



“Desarrollo y evaluación de un sistema de localización para un dron subacuático mediante técnicas de beamforming y machine learning”

Ortiz Carreño, Andrés Miguel y Sánchez Lincango, Luis Fernando

Departamento de Eléctrica, Electrónica y Telecomunicaciones

Carrera de Ingeniería en Electrónica y Telecomunicaciones

Trabajo de titulación, previo a la obtención del título de Ingeniero en Electrónica y Telecomunicaciones

Ing. Carrera Erazo, Enrique Vinicio, PhD

27 de junio de 2023

Originality report

COURSE NAME

Tesis

STUDENT NAME

ANDRES MIGUEL ORTIZ CARREÑO

FILE NAME

Documento-Tesis-Ortiz-Sanchez

REPORT CREATED

Jun 27, 2023

Summary

Flagged passages	1	0.9%
Cited/quoted passages	0	0%

Web matches

docplayer.es	1	0.9%
--------------	---	------

1 passage

Student passage **FLAGGED**

Trabajo de titulación, previo a la obtención del título de Ingeniero en Electrónica y Telecomunicaciones

Top web match

TRABAJO DE TITULACIÓN, PREVIO A LA OBTENCIÓN DEL TÍTULO DE INGENIERO EN ELECTRÓNICA E INSTRUMENTACIÓN IMPLEMENTACIÓN DE UN SISTEMA TECNOLÓGICO MEDIANTE ...

TRABAJO DE TITULACIÓN, PREVIO A LA OBTENCIÓN DEL ... <https://docplayer.es/93132242-Trabajo-de-titulacion-previo-a-la-obtencion-del-titulo-de-ingeniero-en-electronica-e-instrumentacion.html>





Departamento de Eléctrica, Electrónica y Telecomunicaciones

Carrera de Ingeniería en Electrónica y Telecomunicaciones

Certificación

Certifico que el trabajo de titulación: **"Desarrollo y evaluación de un sistema de localización para un dron subacuático mediante técnicas de beamforming y machine learning"** fue realizado por los señores **Ortiz Carreño, Andrés Miguel y Sanchez Lincango, Luis Fernando** ; el mismo que cumple con los requisitos legales, teóricos, científicos, técnicos y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, además fue revisado y analizado en su totalidad por la herramienta de prevención y/o verificación de similitud de contenidos; razón por la cual me permito acreditar y autorizar para que se lo sustente públicamente.

Sangolquí, 27 de junio de 2023



Ing. Carrera Erazo, Enrique Vinicio PhD.

C. C.: 1708792104



Departamento de Eléctrica, Electrónica y Telecomunicaciones

Carrera de Ingeniería en Electrónica y Telecomunicaciones

Responsabilidad de Autoría

Nosotros, **Ortiz Carreño, Andrés Miguel** con cédula de ciudadanía n° 1104594435 y **Sanchez Lincango, Luis Fernando** con cédula de ciudadanía n° 1722651765, declaramos que el contenido, ideas y criterios del trabajo de titulación: **Desarrollo y evaluación de un sistema de localización para un dron subacuático mediante técnicas de beamforming y machine learning** es de nuestra autoría y responsabilidad, cumpliendo con los requisitos legales, teóricos, científicos, técnicos, y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, respetando los derechos intelectuales de terceros y referenciando las citas bibliográficas.

Sangolquí, 27 de junio de 2023

Ortiz Carreño, Andrés Miguel

C.C.: 1104594435

Sanchez Lincango, Luis Fernando

C.C.: 1722651765



Departamento de Eléctrica, Electrónica y Telecomunicaciones

Carrera de Ingeniería en Electrónica y Telecomunicaciones

Autorización de Publicación

Nosotros, **Ortiz Carreño, Andrés Miguel** con cédula de ciudadanía n° 1104594435 y **Sanchez Lincango, Luis Fernando** con cédula de ciudadanía n° 1722651765, autorizamos a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de titulación: **Desarrollo y evaluación de un sistema de localización para un dron subacuático mediante técnicas de beamforming y machine learning** en el Repositorio Institucional, cuyo contenido, ideas y criterios son de nuestra responsabilidad.

