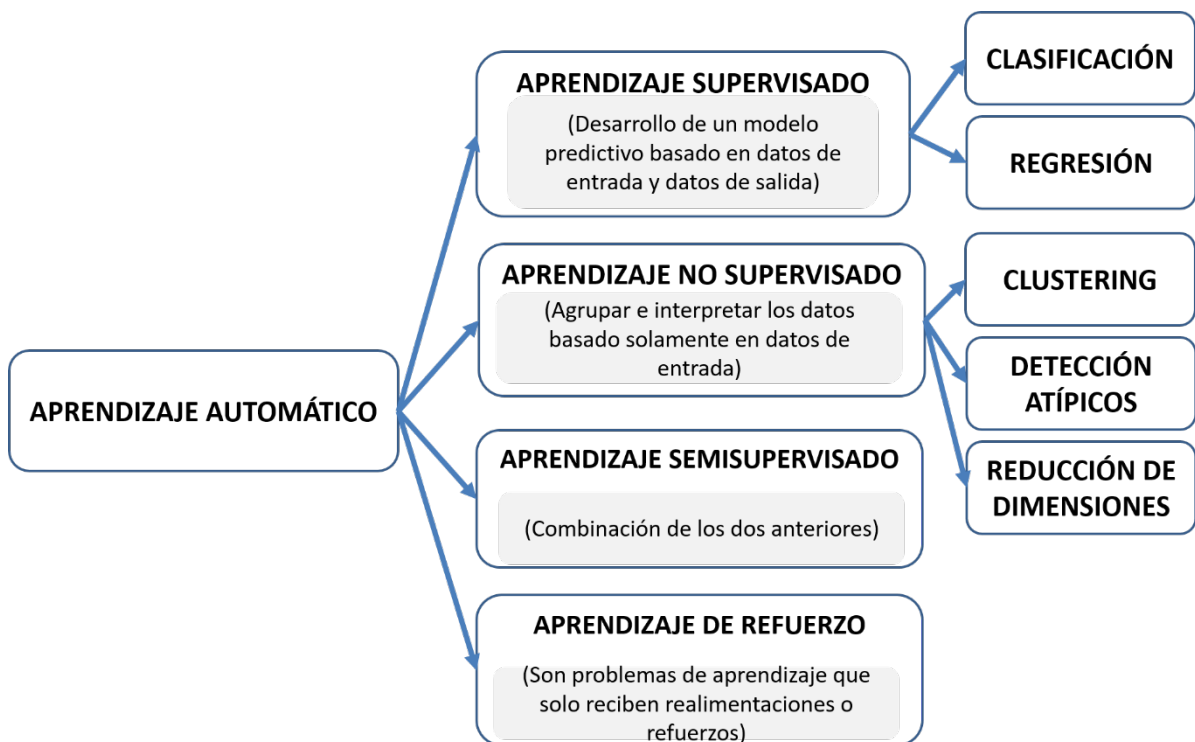


Figura 5-3. Técnicas de aprendizaje automático.

El **aprendizaje supervisado** tiene como objetivo construir un modelo que haga predicciones basadas en pruebas en presencia de incertidumbre. Un algoritmo de aprendizaje supervisado parte de un conjunto conocido de datos de entrada y de respuestas o datos de salida y entrena a un modelo para generar predicciones razonables para la respuesta a nuevos datos de entrada (ver Figura 5-4).

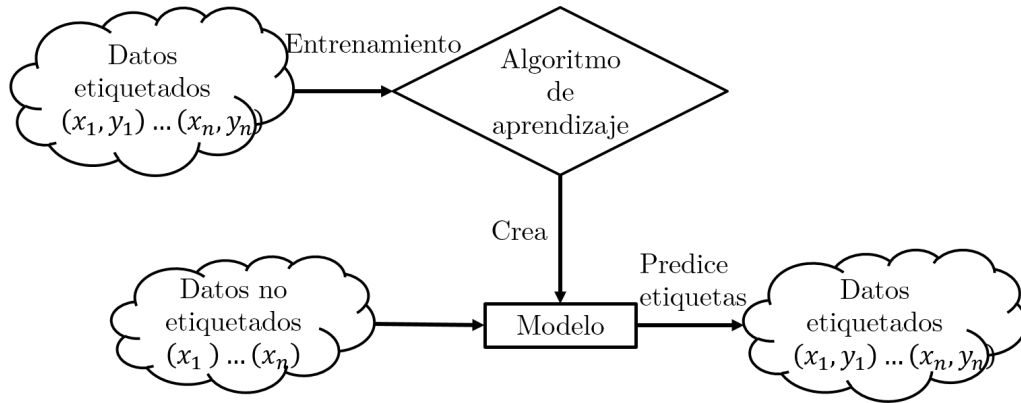


Figura 5-4. Esquema básico de aprendizaje supervisado

El aprendizaje supervisado utiliza técnicas de clasificación y regresión para desarrollar los modelos de predicción.

- Las técnicas de clasificación predicen respuestas discretas, por ejemplo, si un correo electrónico es auténtico o spam, o si un tumor es canceroso o benigno. En definitiva los modelos de clasificación catalogan los datos de entrada en categorías.

Existen dos tipos principales de clasificaciones: binarias, en el que solamente se pueden asignar dos clases (1 o 0) y multiclase, donde se pueden asignar múltiples categorías a las observaciones.

Los clasificadores, además de determinar la clase a la que pertenece un determinado ejemplo, pueden realizar una inferencia de la probabilidad de pertenencia a esa clase y por lo tanto también realizar una ordenación de las posibles clases de pertenencia en función de dicha probabilidad.

Algunas de las técnicas de clasificación son los árboles aleatorios o *random forest*, regresión logística, árboles de decisión, redes neuronales, vecinos más cercanos o *K-nearest neighbors* (KNN), máquinas de vectores soporte, etc.

- Las técnicas de regresión predicen respuestas continuas, por ejemplo, los cambios de temperatura, las fluctuaciones de demanda de energía, etc. Dentro de este grupo nos podemos encontrar los modelos de regresión lineal o no lineal, vecinos más cercanos, redes neuronales, máquinas de vectores soporte, árboles de regresión, etc.

El aprendizaje no supervisado encuentra patrones ocultos o estructuras intrínsecas en los datos. Se utiliza para hacer inferencias a partir de conjuntos de datos que no tienen etiquetadas las respuestas. Básicamente este tipo de aprendizaje se usa en la búsqueda de patrones o *clustering* (ver Figura 5-5), detección de atípicos o reducción de dimensiones (Patel, 2019).

Para la resolución de problemas de clustering nos podemos encontrar los modelos de K-medias, agrupamiento jerárquico o *hierarchical clustering analysis* (HCA), algoritmos basados en densidad o *density based spatial clustering of applications with noise* (DBSCAN), *expectation-maximization* (EM), etc. (C. C. Aggarwal & Reddy, 2014; Geron, 2017).

En el caso de problemas de detección de atípicos existen los modelos *autoencoder* o *local outlier factor* (LOF), mientras que para reducción de dimensiones tenemos las técnicas *autoencoder*, análisis de componente principales o *locally-linear embeddings* (LLE).

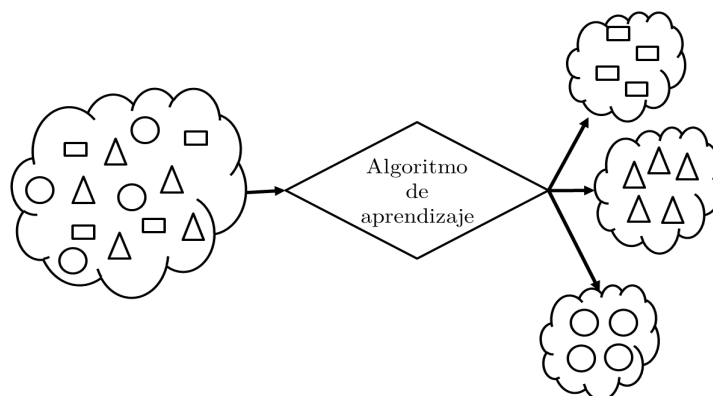


Figura 5-5. Esquema básico de aprendizaje no supervisado (*clustering*)

El aprendizaje automático semisupervisado es una combinación de métodos de aprendizaje automático supervisados y no supervisados (Geron, 2017). Se trata de un algoritmo que aprende de un conjunto de datos que incluye, tanto datos etiquetados como no etiquetados, generalmente en su mayoría no etiquetados (ver Figura 5-6). Se utiliza cuando no se dispone de suficientes datos etiquetados para producir un modelo preciso y no se tiene la capacidad o los recursos para obtener más datos, de este modo las técnicas semisupervisadas permiten aumentar el tamaño de los datos de entrenamiento.

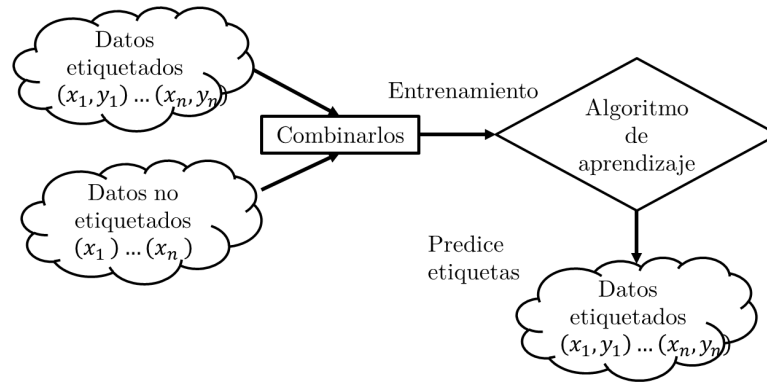


Figura 5-6. Esquema básico de aprendizaje semisupervisado

El aprendizaje por refuerzo es el más diferente de los anteriores, durante el aprendizaje solo reciben realimentaciones o refuerzos y tratan de maximizar dichas recompensas a lo largo del tiempo, por ejemplo, gana o pierde. En estos modelos se sustituye la información supervisada por información del tipo acción/reacción, se trata por lo tanto, de modelos que aprenden por ensayo/error (Russel & Norvig, 2010).

5.3.2. El problema del lanzamiento de señuelos. Aprendizaje supervisado

Para resolver el problema del lanzamiento de señuelos, disponemos de un conjunto suficientemente grande de datos procedentes de la simulación. En concreto, disponemos de dos conjuntos de datos o matrices: una matriz de variables de entrada y una matriz de variables de salida. En definitiva, tenemos una muestra de cómo se comporta el sistema en un número elevado de escenarios, es decir poseemos un conjunto de datos etiquetados.

El objeto de este trabajo consiste en desarrollar un modelo de aprendizaje automático o *machine learning* (ML) que, entrenado a partir de los datos obtenidos en la simulación, obtenga para cualquier escenario qué reacciones del buque permiten seducir al misil. Además, el modelo debe obtener otros datos: la distancia de paso esperada del misil, el porcentaje del tiempo de enfrentamiento que el buque estará dentro de la celda de resolución del misil hasta completar la seducción con los señuelos y la probabilidad de éxito de cada posible solución de lanzamiento. Todos estos datos alimentarán a un gestor de soluciones para ordenar las soluciones válidas, determinar cuál es la mejor y presentar al operador la información evaluada.

La arquitectura general del proceso sería la que se muestra en la Figura 5-7, donde en el laboratorio en tierra se simularían un número elevado de escenarios, para obtener

un conjunto de datos con el que entrenar a un modelo de *machine learning*, que implementado a bordo del buque, nos permita obtener la mejor solución de lanzamiento.

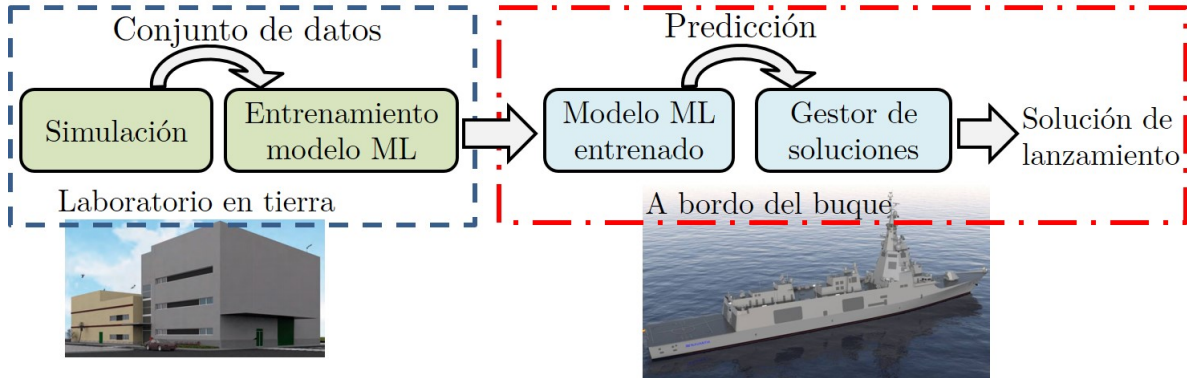


Figura 5-7. Proceso para la obtención de la solución de lanzamiento

El proceso de construcción, validación y puesta en producción de nuestro modelo de inteligencia artificial requerirá de un ciclo continuo de creación, despliegue y mejora (ver Figura 5-8). En este estudio nos centraremos en las cinco primeras fases del proceso hasta la implantación a bordo, es decir las acciones que debería llevar a cabo el laboratorio en tierra.




Figura 5-8. Proceso cíclico de la inteligencia artificial

Uno de los puntos clave del proceso es seleccionar el algoritmo adecuado de inteligencia artificial o aprendizaje automático en nuestro caso. Para ello, será necesario probar y comparar el comportamiento de diferentes modelos para escoger el más adecuado en cada caso concreto. Este comportamiento estará condicionado por el conjunto de datos disponibles, la complejidad y tipo del problema a resolver, si las diferentes clases son o no linealmente separables, o se trata de un problema de regresión o clasificación.

En este trabajo se han seleccionado dos técnicas diferentes como candidatas para resolver el problema del lanzamiento de señuelos: máquinas de vectores soporte y redes

neuronales, de las cuales describiremos el marco conceptual matemático a lo largo de este capítulo.

5.4. ENTRENAMIENTO Y EVALUACIÓN EN APRENDIZAJE AUTOMÁTICO

Antes de introducir los fundamentos matemáticos formales de los modelos de aprendizaje automático empleados en este trabajo, es necesario describir una serie de conceptos y técnicas utilizadas para evaluar el resultado del aprendizaje de dichos modelos.

5.4.1. Entrenamiento, validación y prueba del modelo

Para entrenar y comprobar la efectividad del modelo se utiliza un conjunto de datos o *dataset*, que a su vez se compone de una serie de instancias o registros. Dicho conjunto de datos será necesario dividirlo, a su vez, en dos conjuntos:

- **Conjunto de entrenamiento**

Constituye la parte del conjunto de datos que se utilizará para el entrenamiento del modelo. Normalmente no excede del 80% del total de los datos disponibles.

En ocasiones se suele extraer de este conjunto lo que se denomina conjunto de validación y que se utiliza para proporcionar una evaluación del ajuste del modelo, mientras se calculan los hiperparámetros durante el entrenamiento (G. James, Witten, Hastie, & Tibshirani, 2017).

- **Conjunto de prueba o test**

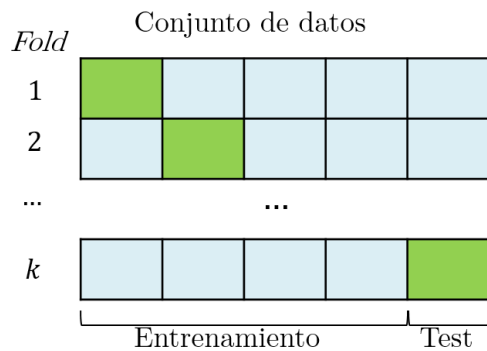
El método habitual y más sencillo, para estimar cómo de eficiente es la predictiva de un modelo de aprendizaje automático ya entrenado, se basa en la medida del error que comete sobre un conjunto de datos, que no se ha utilizado durante el proceso de entrenamiento. Es decir, con este método se separan un conjunto de muestras del conjunto inicial y se reservan para comprobar el grado de generalización del modelo ya entrenado. Este conjunto se denomina conjunto de test o conjunto *hold-out*.

5.4.2. Validación cruzada

La validación cruzada *k-fold* consiste en dividir los datos disponibles en k subconjuntos de aproximadamente el mismo tamaño muestral. Así, de forma sistemática se crean y evalúan diferentes modelos sobre los diferentes subconjuntos del conjunto de datos disponible. De esta manera, al repetir varias veces el proceso de entrenamiento y de prueba del modelo con diferentes datos se consigue, mediante métodos estadísticos, una estimación más fiable del error. El proceso de validación cruzada sigue los siguientes pasos (Berzal, 2019a):

Paso#1. Se divide el conjunto de datos en k conjuntos disjuntos de igual tamaño.

Paso#2. Se toma uno de los k subconjuntos como conjunto de prueba y se utilizan los $k - 1$ restantes como conjunto de entrenamiento (ver Figura 5-9).



Existen algunas variantes a este procedimiento como el método *leave-one-out* (LOO), o la validación cruzada estratificada.

En nuestro caso, al disponer de un número elevado de muestras en el conjunto de entrada se utilizará un procedimiento similar al de validación cruzada, tal y como veremos más adelante.

Figura 5-9. Representación del método de validación cruzada

5.4.3. Métricas de evaluación del modelo

Las métricas de evaluación nos indicarán la bondad de las predicciones del modelo y serán diferentes para los clasificadores y los regresores.

Métricas para clasificadores.

La mejor manera de evaluar un clasificador es observar lo que se denomina matriz de confusión (ver Figura 5-10), que muestra para una fila cualquiera i y una columna j , la proporción de instancias que pertenece a la clase i y está etiquetada como la clase j . La diagonal proporciona la proporción de clasificación correcta para cada clase (Berzal, 2019a; Geron, 2017).

		Predicción				
		1	2	3	4	5
Clase real	1	1600 20.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%
	2	0 0.0%	1579 19.7%	0 0.0%	1 0.0%	163 2.0%
	3	0 0.0%	0 0.0%	1600 20.0%	0 0.0%	3 0.0%
	4	0 0.0%	0 0.0%	0 0.0%	1525 19.1%	40 0.5%
	5	0 0.0%	21 0.3%	0 0.0%	74 0.9%	1394 17.4%

Figura 5-10. Matriz de confusión para un clasificador multiclase

En el caso concreto de un clasificador binario, que es uno de los modelos utilizado en este trabajo, se tienen dos clases que denominaremos clase positiva (P) y clase negativa (N). Cuando se aplica este modelo de clasificación sobre un conjunto de datos, se obtienen cuatro posibilidades de clasificación que se representan en la matriz de confusión de la Figura 5-11 (Berzal, 2019a), donde:

- Verdaderos positivos (*true positives*: TP): es la cantidad de ejemplos de la clase positiva que fueron clasificados correctamente como positivos.
- Verdaderos Negativos (*true negatives*: TN): es la cantidad de ejemplos de la clase negativa que fueron clasificados correctamente como pertenecientes a la clase negativa.
- Falsos positivos (*false positives*: FP): es la cantidad de ejemplos de la clase negativa que fueron clasificados erróneamente como perteneciente a la clase positiva.
- Falsos negativos (*false negatives*: FN): es la cantidad de ejemplos de la clase positiva que fueron clasificados erróneamente como perteneciente a la clase negativa.

		Predicción	
		Positiva	Negativa
Clase real	Positiva	TP	FN
	Negativa	FP	TN

Figura 5-11. Matriz de confusión para un problema de clasificación binaria

A partir de la matriz de confusión, se pueden calcular una serie de métricas para la evaluación general del modelo. La métrica más empleada en modelos de aprendizaje supervisado de clasificación es la precisión o *accuracy*, que se define como:

$$\text{precisión (accuracy)} = \frac{TP + TN}{TP + TN + FP + FN} \quad (5-1)$$

De la misma manera podemos definir el error del modelo, que es el complementario de la precisión:

$$\text{error} = \frac{FP + FN}{TP + TN + FP + FN} = 1 - \text{precisión (accuracy)} \quad (5-2)$$

La métrica precisión o *accuracy*, es intuitiva y da una visión general del comportamiento del modelo. Sin embargo, en el caso de problemas con clases no balanceadas se suele recurrir a otro tipo de métricas sobre la matriz de confusión, *precision*¹², *recall* o recuerdo y especificidad:

$$\text{precision} = \frac{TP}{TP + FP} \quad (5-3)$$

$$\text{recall} = \frac{TP}{TP + FN} \quad (5-4)$$

$$\text{especificidad} = \frac{TN}{TN + FP}$$

¹² No debe confundirse esta medida *precision*, en inglés, con precisión (en español) o *accuracy*.

Curva Receiving Operating Curve (ROC)




Figura 5-12. Ejemplo de curva ROC

La curva ROC (Receiving Operating Curve) es una medida de precisión del clasificador, habitualmente empleada en clasificadores binarios (Berzal, 2019b; Fawcett, 2006). Es la curva que presenta el ratio de verdaderos positivos respecto al ratio de falsos positivos, variando el umbral de probabilidad de que cada muestra pertenezca a la clase positiva.

El área bajo la curva (*area under curve*: AUC), nos indica la precisión del modelo.

Si la curva sigue la diagonal (0,0) a (1,1) la clasificación del modelo es completamente aleatoria, la precisión del modelo es 0,5. Si la curva está por debajo de la diagonal la precisión del modelo es menor de 0,5. Si la curva está por encima de la diagonal la precisión es mayor de 0,5. En el caso de la Figura 5-12 la precisión del modelo es cercana a 0,9.

Métricas para regresores

Para mostrar las métricas utilizadas en los modelos de regresión, vamos a partir de un conjunto de datos etiquetados $\{(x_1, y_1), \dots, (x_i, y_i), \dots, (x_N, y_N)\}$ de tamaño N y cuyas respuestas del modelo vendrán dadas por $f(x_i)$.

La métrica más utilizada es el error cuadrático medio o *mean square error* (MSE), que viene dada por la siguiente fórmula (Berzal, 2019a):

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - f(x_i))^2 \quad (5-5)$$

Básicamente, esta métrica mide el error al cuadrado promedio de las predicciones, aunque tiene el inconveniente que en presencia de valores atípicos, pueden producir un sesgo en la métrica e infravalorar el ajuste del modelo.

Una variante al MSE es la raíz cuadrada del error cuadrático medio o *root mean square error* (RMSE), que permite medir el error en las unidades de los datos y por lo tanto ser más intuitiva.

Otra métrica utilizada es el coeficiente de determinación o R^2 , está relacionada con el MSE, aunque tiene la ventaja de que no está afectada por la escala de los datos y su valor estará siempre comprendido entre $[0,1]$. La forma de calcularlo es la siguiente:

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - f(x_i))^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (5-6)$$

5.4.4. Diagnóstico del modelo

Sobreajuste u *overfitting*

El sobreajuste u *overfitting* ocurre cuando el modelo no generaliza bien, aunque puede suceder que se ajuste muy bien a las muestras del conjunto de datos de entrenamiento. En este caso, podríamos decir que el modelo ha memorizado las muestras, pero no es capaz de hacer una predicción con otras entradas fuera del conjunto de entrenamiento. Cuando ocurre un sobreajuste se observa un error de entrenamiento bajo, en contraposición de un error alto sobre el conjunto de prueba.

Por el contrario puede darse el caso de infrajuste o *underfitting*, cuando el error del modelo es alto tanto en el entrenamiento como para el conjunto de prueba.

En la Figura 5-13 se puede observar la representación de los conceptos de infrajuste y sobreajuste en un modelo de regresión, donde los puntos representan al conjunto de datos y las líneas rojas los modelos construidos en cada caso.




Figura 5-13. Representación de infrajuste/sobreajuste para un modelo de regresión (Badillo et al., 2020)

Sesgo y varianza

El error cometido por el modelo tiene dos componentes denominados sesgo o *bias* y varianza, que definimos de la forma siguiente (Berzal, 2019b):

$$sesgo(x) = E(f(x)) - y \quad (5-7)$$

$$varianza(x) = E[(f(x) - E(f(x)))^2] \quad (5-8)$$

El sesgo o *bias* mide la desviación entre las predicciones del modelo y los datos de entrenamiento para diferentes conjuntos de entrenamiento. Un valor alto es indicador de una falta de flexibilidad del modelo.

Por otra parte, la varianza mide la variabilidad del modelo cuando lo entrenamos con conjuntos de datos diferentes. Un valor alto indica un exceso de flexibilidad del modelo.

Además, el error del modelo puede descomponerse en términos de sesgo y de la varianza (Berzal, 2019a; Reed & Marks, 1999):

$$error(x) = varianza(x) + sesgo^2(x) \quad (5-9)$$

Aunque la descomposición de la desviación del sesgo puede proporcionar información sobre la complejidad del modelo, puede tener un valor práctico limitado, ya que la descomposición de la desviación de la tendencia se basa en promedios con respecto a

los conjuntos de datos, mientras que en la práctica sólo se suele tener un único conjunto y habitualmente de limitado tamaño.

En caso de disponer de un gran número de conjuntos de entrenamiento independientes, la mejor opción consiste en combinarlos en un único gran conjunto de entrenamiento, que reduciría el nivel de sobreajuste para una complejidad de modelo dada (Bishop, 2006).

Si se dispone de un conjunto de entrenamiento grande, como es el caso de este trabajo, existe un mayor margen para obtener la varianza del modelo, que aportará información adicional sobre su comportamiento.

5.5. MÁQUINAS DE VECTORES SOPORTE

Las máquinas de vectores soporte o *support vector machines* (SVM) forman parte de las técnicas de aprendizaje supervisado y sirven tanto para clasificación como para regresión. En este punto, expondremos en primer lugar la teoría matemática para clasificadores y posteriormente la extenderemos a los regresores.

Las SVM pertenecen a la familia de clasificaciones lineales puesto que inducen separadores lineales o hiperplanos (Cortes & Vapnik, 1995). Los hiperplanos separadores tienen dos grandes debilidades: la exigencia de separabilidad lineal de la muestra y su carácter lineal, por lo que para extender el concepto SVM a clasificadores no lineales, se realiza una transformación del espacio de entrada, mediante funciones de kernel, a otro espacio de alta dimensionalidad en el que los datos son separables linealmente (Cristianini & Shawe-Taylor, 2000; Martinez, 2010) (ver Figura 5-14).




Figura 5-14. Transformación del espacio de entrada mediante una función del kernel

5.5.1. Clasificadores de margen máximo

La Figura 5-15a muestra un conjunto de datos linealmente separables, donde cualquiera de las líneas de decisión o hiperplanos representadas producen una separación perfecta entre las dos clases. Sin embargo, podemos apreciar que cualquier nueva instancia se clasificará mejor en la Figura 5-15b ya que el límite tiene una distancia o margen igual para ambas clases.

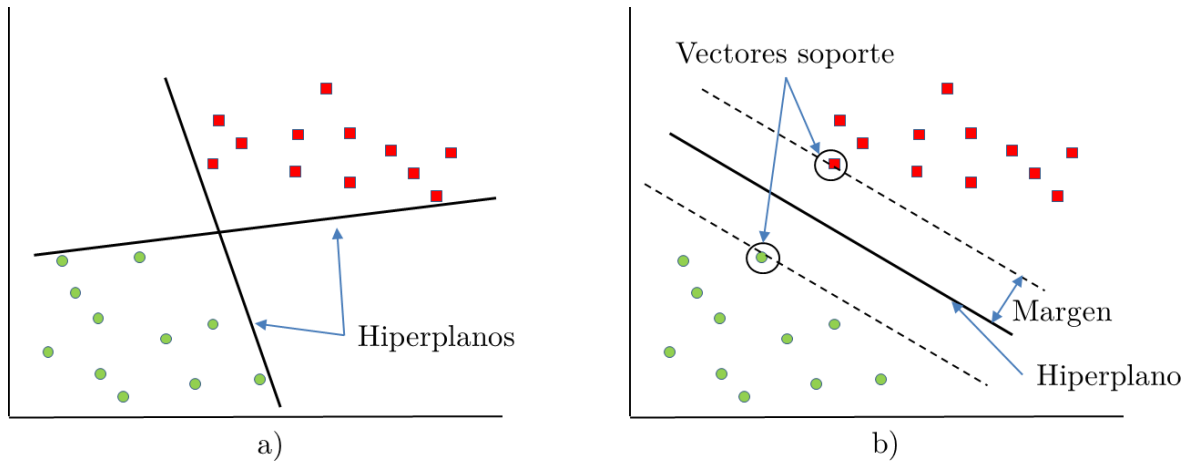


Figura 5-15. Clasificadores de margen máximo

Precisamente, este es el concepto con el que trabajan las máquinas de vectores soporte de margen máximo, buscar el hiperplano separador que esté a la misma distancia de los ejemplos más cercanos de cada clase. De manera equivalente, es el hiperplano que maximiza la distancia mínima entre los ejemplos del conjunto de datos y el hiperplano, Además, sólo considera los puntos que están en las fronteras de la región de decisión, denominándose a estos datos vectores soporte (Cristianini & Shawe-Taylor, 2000; Hernández, Ramirez, & Ferri, 2004).

Continuemos con el caso donde el conjunto de datos del espacio de entrada son linealmente separables. Este es el modelo más sencillo y aunque indiscutiblemente, presenta una aplicabilidad restringida, contiene las ideas subyacentes de la teoría de las SVM.

Si tenemos un conjunto de datos de entrenamiento $S = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)\}$ donde $\mathbf{x}_i \in \mathbb{R}^D$ e $y_i \in \{-1, 1\}$, el hiperplano de separación será una función lineal:

$$y(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b \tag{5-10}$$

donde $\mathbf{w} \in \mathbb{R}^D$ es el vector de pesos ortogonal al hiperplano y $b \in \mathbb{R}$ es el término de sesgo, que son los parámetros que debemos obtener para resolver el problema.

Este hiperplano de separación es el hiperplano medio de otros dos (h^+, h^-), formulados a continuación y que pasan por los vectores soporte (ver Figura 5-16):

$$\begin{aligned} h^+ &\rightarrow \mathbf{w}^T \mathbf{x}_i + b = +1 \\ h^- &\rightarrow \mathbf{w}^T \mathbf{x}_i + b = -1 \end{aligned} \tag{5-11}$$

que dan lugar a la condición: $y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1$

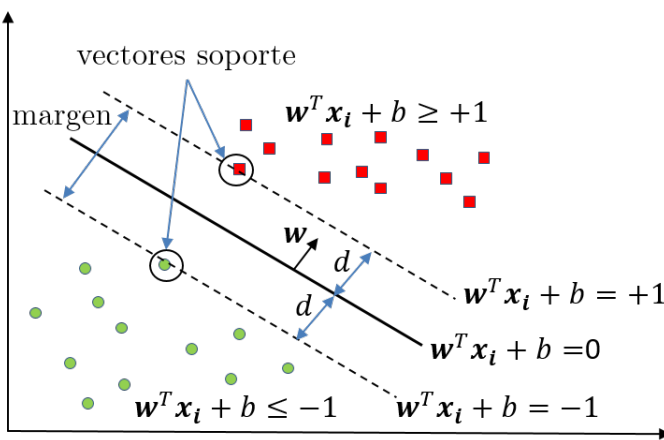


Figura 5-16. Hiperplano de separación, vectores soporte y margen

La distancia perpendicular de cualquier punto \mathbf{x}_i al hiperplano (h^+ o h^-) vendrá dada por:

$$\frac{|\mathbf{w}^T \mathbf{x}_i + b|}{\|\mathbf{w}\|} \tag{5-12}$$

Si dicho punto \mathbf{x}_i , pertenece al conjunto de vectores soporte, entonces $|\mathbf{w}^T \mathbf{x}_i + b| = 1$, por lo que el margen se puede calcular a partir de la distancia (d) a los hiperplanos h^+ y h^- :

$$d = \frac{1}{\|\mathbf{w}\|} \Rightarrow \text{margen} = 2d = 2 \frac{1}{\|\mathbf{w}\|} \tag{5-13}$$

Por lo tanto, debemos maximizar el margen, que viene dado por la expresión anterior, o lo que es lo mismo minimizar la norma del vector de pesos ($\min_{\mathbf{w},b} \|\mathbf{w}\|$).

La formulación más habitual de la SVM lineal y margen máximo en su formulación primal es la siguiente, que corresponde a un problema de optimización cuadrática:

$$\min_{\mathbf{w},b} \frac{1}{2} \|\mathbf{w}\|^2 \quad (5-14)$$

Sujeto a: $y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1, i = 1, 2, \dots, n$

5.5.2. Formulación dual de las SVM

El problema de optimización subyacente a las SVM anteriormente expuesto, cumple las condiciones de Karusk-Kuhn-Tucker (KKT), por lo que puede resolverse utilizando la función de Lagrange y resolver el problema dual del primal (Hernández et al., 2004; Smola & Schölkopf, 2004).

Dado un problema de optimización con función objetivo $f(\mathbf{x})$, con restricciones de igualdad $h(\mathbf{x}) = 0$ y desigualdad $g(\mathbf{x}) \leq 0$ se define la función de Lagrange como:

$$L(\mathbf{x}, \alpha, \beta) = f(\mathbf{x}) + \sum_i \alpha_i g(\mathbf{x}) + \sum_i \beta_i h(\mathbf{x}) \quad (5-15)$$

donde α_i y β_i son los multiplicadores de Lagrange. Por tanto, calculando la función Lagrangiana, a partir del problema primal (5-14), se obtiene el problema dual.

$$\max_{\alpha} \left(\sum_i \alpha_i - \frac{1}{2} \sum_i \sum_j \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \right) \quad (5-16)$$

Sujeto a: $\sum_i \alpha_i y_i = 0 ; \alpha_i \geq 0$

En este problema la solución viene dada como combinación lineal de los datos de entrenamiento, pero solo de aquellas en las que los multiplicadores de Lagrange sean mayores que cero ($\alpha > 0$), que corresponden precisamente a los vectores soporte.

5.5.3. Clasificadores de margen suave

En caso de que el conjunto de datos de entrenamiento no sea linealmente separable o contenga datos atípicos, el rendimiento de las SVM se degrada rápidamente. Para corregir este problema, se puede utilizar lo que se denomina margen suave o *soft margin*. La idea que subyace a este procedimiento, es relajar la condición del margen y permitir un conjunto de errores de clasificación dando mayor robustez al modelo (Cortes & Vapnik, 1995).

La suavización del margen se implementa en el problema de optimización mediante variables de holgura ($\xi_i \geq 0$)

$$\min_{\mathbf{w}, \xi} \left(\frac{1}{2} \|\mathbf{w}\|^2 + C \sum_i \xi_i \right) \tag{5-17}$$

$$\text{Sujeto a: } y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1 - \xi_i, \xi_i \geq 0, i = 1, 2, \dots, n$$

Este problema es también de optimización cuadrática con restricciones lineales, por lo que puede resolverse de la misma manera que el problema (5-14).

El valor de C indica el peso de la regularización, que expresa la importancia o coste de las instancias mal clasificadas. Un valor de C elevado implica un coste mayor en los datos de entrenamiento mal clasificados, por tanto una menor tolerancia a los errores y un margen más estrecho. Sin embargo, un valor pequeño de C supone un modelo más permisivo con los errores y un margen más ancho (Cestero & Caballero, 2018).

Este parámetro C se puede determinar mediante el método *grid* o búsqueda de cuadrícula, validación cruzada u otros métodos como optimización bayesiana (Czarnecki, Podlowska, & Bojarski, 2015; Wu et al., 2019).

5.5.4. Truco de kernel o kernel trick

Tal y como se ha expuesto en el punto anterior, mediante la aplicación del margen suave se puede solucionar el problema de la clasificación de un conjunto de datos no linealmente separable, sin embargo el problema sigue siendo lineal y de escasa utilidad en la práctica.

La solución a este problema consiste en realizar una transformación no lineal en el espacio de entrada a un espacio de características de alta dimensión, donde se pueda encontrar un hiperplano separador. Para conseguir esto reemplazaremos el producto escalar $\mathbf{x}_i^T \mathbf{x}_j$ en la ecuación (5-16) por una función $K(\mathbf{x}, \mathbf{z}) = \phi(\mathbf{x})^T \phi(\mathbf{z})$ denominada *kernel* o núcleo (Bishop, 2006; Boser, Guyon, & Vapnik, 1992; Huang, Kecman, & Kopriva, 2006), obteniendo así el siguiente problema:

$$\begin{aligned} & \max_{\alpha} \left(\sum_i \alpha_i - \frac{1}{2} \sum_i \sum_j \alpha_i \alpha_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j) \right) \\ & \text{Sujeto a: } \sum_i \alpha_i y_i = 0 ; \alpha_i \geq 0 \end{aligned} \tag{5-18}$$

Las funciones de *kernel* de propósito general más comúnmente utilizadas son las que figuran en la siguiente tabla:

Tabla 5-1. Funciones de kernel más comunes.

Polinómica	$K(\mathbf{x}, \mathbf{z}) = (\mathbf{x}, \mathbf{z})^d$
Gaussiana o de base radial	$K(\mathbf{x}, \mathbf{z}) = \exp \left(\frac{-\ \mathbf{x} - \mathbf{z}\ ^2}{2\gamma} \right) \quad \gamma > 0$
Cuadrático inverso	$K(\mathbf{x}, \mathbf{z}) = \frac{1}{\sqrt{\ \mathbf{x} - \mathbf{z}\ ^2 + c^2}} \quad c \geq 0$

De la misma manera, las funciones de *kernel* introducen nuevos hiperparámetros que pueden ser determinados mediante validación cruzada u otros métodos como optimización bayesiana.

5.5.5. Máquinas de vectores soporte de regresión

Los algoritmos de regresión SVM funcionan de forma similar a las SVM de clasificación, pero con ciertas modificaciones para poder predecir una respuesta continua. En lugar de encontrar un hiperplano que separa los datos, los algoritmos de regresión SVM busca un hiperplano que modele la tendencia de los datos, de tal manera que minimice su desviación (Gunn S.R., 1998).

Las SVM de regresión, buscan optimizar los límites de la regresión y se fundamentan en la definición de una función de pérdida, que ignora los errores a una cierta distancia del valor real. En la Figura 5-17 se muestra un ejemplo de función de regresión lineal con la función de pérdida llamada $\varepsilon - insensitive$ propuesta por Vapnik. En este algoritmo, se introducen unas variables de holgura (ξ), que miden el coste de los errores en los puntos de entrenamiento, siendo los valores de dichas variables cero para todos los puntos que se encuentran dentro de la banda $\pm\varepsilon$ (Cherkassky & Ma, 2004; Drucker, Surges, Kaufman, Smola, & Vapnik, 1997).

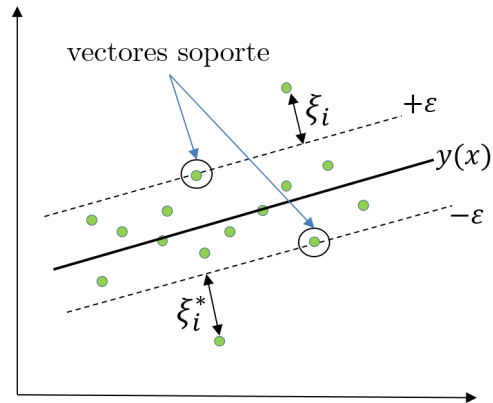


Figura 5-17. Hiperplano de regresión, vectores soporte, variables de holgura y margen $\varepsilon - insensitive$

Partiremos de un conjunto de datos de entrenamiento, que vienen dados por la función lineal:

$$y(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b \quad (5-19)$$

En el caso de las SVM de regresión, la calidad de la estimación vendrá dada por la función de pérdida $L(y, f(\mathbf{x}, \mathbf{w}))$, que el caso concreto de la función $\varepsilon - insensitive$ de Vapnik se formula de la forma siguiente:

$$L_\varepsilon(y, f(\mathbf{x}, \mathbf{w})) = \begin{cases} 0 & \text{si } |y - f(\mathbf{x}, \mathbf{w})| \leq \varepsilon \\ |y - f(\mathbf{x}, \mathbf{w})| - \varepsilon & \text{en otro caso} \end{cases} \quad (5-20)$$

Así, el hiperplano óptimo de la SVM de regresión, vendrá dado por el siguiente problema de minimización:

$$\min_{\mathbf{w}, \xi} \left(\frac{1}{2} \|\mathbf{w}\|^2 + C \sum_i (\xi_i^* + \xi_i) \right)$$

Sujeto a:

$$y_i - f(x_i, \omega) \leq \varepsilon + \xi_i^* \tag{5-21}$$

$$f(x_i, \omega) - y_i \leq \varepsilon + \xi_i$$

$$\xi_i, \xi_i^* \geq 0, i = 1, \dots, n$$

donde el valor de C indica el peso de la regularización y ξ_i^* , ξ_i son variables holgura que representan la desviación de los valores de entrenamiento respecto a los márgenes exteriores de zona $\varepsilon - insensitive$.

Para datos no lineales, al igual que para SVM de clasificación, mediante una función de kernel se realiza una transformación no lineal en el espacio de entrada, a un espacio de características de alta dimensión, donde se pueda encontrar un hiperplano de regresión.

Generalmente las máquinas de vectores soporte consiguen una precisión más alta en comparación con otros algoritmos de clasificación y suelen ser robustas a la presencia de ruido en los datos de entrenamiento. Sin embargo, el coste de entrenamiento es más alto y son difíciles de interpretar al estar basadas en transformaciones matemáticas para obtener clases linealmente separables (Berzal, 2019a).

5.6. REDES NEURONALES

El término red neuronal tiene su origen en los intentos de encontrar representaciones matemáticas de procesamiento de información en sistemas biológicos (McCulloch & Pitts, 1943; Minsky & Papert, 1969; Rosenblatt, 1962; D. E. Rumelhart & McClelland, 1988; Widrow & Hoff, 1960).

Una red neuronal artificial (*artificial neural network: ANN*) es un modelo computacional cuya estructura de capas de nodos conectados, se asemeja a la estructura interconectada de las neuronas en el cerebro. Una red neuronal puede aprender a partir de un conjunto de datos, de manera que se puede entrenar para que reconozca patrones, clasifique datos y pronostique eventos futuros. Una ANN es una estructura potente

que permite crear modelos de predicción no lineales y se utiliza en aprendizaje supervisado y no supervisado. En el caso de aprendizaje supervisado permite construir redes regresoras y clasificadoras binarias y multiclase.

La estructura básica de una red neuronal es la neurona (ver Figura 5-18) la cual se parece a una neurona biológica en su forma y función.




Figura 5-18. Similitudes entre: a) neurona biológica y b) neurona artificial

Las entradas (x_i) están conectadas a la neurona a través de conexiones ponderadas por los pesos (w_i) que emulan las dendritas, mientras que la suma (Σ), el sesgo (b) y la función de activación (h) juegan el papel del cuerpo celular y la propagación de la salida es análoga al axón en una neurona biológica. El comportamiento de la ANN está definido por la forma de las conexiones de sus neuronas o nodos y por los valores de los pesos de dichas conexiones. Estos pesos se ajustan automáticamente durante el entrenamiento de acuerdo con un algoritmo de aprendizaje hasta que la red neuronal lleva a cabo la tarea deseada correctamente (Award & Khanna, 2015).

Desde el punto de vista matemático una neurona o nodo es equivalente a la función:

$$y = h \left(\sum_{i=1}^n w_i x_i + b \right) \quad (5-22)$$

donde el sesgo (b) desplaza la función de activación hacia la derecha o la izquierda, según sea necesario para el aprendizaje, aunque puede omitirse en algunos casos.

Una red neuronal es simplemente una asociación de capas en cascada de neuronas, donde podemos distinguir los tres siguientes tipos de capas:

- Capa de entrada. Compuesta por las neuronas que van a recibir los datos del entorno.

- Capa de salida. Proporciona la respuesta de la red.
- Capa oculta. No tiene conexión directa con el entorno.

Las redes neuronales se pueden clasificar en función de lo que se conoce como arquitectura de la red, definiendo esta arquitectura en función de: a) el número de capas, b) el grado de interconexión de la estructura y c) el carácter de las conexiones. Así nos podemos encontrar los siguientes tipos de redes neuronales:

- **Según el número de capas**

Redes neuronales monocapa que solamente disponen de una capa de entrada y una capa de salida y redes neuronales multicapa que tienen una o más capas intermedias, denominadas capas ocultas.

- **Según el tipo de conexiones**

Existen redes neuronales unidireccionales, no recurrentes o *feedforward neural network (FNN)*, en donde la propagación de las señales se realiza en un solo sentido y redes neuronales recurrentes, que disponen de lazos de realimentación, que pueden ser entre la misma neurona, con neuronas de la misma capa o con neuronas de distintas capas.

- **Según el grado de conexión**

Las redes no recurrentes, en las que todas las neuronas de una capa se encuentran conectadas con las de la capa siguiente o las redes recurrentes en donde todas las neuronas están conectadas con las neuronas de la capa anterior se denominan redes totalmente conectadas. En caso de que no exista una conexión total entre neuronas de diferentes capas, se denominan redes neuronales parcialmente conectadas. El modelo de Hopfield y la máquina de Boltzmann son los más populares de esta clase.




Figura 5-19. Distintas arquitecturas: a) Red monocapa, b) Red multicapa totalmente conectada, c) Red recurrente

Por otra parte, en una red neuronal lo habitual es que todas las neuronas pertenecientes a una misma capa se actualicen a la vez, comenzando en la capa de entrada y continuando hasta la de salida, esto es lo que se conoce como dinámica síncrona en la red.

5.6.1. Perceptrón multicapa

El perceptrón multicapa (*multilayer perceptron*: MLP) o red multicapa con conexiones hacia adelante sin retroalimentación, es una clase de red neuronal del tipo *feed-forward neural network* (FNN). Tiene una arquitectura con un número finito de capas que, a su vez, contienen un número finito de neuronas. En esta estructura se distinguen tres tipos de capas diferentes: la capa de entrada, las capas ocultas y la capa de salida, esta última con tantas salidas como variables a predecir o *targets*. Generalmente, todas las neuronas de una capa están conectadas a todas las neuronas de la siguiente capa, es lo que se conoce como conectividad total o red totalmente conectada.

En el MLP se establece una relación entre las variables de entrada y las variables de salida de la red. Esta relación se obtiene propagando hacia delante los valores de las variables de entrada. Para ello, cada neurona procesa la información recibida por sus entradas y produce una respuesta o activación que se propaga, a través de las conexiones correspondientes, hacia las neuronas de la siguiente capa.

Si tenemos un MLP con D entradas, a continuación hay L capas cada una con n_l neuronas. Las $L - 1$ primeras capas serán las capas ocultas y a continuación está la




Figura 5-20. Nomenclatura utilizada en la definición matemática de una red neuronal

capa de salida, con tantas salidas \$K\$ como dimensiones tenga el *target* a predecir. La salida de la neurona \$i\$ de la capa \$l\$ la denotaremos por \$z_i^l\$. De una capa a la siguiente, la salida de la neurona \$i\$ se pondera por un peso \$w_{ij}^l\$, siendo \$l\$ la capa y \$j\$ la neurona de la capa \$l\$ (ver Figura 5-20).

La suma ponderada de los pesos de las entradas a una neurona se denomina activación, así para la neurona \$j\$ de la capa \$l\$ esta activación viene dada por la siguiente ecuación:

$$a_j^l = \sum_{i=0}^{n_{l-1}} w_{ji}^l z_i^{l-1} \quad (5-23)$$

Esta entrada se transforma utilizando una función de activación \$h^{(l)}(\cdot)\$ para generar la salida a la siguiente capa:

$$z_i^l = h^{(l)}(a_j^{(l)}) = h^{(l)}\left(\sum_{i=0}^{n_{l-1}} w_{ji}^l z_i^{l-1}\right) \quad (5-24)$$

En definitiva, las funciones de activación nos relacionan la salida de una neurona o nodo con la suma agregada ponderada por los pesos. Las funciones de activación más comunes en redes neuronales son las que se muestran en la Tabla 5-2 (Nair & Hinton, 2020).

Las funciones de activación para la capa de salida en nuestro problema se han escogido en función del tipo de predicción. Así, para la clasificación binaria se utilizó la función softmax y para la regresión, la función identidad o purelin. Para las capas ocultas se ha utilizado en todos los casos la función tansig.

Tabla 5-2. Funciones de activación más habituales

Función de activación	Ecuación	Gráfica	Rango
Función escalón	$h(x) = \begin{cases} 0 & \text{si } x < 0 \\ 0,5 & \text{si } x = 0 \\ 1 & \text{si } x > 0 \end{cases}$		[0,1]
Identidad o purelin	$h(x) = x$		$(-\infty, \infty)$
Sigmoide, logística	$h(x) = \frac{1}{1 + e^{-x}}$		(0,1)
Tangente hiperbólica (tansig)	$h(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$		$(-1,1)$
ReLU	$h(x) = \begin{cases} 0 & \text{si } x \leq 0 \\ x & \text{si } x > 0 \end{cases}$		$[0, \infty)$
Softplus	$h(x) = \ln(1 + e^x)$		$(0, \infty)$
Q-RBF	$h(x) = \begin{cases} 1 - \frac{x^2}{2} & \text{si } x \leq 1 \\ \frac{1}{2}(2 - x)^2 & \text{si } 1 < x < 2 \\ 0 & \text{si } x > 2 \end{cases}$		[0,1]
Softmax	$h(x_i) = \frac{e^{x_i}}{\sum_{j=1}^J e^{x_j}}$ <p>para $i = 1, 2 \dots J$.</p> <p>donde J es el número de clases</p>	Transforma las salidas a una representación en forma de probabilidades	(0,1)

5.6.2. Método de entrenamiento del MLP. Backpropagation

El entrenamiento de una red neuronal multicapa se realiza habitualmente con un algoritmo de propagación de errores hacia atrás o *backpropagation*.

Este algoritmo fue desarrollado por Paul Werbos en su tesis doctoral en el año 1974 (Werbos, 1974), algunos años más tarde, publicado de forma independientemente por Rumelhart (David E. Rumelhart, Hinton, & Williams, 1986) y posteriormente por Parker (Parker, 1985), que lo denominó *learning-logic*. Es el modelo más popular, efectivo y fácil de aprender para redes complejas de múltiples capas. El algoritmo de retropropagación o *backpropagation* es una técnica de aprendizaje supervisado que se basa en el método de descenso del gradiente (*gradient descent*: GD). Básicamente el método consiste en lo siguiente:

A partir del conjunto de datos de entrenamiento dado por unas entradas $\{\mathbf{x}_n\}$ y unas salidas o target $\{\mathbf{t}_n\}$, el objetivo del entrenamiento es encontrar un conjunto de pesos \mathbf{w} que minimice la función error o de coste $J_n(\mathbf{w})$, que mide el error asociado a la muestra de entrenamiento y que dependerá del sistema predictivo (regresión o clasificación). Esta función de coste vendrá dada por:

$$J_n(\mathbf{w}) = \sum_{n=1}^D \|\mathbf{y}(\mathbf{x}_n, \mathbf{w}) - \mathbf{t}_n\|^2 \quad (5-25)$$

Para su solución, se utilizan métodos heurísticos basados en el descenso del gradiente denominado *backpropagation* que pasamos a describir a continuación (Bishop, 2006).

A partir de la función de error (5-25) y aplicando la regla de la cadena, tenemos que el gradiente de J_n viene dado por:

$$\nabla_{\mathbf{w}} J_n = \frac{\partial J_n}{\partial w_{ji}^l} = \frac{\partial J_n}{\partial a_j^l} \frac{\partial a_j^l}{\partial w_{ji}^l} = \delta_j^l z_i^{l-1} \quad (5-26)$$

y como por (5-16) se tiene que $a_j^l = \sum_i w_{ji}^l z_i^{l-1}$, entonces:

$$\frac{\partial a_j^l}{\partial w_{ji}^l} = z_i^{l-1} \quad (5-27)$$

donde el término δ_j^l se denomina error del nodo j de la capa l y debe calcularse para cada neurona o nodo de la red.

Para los nodos de salida L tenemos que:

$$\delta_k^L = \frac{\partial J_n}{\partial a_k^L} = y_k - t_k \quad (5-28)$$

y para los nodos de la capa oculta anterior $L - 1$:

$$\delta_j^{L-1} = \frac{\partial J_n}{\partial a_j^{L-1}} = \sum_k \frac{\partial J_n}{\partial a_k^L} \frac{\partial a_k^L}{\partial a_j^{L-1}} \quad (5-29)$$

siendo k los nodos a los que j envía conexiones. Si ahora tenemos en cuenta que $a_k^L = \sum_j w_{kj}^L \delta_j^L$ y que $z_j^L = h(a_j^{L-1})$, entonces resulta que:

$$\delta_j^{L-1} = h'(a_j^{L-1}) \sum_k w_{kj}^L \delta_k^L \quad (5-30)$$

En este procedimiento, hemos utilizado los errores de la última capa L para calcular los errores de la capa anterior $L - 1$. Utilizando estos errores determinamos completamente el gradiente y por lo tanto la modificación de los pesos para minimizar el coste final. Este algoritmo se ejecuta iterativamente hasta llegar a la capa de entrada, por lo que el error de la capa l se calcula a partir de los errores de la capa $l + 1$. Cada ciclo de corrección de propagación hacia atrás y hacia delante para minimizar el coste se denomina época o *epoch*.

A partir de aquí, el enfoque más sencillo es el relativo al método del descenso del gradiente, que básicamente consiste en utilizar la información del gradiente de la función de coste (5-26) en la actualización de vector de pesos en la siguiente ecuación:

$$\mathbf{w}^{T+1} = \mathbf{w}^T - \eta \nabla J_n(\mathbf{w}^T) \quad (5-31)$$

donde el parámetro $\eta > 0$ se conoce como la tasa de aprendizaje. Después de cada actualización de este tipo, se reevalúa el gradiente para el nuevo vector de peso y se repite el proceso.