Sangolquí, 27 de junio de 2023

Ortiz Carreño, Andrés Miguel

C.C.: 1104594435

Sanchez Lincango, Luis Fernando

C.C.: 1722651765

Dedicatoria

Dedico el presente trabajo de investigación a Dios por darme la fortaleza diaria para seguir adelante, a mi esposa Anita por ser mi fuente de inspiración y motivación para alcanzar el éxito, a mi hija Isabelita por constituirse el motor esencial de mi vida, a mi madre Esperanza y mis tíos Lupita e Iván por el apoyo incondicional que me han brindado a lo largo de mi vida, finalmente, a mi amado padre Estebitan que desde el cielo sé que estas orgulloso de este logro alcanzado.

Capt. Ortiz Andrés

El presente trabajo va dedicado a Dios, a mis padres Pilar Lincango y Fernando Sánchez, por su esfuerzo, apoyo y amor incondicional a lo largo de la vida, a mi hermano Diego Sebastián por motivarme e inspirarme a continuar en los momentos más difíciles, a mis tías Mirian, Elizabeth, Cecilia y Nelly que han sido como mis segundas madres en todas las etapas de mi vida, a Danielito que ha sido como un hermano más y a su corta edad ha sido un apoyo fundamental en los momentos más difíciles de mi vida. Finalmente, a mi ángel en el cielo, mi papito Alfredo quien fue un amigo y un padre más que me brindó valiosas enseñanzas y un amor puro e incondicional.

Luis Fernando Sánchez Lincango

Agradecimientos

Agradezco a mi esposa por el amor, el apoyo incondicional que me has dado día a día lo cual se ha traducido en esa fuente motivacional para alcanzar este anhelado objetivo. Al Ejército Ecuatoriano por haberme dado la oportunidad de cursar mis estudios en tan prestigiosa Universidad. A los docentes del Departamento de Eléctrica, Electrónica y Telecomunicaciones por haberme brindado sus conocimientos a lo largo de la etapa universitaria. Un agradecimiento especial a nuestro tutor de tesis al Dr. Vinicio Carrera que con su orientación, soporte y discusión constituyó en el guía esencial para el desarrollo del presente trabajo de investigación.

Capt. Ortiz Andrés

En primer lugar, quiero agradecer a mis padres Pilar y Fernando quienes se han esforzado y han dedicado su atención, esfuerzo, compromiso y amor en el crecimiento profesional de sus hijos, que con su ejemplo y su apoyo he logrado alcanzar uno de mis sueños. Admiro a los valientes, luchadores y trabajadores padres que Dios puso en mi vida.

A mis ñañas Mirian, Elizabeth, Cecilia y Nelly, a mis tíos Diego, Eduardo y Nelson, a mis primos Juanito, Danielito, Fausto, Ariel, Roswell, Amy y Nelson Alfredo, quienes han sido un pilar fundamental para mi crecimiento profesional y personal, y me han enseñado lo importante y valioso que es la unión familiar.

A mis amigos Christian, Michael, Davo, Alejo, Sandrita, Lily, Camis y Angie, por brindarme durante toda la universidad una amistad sincera y enseñarme que, con su apoyo, sus consejos y sobre todo sus sonrisas, cualquier día o momento difícil puede convertirse en algo mejor simplemente con su compañía, los quiero mucho, gracias por hacer de esta aventura un poco más llevadera.

Siempre he dicho que los amigos son la familia que uno elige, por eso también quiero agradecer a Mabe, Anita Constante, Pame, Isack, Andre, Kathy y Anita Brito, que desde que entraron a mi vida han sido como una familia para mí, y a pesar de no vernos seguido, siempre han estado apoyándome y motivándome a ser mejor persona cada día, brindándome un consejo, una llamada, o un abrazo en los momentos más difíciles.

A Camila, quien me brindó su apoyo en gran parte de esta etapa y me enseñó que los sueños se hicieron para luchar y conseguirlos, a la Sra. Gabriela Jiménez y a la Sra. Alegría Alban, por su apoyo, sus consejos y el cariño brindado en momentos difíciles.

A mi compañero Andrés Ortiz, por su apoyo incondicional durante la carrera y en la elaboración de este trabajo de investigación.

Finalmente quiero agradecer al Dr. Enrique Vinicio Carrera, por su apoyo, sus consejos y por confiar en nosotros permitiéndonos participar en el proyecto de investigación.