Capítulo 5. Implementación de un modelo de inteligencia artificial

Por lo tanto, el algoritmo de retropropagación o *backpropagation*, puede resumirse de la siguiente manera:

Paso#1. Se establecen los pesos iniciales, normalmente de forma aleatoria (Nguyen & Widrow, 1990), se aplican las entradas \mathbf{x}_n a la red, se propagan hacia delante y se calculan las salidas y_k .

Paso#2. Se calculan los errores de cada uno de los nodos de la capa de salida $\delta_k^L = y_k - t_k$.

Paso#3. Se propagan hacia atrás los errores, calculándolos para todas las capas ocultas, de tal forma que el error δ_j^l del nodo j de la capa l , se calcula en función de los errores de la capa $l + 1$. Es decir, se opera de forma recursiva capa tras capa moviendo el error hacia atrás.

Paso#4. Se calculan las derivadas del error con respecto a los pesos o gradiente de la función de coste:

$$\nabla_w J_n = \frac{\partial J_n}{\partial w_{ji}^l} = \delta_j^l z_i^{l-1} \quad (5-32)$$

Paso#5. A partir de las derivadas se aplica un algoritmo que ajuste los pesos, para minimizar progresivamente el error. Este ajuste de pesos se suele llevar a cabo mediante métodos de primer orden como el algoritmo del descenso del gradiente, el método del gradiente conjugado, o con métodos de segundo orden como el método de Newton, el método quasi-Newton o el método de Levenberg-Marquardt (Battiti, 1992; Becker & le Cun, 1989; Berzal, 2019b; Reed & Marks, 1999).

Según el modo de aplicación de las derivadas hay dos variantes básicas:

- Métodos online o secuenciales, donde en cada iteración o época, se utiliza solo una instancia del conjunto de entrenamiento.
- Métodos batch cuando se utiliza simultáneamente todo el conjunto de entrenamiento, siendo este el modo habitual de operar.

5.6.3. Algoritmos de entrenamiento

En este trabajo se ha empleado el algoritmo de retropropagación de regularización bayesiana o *bayesian regularization backpropagation*, por lo que expondremos a continuación su fundamento matemático, empezando por el método de Levenberg-Marquardt, al emplearse este en combinación con el primero.

Método de Levenberg-Marquardt

El método de Levenberg-Marquardt (LM) (Levenberg, 1944; Marquardt, 1963) es un algoritmo cuya base conceptual es similar a los denominados quasi-Newton.

Si partimos del método de Newton, el paso básico de este método durante la época n es:

$$\mathbf{w}(n+1) = \mathbf{w}(n) - \mathbf{H}(n)^{-1}g(n) \quad (5-33)$$

donde \mathbf{w} es el vector de pesos, $g(n)$ es el vector gradiente y $\mathbf{H}(n)$ es la matriz Hessiana de derivadas parciales segundas de la función de error respecto a los pesos. El inconveniente que presentan estos métodos es que para un MLP se complica el cálculo de la matriz Hessiana, por lo que los métodos quasi-Newton al igual que el algoritmo de LM aproximan la matriz de Hess mediante:

$$\mathbf{H} = \mathbf{J}^T \mathbf{J} \quad (5-34)$$

donde \mathbf{J} es la matriz Jacobiana que contiene las primeras derivadas de la función error respecto a los pesos y el gradiente se obtiene mediante:

$$g = \mathbf{J}^T \mathbf{e} \quad (5-35)$$

donde \mathbf{e} es el vector de errores de la red. El algoritmo de Levenberg-Marquardt utiliza esta aproximación a la matriz de Hesse según la siguiente ecuación:

$$\mathbf{w}(n+1) = \mathbf{w}(n) - [\mathbf{J}^T \mathbf{J} + \mu \mathbf{I}]^{-1} \mathbf{J}^T \mathbf{e} \quad (5-36)$$

donde el parámetro μ es la tasa de aprendizaje e \mathbf{I} es la matriz identidad. El cálculo de la matriz Jacobiana se lleva a cabo mediante el algoritmo de retropropagación o *backpropagation* (Hagan & Menhaj, 1994).

Algoritmo regularización bayesiana

En este trabajo, para mejorar progresivamente los pesos de la red se ha utilizado el algoritmo de regularización bayesiana o *bayesian regularization (BR)*, desarrollado por David Mackain en el año 1992 (Mackay, 1992).

El algoritmo BR minimiza una combinación lineal de los cuadrados de los errores y pesos, es decir modifica la función de coste añadiendo un término de regularización con el que pretende mejorar también el problema de generalización.

Si tenemos como función de coste el MSE, este lo podemos expresar:

$$MSE_D = \frac{1}{N} \sum_{i=1}^N (y_i - t_i)^2 \quad (5-37)$$

Si añadimos el siguiente término de regularización basado en la suma de los pesos:

$$MSE_w = \frac{1}{N} \sum_{i=1}^N (w_i)^2 \quad (5-38)$$

Obtenemos la nueva función de coste del algoritmo BR:

$$MSE = \beta \cdot MSE_D + \alpha \cdot MSE_w \quad (5-39)$$

donde β y α son parámetros que deben ser ajustados según la metodología Bayesiana de MacKay (Foresee & Hagan, 1997; Mackay, 1992).

En el marco bayesiano, esta metodología asume que los pesos y umbrales son variables aleatorias que siguen distribuciones específicas (habitualmente distribuciones normales) y los parámetros de regularización están relacionados con las varianzas desconocidas asociadas a estas distribuciones. Durante el entrenamiento, la función de densidad para los pesos puede ser actualizada según la regla de Bayes (Foresee & Hagan, 1997).

En el caso de MATLAB, el algoritmo que se emplea en combinación con la técnica de regularización Bayesiana es el método Levenberg-Marquardt (LM), que utiliza la técnica de retropropagación o *backpropagation* para el cálculo del Jacobiano (Suliman & Omarov, 2018). Esta técnica, aunque aumenta el tiempo de entrenamiento, presenta muy buen comportamiento (K. K. Aggarwal, Singh, Chandra, & Puri, 2005).

5.6.4. Tamaño y profundidad de la red y sobreaprendizaje

Un aspecto esencial a considerar cuando se diseña un perceptrón multicapa es el número de capas o profundidad de la red y el número de neuronas por capa.

Una red neuronal de una sola capa, sin capas ocultas, es un clasificador lineal. Es decir, no puede resolver problemas que no sean linealmente separables (Berzal, 2019a). Como la mayoría de los problemas a resolver no se pueden separar linealmente, es evidente que este modelo no tiene una extensa aplicación práctica.

En el ámbito de las redes neuronales multicapa, el Teorema de Aproximación Universal especifica que un MLP, con una capa oculta y con un número finito de neuronas puede representar cualquier función continua, siempre que incluyamos el número suficiente de nodos o neuronas y tengamos un número suficiente de datos de entrenamiento (Cybenko, 1989; Hornik, 1991; Reed & Marks, 1999). Por otra parte, otros trabajos, como el de Lippmann, afirman que dos capas ocultas son suficientes para clasificar cualquier región (Lippmann, 1987; Nguyen & Widrow, 1990).

Sin embargo, los últimos estudios apuntan a que una red con múltiples capas ocultas es capaz de implementar funciones de mayor complejidad y por tanto resolver problemas más complejos (Caruana, Lawrence, & Giles, 2001; Thomas, Petridis, Walters, Gheytaasi, & Morgan, 2017). Más de una capa oculta acelera el proceso de entrenamiento, especialmente en problemas muy pesados y cuantas más neuronas por capa, mejor será la adaptabilidad del modelo al problema.

En contrapartida, un aumento en el número de capas y neuronas puede llevar a un sobreaprendizaje y por lo tanto a una mala generalización (Heaton, 2008; Reed & Marks, 1999). Es decir, en ocasiones la pérdida de capacidad de generalización se produce por un elevado número de nodos y capas ocultas en la red. Esto hace que tienda a ajustarse a los datos de entrenamiento sin que extraiga la información subyacente en los propios datos. En la práctica, la mayoría de los MLP tienen dos o tres

capas, cuatro o más capas se utilizan muy raramente (Hagan, Demuth, Beale, & De Jesús, 2014).

Existe cierta bibliografía (Stathakis, 2009), donde se establecen algunas estrategias para determinar el número óptimo de capas que debe tener un MLP para resolver ciertos problemas. Sin embargo, no existe un método universalmente aceptado para resolver esta cuestión, siendo algunos de los más utilizados los siguientes:

- **Método aleatorio de prueba y error.** Consiste en probar distintas configuraciones aleatorias con distinto número de capas y nodos por capa.
- **Método de la cuadrícula.** Efectúa una búsqueda sistemática en el número de capas y nodos por capa.
- **Método heurístico.** Realiza una búsqueda a través de distintas configuraciones utilizando un algoritmo genético u optimización bayesiana.
- **Exhaustivo.** Prueba todas las combinaciones de capas y el número de nodos. Es un método solo factible para redes neuronales pequeñas con un limitado conjunto de datos.

Para determinar el número de nodos o neuronas por capa, existen algunas reglas como las que se exponen a continuación (Florez & Fernández, 2008; Zepeda, Aguilar, Hernández, & Salgado, 2015):

- **Regla de la pirámide o de Masters.** Establece que el número de nodos o neuronas en la capa oculta debe ser inferior al número de variables de entrada y superior a las variables de salida, de tal manera que el número de neuronas en cada capa sigan una progresión geométrica, tal que, para una red con una capa única oculta, el total de neuronas intermedias (N) debe ser próximo a (Masters, 1993):

$$N = \sqrt{n \cdot m} \quad (5-40)$$

donde n es número de variables de entrada y m el número de nodos de salida.

- **Regla de la capa oculta-capas entrada.** Según esta regla, el número de neuronas está relacionado con el número de neuronas de entrada. En particular, suele aplicarse la regla 2×1 , de forma que el número de neuronas ocultas no puede ser superior al doble del número de variables de entrada (Swingler, 1996).

Parada temprana del entrenamiento en redes neuronales

La parada temprana o *early stopping*, es un método que permite evitar el sobreentrenamiento del modelo. Básicamente, consiste en ir evaluando el proceso de aprendizaje durante el proceso de entrenamiento. Esto se consigue comparando el rendimiento obtenido con el conjunto de datos de entrenamiento y el rendimiento que proporciona el conjunto de validación.

Si durante el entrenamiento, el rendimiento proporcionado por el conjunto de validación comienza a empeorar, indica que el modelo comienza a sobreentrenar, por lo que el método de parada temprana finaliza el entrenamiento. Habitualmente se configuran una serie de épocas o *epoch*, denominadas *validation checks*, de forma que se produzca la parada temprana solo si, durante este número de ciclos no se ha producido una mejora con el conjunto de validación.

En la Figura 5-21 se puede apreciar el caso de una parada temprana del entrenamiento de un modelo debido a una falta de mejora en el rendimiento obtenido por el conjunto de validación. Se observa también, que la métrica de evaluación continuaba mejorando para los datos de entrenamiento, lo que es indicación de sobreentrenamiento.




Figura 5-21. Ejemplo de parada temprana

5.7. CONSTRUCCIÓN DE LOS MODELOS DE APRENDIZAJE AUTOMÁTICO PARA EL PROBLEMA DE LANZAMIENTO DE SEÑUELOS.

Una vez presentado el marco teórico, en este punto vamos exponer los pasos realizados para construir el modelo óptimo de aprendizaje automático, en concreto de aprendizaje supervisado, que resuelva el problema del lanzamiento de señuelos.

Hay que reseñar que todos los pasos realizados para determinación del modelo óptimo, su entrenamiento y análisis, fueron implementados mediante scripts de MATLAB.

5.7.1. Conjunto de datos de entrenamiento. Variables de entrada y de salida

En primer lugar, y con los resultados obtenidos de las simulaciones presentadas en el capítulo anterior, es necesario establecer fehacientemente cuáles serán las variables de entrada al modelo y cuáles las variables de salida o *targets*. En la Tabla 5-3 y Tabla 5-4 se han incluido las variables de entrada y de salida o respuesta que deberá tener el modelo con sus unidades correspondientes.

Esta configuración de variables nos permitirá determinar en cada escenario y para cada reacción del buque (combinación lanzador/maniobra del buque), si existe solución de lanzamiento y en caso afirmativo, cuál será la distancia de paso del misil, la proporción del tiempo total de enfrentamiento en la que el buque está dentro de la celda de resolución del misil y la probabilidad de éxito de la solución.

Dado que tenemos cuatro variables de salida, para mejorar la respuesta final de la solución, se decidió construir cuatro modelos diferentes: dos modelos de clasificación binaria y dos modelos de regresión (ver Tabla 5-4). Para obtener el modelo óptimo de cada una de las cuatro respuestas, se siguieron los siguientes pasos, que detallaremos en los próximos puntos:

Paso#1. Normalización de los datos.

Paso#2. Diseño de los modelos de SVM y de MLP.

Paso#3. Entrenamiento, validación y test de todos los modelos SVM y de MLP.

Paso#4. Determinación del modelo óptimo para cada variable de salida.

Capítulo 5. Implementación de un modelo de inteligencia artificial

Paso#5. Entrenamiento de los modelos óptimos con un número mayor de instancias para mejorar el ajuste.

Paso#6. Construcción del conjunto de modelos para obtener las predicciones de las soluciones de lanzamiento.

Tabla 5-3. Variables de entrada del modelo

VARIABLES DE ENTRADA	UNIDADES
Velocidad del buque (V_{buque})	Nudos
Velocidad del viento (V_{viento})	Nudos
Dirección del viento (B_{viento})	Grados [0°-360°]
Distancia inicial del misil (D_{misil})	Yardas
Marcación inicial del misil (B_{misil})	Grados [0°-360°]
Lanzador (L)	1,2,3,4. Codificado en binario
Cambio de rumbo (maniobra del buque)	Babor, 0°, Estribor. Codificado en binario

Tabla 5-4. Variables de salida o respuesta del modelo

Variable de salida	Tipo de modelo y unidades
Solución	Modelo de clasificación. Binario (1-No impacto/0-Impacto)
Distancia de paso del misil	Modelo de regresión. Yardas
Tiempo en celda	Modelo de regresión. Proporción del tiempo total del enfrentamiento
Probabilidad de éxito	Modelo de clasificación. Binario 1-Probabilidad de éxito >0.8 0-Probabilidad de éxito ≤0.8

5.7.2. Paso#1. Normalización de los datos

Antes de construir y entrenar un modelo de aprendizaje automático es necesario normalizar los datos disponibles. Ello mejora la precisión del modelo y acelera los tiempos de entrenamiento (Bishop, 2006). Para este trabajo se ha empleado la normalización mín-máx que es un algoritmo de escala lineal y transforma el rango de los datos originales en un nuevo rango [0,1]. Para su cálculo se emplea la siguiente ecuación (H. Li, Chen, & Huang, 2018):

$$x_N = \left(\frac{x - \text{min1}}{\text{max1} - \text{min1}} \right) (\text{max2} - \text{min2}) + \text{min2} \quad (5-41)$$

donde el x es el valor original, x_N es el nuevo valor normalizado, min1 y max1 son el mínimo y el máximo de los datos originales, y min2 y max2 son el mínimo y el máximo del nuevo rango de datos normalizados.

5.7.3. Paso#2. Diseño de los modelos del SVM y del MPL

Tal y como se avanzó en el punto 5.3.2, para este estudio se escogieron dos técnicas: máquinas de vectores soporte y redes neuronales, como candidatas a resolver el problema de lanzamiento de señuelos. Además, para determinar el óptimo en la resolución del problema, se diseñaron diferentes modelos de estos dos algoritmos.

Máquina de vectores soporte

En el caso de las SVM se utilizó un clasificador de margen suave o *soft-margin*, para las variables de salida binarias (solución y probabilidad de éxito) y regresores con la función de pérdida ϵ – *insensitive* para las variables distancia de paso y tiempo en celda. Para ambos (clasificadores y regresores) se implementó un kernel de base radial o gaussiano de parámetro gamma ($\gamma > 0$).

Por lo tanto, deberemos obtener en cada caso, los valores óptimos del hiperparámetro del kernel (γ), del peso de la regularización (C) y del ϵ – *insensitive*, este último solo para regresión. Para ello, inicialmente se realizó una búsqueda bayesiana de los hiperparámetros, con ellos se generaron las diferentes combinaciones de valores en cuadrícula y mediante validación cruzada se determinaron los valores óptimos. En la Tabla 5-5 se ha incluido la cuadrícula de hiperparámetros de los diferentes modelos de SVM probados en este trabajo.

Tabla 5-5. Cuadrícula de hiperparámetros de las SVM

Variable de salida	Hiperparámetros
Solución	$\gamma = 1; 1,25; 1,75; 2$ $C = 10; 50; 100$
Distancia de paso	$\gamma = 0,5; 1; 1,75; 2$ $C = 500; 1000; 1500$ $\epsilon = 10; 15; 20$
Tiempo en celda	$\gamma = 0,75; 1; 1,25; 2$ $C = 0,5; 1; 2$ $\epsilon = 0,005; 0,01; 0,05$
Probabilidad de éxito $>0,8$	$\gamma = 0,5; 1; 1,75; 2$ $C = 500; 1000; 1500$

Perceptrón multicapa

La búsqueda del modelo óptimo de MLP para cada una de las cuatro variables de salida se asentó en encontrar la topología de la red que minimizase el error de predicción. Al efecto, se diseñó el entrenamiento y se configuraron los modelos a analizar de la siguiente manera:

- División del conjunto de datos de entrenamiento. Un 80% de los datos se utilizaron para entrenamiento y validación. Mientras que el 20% restante se tomó como conjunto de prueba.
- Funciones de activación. Para las capas ocultas se utilizó la función tangente hiperbólica o *tansig* y para la capa de salida en el caso de las clasificaciones binarias la función softmax y para los regresores la función identidad o *purelin*.
- Algoritmo de entrenamiento. Se utilizó el algoritmo de retropropagación con regularización bayesiana
- Parada temprana o *early stop*. Se configuró con un valor de *validation checks* de 6 épocas o ciclos.
- Número máximo de épocas de entrenamiento. Se establecieron 3000 épocas como número máximo de ciclos del entrenamiento.

Para determinar la topología óptima de los modelos MLP, se empleó el método de la cuadrícula. Es decir, se efectuó una búsqueda sistemática del número de capas y de nodos por capa, para posteriormente analizar el comportamiento del error de predicción en cada uno de ellos.

Se decidió comenzar con una red de una sola capa oculta, y aumentar progresivamente de 1 a 3 el número de capas. De la misma manera, se realizó un cambio incremental en el número de nodos o neuronas en las capas ocultas, para buscar una disminución del error o su estabilización. En el caso de configuraciones con más de una capa oculta, se utilizó la técnica de la pirámide, que consiste en disminuir el número de nodos desde la capa de entrada a la capa de salida.

Después de un estudio inicial, se decidió descartar la topología de 4 capas ocultas, ya que los resultados preliminares arrojaron métricas de evaluación muy pobres en todas

Capítulo 5. Implementación de un modelo de inteligencia artificial

las variables de salida y paradas tempranas o *early stopping* en épocas iniciales del entrenamiento de los modelos. Estos resultados, vienen reforzados por lo establecido en la bibliografía contenida en el punto 5.6.4 sobre la profundidad del perceptrón multicapa. En la Tabla 5-6 se presentan las diferentes topologías analizadas.

Tabla 5-6. Topologías de MLP utilizadas en el análisis

Capas ocultas	Número de neuronas o nodos por capa oculta		
	Capa 1	Capa 2	Capa 3
1	[10-150] (Saltos 10 neuronas)	—	—
2	[10-50] (Saltos 5 neuronas)	5 neuronas menos que la capa 1	—
3	[10-50] (Saltos 5 neuronas)	5 neuronas menos que la capa 1	5 neuronas menos que la capa 2

5.7.4. Paso#3. Entrenamiento, validación y test de todos los modelos de SVM y de MLP

En este paso se entrenaron todos los modelos construidos en el Paso#2, y se calcularon para cada una de las cuatro variables de salida, las métricas de evaluación de cada configuración de hiperparámetros de las SVM y de cada una de las topologías de los MLP. Estos valores de las métricas permitieron determinar el modelo óptimo a implementar en cada variable del problema de lanzamiento de señuelos.

Las acciones llevadas a cabo en este paso, se han plasmado de forma esquemática en la Figura 5-22 y se resumen a continuación.

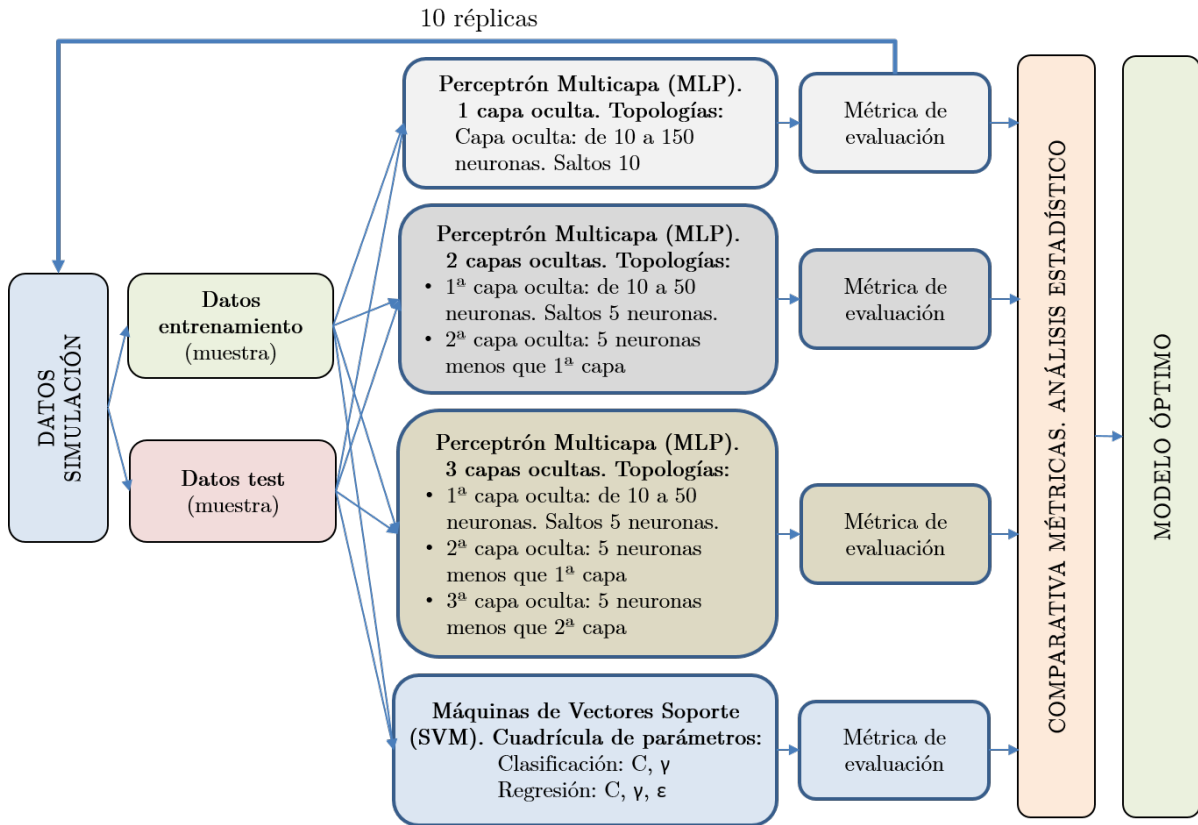


Figura 5-22. Esquema de las acciones seguidas en el Paso#3

Del conjunto total de datos de la simulación se obtuvo una muestra aleatoria simple de tamaño 56 000 instancias. Este tamaño muestral se determinó al fijar un máximo de 2 semanas como el tiempo total de computación para entrenar toda la panoplia de casos en estudio de cada variable de salida. Con ello, se pretendía no superar las 8 semanas (2 semanas x 4 variables de salida) de tiempo de total invertido en este paso.

La muestra anterior se dividió en dos conjuntos: un 80% de los datos para entrenamiento y validación y un 20 % para prueba o test. A continuación, se entrenaron todas las configuraciones de hiperparámetros de SVM y topologías de MLP y se archivaron las métricas resultantes de todos los casos. Este proceso se replicó 10 veces, realizándose la extracción de datos del conjunto total de la simulación sucesivamente mediante muestreo aleatorio simple sin reposición. Se aplicó, por consiguiente, un procedimiento similar al de validación cruzada.

El proceso descrito anteriormente, se realizó para cada una de las cuatro variables de salida, utilizando los modelos y las métricas de evaluación que figuran en la Tabla 5-7.

Tabla 5-7. Métricas de evaluación de cada tipo de modelo

Variable de salida	Tipo de modelo	Métrica utilizada
Solución	Clasificación	Precisión (<i>accuracy</i>)
Distancia de paso del misil	Regresión	Error cuadrático medio (MSE) y R^2
Tiempo en celda	Regresión	Error cuadrático medio (MSE) y R^2
Probabilidad de éxito >0,8	Clasificación	Precisión (<i>accuracy</i>)

5.7.5. Paso#4. Determinación del modelo óptimo para cada variable de salida

La ejecución del paso anterior, nos permitió disponer de 10 valores de las métricas de evaluación de cada caso de los modelos de SVM y MLP analizados. Así, para comparar los resultados y determinar el modelo óptimo fue necesario aplicar técnicas de estadística descriptiva e inferencial. En los siguientes apartados se describe este proceso para cada uno de los modelos de las variables de salida.

Modelo de clasificación para la salida solución

En esta variable y tras analizar las matrices de confusión de los distintos modelos, se obtuvo la gráfica de la Figura 5-23, donde en el eje de ordenadas se presentan las medias de los valores de precisión (*accuracy*) y el eje de abscisas corresponde a las distintas configuraciones de los modelos, que no se han incluido en la figura para mayor claridad de la gráfica.

En la figura, se puede observar que para el caso de MLP de 2 y 3 capas ocultas se han conseguido valores de precisión mayores de 93%.

Además, aplicando el contraste de hipótesis de igualdad de medias a los datos de las métricas para los MLP de 2 y 3 capas, estadísticamente y con una confianza del 95%, no se apreciaron diferencias en los resultados. Por ello, se tomó como modelo óptimo para esta variable un MLP de 2 capas ocultas, con 40 y 35 neuronas en cada una de las capas.

Por otra parte, en cuanto a la variabilidad de la métrica precisión para este modelo óptimo de MLP de 2 capas ocultas, podemos afirmar que está contenida, el valor de la cuasidesviación típica de la muestra es de 0,0032 y en la Figura 5-24 podemos observar lo estrecho del intervalo de confianza resultante de la media.




Figura 5-23. Comparativa de las medias de precisión (accuracy) para los distintos casos




Figura 5-24. Intervalos de confianza del 95% de la media de la precisión para las distintas topologías del MLP de 2 capas ocultas

Modelo de regresión para la salida distancia de paso

Para esta variable se utilizó como métrica principal de comparación el valor del error cuadrático medio (MSE). Tras entrenar todos los casos previstos, se obtuvo la gráfica de la Figura 5-25, donde se incluyen los valores medios del MSE y donde se puede observar que el mínimo de la métrica se ha obtenido para un MLP de 3 capas ocultas con 35-30-25 neuronas.

Posteriormente, se comprobó mediante contrastes de hipótesis para la media que estadísticamente y con una confianza del 95%, los valores medios del MSE para el MLP de 3 capas son estadísticamente inferiores a los de los modelos MLP de 2 capas. Por ello, se tomó el MLP de 3 capas ocultas con una configuración de 35-30-25 neuronas por capa, como modelo óptimo.

En el modelo escogido, tanto la media del error cuadrático medio como su cuasidesviación típica tomaron valores francamente pequeños ($\overline{MSE} = 3,866 \text{ yardas}^2$ y $S = 0,6228$). Por otra parte, en la Figura 5-26 se puede apreciar la estrechez del intervalo de confianza del 95% de la media del MSE para las distintas topologías del MLP de 3 capas, lo que nos da una indicación de la escasa variabilidad de la métrica.

Además, el valor medio del coeficiente de determinación del modelo óptimo fue de $R^2 = 0,9999$ lo que implica también un muy buen ajuste de los datos.




Figura 5-25. Comparativa de las medias del error cuadrático medio (MSE) para los distintos casos




Figura 5-26. Intervalos de confianza del 95% de la media del MSE para las distintas topologías del MLP de 3 capas ocultas

Modelo de regresión para la salida tiempo en celda

En este caso se utilizó también el valor del error cuadrático medio y el coeficiente de determinación (R^2) como métricas de evaluación y comparación.

Después de entrenar todos los casos previstos se obtuvieron valores muy altos de MSE, superiores a 0,01 y valores de R^2 inferiores a 0,80 en todas las réplicas. Para mejorar los resultados se introdujo la distancia de paso como una variable más de entrada y se volvieron a entrenar todos los modelos. Con ello, los resultados mejoraron ostensiblemente, disminuyendo el MSE en aproximadamente un 40% y obteniendo con este procedimiento valores de R^2 superiores a 0,88.

Con los valores de las métricas obtenidos en nuevo proceso de entrenamiento, se elaboró la gráfica de la Figura 5-27 en la que se puede observar que los mejores resultados de MSE se obtuvieron para MLP de 3 capas ocultas, en concreto para una configuración de 35-30-25 neuronas por capa. Comprobándose además, mediante contrastes de hipótesis para la media, que estadísticamente y con una confianza del 95%, los valores medios del MSE para este modelo son estadísticamente inferiores a los de los modelos MLP de 2 capas ocultas.

El valor medio de la métrica MSE en el modelo óptimo fue de $\overline{MSE} = 0,0053$ con una cuasidesviación típica de $S = 0,0002$ y se obtuvo un valor medio del coeficiente de determinación de $R^2 = 0,8847$ con una cuasidesviación típica de $S = 0,0036$. Además,

en la Figura 5-28 se puede observar el tamaño de los intervalos de confianza de la media del MSE las diferentes topologías del MLP de 3 capas, donde se aprecia también la baja variabilidad obtenida.




Figura 5-27. Comparativa de las medias del error cuadrático medio (MSE) para los distintos casos




Figura 5-28. Intervalos de confianza del 95% de la media del MSE para las distintas topologías del MLP de 3 capas ocultas

Modelo de clasificación para la salida probabilidad de éxito

Inicialmente se trató esta variable de salida como una variable continua y se intentó obtener un modelo de regresión. Sin embargo, los resultados obtenidos, tanto para MLP como para SVM fueron extremadamente pobres, consiguiendo valores del coeficiente de determinación R^2 inferiores a 0,5. Se intentó mejorar el ajuste introduciendo la distancia de paso como variable de entrada al modelo, pero tampoco se consiguió corregir el resultado.

Para no perder la información sobre la probabilidad de éxito de la solución, se decidió codificar esta variable como binaria y separar las soluciones con probabilidad de éxito mayor de 0,8 del resto. Se tomó específicamente este valor, ya que según se aprecia en la gráfica de la Figura 5-29, este valor corresponde al punto de inflexión del histograma de la variable, coincide con el percentil 90 y se comprobó que presenta el mejor comportamiento para separar los datos.




Figura 5-29. Histograma de la probabilidad de éxito. Datos obtenidos de la simulación

Una vez decidido codificar la variable para clasificación binaria, se procedió al entrenamiento de los modelos. En este caso se encontró el mismo problema que para la variable tiempo en celda, la precisión en las matrices de confusión para las distintas configuraciones de los modelos, fueron inferiores a 80%, resultado no considerado válido para nuestro problema.

Para mejorar la precisión de la predicción se introdujo también la distancia de paso como nueva entrada del modelo, mejorando los resultados y alcanzando valores de precisión del 90%.

Tal y como se aprecia en la gráfica de la Figura 5-30, todos los modelos consiguen valores similares. Mediante la aplicación de contrastes de hipótesis se obtuvo que estadísticamente y con una confianza del 95%, el modelo de MLP de 1 capa oculta y 80 neuronas alcanzó un valor medio de la precisión más alto, por lo que se optó por tomar este modelo como óptimo para esta variable.

La precisión media del modelo óptimo fue de 90,03% con una variabilidad muy baja, tomando la cuasidesviación típica de la muestra un valor de $S = 0,0036$. En general para los modelos MLP de 1 capa oculta presentaron todos ellos valores bajos de variabilidad en esta métrica, tal y como se aprecia en los intervalos de confianza de la Figura 5-31.




Figura 5-30. Comparativa de las medias de precisión (accuracy) para los distintos casos




Figura 5-31. Intervalos de confianza del 95% de la media de la precisión para las distintas topologías del MLP de 1 capa oculta

5.7.6. Paso#5. Entrenamiento de los modelos óptimos con número mayor de instancias para mejorar el ajuste del modelo, construcción de la solución final y test.

Una vez determinados los modelos óptimos, las acciones a seguir en este paso fueron las que se reflejan en la Figura 5-32. Se entrenaron los modelos óptimos con un mayor número de instancias, se construyó el conjunto final de modelos y se realizaron las pruebas para el cálculo de las métricas de evaluación de dicho conjunto.

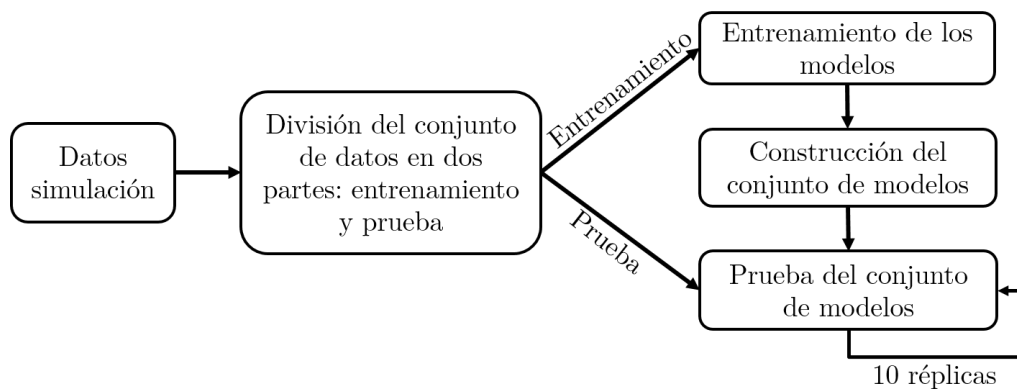


Figura 5-32. Entrenamiento, construcción y prueba del conjunto de modelos

Tal y como expuso en el Paso #3, para ahorrar tiempo de computación en la búsqueda de los modelos óptimos se utilizaron muestras relativamente pequeñas del conjunto

de datos de la simulación, por lo que existía todavía un volumen adicional de datos para el entrenamiento de los modelos.

Por esta razón, el siguiente paso fue entrenar los modelos óptimos, encontrados en el paso anterior, con un número mayor de instancias para mejorar el ajuste. Para ello, del conjunto total de datos de la simulación, se tomaron mediante un muestreo aleatorio simple, un total de 500 000 registros, dejando el resto de instancias para la prueba o test final de los modelos.

A continuación, y dado que a los modelos tiempo en celda y probabilidad de éxito se les añadió como una entrada más la variable de salida distancia de paso, y esta variable no está disponible como datos del escenario real, fue necesario construir un conjunto de cuatro MLP enlazados entre sí, de tal forma que la salida del modelo correspondiente a la variable distancia de paso, forme parte de la entrada de los modelos tiempo en celda y probabilidad de éxito (ver Figura 5-33).

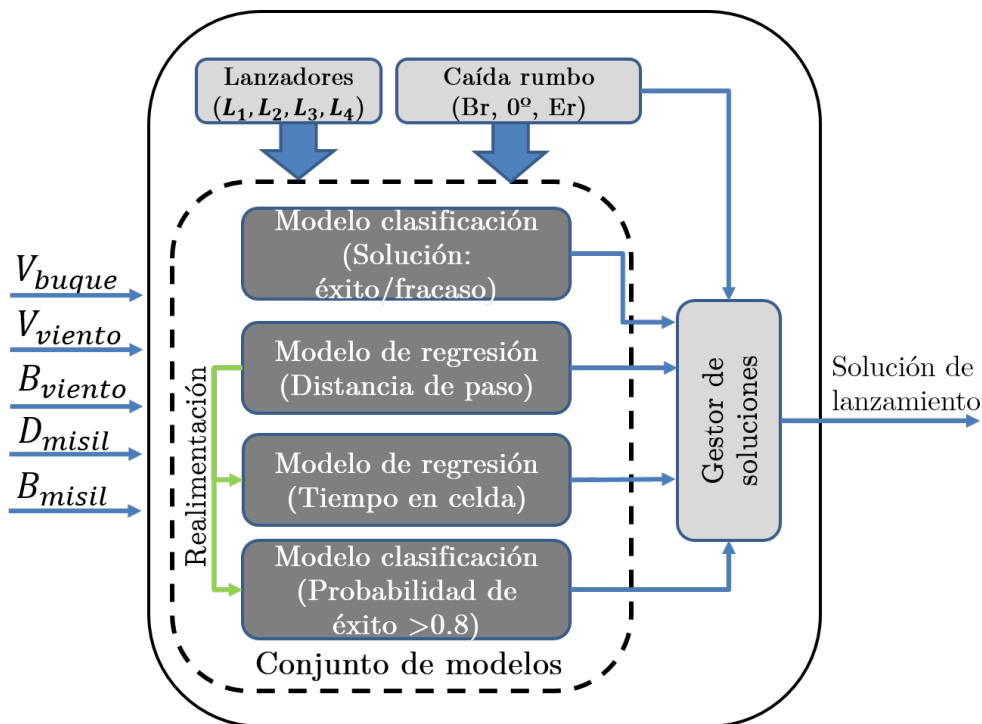


Figura 5-33. Solución final. Conjunto de modelos de perceptrón multicapa

Al existir realimentaciones entre modelos, inevitablemente se produce una propagación de errores. Por tal motivo, fue necesario determinar cuáles son los valores de las métricas una vez que se ha construido el conjunto completo. Para ello, se utilizó la

Capítulo 5. Implementación de un modelo de inteligencia artificial

muestra separada del conjunto de entrenamiento, de la que mediante muestreo aleatorio simple se extrajeron 10 subconjuntos de prueba, con los que obtuvieron los intervalos de confianza del 95% de las medias de las métricas que se observan en la Tabla 5-8.

Las variables de clasificación binaria presentan cierto desbalanceo en las clases reales, siendo más acusado este desequilibrio en la variable probabilidad de éxito. Por ello, fue necesario realizar un análisis global de las matrices de confusión para comprobar el comportamiento de los modelos.

Las matrices de confusión de ambas variables son las se presentan en la Figura 5-34, en donde se puede apreciar que el comportamiento de la variable solución es homogénea para las dos clases, no así la variable probabilidad de éxito que presenta un valor de especificidad bajo del 60,75%.

Se intentó mejorar el valor de especificidad entrenando en modelo con un conjunto de entrenamiento más balanceado, pero no se consiguieron mejoras, la corrección o amortiguamiento de este problema se ha incluido como una futura línea de investigación.

Tabla 5-8. Métricas de evaluación del conjunto de modelos

Variable de salida	Intervalo de confianza del 95% de la media de la métrica
Solución	Precisión: (96,69%; 96,71%)
Distancia de paso	MSE: (1,4118 ; 1,4384) $R^2 = 0.9999$ (<i>ver nota</i>)
Tiempo en celda	MSE: (0,0042; 0,0043) $R^2 = (0,9049 ; 0,9051)$
Probabilidad de éxito >0,8	Precisión: (93,64%; 93,68%)

Nota: Se ha obtenido un valor de la cuasi desviación típica de la distancia de paso de $S = 9,949 \cdot 10^{-8}$, por lo que el ancho del intervalo de confianza es extremadamente pequeño y no se incluye en la tabla




Figura 5-34. Matrices de confusión de las variables de salida solución (izquierda) y probabilidad de éxito >0,8 (derecha)

A modo de conclusión, y a la vista de las métricas de evaluación del conjunto de modelos, se puede afirmar que la solución final alcanzada cumple con los objetivos que se pretendían en la resolución del problema de lanzamiento de señuelos. Además, con las predicciones que se obtienen, se está en condiciones de alimentar a un gestor de soluciones para que ordene y evalúe todas las soluciones posibles para un escenario determinado en el que se requiera una reacción con señuelos.

5.7.7. Ampliación de la solución final

La solución final desarrollada con esta metodología es ampliable, ya que se pueden implementar a bordo tantos conjuntos de modelos como misiles amenaza existan en la zona de operaciones y tener solución de lanzamiento para cada uno de ellos de forma inmediata.

En la Figura 5-35 se muestra, de forma esquemática, la forma de escalar la solución final, donde bastaría añadir una entrada más al conjunto para indicar el tipo de misil (T_{misil}) sobre el cual se necesita obtener la solución de lanzamiento.

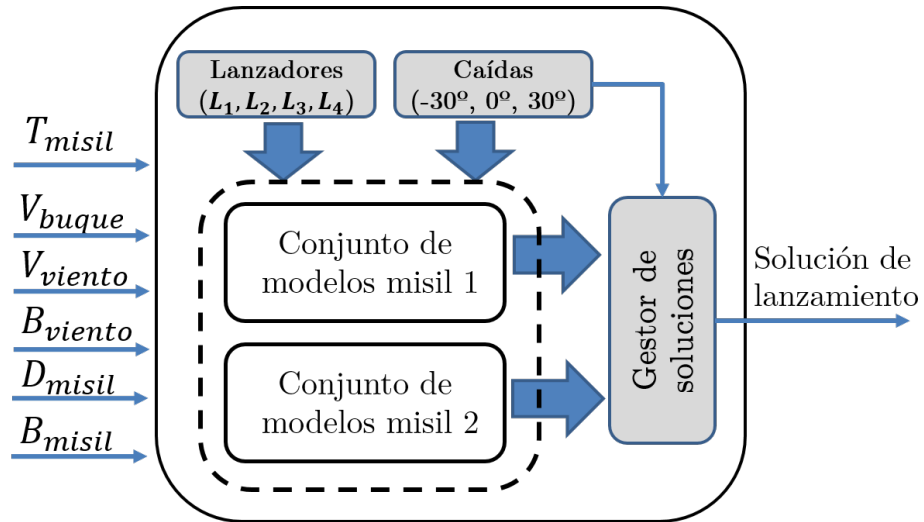


Figura 5-35. Ampliación de solución final

CAPÍTULO 6. EVALUACIÓN DE LAS SOLUCIONES DE LANZAMIENTO DE SEÑUELOS. EL GESTOR DE SOLUCIONES

6.1. INTRODUCCIÓN

El conjunto de modelos de perceptrón multicapa descrito en el capítulo anterior calcula todas las soluciones de lanzamiento de señuelos en el escenario en el que se encuentre un buque. Sin embargo, para un escenario pueden existir hasta 12 soluciones (4 lanzadores x 3 posibles caídas de rumbo) y cada una de ellas puede ser una respuesta válida para evitar el impacto del misil amenaza. Además por cada solución se obtiene también otra información adicional como: la distancia de paso del misil respecto al buque, el tiempo que estará el buque dentro de la celda de resolución del misil hasta que se complete la seducción y si la probabilidad de éxito de la solución es mayor o menor de 0,8.

Es evidente que en una situación de defensa antimisil, toda esta información no puede ser evaluada en tiempo real por el oficial de acción táctica¹³ (*tactical action officer*: TAO) por lo que es necesario automatizar la gestión de la respuesta del buque y presentar al TAO cuáles son las mejores soluciones para efectuar el lanzamiento de señuelos.

Con todo lo anterior, en este capítulo describiremos cómo, mediante técnicas de decisión multicriterio discreta, se ha implementado un gestor de soluciones que permite ordenar, en función de una serie de criterios, las reacciones válidas obtenidas por el conjunto de modelos.

Este capítulo comienza introduciendo el paradigma de la decisión multicriterio discreta, a continuación se describen los fundamentos teóricos de los modelos *multi-attribute utility theory* (MAUT) y proceso de análisis jerárquico o *analytic hierarchy*

¹³ El oficial de acción táctica es el responsable de controlar las armas y los sensores en la defensa del buque o el ataque contra las fuerzas enemigas.

process (AHP), que nos permitirán resolver el problema de la ordenación de las soluciones de lanzamiento. Finalmente se detalla cómo se han implementado estas técnicas para construir el gestor de soluciones y su aplicación sobre un caso de uso.

6.2. EL PARADIGMA DE LA DECISIÓN MULTICRITERIO DISCRETA

El paradigma tradicional en un proceso de toma de decisiones establece inicialmente un conjunto de soluciones factibles o posibles del problema a analizar y a continuación, en función de algún criterio, cada solución se asocia a un valor que representa el grado de deseabilidad de cada una de ellas. Seguidamente, utilizando alguna técnica matemática se realiza una búsqueda de cuál es la solución que posee un mayor grado de deseabilidad, es decir se calcula la solución óptima.

Los problemas de programación matemática se ajustan a este paradigma, las posibles soluciones son aquellas que pertenecen al conjunto de restricciones, el valor de la deseabilidad de cada solución se asigna mediante un criterio que corresponde a la función objetivo y para la búsqueda del óptimo se emplea alguna técnica, por ejemplo en el caso de problemas lineales el algoritmo del simplex (Romero, 1993).

Sin embargo, en ciertas ocasiones, es necesario tomar una decisión no solo en base a un único criterio (una función objetivo), sino que existen diferentes objetivos o criterios. Este tipo de problemas impusieron un nuevo paradigma denominado decisión multicriterio. Hay que reseñar que el óptimo, en sentido estricto del término, no existe en el análisis multicriterio, por lo que la solución a un problema de este tipo la denominaremos como la mejor posible (Barba-Romero & Pomerol, 1997).

En un problema de decisión multicriterio o *multiple criteria decision maker* (MCDM), existe un decisor que se encuentra en disposición de escoger entre varias posibilidades, denominadas alternativas, cuyo conjunto constituye el llamado conjunto de elección. Para seleccionar una alternativa del conjunto de elección el decisor tiene diversos puntos de vista, denominados criterios. Estos criterios son, al menos parcialmente contradictorios, en el sentido de que si el decisor adopta uno de dichos puntos de vista, no escogerá la misma alternativa que si se basa en otro criterio. Este tipo de problemas, a su vez, los podemos dividir en dos ramas: decisión multicriterio continua y decisión multicriterio discreta.

La decisión multicriterio continua, decisión multiobjetivo, programación multiobjetivo o *multi objective decision maker* (MODM), corresponde a un problema de optimización con dos o más funciones objetivo en conflicto, que trata de encontrar el conjunto de soluciones eficientes, para lo cual se puede utilizar, por ejemplo, el método de las ponderaciones o el método de las restricciones (Romero, 1996).

La **decisión multicriterio discreta**, decisión multiatributo o *multi attribute decision maker* (MADM), es una disciplina que permite apoyar la toma de decisiones sobre un cierto número finito de alternativas, a partir de ciertos criterios. En este ámbito pueden abordarse tres tipos de problemas (Barba-Romero & Pomerol, 1997):

- El problema de la selección.
- El problema de la ordenación.
- El problema de la clasificación.

El problema de la selección o problemática P_{α} trata de encontrar la mejor selección del conjunto de elección, se buscará un subconjunto tan restringido como se pueda conteniendo las alternativas satisfactorias.

El problema de la ordenación o problemática P_{γ} es más ambiciosa que la anterior, fijándose como objetivo una ordenación del conjunto de elección de las alternativas. Es decir se desea obtener un preorden total sobre dicho conjunto.

La problemática de la clasificación o problemática P_{β} consiste en asignar las alternativas en clases definidas a priori.

Hay que señalar que estas tres problemáticas no son independientes las unas de las otras, en particular la ordenación de alternativas nos puede servir para resolver el problema de la selección.

En el problema de lanzamiento de señuelos, las soluciones válidas para un escenario concreto forman un conjunto finito, que en términos del problema de decisión multicriterio discreta constituyen el conjunto de elección o de alternativas. Conjunto que debemos ordenar en función de una serie de criterios, que definiremos más adelante, y que también constituyen un conjunto finito, sobre los cuales se sustentará la decisión. Tenemos por lo tanto, un problema de decisión multiatributo que abordaremos desde la problemática de la ordenación o problemática P_{γ} .

6.2.1. El decisor y el analista

La decisión multicriterio discreta supone la existencia de un decisor, que hace referencia a los individuos que tienen la responsabilidad de analizar o tomar una decisión. Además existe lo que se denomina el analista, que es el encargado de modelar el problema objeto del estudio y el que hace las recomendaciones relativas a la selección final.

Para el problema de este trabajo, el decisor podrá ser el personal de la Junta de Táctica (JUTAC) o cualquier otro organismo dentro de la Armada que se determine y que con el objeto de automatizar el proceso de la decisión en el buque, deberá auxiliar al analista en la definición de los criterios de evaluación y en otras cuestiones relativas al problema de lanzamiento de señuelos.

En el caso real de una reacción antimisil, una vez resuelto de forma automatizada el problema multicriterio, el personal táctico de a bordo deberá recibir la información evaluada, liberándolo de ciertas decisiones para las cuales no tiene tiempo de reacción. Es decir, el proceso de decisión debe automatizarse en el laboratorio en tierra, para que el TAO sea un ejecutor de las respuestas del gestor de soluciones.

6.2.2. El conjunto de elección

La elección del decisor debe ejercerse con respecto a un número finito de alternativas denominado conjunto de elección $A = \{A_1, A_2, \dots, A_m\}$. Supondremos que las alternativas son diferentes, excluyentes y exhaustivas, además, de ser homogéneas y comparables.

Estas hipótesis son bastante fuertes, según ellas se prohíbe que el decisor escoja una solución intermedia entre las alternativas A_i y A_{i+1} o escoger una alternativa que no pertenezca al conjunto de elección. Si el decisor introduce una nueva alternativa es necesario realizar un nuevo análisis con el nuevo conjunto.

6.2.3. Atributos y criterios

Los atributos son las características, cualidades o parámetros que poseen o describen cada una de las alternativas del problema. Para llevar a cabo la elección entre las

alternativas del conjunto de elección, el decisor debe poseer uno o varios ejes de evaluación. Estos ejes de evaluación son las características de las alternativas, denominados criterios $C = \{C_1, C_2, \dots, C_n\}$ y que también supondremos que constituye un conjunto finito.

En un problema de decisión multicriterio podemos distinguir en entre dos tipos de criterios: cuantitativos, cuando se miden en una escala numérica (velocidad, distancia, tiempo, etc.) y cualitativos cuando su escala no es numérica (riesgo, calidad, razones políticas, etc.).

En relación a este aspecto, para que los resultados sean significativos y útiles, es imprescindible una adecuada selección y estructuración de los criterios relevantes del problema. Se considera que una familia de criterios es coherente si satisface las tres propiedades siguientes (Martínez & Escudey, 1998):

- **Exhaustividad:** es necesario ser cuidadoso en la inclusión de todos los criterios que permitan discriminar las alternativas. Esta es una cuestión de vital importancia, ya que de ella depende en gran medida la calidad de los resultados del proceso de la decisión.
- **Coherencia:** las preferencias globales del decisor deben ser coherentes con las preferencias según cada criterio, en el sentido de que si dos alternativas A_i y A_k tienen la misma calificación en todos los criterios, y por tanto son globalmente indiferentes para el decisor, la mejora de A_i respecto a un criterio implica una preferencia global de A_i respecto a A_k .
- **No redundancia:** es muy deseable que un mismo concepto no sea valorado varias veces dentro del proceso de la decisión, ya que ello podría implicar que se le esté otorgando excesiva importancia a un elemento de valoración, resultando más difícil determinar cuál es su influencia real, lo que podría corromper en cierta medida la solución alcanzada y confundir al decisor.

Por otro lado, cada uno de los criterios debe tener un peso o importancia, los cuales representan la estructura de preferencias del decisor, lo que da lugar a lo que se denomina vector de pesos $W = \{W_1, W_2, \dots, W_n\}$, que constituirá las ponderaciones de los criterios.

En ocasiones, si existe un número elevado de criterios, es aconsejable construir un modelo de jerarquía de criterios y subcriterios, lo que facilita al decisor elaborar el vector de pesos.

6.2.4. La matriz de decisión o matriz decisional

Supondremos que el decisor es capaz de dar, para cada uno de los criterios considerados y para cada alternativa del conjunto de elección, un valor numérico o simbólico (a_{ij}) que expresa una evaluación de la alternativa A_i respecto al criterio C_j , que será según el caso, una valoración o un coste.

La matriz $[a_{ij}]$ se llama matriz de decisión o matriz decisional (ver Figura 6-1). Cada fila de esta matriz expresa las cualidades de la alternativa i respecto a los n criterios considerados. Cada columna j recoge las evaluaciones, hechas por el decisor, de todas las alternativas con respecto al criterio C_j .

		Criterios					
		C_1	C_2	...	C_j	...	C_n
Alternativas	A_1	a_{11}	a_{12}	...	a_{1j}	...	a_{1n}
	A_2	a_{21}	a_{22}	...	a_{2j}	...	a_{2n}

	A_i	a_{i1}	a_{i2}	...	a_{ij}	...	a_{in}

	A_m	a_{m1}	a_{m2}	...	a_{mj}	...	a_{mn}
		W_1	W_2	...	W_j	...	W_n
		Vector de pesos					

Figura 6-1. Matriz de decisión

6.2.5. Cuantificación de las evaluaciones. La función de utilidad

Tal y como se expuso en el punto anterior, se denominan evaluaciones a las distintas características que las alternativas presentan frente a cada criterio, siendo necesario cuantificarlas de la manera más precisa posible, ya que representan a dichas alternativas en todo el proceso de análisis posterior.