Luis Fernando Sánchez Lincango

Índice de Contenido

Dedicatoria.....	6
Agradecimientos	7
Resumen	16
Abstract.....	17
Capítulo I: Introducción.....	18
<i>Justificación.....</i>	<i>18</i>
<i>Antecedentes.....</i>	<i>18</i>
<i>Alcance del proyecto.....</i>	<i>20</i>
<i>Objetivos</i>	<i>21</i>
Objetivo General	21
Objetivos Específicos.....	21
Capítulo II: Marco teórico	22
<i>Acústica subacuática</i>	<i>22</i>
<i>Parámetros que afectan la velocidad del sonido</i>	<i>22</i>
Temperatura	22
Salinidad	23
Presión.....	23
<i>Pérdidas de propagación del sonido</i>	<i>23</i>
Reflexión.....	23
Reverberación.....	23
Absorción.....	24

	10
Multitrayecto	24
<i>Transductores electroacústicos</i>	24
Hidrófono.....	25
<i>Tipos de hidrófonos</i>	26
Hidrófonos esféricos y cilíndricos	26
Hidrófonos planos	26
Hidrófonos de vector.....	27
<i>Sistema Hidrofónico</i>	27
<i>Tipos de arreglos para hidrófonos</i>	27
Arreglos lineales uniformes	28
<i>Algoritmo de conformación de haz</i>	32
<i>Dirección de arribo</i>	33
Algoritmo de Clasificación de señales múltiples	33
Algoritmo de Estimación de Parámetros vía Técnicas de Invarianza Rotacional	34
<i>Machine learning</i>	36
Aprendizaje supervisado	36
Aprendizaje no supervisado	36
Aprendizaje por refuerzo.....	37
<i>Técnicas de aprendizaje supervisado</i>	37
Regresión Lineal	37
Arboles de decisión	38
Redes neuronales.....	38
Procesos gaussianos.....	39
Máquinas de vectores de soporte (SVM)	39

	11
<i>Evaluación de modelos</i>	39
<i>Error en regresión</i>	40
Error Cuadrático Medio (RMSE).....	40
Coeficiente de determinación (R-Squared)	41
Error Absoluto Medio (MAE)	41
<i>Métodos de validación</i>	42
Validación Cruzada k-fold	42
Validación Holdout	43
Capítulo III: Materiales y métodos	44
<i>Materiales</i>	44
PowerVision PowerRay	44
DolphinEar DE200	44
Behringer U-Phoria UMC404HD	45
Audacity.....	46
AutoCAD 2024.....	46
Matlab 2023a	46
<i>Metodología</i>	47
<i>Diseño del arreglo lineal uniforme de hidrófonos</i>	47
<i>Adquisición y procesamiento de señales para algoritmos Music y Espirit.</i>	50
Adquisición de las señales de audio y cálculo de ángulos teóricos.	50
Procesamiento para las señales de audio y método de evaluación del ángulo de arribo.....	53
<i>Generación de base de datos y entrenamiento de modelos para machine learning en el medio ideal y no ideal</i>	55
Base de datos y segmentación de la señal	55

	12
Recorte de ventanas iniciales.....	55
Cálculo de los ángulos teóricos.....	56
Etiquetado de datos	57
Entrenamiento y validación de datos	58
Capítulo IV: Resultados y Discusión	59
<i>Resultados de beamforming.</i>	59
Medio controlado.	59
Medio no controlado.....	60
<i>Resultados de machine learning</i>	61
Medio controlado	61
Medio no controlado.....	64
<i>Comparación de los algoritmos beamforming y machine learning.</i>	66
Medio controlado	66
Medio no controlado.....	67
Capítulo VI: Conclusiones y Trabajos Futuros	68
<i>Conclusiones</i>	68
<i>Trabajos futuros</i>	69
Referencias	70

INDICE DE TABLAS

Tabla 1 Ángulo de arribo obtenido a la distancia de 3 metros en la piscina	51
Tabla 2 Ángulo de arribo obtenido a la distancia de 3 metros en el lago.....	53