Una función de utilidad es un mecanismo que permite evaluar las alternativas asignando números reales a las preferencias (satisfacción o utilidad) del decisor, de manera que si la preferencia aumenta el número asignado a la función utilidad también se incrementa. Para poder aceptar la existencia de una función de utilidad es necesario aceptar los siguientes supuestos (Barba-Romero & Pomerol, 1997):

- Comparabilidad. Dadas dos elecciones cualesquiera x e y ha de verificarse $x \succcurlyeq y$ ó $y \succcurlyeq x$ o ambas simultáneamente.
- Reflexibilidad. Para cualquier elección x se verifica que $x \succcurlyeq x$.
- Transitividad. Dadas tres elecciones cualesquiera x, y, z se verifica que si $x \succcurlyeq y$ & $y \succcurlyeq z$ entonces $x \succcurlyeq z$.

Así podemos dar la siguiente definición:

Una función $U: X \rightarrow R$ es una función de utilidad que representa la relación de preferencia \succcurlyeq , si para todo $x, y \in X$, $x \succcurlyeq y \Leftrightarrow U(x) \geq U(y)$.

Las funciones de utilidad las podemos clasificar, según se refleja en la Figura 6-2, en ordinales y cardinales y dentro de esta última categoría en cardinales ratio o intervalo.

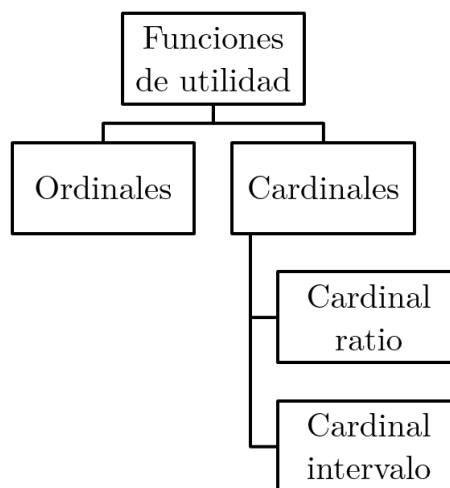


Figura 6-2. Tipos de funciones de utilidad

La **función de utilidad ordinal** indica el orden y nada más. En la Tabla 6-1 se muestra un ejemplo de este tipo de función de utilidad que ocasiona el siguiente orden de preferencias de las alternativas $A_1 \succ A_2 \succ A_3$.

Tabla 6-1. Ejemplo de función de utilidad ordinal

Alternativa	Utilidad $U(x)$
A_1	3
A_2	2
A_3	1

En las **funciones cardinales intervalo** el decisor expresa las diferencias de preferencias. Es decir, si indica que $x \succ y$ y $a \succ b$, se puede asimismo, decir que la diferencia entre x e y es igual, más grande o más pequeña que la diferencia entre a y b . Una función de utilidad cardinal intervalo será pues una función que respeta las diferencias, además de respetar el orden.

La **función cardinal ratio** supone, además de las condiciones de la utilidad cardinal intervalo, la existencia de cero verdadero. Cuando una alternativa A_i tiene como evaluación, para un determinado criterio C_j el valor a_{ij} =cero verdadero, significa la ausencia física de esa propiedad. Por lo tanto, se dice que un decisor expresa preferencias cardinal ratio si:

- Puede comparar las diferencia de las preferencias, es decir, que si indica $x \succ y$ y $a \succ b$ puede asimismo, afirmar que la diferencia entre x e y es igual, mayor o menor que la diferencia entre a y b .
- Existe un elemento $a \in A$ que puede servir de referencia absoluta, y tal que para toda utilidad U es $U(a) = 0$.

6.2.6. Métodos de construcción de funciones de utilidad

El primer paso para construir una función de utilidad cardinal es establecer la escala de medida de la utilidad, que frecuentemente se mide entre 0 y 1, aunque por razones prácticas o de interpretación puede adoptarse cualquier otra. A continuación se debe definir la función de utilidad, para lo cual Barba-Romero y Pomerol (Barba-Romero & Pomerol, 1997) plantean diversos métodos para ayudar al decisor:

Método de evaluación directa. Consiste en dejar que el decisor establezca la forma de la función de utilidad. Se le puede ayudar interrogándole directamente planteándole

cuestiones del tipo “¿es la preferencia de b sobre a dos veces más fuerte que la de c sobre a ?”, que conduce a que $U(b) - U(a) = 2 \times (U(c) - U(a))$. Con un número suficiente de tales cuestiones se llega a una aproximación razonable de la curva de utilidad.

Método de las razones. A partir de una alternativa cuya utilidad sirve de unidad (no que tenga la utilidad igual a 1 en una escala $[0,1]$) y en hacer que el decisor exprese su satisfacción en relación con ella.

Método de las categorías. Consiste en demandar al decisor una partición de la escala en intervalos de igual valor, situando entonces el decisor las alternativas en estas categorías.

Método de la bisección. Primero se determinan las utilidades de las alternativas extremas. Se insta entonces al decisor a que precise cuál es la alternativa que procura una satisfacción exactamente intermedia entre la mejor y la peor. Si la mejor alternativa se puntúa con utilidad 1 y la peor 0, se busca entonces la alternativa que tenga una utilidad 0,5, después las que tengan utilidades de 0,25 y 0,75, y así sucesivamente dividiendo en dos cada vez los intervalos.

Método de las diferencias equivalentes. Se trocea la escala de las utilidades en intervalos procurando una igual satisfacción. Respetando la igualdad de estos intervalos en el eje de ordenadas es fácil construir la utilidad.

6.2.7. Pasos en un problema de decisión multicriterio

Una vez vistos los conceptos básicos relacionados con los problemas de decisión multicriterio, podemos resumir los pasos necesarios para resolver estos problemas mediante el gráfico de la Figura 6-3.

El paso correspondiente al análisis de sensibilidad, consiste en determinar si los resultados obtenidos en la solución son robustos o por el contrario un pequeño cambio, bien sea en los pesos o en la valoración de los atributos de las alternativas, pueden provocar un cambio en la solución general de problema. Aunque este paso es deseable

en todo proceso de decisión multicriterio, dicho análisis no es factible realizarlo durante una reacción antimisil de lanzamiento de señuelos por lo reducido del tiempo disponible y por lo tanto no se implementó en el gestor de soluciones.

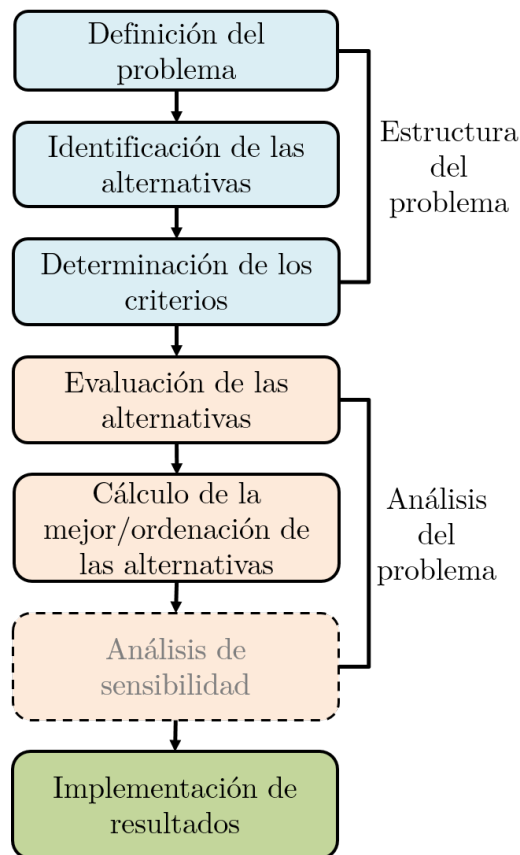


Figura 6-3. Pasos en un problema de decisión multicriterio

6.2.8. Elección del modelo de decisión multicriterio discreta

Dentro de los modelos de decisión multiatributo, podemos distinguir dos grandes familias metodológicas (Carrillo, 2006):

- Por un lado la que podríamos denominar escuela americana, centrada en el estudio de las funciones de utilidad multicriterio y liderada por Ralf Keeney y Howard Raiffa (Keeney & Raiffa, 1976), entre otros. Como ejemplos de los métodos basados en la utilidad podemos encontrar la teoría de utilidad multiatributo o *multi-attribute utility theory* (MAUT) o *multi-attribute value theory* (MAVT).

También dentro de este grupo hay que destacar los modelos basados en matrices de comparación por parejas diseñados por Saaty (T. Saaty, 1977). Estos algoritmos son muy útiles para obtener el vector de pesos de los criterios del problema y evaluar criterios subjetivos mediante la comparación de las alternativas entre sí. Entre ellos nos podemos encontrar el modelo proceso de análisis jerárquico o *analytic hierarchy process* (AHP), *analytic network process* (ANP) o *measuring attractiveness by a categorical based evaluation technique* (MACBETH) (Penadés-Plà, García-Segura, Martí, & Yepes, 2016).

- Por otra parte, la escuela europea o escuela francesa está centrada en el estudio de los llamados métodos de superación o sobreclasificación y liderada por el francés Bernard Roy y otros investigadores franceses, belgas y holandeses (Benayoun, Roy, & Sussmann, 1966; Roy, 1968, 1991). Dentro de estos métodos encontramos el algoritmo *elimination et choix traduisant la réalité* (ELECTRE), al que le siguieron versiones más sofisticadas como las ELECTRE II, III y IV y otras variantes como el *qualitative flexible* (QUALITEX), *organization, rangement et synthese de donnes relationnelles* (ORESTE) o *preference ranking organization method for enrichment evaluations* (PROMETHEE).

Una vez vistos los principales métodos de decisión multiatributo y el marco teórico general que los sustenta, la cuestión que se nos plantea ahora es la elección del mejor método multicriterio para implementarlo en el gestor de soluciones. En relación a este tema, no podemos establecer un método como el óptimo con respecto al resto (Romero, 1993), incluso algunos autores como Ozernoy (Ozernoy, 1992), apuntan que la elección del mejor método multicriterio es un problema multicriterio en sí mismo.

Para este trabajo, se ha utilizado el método AHP con la inclusión de las valoraciones de las alternativas frente a los criterios mediante funciones de utilidad previamente determinadas por el decisor. Podríamos afirmar que se ha utilizado un método mixto AHP/MAUT, donde el uso de funciones de utilidad, como veremos en el punto 6.5, nos va a permitir una evaluación automática de las alternativas en el gestor de soluciones que se implemente a bordo del buque.

Fundamentalmente se ha escogido el método AHP por su sencillez, ya que permite una fácil interpretación por parte del decisor no técnico y además se viene utilizando en la Armada para la toma de decisiones en diferentes campos, mediante una herramienta informática denominada Ayuda a la Decisión de las Líneas de Acción (ADLA) que implementa esta metodología.

En concreto la aplicación ADLA se desarrolló como un componente independiente del realizado para integrar la herramienta en el sistema de mando y control (*command and control*: C2) Talos¹⁴ para la comparación de Líneas de acción y la toma de decisión en función de una serie de criterios. Fue desarrollada por la empresa GMV, en colaboración con el GIMO (Gabinete de Investigación Operativa de la Armada), que estableció los requisitos y evaluó su correcto funcionamiento (GMV, 2014) .

6.3. TEORÍA DE UTILIDAD MULTIATRIBUTO (MAUT)

La teoría de la utilidad multiatributo o *multi-attribute utility theory* (MAUT), desarrollada por Keeney y Raiffa (Keeney & Raiffa, 1976), proporciona una base formal para describir elecciones entre alternativas cuyas consecuencias están caracterizadas por múltiples atributos relevantes (Rios-Insua, Mateos, & Jimenez-Martín, 2002).

Se asume que el decisor es racional, y por lo tanto es capaz de asignar para cada alternativa y en cada criterio, un nivel de preferencia que vendrá dado por la correspondiente función de utilidad. Posteriormente, todas las funciones de utilidad se agregan de forma aditiva o multiplicativa, consiguiendo determinarse la utilidad global de cada una de las alternativas, obteniendo así una ordenación completa del conjunto (Ross, 2005).

Los pasos para la aplicación del método MAUT son los siguientes (Sutter, 2003):

¹⁴ Talos es un sistema de mando y control que permite realizar la coordinación y ejecución del apoyo de fuegos de las fuerza terretres.

Paso#1. Estructurar una jerarquía de criterios

El decisor establece el conjunto de alternativas y formula el conjunto de atributos o criterios para el problema al que se enfrenta.

Paso#2. Definición de las funciones de utilidad

Para cada criterio se define una función de utilidad que traduce la medida del evaluador o la evaluación del criterio en una utilidad.

Normalmente estas funciones están normalizadas en un intervalo entre 0 y 1, que será la escala que utilicemos en el gestor de soluciones.

Paso#3. Transformar las preferencias en pesos

Se utilizan pesos para caracterizar la importancia de los criterios. Las preferencias de los evaluadores son traducidas a valores numéricos.

Paso#4. Caracterización de los criterios

Se valoran todos los criterios para todas las alternativas, los cuáles pueden ser evaluados de manera cuantitativa o cualitativa.

Paso#5. Agregación de los resultados

Para cada alternativa, los criterios son transformados en una utilidad con las funciones creadas en el paso 2. Posteriormente, ponderadas dichas utilidades con los pesos del paso 3, se combinan en un valor único aplicando una forma especial de composición que puede ser un modelo aditivo o multiplicativo.

6.4. EL PROCESO DE ANÁLISIS JERÁRQUICO (AHP)

El proceso de análisis jerárquico o *analytic hierrchy process* (AHP) es un procedimiento para la toma de decisiones desarrollado originalmente por Saaty (T. Saaty, 1977, 1980, 1986) utilizado para resolver problemas de decisión multicriterio discreta. El AHP organiza el objetivo o meta del problema, los criterios y las alternativas en una estructura jerárquica, asignando pesos en los diferentes niveles de los criterios.

Otra característica del modelo es la forma de realizar el cálculo de vector de pesos y las valoraciones a las alternativas para los criterios del problema. En este procedimiento se realizan mediante la construcción de lo que se denominan matrices de comparación por parejas (MCP), donde el decisor plasma sus preferencias mediante la comparación entre pares de elementos en cada uno de los niveles (criterios y alternativas).

Es evidente que la información vertida por el decisor en las MCP tendrá un componente subjetivo y además estará sujeta a juicios inconsistentes que tendrán que medirse y corregirse, en su caso, para evitar resultados erróneos en la solución final. Por ejemplo, para un problema de tres criterios $C = \{C_1, C_2, C_3\}$, el decisor puede establecer inicialmente que $C_1 > C_2$, $C_3 > C_1$ y $C_2 > C_3$, lo cual constituye una inconsistencia ya que necesariamente $C_3 > C_2$.

Por último, obtenidos el vector de pesos y las valoraciones de las alternativas, el siguiente paso es establecer las prioridades totales asociadas a cada una de las alternativas.

6.4.1. Axiomas básicos

Los axiomas básicos en los que se basa la teoría AHP, enumerados por Saaty (T. Saaty, 1986) y resumidos por García Cascales (García Cascales, 2009) en su tesis doctoral son:

- **Axioma de comparación recíproca:** El decisor debe ser capaz de realizar comparaciones y establecer la fuerza de sus preferencias. La intensidad de estas preferencias debe satisfacer la condición recíproca: “Si A_i es x veces preferido que A_j , entonces A_j es veces preferido que $(1/x)A_i$ ”.
- **Axioma de homogeneidad:** “Las preferencias se representan por medio de una escala limitada”.
- **Axioma de independencia:** “Cuando se expresan preferencias, se asume que los criterios son independientes de las propiedades de las alternativas”.
- **Axioma de las expectativas:** “Para el propósito de la toma de una decisión, se asume que la jerarquía es completa”.

6.4.2. Metodología del proceso AHP

Los pasos para implementar la metodología AHP pueden resumirse según lo contenido en la Figura 6-4. Figura que ha sido elaborada a partir de la formulación de la metodología propuesta por Saaty (R. W. Saaty, 1987; T. Saaty, 1980), la exposición realizada por García Cascales en su tesis doctoral (García Cascales, 2009) y los trabajos de Willian Ho (Ho, 2008).

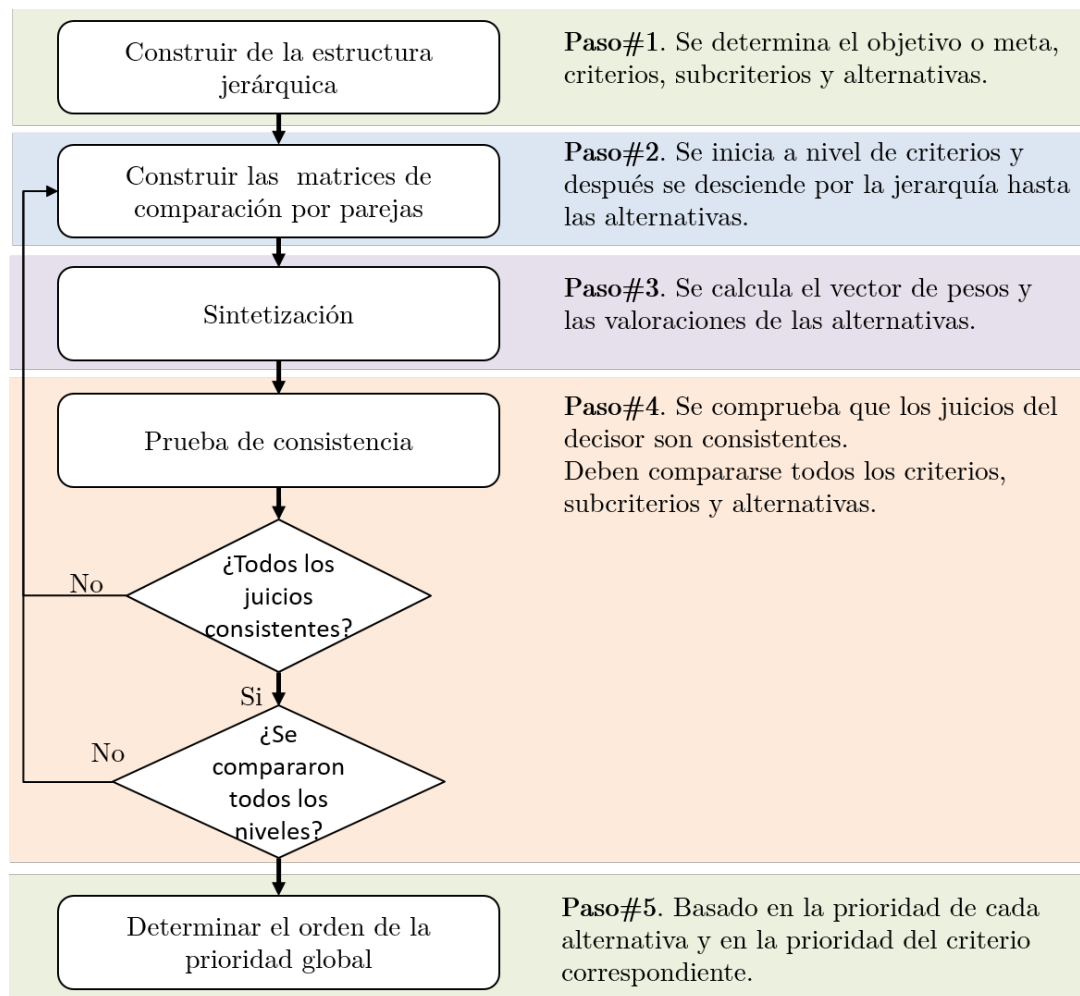


Figura 6-4. Pasos del método AHP (García Cascales, 2009; Ho, 2008)

6.4.3. Construcción de la estructura jerárquica del problema

El primer paso que debe darse en todo problema multicriterio, es la determinación del objetivo, los criterios y alternativas. En la metodología AHP, estos elementos se ordenan según una jerarquía en distintos niveles, donde en el nivel superior se encuentra

el objetivo del problema y en el nivel más bajo las alternativas que se pretenden valorar.

En caso de que el número de criterios sea elevado, lo recomendable es agruparlos en criterios y subcriterios para permitir un mejor tratamiento de la jerarquía durante la aplicación del proceso (ver Figura 6-5).

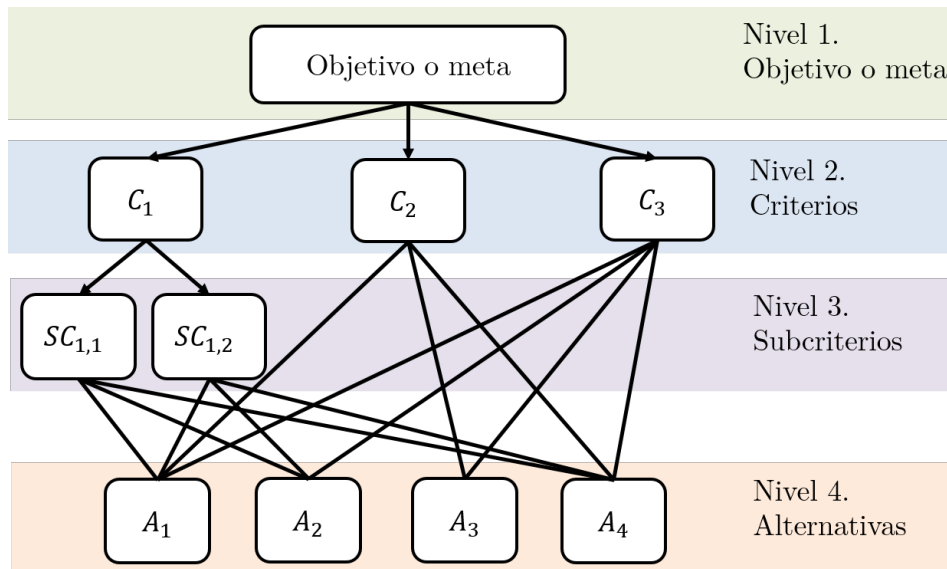


Figura 6-5. Jerarquía de elementos en un modelo AHP

6.4.4. Construcción de las matrices de comparación por parejas

Una vez establecida la estructura jerárquica del problema, el decisor debe emitir sus juicios para poder determinar el vector de pesos de los criterios y las valoraciones de las alternativas. En la metodología AHP, estas acciones se realizan mediante MCP.

Las MCP son matrices cuadradas, donde el decisor enfrenta parejas de criterios para obtener el vector de pesos y parejas de alternativas para cada criterio, de cara a obtener las valoraciones de las alternativas.

En la Figura 6-6 se ha incluido un ejemplo de cómo el decisor, en forma de matrices y siguiendo la escala de Saaty, que se muestra en la Tabla 6-2, plasma sus juicios de valor o preferencias en cada uno de los niveles jerárquicos establecidos.

No es aconsejable la construcción de MCP de dimensión mayor de 7 ± 2 , denominado número mágico de Miller (Miller, 1956), ya que a partir de este tamaño el decisor no

Capítulo 6. Evaluación de las soluciones de lanzamiento de señuelos. El gestor de soluciones

será capaz de dar juicios suficientemente consistentes. En estos casos es aconsejable dividir los criterios en subcriterios para reducir la dimensión de las matrices.

MCP de los pesos				MCP de las alternativas para el criterio C_i			
	C_1	C_2	C_3		A_1	A_2	A_3
C_1	1	4	1/3	A_1	1	1/3	5
C_2	1/4	1	1/6	A_2	3	1	6
C_3	3	6	1	A_3	1/5	1/6	1

Figura 6-6. Ejemplos de matrices de comparación por parejas para determinar el vector de pesos (izquierda) y asignar valores a las alternativas para un criterio (derecha)

Tabla 6-2. Escala de Saaty (T. Saaty, 1980)

Escala numérica	Escala verbal	Explicación
1	Igual importancia	Los dos elementos contribuyen igualmente a la propiedad o criterio
3	Moderadamente más importante un elemento que el otro	El juicio y la experiencia previa favorecen a un elemento frente al otro
5	Fuertemente más importante un elemento que el otro	El juicio y la experiencia previa favorecen fuertemente a un elemento frente al otro
7	Mucho más fuerte la importancia de un elemento que la del otro	Un elemento domina fuertemente. Su dominación está probada en práctica
9	Importancia extrema de un elemento frente al otro	Un elemento domina al otro con el mayor orden de magnitud posible

Nota: se pueden utilizar valores intermedios para una mejor aproximación.

6.4.5. Sintetización. Cálculo del vector de pesos y valoración de las alternativas

El método AHP calcula, a partir de las MCP construidas en el paso anterior, el vector de pesos y asigna las valoraciones a las alternativas para los criterios del problema.

Dada la necesidad de automatizar el proceso de la decisión en nuestro problema de ordenación de las soluciones de lanzamiento de señuelos, utilizaremos las MCP para determinar el vector de pesos de los criterios, mientras que la valoración (a_{ij}) de cada alternativa (i) en cada criterio (j) se implementarán mediante funciones de utilidad, que serán construidas por el decisor con el apoyo del analista y mediante alguno de los métodos citados en el punto 6.2.6.

Para el cálculo del vector de pesos a partir de las MCP, existen diferentes metodologías: el método del eigenvalor o *eigenvalor method* (EM), *least squares method* (LLSM) o el método aproximado (T. Saaty & Hu, 1998). La implementación llevada a cabo en el gestor de soluciones corresponde a este último cuyos pasos se describen a continuación:

Paso#1

Partiendo de la matriz de comparación por parejas A de dimensión $m \times m$, se calcula la matriz $B = A \times A = A^2$

$$A = \begin{pmatrix} A_{11} & \cdots & A_{1m} \\ \vdots & \ddots & \vdots \\ A_{m1} & \cdots & A_{mm} \end{pmatrix} \Rightarrow B = A \times A = A^2 = \begin{pmatrix} B_{11} & \cdots & B_{1m} \\ \vdots & \ddots & \vdots \\ B_{m1} & \cdots & B_{mm} \end{pmatrix} \quad (6-1)$$

Paso#2

Se normaliza la matriz B , obteniendo la matriz N , dividiendo cada valor de la columna por la suma de cada columna.

$$N = \begin{pmatrix} B_{11}/\sum_{i=1}^m B_{i1} & \cdots & B_{1m}/\sum_{i=1}^m B_{im} \\ \vdots & \ddots & \vdots \\ B_{m1}/\sum_{i=1}^m B_{i1} & \cdots & B_{mm}/\sum_{i=1}^m B_{im} \end{pmatrix} = \begin{pmatrix} N_{11} & \cdots & N_{1m} \\ \vdots & \ddots & \vdots \\ N_{m1} & \cdots & N_{mm} \end{pmatrix} \quad (6-2)$$

Paso#3

A partir de la matriz normalizada N se obtiene el vector de pesos W , calculando la media de cada fila de la matriz N . Los valores de los pesos o prioridades vendrán dados en la escala $[0,1]$.

$$W = \begin{pmatrix} \sum_{i=1}^m N_{1i}/m \\ \dots \\ \sum_{i=1}^m N_{mi}/m \end{pmatrix} = \begin{pmatrix} W_1 \\ \dots \\ W_m \end{pmatrix} \quad (6-3)$$

6.4.6. Prueba de consistencia

La inconsistencia surge cuando algunos juicios de la matriz de comparación por parejas se contradicen unos a otros. En toda MCP se van a producir inconsistencias ya que ello es inherente al pensamiento humano, pero dichas inconsistencias deben estar controladas y no sobrepasar cierto nivel, ya que un valor alto estaría indicando que los juicios del decisor pueden haber sido elaborados de forma aleatoria o que el decisor no entiende el problema al que se enfrenta.

Para calcular esta inconsistencia existe un índice que se denomina relación de consistencia (RC), que nos indicará el nivel de validez de los resultados. Para su cálculo deben seguirse los siguientes pasos:

Paso#1

Se multiplica la MCP por su vector de pesos, obteniendo el vector suma ponderada.

$$\text{vector suma ponderada} = \begin{pmatrix} A_{11} & \dots & A_{1m} \\ \vdots & \ddots & \vdots \\ A_{m1} & \dots & A_{mm} \end{pmatrix} \times \begin{pmatrix} W_1 \\ \dots \\ W_m \end{pmatrix} = \begin{pmatrix} Sp_1 \\ \dots \\ Sp_m \end{pmatrix} \quad (6-4)$$

Paso#2

Se dividen los elementos del vector de suma ponderada entre el correspondiente valor de prioridad del elemento, obteniendo la siguiente matriz:

$$\begin{pmatrix} Sp_1/W_1 \\ \dots \\ Sp_m/W_m \end{pmatrix} \quad (6-5)$$

Paso# 3

Se calcula el valor λ_{max} , que corresponde a la media de los valores que se determinaron en el paso anterior.

$$\lambda_{max} = \frac{(Sp_1/W_1 + \dots + Sp_m/W_m)}{m} \quad (6-6)$$

Paso#4

Se calcula el índice de consistencia (IC) mediante la siguiente expresión:

$$IC = \frac{\lambda_{max} - m}{m - 1} \quad (6-7)$$

Paso#5

Se determina la relación de consistencia (RC) que vendrá dada en función del índice de consistencia (IC) y del número de elementos que se comparan, es decir del tamaño de la matriz. En este punto se tiene en cuenta la inconsistencia aleatoria media (IAM) (ver Tabla 6-3) desarrollada por Saaty (T. Saaty & Vargas, 2001), para así obtener un índice que nos indique la consistencia de la matriz independientemente de su dimensión.

La relación de consistencia vendrá dada por el cociente entre el índice de consistencia y la inconsistencia aleatoria media:

$$RC = \frac{IC}{IAM} \quad (6-8)$$

En general, un valor de RC menor de 0,10 se acepta como válido, en caso contrario deberían revisarse los juicios emitidos por el decisor.

Tabla 6-3. Tabla de índices de inconsistencia aleatoria media (T. Saaty & Vargas, 2001)

Dimensión de la matriz	3	4	5	6	7	8	9	10
IAM	0,52	0,89	1,11	1,25	1,35	1,40	1,45	1,49

Nótese que no puede haber inconsistencia para una matriz 2x2

6.4.7. Determinar el orden de la prioridad global

Para finalizar, una vez obtenida la matriz de decisión de la Figura 6-7 y empleando una agregación aditiva ponderada por el vector de pesos, se calcula la prioridad o importancia relativa entre las alternativas para determinar posteriormente el orden de prioridad global o solución al problema.

		Criterios				
		C_1	...	C_i	...	C_n
Alternativas	A_1	a_{11}	...	a_{1i}	...	a_{1n}

	A_j	a_{j1}	...	a_{ji}	...	a_{jn}

	A_m	a_{m1}	...	a_{mi}	...	a_{mn}
		W_1	...	W_i	...	W_n
		Vector de pesos				

Figura 6-7. Matriz de decisión

Inicialmente para obtener la unicidad del vector de prioridades, se pueden utilizar fundamentalmente dos métodos de normalización: el método ideal o el método distributivo (Moreno Jimenez & Escobar Urmeneta, 2000).

El **método ideal o de BG (Belton & Gear)** normaliza la matriz decisional dividiendo cada elemento de la matriz por el valor máximo de su columna o criterio (ver Figura 6-8). Este procedimiento minimiza los casos de inversión de rangos o *rank reversal*, es decir cambios en la ordenación final de las alternativas al incluir una nueva en el conjunto (Belton & Gear, 1983, 1984).

Este es el procedimiento que se ha implementado en el gestor de soluciones.

	C_1	...	C_n
A_1	$a_{11}/\max(a_{11}..a_{m1})$...	$a_{1n}/\max(a_{1n}..a_{mn})$
...	$a_{i1}/\max(a_{11}..a_{m1})$...	$U_{in}/\max(a_{1n}..a_{mn})$
A_m	$a_{m1}/\max(a_{11}..a_{m1})$...	$a_{mn}/\max(a_{1n}..a_{mn})$

Figura 6-8. Matriz decisional en el método ideal

El **método distributivo** es similar anterior, calcula la matriz decisional normalizada distributiva dividiendo cada elemento de la matriz por la suma de los elementos de su columna o criterio (ver Figura 6-9).

	C_1	...	C_n
A_1	$a_{11}/\sum_1^m a_{i1}$...	$a_{1n}/\sum_1^m a_{in}$
...	$a_{i1}/\sum_1^m a_{i1}$...	$a_{in}/\sum_1^m a_{in}$
A_m	$a_{m1}/\sum_1^m a_{i1}$...	$a_{mn}/\sum_1^m a_{in}$

Figura 6-9. Matriz decisional en el método de la normalización o distributivo

6.5. CONSTRUCCIÓN DEL GESTOR DE SOLUCIONES

Una vez visto el marco teórico de la decisión multicriterio discreta y de los métodos MAUT y AHP, a continuación se expondrá cómo se han implementado estas técnicas en la construcción del gestor de soluciones.

Para un escenario concreto en el que se pueda encontrar el buque en caso de ataque con misiles, el conjunto de modelos de MLP, que se desarrolló en el capítulo anterior, obtiene todas las soluciones para conseguir la seducción del misil.

El número máximo de soluciones posibles es de 12 (4 lanzadores x 3 posibles maniobras del buque), por lo que nos podemos encontrar con un escenario en el que tengamos que escoger entre un conjunto finito de posibles respuestas todas ellas válidas. Por

Capítulo 6. Evaluación de las soluciones de lanzamiento de señuelos. El gestor de soluciones

ello es necesario que al operador se le presente la información evaluada de tal forma que el conjunto de soluciones esté ordenado de la mejor a la peor.

Para resolver esta cuestión se ha construido un gestor de soluciones que realice esta tarea mediante la implementación de métodos de decisión multicriterio discreta.

Además también se tendrán en cuenta la información proporcionada por la variable probabilidad de éxito, con la que dividiremos al conjunto de soluciones en dos grupos.

El gestor de soluciones se implementó mediante un script de MATLAB y trabaja en serie con el conjunto de modelos de MLP, para obtener la solución evaluada del problema del lanzamiento de señuelos.

6.5.1. Jerarquía. Alternativas y criterios

El primer paso del método AHP consiste en construir la estructura jerárquica del problema (ver Figura 6-10). Así, siguiendo con la terminología de los métodos multicriterio, el objetivo o meta que se nos plantea, es ordenar “*de mejor a peor*” las soluciones válidas de lanzamiento, que constituirán el conjunto de alternativas. Además, esta ordenación se realizará en función del siguiente conjunto de criterios:

- Distancia de paso del misil.
- Tiempo en celda.
- Caída de rumbo o maniobra del buque.

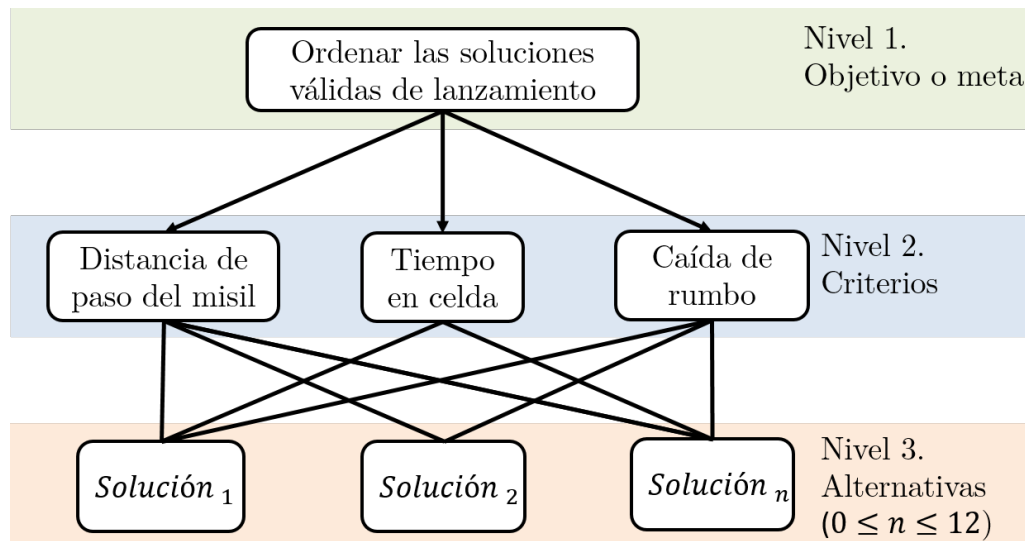


Figura 6-10. Estructura jerárquica del problema

6.5.2. Pesos de los criterios. Matriz de comparación por parejas

Continuando con la metodología AHP, en este paso se procede a calcular el vector de pesos de los criterios. En este punto el decisor deberá comparar los criterios por pares utilizando la escala de Saaty contenida en la Tabla 6-2 y plasmar sus juicios en una matriz de comparación de parejas.

Para nuestro problema se construyó la matriz de la Tabla 6-4 y se determinó la relación de consistencia, que alcanzó un valor inferior a 0,1, considerándose correcto para nuestro problema. A continuación, se realizaron los cálculos expuestos en el punto 6.4.5 para calcular el vector de pesos, obteniéndose los resultados que se han plasmado en la gráfica de la Figura 6-11.

Tabla 6-4. Matriz de comparación por parejas. Vector de pesos

	Distancia de paso	Tiempo en celda	Caída de rumbo
Distancia de paso	1	2	3
Tiempo en celda	1/2	1	2
Caída de rumbo	1/3	1/2	1
Relación de Consistencia	0,05		




Figura 6-11. Vector de pesos de los criterios

La matriz anterior ha sido elaborada con los juicios del autor de esta tesis, pero puede construirse mediante un grupo de expertos, de tal forma que cada uno de ellos emita sus juicios y posteriormente se cree una matriz consolidada calculada mediante la media geométrica o aritmética de los juicios individuales del grupo.

6.5.3. Valoración de las alternativas. Funciones de utilidad

El siguiente paso en la construcción del gestor de soluciones consistió en determinar las funciones de utilidad de los tres criterios señalados anteriormente.

Para construir la función de utilidad del criterio distancia de paso del misil, se utilizó el método de la bisección, señalado en el punto 6.2.6. Inicialmente se elaboró la Tabla 6-5 de utilidades y posteriormente se utilizó la aplicación CurveExpert Basic 2.1.0 para ajustar la función mediante métodos de regresión, resultando la siguiente función logística con un $R^2 = 0,95$.

$$U(x) = \frac{a}{1 + b \cdot e^{-cx}} \quad \begin{array}{l} a = 0,9961 \\ b = 0,2528 \\ c = 0,1288 \end{array} \quad (6-9)$$

El resultado gráfico de la función de utilidad se puede observar en la Figura 6-12, donde se aprecia que para distancias pequeñas, menores de una eslora del buque (la eslora del buque empleado es de 100 metros) la utilidad es muy pobre, aumentando

Capítulo 6. Evaluación de las soluciones de lanzamiento de señuelos. El gestor de soluciones

de forma casi lineal entre 200 y 400 yardas, para conseguir el valor de saciedad en las 1000 yardas.

Tabla 6-5. Tabla de utilidades de la distancia de paso

Distancia de paso (yardas)	Utilidad U(x)
0	0
150	0.25
250	0.5
350	0.75
450	0.95
1000	1




Figura 6-12. Función de utilidad de la distancia de paso

En el caso del criterio porcentaje del tiempo en celda, se ha actuado de la misma manera. Se construyó la Tabla 6-6 utilizando el método de la bisección y mediante la aplicación CurveExpert se obtuvo la curva de ajuste a la nube de puntos, resultando la siguiente función exponencial con un $R^2 = 0,98$.

$$U(x) = a(b - e^{-c \cdot x}) \quad \begin{array}{l} a = 4,4777 \\ b = 23,0629 \\ c = -3,1595 \end{array} \quad (6-10)$$

Para este criterio, la gráfica resultante de la función utilidad se ha incluido en la Figura 6-13. Obsérvese que para mayor tiempo en celda implica menor utilidad, aumentando la pendiente negativa para valores en el criterio superiores a 0,5.

Tabla 6-6. Tabla de utilidades del tiempo en celda

Tiempo en celda	Utilidad $U(x)$
1	0
0.95	0.1
0.9	0.25
0.8	0.5
0.6	0.75
0.3	0.9
0	1




Figura 6-13 Función de utilidad del tiempo en celda

En cuanto al criterio caída de rumbo, se ha construido la función de utilidad en escalón (ver Figura 6-14), asignado utilidad $U(x) = 1$ cuando no es necesario caer de rumbo y utilidad $U(x) = 0$ en el caso contrario. Estos valores de utilidad modelan la premisa: “mejor cuantas menos acciones deba ejecutar el buque en una reacción antimisil”.




Figura 6-14. Función de utilidad de la caída de rumbo

6.5.4. Cálculo del orden global

Una vez obtenidos el vector de pesos y el conjunto de alternativas o soluciones validadas de lanzamiento con los valores de cada criterio, se transforman dichos valores en utilidad según las funciones vistas en el punto anterior, se calcula la matriz decisional normalizada y se pondera con los pesos en un modelo aditivo, obteniendo así la utilidad global final.

Además de utilizar el procedimiento AHP para la obtención de las utilidades globales de cada alternativa, el gestor de soluciones tiene en cuenta las siguientes condiciones para modelar el orden final de las soluciones de lanzamiento.

Condición#1. Solo toma como soluciones válidas de lanzamiento aquellas que obtengan un valor de probabilidad mayor de 0,5 a la salida del modelo MLP de clasificación *solución*.

Condición#2. La utilidad de la alternativa calculada mediante el procedimiento AHP se multiplica por la probabilidad obtenida en el modelo de clasificación *solución*, para obtener lo que denominaremos la utilidad global modificada.

Condición#3. Una vez obtenidas las utilidades globales modificadas de todas las alternativas, se forman dos grupos de prioridad (prioridad 1 y prioridad 2) basados en la salida del modelo de clasificación *probabilidad de éxito* $>0,8$. Aquellas alternativas con probabilidad de éxito superior a 0,8 serán siempre prioritarias respecto al resto, aunque tengan una menor utilidad calculada.

Una vez aplicadas todas las correcciones, se le presenta al operador una lista de soluciones ordenada en función de su utilidad final. En la Figura 6-15 se muestra, para el buque ficticio utilizado en el trabajo, el listado ordenado de soluciones obtenido por gestor de soluciones para el escenario correspondiente a los parámetros de entrada.

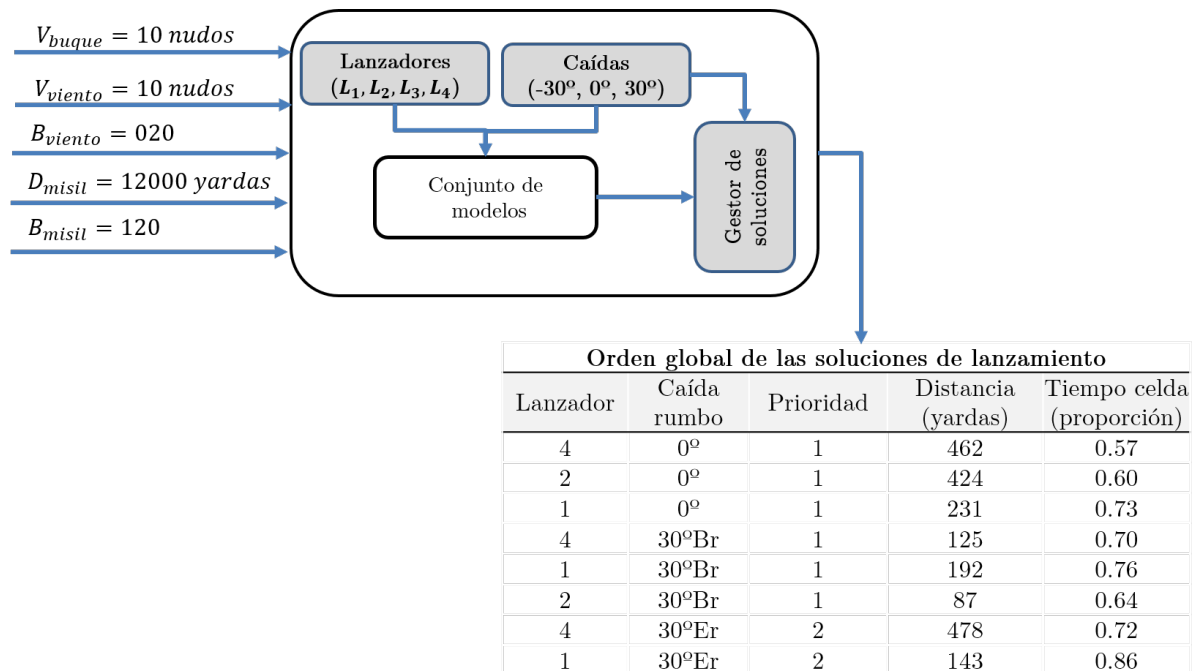


Figura 6-15. Salida del gestor de soluciones para un escenario

6.6. APLICACIÓN DE LA SOLUCIÓN A UN CASO DE USO

Para finalizar, y para comprobar la bondad de la solución final del conjunto de modelos y el gestor de soluciones, se creó un escenario o caso de uso con los modelos ficticios de buque, señuelos y misil que se han utilizado en este trabajo. Se trató de construir un escenario lo más realista posible, para lo cual se partió de las siguientes condiciones:

- Generar un escenario no incluido en el conjunto de entrenamiento o *dataset*.
- Utilizar un viento proel, ya que en caso de amenaza de misil, el buque siempre trata de aumentar el viento relativo, para incrementar la velocidad relativa de separación buque/señuelos.

- Utilizar como velocidad del buque 17 nudos, ya que está próxima a la velocidad económica del buque.

Para el caso planteado se obtuvieron las soluciones recomendadas por el gestor de soluciones, a continuación se simularon los escenarios en la aplicación ALSA y se compararon ambos resultados. Finalmente, la mejor solución recomendada se analizó con detalle para comprobar la bondad del resultado del lanzamiento de señuelos.

6.6.1. Conjunto de modelos/Gestor de soluciones vs simulador ALSA

El caso diseñado se corresponde a un escenario cuyos parámetros de configuración son los que figuran en la Tabla 6-7.

Estos parámetros se introdujeron como entradas en el conjunto de modelos y se obtuvieron las soluciones de lanzamiento válidas ordenadas por gestor de soluciones que figuran en la Tabla 6-8. A su vez, se configuró el mismo escenario en el simulador ALSA obteniéndose los resultados de la Tabla 6-9, donde se incluye la distancia de paso en yardas para cada una de las soluciones.

Comparando ambas tablas, se puede apreciar que las soluciones calculadas por el conjunto de modelos y las obtenidas mediante el simulador son las mismas, con pequeñas diferencias en las distancias de paso del misil, que en todos los casos son menores a una eslora del buque.

Tabla 6-7. Parámetros del escenario

Parámetro	Valor
Velocidad del buque	17 nudos
Distancia inicial del misil	16 000 yardas
Marcación inicial del misil	345°
Dirección del viento	45°
Fuerza del viento	10 nudos

Tabla 6-8. Salidas ordenadas del gestor de soluciones

Lanzador	caída	Prioridad	Distancia	Tiempo celda
2	30°Er	1	460,09	0,63
2	0°	1	315,69	0,57
1	30°Er	1	266,18	0,55
1	0°	1	123,67	0,50
2	30°Br	1	127,39	0,60
1	30°Br	1	26,10	0,54

Tabla 6-9. Resultados de la simulación

Buque	Lanzador	Señuelo	30° Br	0	30° Er
Ficticio	2	Chaff_S_45	143	318	454
Ficticio	1	Chaff_S_45	1	139	274
Ficticio	3	Chaff_S_45	0	0	0
Ficticio	4	Chaff_S_45	0	0	0

6.6.2. Análisis y visualización de la solución recomendada

Para finalizar, se analizó en el simulador la reacción recomendada por el conjunto de modelos/gestor de soluciones que corresponde, tal y como se desprende de la Tabla 6-8, al lanzamiento del señuelo con el lanzador nº 2 acompañada de una caída de 30° de rumbo a estribor.

Comparando la salida del gestor de soluciones y las medidas de eficacia obtenidas del simulador para esta reacción, se elaboró la Tabla 6-10, donde se aprecia la similitud de los valores de las variables en los dos métodos empleados (conjunto de modelos/gestor de soluciones y simulador ALSA).

Tabla 6-10. Comparación de resultados

	Conjunto modelos / gestor soluciones	Simulador ALSA	Diferencia
Distancia de paso de misil (yardas)	460	454	6
Tiempo en celda (proporción)	0,63	0,61	0,02
Probabilidad de éxito	Prioridad 1 ($P_{\text{éxito}} > 0,8$)	Éxito en 10 de 10 réplicas (ver nota)	-

Nota: Para determinar la probabilidad de éxito en el simulador se realizaron un total de 10 réplicas de la reacción

Para comprobar de forma visual la eficacia de la solución recomendada, con los datos proporcionados por el simulador y utilizando el visualizador SIMDIS¹⁵, se reconstruyó la secuencia completa de lanzamiento. En la Figura 6-16 se han incluido tres fotografías de la reconstrucción del enfrentamiento, donde se puede observar la reacción del buque y la correcta evolución temporal del proceso de seducción del misil por parte de los señuelos, dando así validez a la solución aportada por el conjunto modelos/gestor de soluciones.

¹⁵ SIMDIS es un conjunto de herramientas de software desarrolladas por la Marina de los Estados Unidos, que proporciona una visualización gráfica y de vídeo interactiva, en dos y tres dimensiones, de datos de simulación, de prueba y operativos en tiempo real y postprocesados.

Capítulo 6. Evaluación de las soluciones de lanzamiento de señuelos. El gestor de soluciones

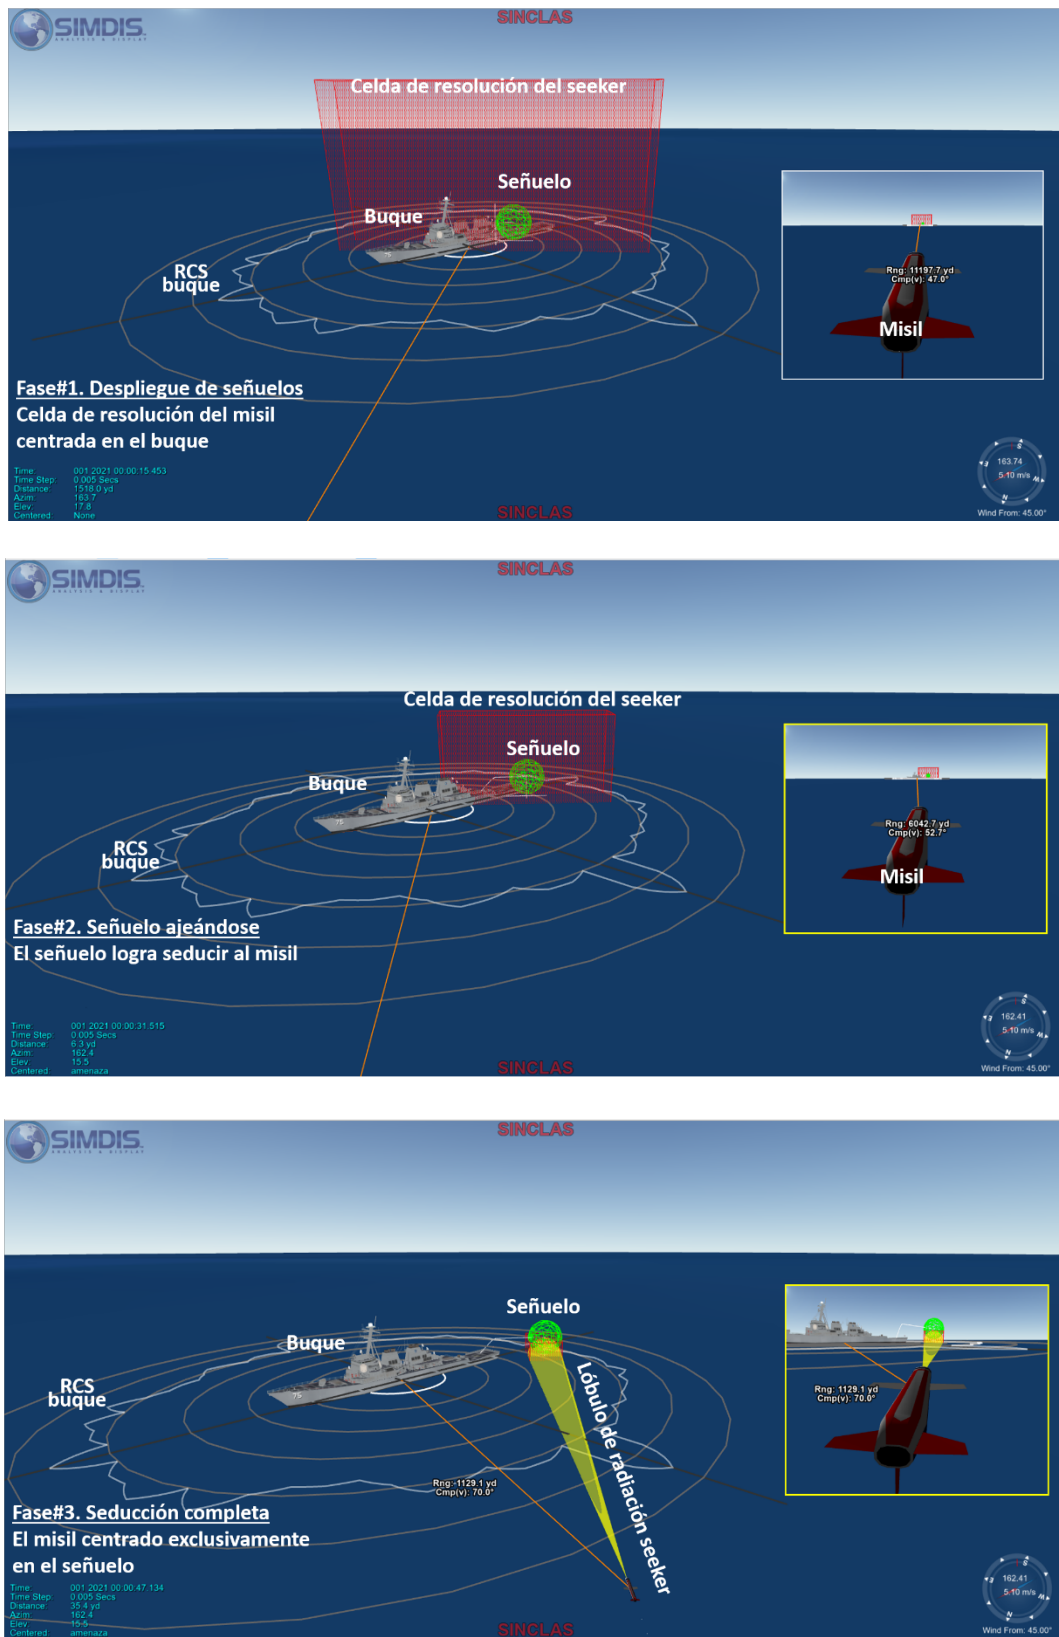


Figura 6-16. Secuencia del enfrentamiento

CAPÍTULO 7. CONCLUSIONES Y LÍNEAS FUTURAS DE INVESTIGACIÓN

En este capítulo se presentan las conclusiones derivadas de los estudios realizados, el grado de cumplimiento de los objetivos planteados y las posibles líneas futuras de investigación.