INDICE DE FIGURAS

Figura 1 Patrón polar de un hidrófono direccional ideal.....	28
Figura 2 Arreglo lineal uniforme	29
Figura 3 Ancho de haz determinado por la dirección de apuntamiento y el número de sensores	31
Figura 4 Ambigüedad del arreglo lineal uniforme de sensores	32
Figura 5 Arreglo de antenas compuesto por dos subarreglos idénticos	34
Figura 6 Vehículo subacuático PowerVision PowerRay.....	44
Figura 7 Hidrófono DolphinEar DE200	45
Figura 8 Interfaz de sonido Behringer U-Phoria UMC404HD	45
Figura 9 Rango de frecuencias del sonido de los motores del dron subacuático	47
Figura 10 Arreglo lineal uniforme para el medio controlado	49
Figura 11 Arreglo lineal uniforme para el medio no controlado	49
Figura 12 Pruebas en el medio controlado (piscina)	50
Figura 13 Posición del dron en cada instante de tiempo a una distancia de 3 metros en la piscina	51
Figura 14 Pruebas en el medio no controlado (lago)	52
Figura 15 Posición del dron a una distancia de 3 metros en el lago.....	53
Figura 16 Método de evaluación de los ángulos de arribo (DOA)	54
Figura 17 Segmentación de la señal con el comando buffer.....	56
Figura 18 Ajuste de curvas realizada con series de Fourier a la distancia de 3 metros (piscina)	57
Figura 19 Ajuste de curvas polinómica realizada a la distancia de 9 metros (piscina)	57
Figura 20 Etiqueta de datos para el entrenamiento de machine learning	58
Figura 21 Pruebas de los algoritmos Music y Espirit en el campo ideal (piscina)	60
Figura 22 Pruebas de los algoritmos Music y Espirit en el campo no ideal (lago)	61
Figura 23 Prueba de machine learning en el tiempo (piscina)	62

Figura 24 Entrenamiento en el tiempo con una ventana de 20 ms y 90% de solapamiento (piscina)	62
Figura 25 Prueba de machine learning en la frecuencia (piscina)	63
Figura 26 Entrenamiento en el dominio de la frecuencia para una ventana de 100 ms y 90% de solapamiento (piscina).....	64
Figura 27 Pruebas de machine learning en la frecuencia (lago).....	65
Figura 28 Entrenamiento en el dominio de la frecuencia para una ventana de 100 ms y 90% de solapamiento (lago).....	66
Figura 29 Comparación de valores RMSE entre los algoritmos de beamforming y machine learning (ML) (piscina)	67
Figura 30 Comparación de valores RMSE entre los algoritmos de beamforming y machine learning (ML) (lago).....	67

Resumen

En el presente trabajo de investigación se desarrolló un sistema de localización para un dron subacuático mediante el diseño e implementación de un arreglo lineal de hidrófonos, el cual permitió captar las señales acústicas generadas por los motores del vehículo en diferentes trayectorias.

Para la recolección de dichas señales se consideraron dos escenarios, una piscina a la cual se le denominará "medio controlado" y un lago el cual será el "medio no controlado", posicionando al vehículo subacuático mediante el método del ángulo de arriba hacia el arreglo de hidrófonos. Posteriormente, se realizó el análisis de dicha información mediante la aplicación de un filtro pasabanda garantizando así que las señales se encuentren en el rango de frecuencias requeridas para la investigación, obteniendo una base de datos para finalmente analizarlas con los algoritmos de beamforming y el entrenamiento de modelos de machine learning los cuales fueron programados en el ambiente de Matlab.

En cuanto al análisis de beamforming se utilizaron los algoritmos Music y Espirit donde de acuerdo con los resultados obtenidos se alcanzó un alto error cuadrático medio, evidenciando así que este tipo de técnicas no son eficientes para detectar la posición del dron en ninguno de los medios establecidos para la presente investigación. Por otro lado, para machine learning se analizaron los modelos tanto en el dominio del tiempo como de la frecuencia, llegando a determinar que en este último caso se presentan resultados eficientes y con bajo costo computacional.

Finalmente se realizó la comparación de las diferentes técnicas utilizadas concluyendo que machine learning con el uso de los Modelos de Redes Neuronales posee un rendimiento óptimo y efectivo en la detección del dron en los dos escenarios propuestos.

Palabras claves: dron subacuático, beamforming, machine learning, error cuadrático medio, sistema de localización.