Comenzaremos, tal y como se muestra en la Figura 7-1, con la exposición de las conclusiones relativas a los objetivos de nivel inferior, para terminar con los objetivos principales o de nivel#1.

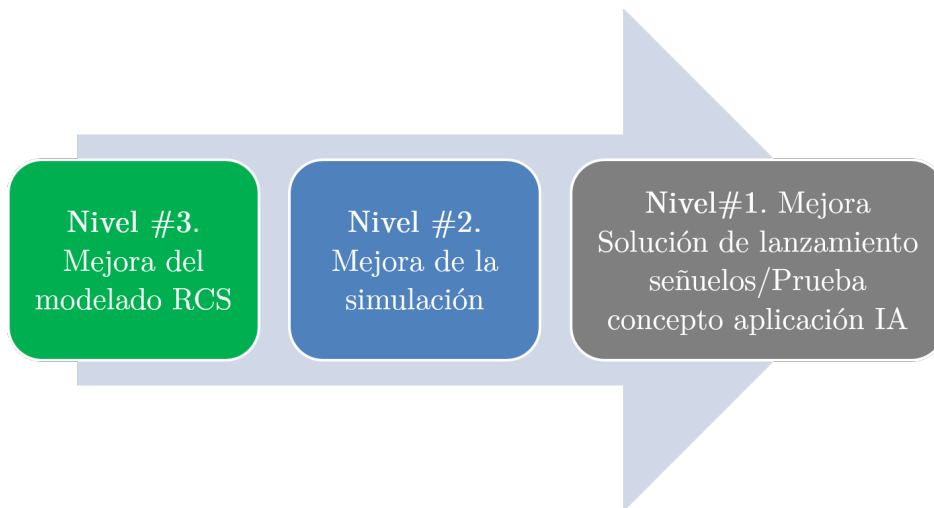


Figura 7-1 Secuencia de exposición de los objetivos alcanzados y conclusiones

7.1. OBJETIVO NIVEL#3. METODOLOGÍA PARA MODELADO DE LA SUPERFICIE EQUIVALENTE RADAR

El objetivo inicial o de nivel#3 que se planteó al comienzo de este trabajo fue la generación de una metodología que permita automatizar el análisis de los datos procedentes de la caracterización de la superficie equivalente radar de buques y señuelos y mejorar el modelado de la RCS mediante distribuciones de probabilidad. Se puede considerar que el objetivo se ha alcanzado en un 90%.

Capítulo 7. Conclusiones y líneas futuras de investigación

Se ha construido la metodología y se ha aplicado sobre las medidas reales de la caracterización de un buque de la Armada. Sin embargo, no se ha podido emplear el método generado para determinar el modelo de RCS de un señuelo al carecer de datos, aunque su aplicación resultará más sencilla al ser su despliegue simétrico y por lo tanto tener la misma superficie equivalente radar en los 360° de aspecto.

El volumen de datos obtenidos con el radar instrumental DIAR, hace factible modelar el efecto de centelleo o *glint* de la RCS de un buque, mediante distribuciones de probabilidad y con precisión de 1° de amplitud. Esta capacidad nos permite disponer de modelos con suficiente exactitud, para ser utilizados en la mayoría de los marcos experimentales del ámbito de la simulación de una fuerza naval en escenarios electromagnéticos complejos.

La distribución de Weibull es la que consigue un mejor ajuste de la RCS del buque en todas las frecuencias y marcaciones. Las anomalías detectadas en popa y proa y en menor medida en los traveses, coinciden con los clásicos picos o puntos calientes de la RCS en todos los buques. Sería recomendable obtener un mayor número de datos en estas marcaciones para realizar un estudio más detallado.

Considero que sería factible lograr una precisión mayor, si las mediciones con el DIAR se realizan con una evolución más lenta del buque, logrando así aumentar el número de tramas en la caracterización de la RCS.

7.2. OBJETIVO NIVEL#2. MEJORA DE LA SIMULACIÓN

Los resultados alcanzados en este nivel están enlazados con el anterior, donde mediante la modificación del código fuente del simulador ALSA, se consiguió implementar los modelos de probabilidad de la superficie equivalente radar obtenidos en el paso previo. Esto mejoró los resultados de la simulación del lanzamiento de señuelos, haciéndolos más realistas y acordes con nuestro marco experimental.

Con el nuevo simulador, se diseñó una batería de experimentos y se generaron un número elevado de réplicas de todos los escenarios, lo cual permitió disponer de un volumen de datos suficientemente grande para el entrenamiento de un modelo de inteligencia artificial/machine learning.

Se puede concluir que este objetivo se cumplió al 100%.

7.3. OBJETIVOS NIVEL#1. MEJORA DE LA SOLUCIÓN DE LANZAMIENTO DE SEÑUELOS. APLICACIÓN DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL

Los objetivos principales o de nivel #1 que se plantearon al comienzo del trabajo, fueron dos:

- Mejorar la solución del lanzamiento de señuelos utilizando técnicas de inteligencia artificial/*machine learning*.
- Utilizar el objetivo anterior como prueba de concepto para determinar la posibilidad de implementar técnicas de inteligencia artificial/*machine learning* en el ámbito de la decisión táctica en los buques de la Armada.

7.3.1. Mejora de la solución de lanzamiento

El conjunto de modelos de *machine learning* basados en redes neuronales, junto con el gestor de soluciones, ha obtenido un nivel de precisión alto (precisión mayor del 96% en la clasificación de las posibles soluciones y un coeficiente de determinación R^2 en las variables distancia de paso y tiempo en celda superior a 0,9).

Se ha conseguido mejorar el proceso que actualmente tienen los buques para obtener la solución de lanzamiento y se ha implementado, mediante el gestor de soluciones, una doctrina para la evaluación de las soluciones válidas, que permite presentar al oficial táctico la información ya evaluada en tiempo real. Por lo tanto, el objetivo planteado al principio de este estudio ha sido alcanzado al 100%.

Podemos afirmar que el resultado final obtenido en este trabajo es perfectamente válido e implementable en cualquier buque. Para ello, tan solo se requeriría el entrenamiento de los modelos con los datos específicos de cada barco, de los señuelos disponibles y del misil amenaza.

Por otra parte, el modelo desarrollado es escalable, ya que se pueden implementar a bordo, tantos conjuntos de modelos como misiles amenaza existan en la zona de operaciones y tener solución para cada uno de ellos de forma inmediata.

Hay que reseñar también, que aunque el trabajo se ha centrado en la defensa contra misiles de guía por radiofrecuencia, la metodología aquí expuesta puede ser aplicable a misiles amenaza de guiado por infrarrojos o dual.

7.3.2. Implementación de técnicas de IA/machine learning en ámbitos de decisión táctica

La implementación de modelos de aprendizaje automático, para resolver el problema del lanzamiento de señuelos, abre el camino para la introducción de diferentes técnicas de inteligencia artificial en otros sistemas del buque, incluso en aquellas situaciones en las que es necesario tomar decisiones tácticas.

El uso combinado de la simulación naval y técnicas de IA/aprendizaje automático, permite construir modelos que mejoren y automaticen ciertos procesos operativos a bordo, lo que puede redundar en un incremento de la probabilidad de supervivencia del buque y ser una de las palancas que ayuden a conseguir la superioridad en el combate. Además, la automatización de ciertas tareas repetitivas, permitiría reducir la dotación y ahorrar costes.

A la vista de los resultados de esta investigación, podemos concluir que sería factible sustituir algunos de los actuales sistemas expertos de apoyo a las decisiones tácticas basados en motores de reglas, por redes neuronales u otros modelos de aprendizaje automático entrenados mediante datos procedentes de simuladores del ámbito naval. Las respuestas de estos modelos pueden ofrecer mucha más flexibilidad, una implementación de la doctrina menos rígida y además contemplar un mayor número de casos o escenarios en los que pueda encontrarse el buque. Se trata de conseguir una aplicación inteligente de la doctrina y de la táctica naval por parte del sistema de combate del buque.

7.4. LÍNEAS FUTURAS DE INVESTIGACIÓN

A la vista de los resultados de los trabajos de investigación de esta tesis, considero que sería conveniente profundizar en algunos aspectos, mejorar ciertas cuestiones e iniciar nuevas líneas relacionadas con este estudio. A continuación se detallan las posibles líneas futuras de investigación.

Línea futura #1. Retomar los estudios de Pérez-Ojeda y mejorar los modelos de RCS de los buques añadiéndoles el comportamiento con diferentes ángulos de escora. En las reacciones de defensa antimisil, los cambios de rumbo se realizan con pronunciados ángulos de caña, lo que ocasiona ciertos ángulos de escora (α) y por lo tanto variaciones su superficie equivalente radar (ver Figura 7-2).




Figura 7-2. Escora de un buque al realizar una caída de rumbo

Línea futura#2. Mejorar el modelo de perceptrón multicapa que determina la probabilidad de éxito de la solución. Los resultados alcanzados en este trabajo para esta variable son pobres. Considero necesario investigar nuevas vías que permitan implementar un modelo de regresión, que quizás pasen por incluir nuevas variables de entrada en el entrenamiento.

Línea futura#3. Implementar la metodología descrita en esta tesis en la defensa del buque contra misiles de guía de infrarrojos y duales. Ello permitiría trazarse el objetivo de generar una sola solución que permita la defensa contra varios tipos de misiles.

Línea futura#4. Utilizar otros simuladores del ámbito naval como el Ship Air Defense Model (SADM)¹⁶ y técnicas de aprendizaje automático, para integrar la solución de lanzamiento de señuelos con el empleo de otras armas (*hardkill* y *softkill*) del buque, en una defensa coordinada antimisil, donde las técnicas de aprendizaje automático optimicen el empleo de todos los medios. Es decir, implementar un TEWA mediante técnicas de inteligencia artificial.

¹⁶ El simulador SADM utilizado por un gran número de países de la OTAN, simula la protección del buque propio y de una *Task Force* mediante cañones, misiles, señuelos activos, chaff y *jammers*, e incluye modelos detallados de los sensores de a bordo y sus interacciones con los sistemas de combate del buque. También incluye efectos meteorológicos para modelar la propagación de la señal y su atenuación en caso de lluvia y otras condiciones.

REFERENCIAS

- Aggarwal, C. C., & Reddy, C. K. (2014). *Data clustering: Algorithms and applications* (C. & H. Pres., Ed.).
- Aggarwal, K. K., Singh, Y., Chandra, P., & Puri, M. (2005). Bayesian Regularization in a Neural Network Model to Estimate Lines of Code Using Function Points. *Journal of Computer Science*, *1*(4), 505–509. <https://doi.org/10.3844/jcssp.2005.505.509>
- Anderson, S. L. (1990). Random Number Generators on Vector Supercomputers and Other Advanced Architectures. *Society for Industrial and Applied Mathematics (SIAM) Review*, *32*(2), 221–251.
- Anderson, T. W., & Darling, D. A. (1952). Asymptotic theory of certain “goodness-of-fit” criteria based on stochastic processes. *Annals of Mathematical Statistics*, *23*, 193–212. <https://doi.org/10.1214/aoms/1177729437>
- Anderson, T. W., & Darling, D. A. (1954). A Test of Goodness-of-Fit. *Journal of the American Statistical Association*, *49*, 765–769. <https://doi.org/10.2307/2281537>
- Aracil, J., & Gordillo, F. (2005). *Dinámica de sistemas*. Madrid: Alianza Editorial, S.A.
- Armada Argentina. (1992). *Historia de la Aviación Naval Argentina. Tomo III (Conflicto del Atlántico sur* (Departamento de Estudios Históricos Navales, Ed.). Buenos Aires.
- Award, M., & Khanna, R. (2015). *Efficient Learning Machines: Theories, Concepts, and Applications for Engineers and System Designers*. Apress Media, LLC.
- Ayling, R., Butters, B., Millwood, N., & Walmsley, R. (2008). Simultaneous IR and RF modelling and simulation of platforms, threats and countermeasures using CounterSim. *AOC International Exhibition and Symposium*.
- Babu, K. S., Toppo, T. K., Patel, S., & Kumar, R. K. (2013). Active Radar Seeker Modeling and Simulation. *9th International Radar Symposium India (IRSI-13)*, (December), 1–5. Retrieved from <http://www.radarindia.com/irsi13papers/13-FP-153.pdf>
- Badillo, S., Banfai, B., Birzele, F., Davydov, I. I., Hutchinson, L., Kam-Thong, T., ... Zhang, J. D. (2020). An Introduction to Machine Learning. *Clinical*

Referencias

- Pharmacology and Therapeutics*, 107(4), 871–885.
<https://doi.org/10.1002/cpt.1796>
- Banks, J. (1998). *Handbook of Simulation. Principles, Metodology, Advances, Applications and Practice*. John Wiley and Sons Ltd.
- Barba-Romero, S., & Pomerol, J.-C. (1997). *Decisiones multicriterio. Fundamentos teóricos y utilización práctica*. Alcalá de Henares (Madrid): Universidad de Alcalá, Servicio de Publicaciones, 1997.
- Barbudo, I. (2004). *Tratado de maniobra. Tomo I. Fundamentos* (8ª Edición). Fragata Libros Náuticos.
- Battiti, R. (1992). First- and Second-Order Methods for Learning: Between Steepest Descent and Newton's Method. *Neural Computation*, 4(2), 141–166.
<https://doi.org/10.1162/neco.1992.4.2.141>
- Baussard, A., Rochdi, M., & Khenchaf, A. (2011). PO/MEC-Based scattering model for complex objects on sea surface. In *Progress In Electromagnetics Research* (Vol. 111). Retrieved from <http://www.jpier.org/PIER/pier111/13.10083005.pdf>
- Becker, S., & le Cun, Y. (1989). Improving the Convergence of Back-Propagation Learning with Second Order Methods. *Proceedings of the 1988 Connectionist Models Summer School*, (January), 29–37.
- Belton, V., & Gear, A. E. (1983). On shortcoming of Saaty's Method of Analytic Hierarchies. *Omega*, 11, 228–230.
- Belton, V., & Gear, A. E. (1984). The Legitimacy of Rank Reversal. *Omega*, 12, 513–516.
- Ben, D., & Scott, R. (2006). Intelligence failure led to strike on Hanit.
- Benayoun, R., Roy, B., & Sussmann, B. (1966). *ELECTRE: une méthode pour guider le choix en présence de points de vue multiples* (No. 49).
- Berzal, F. (2019a). *Redes neuronales & deep learning I*. Amazon Italia Logistica.
- Berzal, F. (2019b). *Redes neuronales & deep learning II*. Amazon Italia Logistica.
- Bishop, C. M. (2006). *Pattern recognition and machine learning* (Springer, Ed.).
<https://doi.org/10.13109/9783666604409.185>

Referencias

- Blanche, P.-A., Neifeld, M., & Peyghambarian, N. (2017). A 100,000 Scale Factor Radar Range. *Scientific Reports*, 7, 17767. <https://doi.org/10.1038/s41598-017-18131-1>
- Boser, B. E., Guyon, I. M., & Vapnik, V. N. (1992). A training algorithm for optimal margin classifiers. *Proceedings of the Fifth Annual Workshop on Computational Learning Theory*, 144–152.
- Butters, B. C. F. (1982). Chaff. *IEE Proceedings, Part F - Communications Radar, and Signal Processing*, 129(3), 197–201.
- Cai, Q., & Zhang, W. (2009). The research on the simulation system of the passive countermeasure. *2009 IEEE International Conference on Mechatronics and Automation, ICMA 2009*, (1), 2617–2621. <https://doi.org/10.1109/ICMA.2009.5246700>
- Cao, R., Francisco, M., Naya, S., Presedo, M., Vázquez, M., Villar, J., & JM, V. (2001). *Introducción a la estadística y sus aplicaciones*. Madrid: Ediciones Pirámide.
- Carrillo, A. (2006). *Teoría de la decisión*. Universidad Complutense de Madrid. Instituto de Estadística e Investigación Operativa.
- Caruana, R., Lawrence, S., & Giles, L. (2001). Overfitting in neural nets: Backpropagation, conjugate gradient, and early stopping. *Advances in Neural Information Processing Systems*.
- CESEDEN. (2018). *La inteligencia artificial aplicada a la defensa. Documento de trabajo 06/2018*. Retrieved from http://www.ieee.es/Galerias/fichero/docs_trabajo/2019/DIEEET0-2018La_inteligencia_artificial.pdf
- Cestero, E. V., & Caballero, A. M. (2018). *Data Science y Redes Complejas: Métodos y aplicaciones*. Editorial Centro de Estudios Ramón Areces.
- Charte, F. (2002). *Programación con Visual C#.NET*. Ediciones Anaya Multimedia.
- Chemring countermeasures. (2013). *Cart CM Chaff 130mm Mk36 Type 1. Description*.
- Cherkassky, V., & Ma, Y. (2004). Practical selection of SVM parameters and noise estimation for SVM regression. *Neural Networks*, 17(1), 113–126.

Referencias

[https://doi.org/10.1016/S0893-6080\(03\)00169-2](https://doi.org/10.1016/S0893-6080(03)00169-2)

Cortes, C., & Vapnik, V. (1995). Support-Vector Networks. In *Machine Learning* (Vol. 20). Kluwer Academic Publishers.

Cristianini, N., & Shawe-Taylor, J. (2000). *An Introduction to Support Vector Machines and Other Kernel-based Learning Methods*. Cambridge University Press.

Cucharero, F. (1995). *Guiado y Control de Misiles* (2º edición). Madrid: Ministerio de Defensa.

Cybenko, G. (1989). Approximation by Superpositions of a Sigmoidal Function. *Math. Control Signals Systems*, 2(4), 303–314. <https://doi.org/10.1007/BF02836480>

Czarnecki, W. M., Podlewska, S., & Bojarski, A. J. (2015). Robust optimization of SVM hyperparameters in the classification of bioactive compounds. *Journal of Cheminformatics*, 7(1), 1–15. <https://doi.org/10.1186/s13321-015-0088-0>

D'Agostino, R. B., & Stephens, M. A. (1986). *Goodness-of-Fit Techniques*. New York: Marcel Dekker.

Das, R. (2005). Advances in active radar seeker technology. *Defence Science Journal*, 55(3), 329–336. <https://doi.org/10.14429/dsj.55.1996>

De la Fuente Chacón, J. C. (2019). La inteligencia artificial y su aplicación en el mundo militar. *Inteligencia Artificial Aplicado a La Defensa*, 69–98. Retrieved from <http://publicacionesoficiales.boe.es/>

De Maio, A., Farina, A., & Foglia, G. (2004). Target fluctuation models and their application to radar performance prediction. *IEEE Proceedings-Radar , Sonar and Navigation*, 151(5), 261–269. <https://doi.org/10.1049/ip-rsn>

Department of the Navy. (1983). *Lessons of the Falklands*. <https://doi.org/10.1111/j.1559-3584.1983.tb01271.x>

Det 8 ACC TRSS. US Air Force. (2000). *Electronic Warfare Fundamentals*.

Díaz Charris, V., & Gómez Torres, J. M. (2017). Analysis of radar cross section assessment methods and parameters affecting it for surface ships. *Ciencia y Tecnología de Buques*, 6(11), 91. <https://doi.org/10.25043/19098642.72>

Dibble, C., & Turner, H. (2014). Random Number Generators. *B.S. Undergraduate*

Referencias

- Mathematics Exchange*, 9(1), 39–51. <https://doi.org/10.2307/3006992>
- Dowdy, P. C. (1991). RCS Probability distribution function modeling of a fluctuating target. *IEEE National Radar Conference*, 164–168. Los Angeles.
- Drucker, H., Surges, C. J. C., Kaufman, L., Smola, A., & Vapnik, V. (1997). Support vector regression machines. *Advances in Neural Information Processing Systems*, (June 2013), 155–161.
- Espejo, I. L. (2011). *Introducción al RADAR*.
- Farris, R. S., & Stuckey, C. B. (2000). Ship defense analysis process. *Johns Hopkins APL Technical Digest (Applied Physics Laboratory)*, 21(3), 393–402.
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861–874. <https://doi.org/10.1016/j.patrec.2005.10.010>
- Florez, R., & Fernández, J. M. (2008). *Las redes neuronales artificiales. Fundamentos teóricos y aplicaciones prácticas*. netbiblio.
- Foresee, F. D., & Hagan, M. T. (1997). Gauss-Newton approximation to bayesian learning. *Proceedings of International Conference on Neural Networks (ICNN'97)*, Houston, TX, USA, 3, 1930–1935. <https://doi.org/10.1109/ICNN.1997.614194>
- Fuerza Aérea Argentina. (1998). *El accionar de la Fuerza Aérea en Malvinas*. Dirección de Estudios Históricos.
- Galle, L. F. (2002). Royal Netherlands Navy The Survivable Frigate. *1º European Survivability Workshop*.
- Galle, L. F., Heemskerk, E. J. M., & Van Ewijk, L. J. (1999). Naval Radar Signature Management in support of Above Water Ship Survivability “The Dutch Perspective.” *SMI Defence Conferences*, 1–17. Retrieved from [http://www.leongalle.com/Documents/Galle, L.F., Heemskerk E.J. & Ewijk, L.J. - Naval Radar Signature Management in support of Above Water Ship Survivability.pdf](http://www.leongalle.com/Documents/Galle,%20L.F.,%20Heemskerk%20E.J.%20&%20Ewijk,%20L.J.-%20Naval%20Radar%20Signature%20Management%20in%20support%20of%20Above%20Water%20Ship%20Survivability.pdf)
- Gamer, T., & Isaksson, A. (2018). Autonomous systems. In *ABB Review*. https://doi.org/10.1007/1-4020-0613-6_1171
- García-Tuñón, I., Obelleiro, F., Rodríguez, J., Pérez-Ojeda, F., & Sanjuan, R. (2010). LIBRA: Sistema de medidas radar de la Armada. *Boletín de Observación*

Referencias

- Tecnológica En Defensa*, 29(Cuarto trimestre), 18–23.
- García Cascales, M. del S. (2009). *Métodos para la comparación de alternativas mediante un Sistema de Ayuda a la Decisión (S.A.D.) y “Soft Computing.”* Universidad Politécnica de Cartagena.
- García Tuñón, I., Cortina, D., Rodríguez, J. L., Obelleiro, F., Nuñez, J., & Garcia-Fernández, S. (2014). Experiencia en el control de la firma radar y reducción de la sección recta radar (RCS) de una plataforma naval sección recta radar (RCS) de una plataforma naval. *II Congreso Nacional de I+D En Defensa y Seguridad*, (November), 347–357. Zaragoza.
- Geron, A. (2017). Hands-On Machine Learning With Scikit-Learn & Tensor Flow. In *Hands-on Machine Learning with Scikit-Learn and TensorFlow*. Retrieved from <http://arxiv.org/abs/1412.3919>
- GMV. (2014). *Manual de usuario ADLA*.
- Gordon, G. (1969). *System Simulation*. Prentice-Hall, Inc. Englewood Cliffs.
- Green, B. F., Smith, J. E. K., & Klem, L. (1959). Empirical tests of an additive random number generator. *J. ACM*, 6, 527–537.
- Gunn S.R. (1998). Support Vector Machines for classification and regression. In *Technical Report*. <https://doi.org/10.1039/b918972f>
- Hagan, M. T., Demuth, H. B., Beale, M. H., & De Jesús, O. (2014). *Neural Networks Design* (2nd Editio). <https://doi.org/10.1007/1-84628-303-5>
- Hagan, M. T., & Menhaj, M. B. (1994). Training Feedforward Networks with the Marquardt Algorithm. *IEEE Transactions on Neural Networks*, 5(6), 989–993. <https://doi.org/10.1006/brcg.1996.0066>
- Hannen, P. J. (2014). *Radar and electronic Warfare Principles* (4ª Edición). Scitech Publishing, INC.
- Heaton, J. (2008). *Introduction to Neural Networks for Java* (2nd Editio). Heaton Research, Inc.
- Hernández, J., Ramirez, M. J., & Ferri, C. (2004). *Introducción a la minería de datos*. Pearson Educación.
- Ho, W. (2008). Multiple Criteria Decision Making in Higher Education. *European*

Referencias

- Journal of Operational Research*, (ii).
- Hodgson, J., & Lee, D. (2003). Terminal Guidance Using a Doppler Beam Sharpening Radar. *AIAA Guidance, Navigation, and Control Conference and Exhibit*. <https://doi.org/10.2514/6.2003-5796>
- Hollander, M., & Wolfe, D. A. (1999). *Nonparametric Statistical Methods*. Hoboken, NJ: John Wiley & Sons, Inc.
- Hornik, K. (1991). Approximation Capabilities of Multilayer Neural Network. *Neural Networks*, 4(1991), 251–257.
- Horowitz, M. C., Kahn, L., & Mahoney, C. (2020). The Future of Military Applications of Artificial Intelligence: A Role for Confidence-Building Measures? *Orbis*, 64(4), 528–543. <https://doi.org/10.1016/j.orbis.2020.08.003>
- Huang, T. M., Kecman, V., & Kopriva, I. (2006). *Kernel Based Algorithms for Mining Huge Data Sets: Supervised, Semi-Supervised, and Unsupervised Learning*. Springer, NY.
- Huber, P. (2011). Chaff S: Seduction Countermeasures. *FrontLine Defense*, (4), 20–22.
- Huynen, J. R., Mcnolty, F., & Hansen, E. (1975). Component Distributions for Fluctuating Radar Targets. *IEEE Transactions on Aerospace and Electronic Systems*, AES-11(6), 1316–1332. <https://doi.org/10.1109/TAES.1975.308189>
- IEEE. (2019). Usos militares de la inteligencia artificial, la automatización y la robótica (IAA&R). *Documento de Trabajo (Instituto Español de Estudios Estratégicos)*, 04/2019(Usos militares de la inteligencia artificial, la automatización y la robótica (IAA & R)), 1–158. Retrieved from <http://www.ieee.es/contenido/noticias/2019/11/DIEEET04-2019InteligenciaRobotica.html>
- Iwaszczuk, K., Heiselberg, H., & Jepsen, P. U. (2007). Radar cross section measurements using terahertz waves. *Meeting Proceedings RDP. NATO Science and Technology Organization*, RTO-MP-SET(2004), 1–12. <https://doi.org/10.14339/RTO-MP-SET-159>
- James, D. A. (1986). *Radar Homing Guidance for Tactical Missiles*. https://doi.org/https://doi.org/10.1007/978-1-349-08602-3_8

Referencias

- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2017). *An Introduction to Statistical Learning: with Applications in R* (7th editio). Springer.
- JCGUAS. (2021). *Unammned Aircraft Systems Artificial Intelligence (AI)*. Joint Capabilities Unammned Aircraft Systems. NATO Naval Armaments group.
- Johansson, F., & Falkman, G. (2009). Performance evaluation of TEWA systems for improved decision support. *Modeling Decisions for Artificial Intelligence, 6th International Conference, MDAI 2009, Awaji Island, Japan, 5861 LNAI*(November 2009), 205–216. https://doi.org/10.1007/978-3-642-04820-3_19
- Keeney, L., & Raiffa, H. (1976). *Decisions with Multiple Objectives: Preferences and Value Trade-Off*. New York: Wiley.
- Khan, J., Duan, W., & Sherbaz, S. (2012). Radar cross section prediction and reduction for naval ships. *Journal of Marine Science and Application, 11*(2), 191–199. <https://doi.org/10.1007/s11804-012-1122-5>
- Kim, D., & Ryoo, C. K. (2009). Defense strategy against multiple anti-ship missiles. *ICCAS-SICE 2009 - ICROS-SICE International Joint Conference 2009, Proceedings*, 3635–3639.
- Kim, K., Kim, J.-H., Kim, Y.-H., & Cho, D.-S. (2012). *Numerical investigation on dinamic radar cross section of naval ship considering ocean wave-ocean wave induced motion* (Vol. 27). Retrieved from <http://www.jpier.org/PIERM/pierm27/02.12101211.pdf>
- Knott, E., Shaeffer, J., & Tuley, M. (2004). Radar Cross Section. In *Radar Cross Section Lectures* (Second Edi). <https://doi.org/10.2514/4.928880>
- Knuth, D. E. (1998). The art of computer programming. Vol 2. Seminumerical algorithms. In I. Addison Wesley Longman (Ed.), *Journal of Chemical Information and Modeling* (3º Edition, Vol. 53).
- Kunte, S., & Gore, A. P. (1992). The paradox of large samples. *Current Science, 62*(5), 391–395.
- L'Ecuyer, P. (1990). Random numbers for simulation. *Communications of the ACM, 33*(10), 85–97. <https://doi.org/10.1145/84537.84555>
- L'Ecuyer, P. (1997). Uniform Random Number Generators: A Review. *Proceedings of the 1997 Winter Simulation Conference*, 127–134.