Abstract

In this research work, a localization system for an underwater drone was developed through the design and implementation of a linear array of hydrophones, which allowed to capture the acoustic signals generated by the vehicle's engines in different trajectories.

For the collection of these signals two scenarios were considered, a pool which will be called "controlled environment" and a lake which will be the "uncontrolled environment", positioning the underwater vehicle by the method of the angle of arrival to the hydrophone array. Afterwards, the analysis of this information was performed by applying a band-pass filter to ensure that the signals are in the frequency range required for the research, obtaining a database to finally analyze them with beamforming algorithms and training machine learning models which were programmed in the Matlab environment.

Regarding the beamforming analysis, MUSIC and ESPRIT algorithms were used, where according to the results obtained, a high mean square error was reached, showing that this type of techniques is not efficient to detect the position of the drone in any of the environments established for this research. On the other hand, for machine learning, the models were analyzed both in the time and frequency domains, and it was determined that in the latter case the results were efficient and with low computational cost.

Finally, a comparison of the different techniques used was carried out, concluding that machine learning with the use of Neural Network Models has an optimal and effective performance in the detection of the drone in the two proposed scenarios.

Keywords: underwater drone, beamforming, machine learning, mean squared error, localization system.

Capítulo I: Introducción

Justificación

La seguridad ciudadana, es uno de los derechos humanos que debe ser garantizada por el Estado; sin embargo, en las provincias del cordón fronterizo del Ecuador esta se ha visto vulnerada por actividades ilícitas como el narcotráfico y el contrabando, lo cual ha conllevado a que los grupos ilegales recluten a ciudadanos procedentes de dichas zonas para el ocultamiento de alcaloides en caletas y la transportación de droga en embarcaciones por los medios fluviales (Ministerio de Defensa, 2018).

Según (J. Jiang, 2022), el desarrollo de nuevos sistemas y equipos de navegación submarina han permitido que se amplíe la investigación sobre la localización y reconocimiento de objetos acústicos submarinos; es así, que a través del presente proyecto se busca desarrollar un sistema de localización de vehículos fluviales, el cual podría ser considerado como una herramienta para fortalecer las operaciones militares realizadas por las Fuerzas Armadas, que se ejecutan en el perímetro fronterizo del Ecuador, con la finalidad de mitigar dichas actividades ilegales.

Antecedentes

En la actualidad existen diversos estudios que enfocan su investigación en el posicionamiento de vehículos fluviales utilizando diferentes técnicas que conllevan el análisis de señales. El beamforming es una de las técnicas más utilizadas para estimar la dirección de llegada de una señal subacuática, esto suponiendo que las señales se modelen como ondas planas (Z. Xu, 2020).

Existen varios estudios que utilizan dicha técnica para determinar el posicionamiento de AUVs a nivel submarino. Por ejemplo, (D. F. Nsalo Kong, 2021) realiza un estudio sobre una arquitectura de bajo costo para emplear beamforming, con la finalidad de monitorear actividades ilegales como la pesca y la piratería a nivel marítimo; para lo cual se utiliza un sistema conformado por boyas en las que se incluyen baterías, un arreglo lineal de hidrófonos y una técnica de beamforming, enfocada al dominio de la

frecuencia, la cual permite medir la diferencia de fase entre cada senoide para recuperar la señal de tiempo original. Sin embargo, (A. B. Gershman, 1995) menciona que, al momento de localizar señales subacuáticas en situaciones reales, uno de los problemas es el utilizar algoritmos de alta precisión, esto debido a que son sensibles al desajuste entre el modelo de propagación asumido y las condiciones reales de propagación de la señal. Es por ello, que propone el uso de beamforming adaptativo para la localización y seguimiento de señales subacuáticas con el fin de lograr suprimir interferencias fuertes antes del filtrado espacial de la señal o del análisis espectral lineal. La ventaja del uso de este tipo de beamforming es que no es necesario conocer sobre los frentes de onda, ni los modelos de frente de onda para la supresión de interferencias.

Además, (Fischer, 2021) evalúa una matriz de hidrófonos como un método para la localización de fuentes acústicas débiles vinculadas al flujo generado por un modelo impulsado por flotabilidad. Para lo cual se hizo uso de la técnica de beamforming convencional (Delay and Sum), la cual se basa en retrasar y sumar las señales de los hidrófonos con respecto a varias posiciones de la fuente con la finalidad de aumentar la relación señal a ruido e inferir los parámetros de la fuente como la posición o el espectro.