Referencias

- Lamas, F. (2018). Evolución del apoyo logístico en la Armada mediante tecnologías 4.0. *XVIII Conferencia de La Asociación Española Para La INteligencia Artificial*, 1345–1350.
- Law, A., & Kelton, W. D. (2000). *Simulation Modeling and Analysis* (2nd ed.). New York: McGraw-Hill Education.
- Lehmer, D. H. (1951). Mathematical methods in large-scale computing units. *Annals of the Computation Laboratory of Harvard University*, 26, 141–146.
- Lesinski, G., & Corns, S. (2018). Multi-objective evolutionary neural network to predict graduation success at the United States Military Academy. *Procedia Computer Science*, 140, 196–205. <https://doi.org/10.1016/j.procs.2018.10.329>
- Levenberg, K. (1944). *NOTES-A METHOD FOR THE SOLUTION OF CERTAIN NON-LINEAR PROBLEMS IN LEAST SQUARES**.
- Li, H., Chen, C. L. P., & Huang, H. P. (2018). *Fuzzy neural intelligent systems: Mathematical foundation and the applications in engineering*. CRC Press.
- Li, Z. S., Sun, Z., Xu, J., Du, Y., & Xu, D. (2009). Research on model and simulation of chaff centroid jamming for ship. *Journal of System Simulation*, 21(14), 4203–4206.
- Lin, M., Lucas, H. C., & Shmueli, G. (2013). Too big to fail: Large samples and the p-value problem. *Information Systems Research*, 24(4), 906–917. <https://doi.org/10.1287/isre.2013.0480>
- Lippmann, R. P. (1987). An Introduction to Computing with Neural Nets. *IEEE ASSP Magazine*, 4(2), 4–22. <https://doi.org/10.1109/MASSP.1987.1165576>
- Lord, R. (2006). *Advances in Anti Ship Missile Protection - Naval Countermeasures*. Chemring Naval Countermeasures. Salisbury, England.
- Mackay, D. J. C. (1992). A Practical Bayesian Framework for Backprop Networks. *Neural Computation*, 4(3), 448–472.
- Maffet, A. L. (1989). *Topics for a Statistical Description of Radar Cross Section* (Wiley). New York.
- Mahafza, B. R. (2000). Radar Systems Using MATLAB. In *Chapman & Hall/CRC*. Retrieved from www.crcpress.com

Referencias

- Marquardt, D. W. . (1963). An Algorithm for Least-Squares Estimation of Nonlinear Parameters. *Journal of the Society for Industrial and Applied Mathematics*, 11(2), 431–441.
- Marsaglia, G. (1985). A current View of Random Number Generators. *Computing Science Ans Statistics: Proceedings of the XVIth Symposium on the Inteface*, 3–10.
- Martínez, E., & Escudey, M. (1998). *Evaluación y decisión multicriterio: reflexiones y experiencias*. Editorial Universidad de Santiago de Chile.
- Martinez, J. (2010). *Clasificación de placas de pizarra mediante técnicas de visión artificial y machine learning*. Universidad de Vigo.
- Masters, T. (1993). *Practical Neural Networks Recepies in C++*. Academic Press.
- Matsumoto, M., & Nishimura, T. (1998). Mersenne Twister: A 623-Dimensionally Equidistributed Uniform Pseudo-Random Number Generator. *ACM Transactions on Modeling and Computer Simulation*, 8(1), 3–30. <https://doi.org/10.1145/272991.272995>
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5, 115–133.
- McEachron, F. F. (1997). Subsonic and Supersonic Antiship Missiles: An Effectiveness and Utility Comparison. *Naval Engineers Journal*, 109, 57–73.
- Mcintosh, G. C., & Kerry, J. T. (2018). *Development of Soft - kill Tactics for Anzac Frigate Self Defence Using Ship Air Defence Model DEFENCE MODEL*. Auckland (New Zeland).
- McNolty, F., & E., H. (1974). *Some Aspects of Swerling Models for Fluctuating Radar Cross Section* (pp. 281–285). pp. 281–285. Palo Alto, California: Lockheed Oalo Alto Research Lab.
- Mélard, G. (2014). On the accuracy of statistical procedures in Microsoft Excel 2010. *Computational Statistics*, 29(5), 1095–1128. <https://doi.org/10.1007/s00180-014-0482-5>
- Miacci, M. A. S., & Rezende, M. C. (1988). *Basics on Radar Cross Section Reduction Measurements of Simple and Complex Targets Using Microwave Absorbers*.
- Micromag. (n.d.). Materiales absorbentes radar. Retrieved April 22, 2019, from

Referencias

- <http://www.micromag.es/es/radar-absorbing-materials-es/>
- Microsoft. (n.d.). Microsoft Office Support. RAND function. Retrieved December 31, 2020, from <https://support.microsoft.com/en-us/office/rand-function-4cbfa695-8869-4788-8d90-021ea9f5be73>
- Miller, G. A. (1956). The magical number seven, plus or minus two: some limits on our capacity for processing information. *Psychological Review*, *63*(2), 81–97. <https://doi.org/https://doi.org/10.1037/h0043158>
- Ministère des Armées. (2019). *Artificial Intelligence in Support of Defence*. Retrieved from https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=&ved=2ahUKEwjH6YfqsOjrAhWRmFwKHVamCzkQFjADegQIAhAB&url=https%3A%2F%2Fwww.defense.gouv.fr%2Fcontent%2Fdownload%2F573877%2F9834690%2FStrat%25C3%25A9gie%2520de%2520l%2527IA-UK_9%2520l%25202020.pdf
- Minsky, M., & Papert, S. A. (1969). *Perceptrons: An Introduction to Computational Geometry*. MIT Press.
- Mitchell, T. M. (1997). *Machine learning*. McGraw-Hill Science/Engineering/Math.
- Moller, F., & Struth, G. (2013). *Modelling Computing Systems*. Springer.
- Moreno Jimenez, J. M., & Escobar Urmeneta, M. T. (2000). Regret in the hierarchical analytical process. *Applied Economics Studies*, *14*, 95–115. Retrieved from https://ideas.repec.org/a/lrk/eeart/14_1_5.html
- Moreu, & Martínez. (1987). *Astronomía y Navegación (vol II)* (2º edición). Ministerio de Marina.
- Nair, V., & Hinton, G. E. (2020). Rectified Linear Units Improve Restricted Boltzmann Machines. *Proceedings of the 27th International Conference on Machine Learning*.
- Nakagami, M. (1960). The m-Distribution—A General Formula of Intensity Distribution of Rapid Fading. *Statistical Methods in Radio Propagation*, 3–36. Pergamon, New York.
- NAWCWD. (2013). *Electronic Warfare and Radar Systems Engineering Handbook* (4 Edition). Retrieved from

Referencias

<https://apps.dtic.mil/dtic/tr/fulltext/u2/a617071.pdf>

Naylor, T. H., Balintfy, J. L., Burdick, D. S., & Chu, K. (1966). *Computer Simulation Techniques*. John Wiley and Sons Ltd.

Nguyen, D., & Widrow, B. (1990). Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptive weights. *IJCNN. International Joint Conference on Neural Networks*, 21–26. <https://doi.org/10.1109/ijcnn.1990.137819>

O’Neil, W. (1991). Don ’ t give up on the ship. *Proceedings*, 117(January), 46–50.

Odendaal, J. W., Botha, L., & Joubert, J. (2007). A full-scale static radar cross-section (RCS) measurement facility. *South African Journal of Science* , 103, 196–198. Retrieved from www.sajs.co.za

Ozernoy, V. M. (1992). Choosing The “Best” Multiple Criterly Decision-Making Method. *INFOR: Informations Systems and Operational Research*, 30(2), 159–171.

Paradis, S., Benaskeur, A., Oxenham, M., & Cutler, P. (2005). Threat evaluation and weapons allocation in network-centric warfare. *2005 7th International Conference on Information Fusion, FUSION*, 2, 1078–1085. <https://doi.org/10.1109/ICIF.2005.1591977>

Parker, D. B. (1985). *Learning-Logic: Casting the Cortex of the Human Brain in Silicon. Technical Report Tr-47*.

Patel, A. A. (2019). Hands-On Unsupervised Learning Using Python. In *O’Reilly*. O’Reilly Media.

Peebles, P. Z. (1998). *Radar Principles* (Willey, Ed.).

Penadés-Plà, V., García-Segura, T., Martí, J. V., & Yepes, V. (2016). A review of multi-criteria decision-making methods applied to the sustainable bridge design. *Sustainability (Switzerland)*, 8(12). <https://doi.org/10.3390/su8121295>

Pérez-Ojeda, J. F. (2007). *Contribución al estudio de predicción y medida de sección recta radar de buques*. Universidad de Vigo.

Pérez Martínez, F. (2011). *Sensores electromagnéticos. Los sentidos de los Sistemas para la Defensa y la Seguridad* (1ª edición; F. R. S. para el D. de las Telecomunicaciones, Ed.). 1ª edición. Madrid: Cuadernos Cátedra ISDEFE-UPM

Referencias

nº 9.

- Python. (2020). Python Documentation. Numerical and Mathematical Modules. Retrieved from <https://docs.python.org/3/library/random.html>
- Pouliguen, P. (1993). Complete Modelling of Electromagnetic Scattering by a Cloud of Dipoles. *Annals of Telecommunications*, 48, 305–318.
- Rahman, H. (2019). Fundamental Principles of Radar. In *Fundamental Principles of Radar*. <https://doi.org/10.1201/9780429279478>
- Ramachandra, K. V. (2000). *Kalman filtering techniques for radar tracking*. CRC Press.
- Reed, R. D., & Marks, R. J. (1999). *Neural Smithing. Supervided Learning in Feedforward Artificial Neural Networks*. MTI Press.
- Reza, M., & García, E. (1996). *Simulación y análisis de procesos estocásticos*. McGraw-Hill, Inc.
- Rich, E. (1983). *Artificial Intelligence*. McGraw-Hill, Inc.
- Richards, M. A., Scheer, J. A., & Holm, W. A. (2015). Principles of Modern Radar: Basic Principles. In *PhD Proposal* (Vol. 1). <https://doi.org/10.1017/CBO9781107415324.004>
- Rios-Insua, S., Mateos, A., & Jimenez-Martín, A. (2002). La Teoría de la Utilidad para Modelos de Preferencias en Decisión Multiatributo. In *Teoría de decisión con criterios múltiples* (pp. 56–72). Revista Electrónica de Comunicaciones y Trabajos de ASEPUMA.
- Rius, J. (1991). *Sección recta de blancos complejos en tiempo real* (Universidad Politécnica de Cataluña). Retrieved from <https://upcommons.upc.edu/bitstream/handle/2117/94205/01JRC01de03.pdf?sequence=1&isAllowed=y>
- Rius, J. M., Ubeda, E., & Heldring, A. (2018). GRECO: 30 years of graphical processing techniques for RCS computation. *XXXIII Simposium Nacional de La Unión Científica Internacional de Radio (URSI 2018)*, (1), 1–4. Granada (Spain).
- Rodriguez Osuna, J. (2001). *Cuadernos metodológicos 1. Métodos de muestreo*. Centro de Investigaciones Sociológicas.

Referencias

- Rodriguez Osuna, J. (2005). *Cuadernos metodológicos 6. Métodos de muestreo. Casos prácticos*. Centro de Investigaciones Sociológicas.
- Romero, C. (1993). *Teoría de la decisión multicriterio: Conceptos, técnicas y aplicaciones* (31 de mayo). Madrid: Alianza Universidad.
- Romero, C. (1996). *Análisis de las decisiones multicriterio*. Madrid: ISDEFE Ingeniería de Sistemas.
- Rosenblatt, F. (1962). *Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms*. Washington DC: Spartan Books.
- Ross, D. (2005). *Economic Theory and Cognitive Science: Microexplanation*. MTI Press.
- Roy, B. (1968). Classement et choix en présence de points de vue multiples (La méthode ELECTRE). *Revue Française d'informatique et de Recherche Opérationnelle*, 2(8), 57–75. <https://doi.org/10.1051/ro/196802v100571>
- Roy, B. (1991). The outranking approach and the foundations of electre methods. *Theor Decis*, 31, 49–73. <https://doi.org/https://doi.org/10.1007/BF00134132>
- Rumelhart, D. E., & McClelland, J. L. (1988). Parallel Distributed Processing, Volume 1 Explorations in the Microstructure of Cognition: Foundations. In *A Bradford Book* (Vol. 1).
- Rumelhart, David E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533–536. <https://doi.org/10.1038/323533a0>
- Russel, S., & Norvig, P. (2010). *Artificial Intelligence. A modern approach* (3rd editio). Prentice Hall.
- Saaty, R. W. (1987). The analytic hierarchy process-what it is and how it is used. *Mathematical Modelling*, 9(3–5), 161–176. [https://doi.org/10.1016/0270-0255\(87\)90473-8](https://doi.org/10.1016/0270-0255(87)90473-8)
- Saaty, T. (1977). A scaling method for priorities in hierarchical structures. *Journal of Mathematical Psychology*, 15(3), 234–281.
- Saaty, T. (1980). *The Analytic Hierarchy Process*. New Yoyk: McGraw-Hill.
- Saaty, T. (1986). Axiomatic Foundation of the Analytic Hierarchy Process.

Referencias

- Management Science*, 32(7), 841–855. <https://doi.org/10.1287/mnsc.32.7.841>
- Saaty, T., & Hu, G. (1998). Ranking by eigenvector versus other methods in the analytic hierarchy process. *Applied Mathematics Letters*, 11(4), 121–125. [https://doi.org/10.1016/S0893-9659\(98\)00068-8](https://doi.org/10.1016/S0893-9659(98)00068-8)
- Saaty, T., & Vargas, L. G. (2001). *Models, Methods, Concepts & Applications of the Analytic Hierarchy Process*. Kluwer Academy Publishers.
- Sandhu, G. S., & Saylor, A. (1985). A Real-Time Statistical Radar Target Model. *IEEE Transactions on Aerospace and Electronic Systems*, AES-21(4), 490–507.
- Schleijpen, R. H. M. A. (2012). Modelling infrared signatures of ships and decoys for countermeasures effectiveness studies. *Technologies for Optical Countermeasures*, 8543–14. <https://doi.org/10.1117/12.869849>
- Scott, R. (2016). Breaking the kill chain: Rethinking soft kill in anti-ship missile defence. *Jane's Navy International*, 1–8.
- Semenova, M. A., & Khalin, D. S. (2018). Research of Statistic Distributions of Nonparametric Goodness-of-Fit Tests by Large Samples. *2018 14th International Scientific-Technical Conference on Actual Problems of Electronic Instrument Engineering, APEIE 2018 - Proceedings*, 2(3), 260–264. <https://doi.org/10.1109/APEIE.2018.8545909>
- Shadkam, E., & Aghaie, A. (2010). Create Randomization in Simulation Models. *Proceedings of ICIEBM*, 481–486.
- Shannon, R. E. (1975). *Systems simulation; the art and science*. Prentice-Hall Inc. Englewood Cliffs.
- Shannon, R. E. (1998). Introduction to the art and science of simulation. *Winter Simulation Conference Proceedings*, 1, 7–14. <https://doi.org/10.1109/wsc.1998.744892>
- Sheldon, M. R. (2004). *Introduction to Probability and Statistics for Engineers and Scientists* (3^o Edition). Elsevier.
- Shulte, J. C. (1994). *An Analysis of the Historical Effectiveness of Anti-ship Cruise Missiles in Littoral Warfare* (Trabajo de Postgrado; Vol. 39). Retrieved from <https://apps.dtic.mil/dtic/tr/fulltext/u2/b192139.pdf>
- Sinclair, G. (1948). Theory of Models of Electromagnetic Systems. *Proc. Inst. Radio*

Referencias

- Engin*, 36(11), 1364–1370. <https://doi.org/10.1007/bfb0110342>
- Siouris, G. M. (2004). *Missile Guidance and Control Systems*. New York: Springer, NY.
- Skolnik, M. (1981). *Introduction to Radar Systems* (Second Edi). International Edition: McGraw-Hill, Inc.
- Skolnik, M. (2008). *Radar Handbook 3rd ed.* (Tercera ed). <https://doi.org/10.1007/s10194-006-0268-4>
- Smola, A. J., & Schölkopf, B. (2004). A tutorial on support vector regression. In *Statistics and Computing* (Vol. 14). Kluwer Academic Publishers.
- Spiegel, M. R., & Stephens, L. J. (2009). *Estadística. Shaum* (4ª Edición). McGraw-Hill Education.
- Stathakis, D. (2009). How many hidden layers and nodes? *International Journal of Remote Sensing*, 30(8), 2133–2147. <https://doi.org/10.1080/01431160802549278>
- Stephens, M. A. (1974). EDF statistics for goodness of fit and some comparisons. *Journal of the American Statistical Association*, 69(347), 730–737. <https://doi.org/10.1080/01621459.1974.10480196>
- Suliman, A., & Omarov, B. (2018). Applying Bayesian Regularization for Acceleration of Levenberg Marquardt based Neural Network Training. *International Journal of Interactive Multimedia and Artificial Intelligence*, 5(1), 68. <https://doi.org/10.9781/ijimai.2018.04.004>
- Sun, W. (2019). Maneuvering Calculation of Ship Centroid Jamming. *9th International Conference on Information and Social Science*, 386–390. <https://doi.org/10.25236/iciss.2019.071>
- Sutter, C. (2003). *Sustainability check up for CDM projects How to assess the sustainability of international projects under the Kyoto Protocol* (Swiss Federal Institute of Technology Zurich). Retrieved from <https://doi.org/10.3929/ethz-a-010025751>
- Swerling, P. (1960). Probability of Detection For Fluctuating Targets. *IRE Transactions on Information Theory*, 6(2), 269–308.
- Swerling, P. (1965). More on Detection of Fluctuating targets. *IEEE Transactions on Information Theory*, 11(3), 459–460.

Referencias

- Swerling, P. (1997). Radar Probability of Detection for Some Additional Fluctuating Target Cases. *IEEE Transactions on Aerospace and Electronic Systems*, 33(2), 698–709.
- Swingler, K. (1996). *Applying Neural Networks: A Practical Guide*. Academic Press.
- Taboada, J. M., Araújo, M. G., Bértolo, J. M., Landesa, L., Obelleiro, F., & Rodriguez, J. L. (2010). MLFMA-FFT parallel algorithm for the solution of large-scale problems in electromagnetics (invited paper). *Progress in Electromagnetics Research*, 105, 15–30. <https://doi.org/10.2528/PIER10041603>
- Taboada, Jose Manuel, Araujo, M. G., Basteiro, F. O., Rodriguez, J. L., & Landesa, L. (2013). MLFMA-FFT parallel algorithm for the solution of extremely large problems in electromagnetics. *Proceedings of the IEEE*, 101(2), 350–363. <https://doi.org/10.1109/JPROC.2012.2194269>
- Taha, H. A. (2012). *Investigación de Operaciones* (9ª edición). Pearson Educación.
- Tezuka, S. (1995). *Uniform Random Numbers: Theory and Practice*. Springer Science+Business Media. New York.
- Thomas, A. J., Petridis, M., Walters, S. D., Gheytaasi, S. M., & Morgan, R. E. (2017). Two hidden layers are usually better than one. *International Conference on Engineering Applications of Neural Networks*, 279–290. https://doi.org/10.1007/978-3-319-65172-9_24
- Townsend, J. R. (1999). *Defense of Naval Task Forces From Anti-Ship Missile Attack*. Naval PostGraduate School (NPS).
- Turing, A. M. (1950). Computing machinery and intelligence. *Mind*, 59(236), 433–460.
- UK Royal Navy. (1982a). *Loss of HMS Sheffield-Board of inquiry*. Northwood.
- UK Royal Navy. (1982b). *Loss of SS Atlantic Conveyor- Board of Inquiry*. Northwood.
- Urquía, A. (2005). *Simulación. Texto base de teoría*. Escuela Técnica Superior de Ingeniería Informática, UNED.
- US Navy. (1987). *Formal investigation into circumstances surrounding the attack on USS Stark (FFG 31) on 17 may 1987*. Miami.

Referencias

- Vandervelde, J. (2017). Disrupt the spectrum with AI. *Proceedings. US Naval Institute*.
- Vaughan, J., Eisenstadt, M., & Knights, M. (2020). Missile Attacks on the USS Mason : Principles to Guide a US Response. *The Washington Intitute for Near East Policy*, october.
- Vego, M. (2014). On Littoral Warfare. In *Naval War College Review* (Vol. 68). Retrieved from <https://digital-commons.usnwc.edu/nwc-review/vol68/iss2/4>
- Vélez, R., & García, A. (1993). *Principios de inferencia estadística*. Universidad Nacional de Educacion a Distancia (UNED).
- Viau, C., DÁgostino, I., & Cathala, T. (2014). *Physical modelling of naval infrared decoys in TESS and SE-WORKBENCH-EO for ship self-protection*.
- Waldman, J., Fetterman, H. R., Goodhue, W. D., Bryant, T. G., & Temme, D. H. (1980). Submilimeter modeling of milimeter radar systems. *SPIE*, 259(Milimeter Optics), 152–157.
- Wang, H., Shao, J., & Hu, Y. (2015). Anti-ship Missile Target Dynamic RCS Statistical Distribution Fitting Technique. *Internatinal Conference on Automation, Mechanical Control and Computational Engineering (AMCCE)*, (92941), 2075–2079. <https://doi.org/10.2991/amcce-15.2015.373>
- Weaver, B. L. (2008). *A methodology for ballistic missile defense system analysis using nested neural networks*. (Master of Science) Georgia Institute of Technology, Georgia (United States of America).
- Weibull, W. (1951). A Statistical Distribution Function of Wide Applicability. *Journal of Applied Mechanics*, Vol. 18, 293–297.
- Weinstock, W. (1964). *Target cross section models for radar systems analysis*. Pennsylvania.
- Werbos, P. (1974). *Beyond Regression : New Tools for Prediction and Analysis in the Behavioral Sciences* (Phd thesis. Harvard University). Retrieved from <https://www.researchgate.net/publication/35657389>
- Widrow, B., & Hoff, M. E. (1960). Adaptive switching circuits. In *IRE WESCON Convention Record, Volume 4, Pp. 96–104*.
- Wilcoxon, F. (1945). Individual comparisons by ranking methods. *Biometrics Bulletin*,

Referencias

- 1(6), 80–83. <https://doi.org/10.2307/3001968>
- Wu, J., Chen, X. Y., Zhang, H., Xiong, L. D., Lei, H., & Deng, S. H. (2019). Hyperparameter optimization for machine learning models based on Bayesian optimization. *Journal of Electronic Science and Technology*, 17(1), 26–40. <https://doi.org/10.11989/JEST.1674-862X.80904120>
- Yanushevsky, R. (2008). *Modern Missile Guidance*. Florida: Taylor & Francis Group.
- Zak, J., Gregor, L., Dvoracek, F., & Papez, V. (2018). Measurement of CHAFF RCS. *Proceedings International Radar Symposium, 2018-June*, 1–7. <https://doi.org/10.23919/IRS.2018.8448133>
- Žák, J., Vach, M., & Dvořáček, F. (2016). Advanced chaff usage in modern EW. *2016 IEEE Radar Methods and Systems Workshop, RMSW 2016 - Proceedings*, 56–59. <https://doi.org/10.1109/RMSW.2016.7778550>
- Zeeb, C. N., & Burns, P. J. (1997). Random Number Generator Recommendation. In *Technical Report*. https://doi.org/10.1007/978-3-319-39711-5_2
- Zepeda, J. A., Aguilar, A. E., Hernández, Á., & Salgado, M. C. (2015). Metodología para determinar la topología , patrones de parámetros eléctricos y entrenamiento de una Red Neuronal Artificial para un control inteligente. *Revista Tecnología Digital*, 5(1), 103–113.