Dentro de las técnicas utilizadas en el estudio del posicionamiento de AUVs mediante señales acústicas; se encuentran las de trilateración pasivas, estas permiten identificar la posición del vehículo haciendo uso únicamente de la fuente de sonido emitida por el AUV. Para lo cual, (Carrera & Guevara, 2023) proponen el uso de las técnicas RSSI (Received Signal Strength Indication) y TDOA (Time Difference of Arrival). RSSI, basa la localización del AUV, en medir la fuerza de las señales recibidas por hidrófonos ubicados en posiciones previamente conocidas.

Mientras que TDOA, determina la posición del AUV midiendo las diferencias de tiempo existentes entre cada señal recibida por los hidrófonos, para lo cual requiere que los receptores se encuentren sincronizados entre sí.

Machine learning es otra de las técnicas que resulta eficaz al momento de diseñar sistemas de detección de objetos. Para lo cual, (B. Wehbe, 2017) estudia el movimiento y la localización de AUVs utilizando técnicas de machine learning como redes neuronales, regresión de vectores de soporte, regresión del proceso gaussiano, y la regresión de Kernel. Para cada uno de los entrenamientos se trabajó con datos obtenidos en un ambiente controlado de sensores ubicados sobre el AUV. Como resultado se obtuvo que el método de regresión de vectores de soporte es el más adecuado cuando se tiene una mayor cantidad de muestras y sobre todo puede ser utilizado para la localización en línea de objetos en movimiento.

Alcance del proyecto

El presente proyecto tiene como objetivo la detección de un dron subacuático mediante el desarrollo e implementación de un arreglo lineal uniforme de hidrófonos , utilizando una metodología cuantitativa de tipo teórico experimental, basada en el uso de herramientas computacionales de software y hardware, así como en teorías de procesamiento digital de señales; para en el futuro poder aplicar el estudio a la localización de vehículos acuáticos motorizados en tiempo real, lo cual es esencial al momento de realizar patrullajes de contrabando y narcotráfico por los ríos fronterizos de la nación para detectar actividades ilícitas.

Objetivos

Objetivo General

Desarrollar un sistema de localización de un dron subacuático, mediante la construcción de un arreglo de hidrófonos utilizando técnicas de beamforming y machine learning.

Objetivos Específicos

- Contrastar la teoría sobre el posicionamiento de vehículos subacuáticos mediante el uso de señales acústicas y la implementación de técnicas de beamforming y machine learning.
- Diseñar e implementar un arreglo de hidrófonos, para la adquisición de señales acústicas en un medio subacuático controlado y en uno no controlado.
- Generar una base de datos de las señales acústicas obtenidas del dron en los dos posibles escenarios subacuáticos.
- Realizar la programación del algoritmo de beamforming y el entrenamiento de machine learning, mediante el uso del software Matlab, para determinar el posicionamiento del dron en los dos posibles escenarios subacuáticos.
- Comparar el desempeño de los algoritmos de beamforming y machine learning, para determinar el rendimiento de estos y seleccionar el más efectivo en los dos escenarios propuestos.

Capítulo II: Marco teórico

Acústica subacuática

Según (Lawrence, Austin, & Sanders, 2011) cuando un objeto oscila en un medio elástico en este caso el agua, se producen ondas de presión sonoras que comprimen y descomprimen los átomos del medio descomponiendo su configuración normal originando una fuerza elástica restauradora que permite que la materia produzca ondas vibratorias transfiriendo energía sin transportar masa y como consecuencia de esto se transmitan las ondas acústicas. Las mencionadas ondas no se mitigan fácilmente en el medio acuático en comparación con las ondas electromagnéticas que sufren grandes pérdidas de energía por lo que no pueden alcanzar grandes distancias, es por esta razón que el comportamiento del sonido dentro del agua ha sido motivo de estudio en diferentes aplicaciones y una de éstas es detectar la dirección de origen de una fuente sonora. Para el presente análisis es necesario comprender los diferentes parámetros que condicionan la transmisión del sonido dentro del agua los mismos que se tratan en los siguientes apartados.

Parámetros que afectan la velocidad del sonido

Según (Bustamante, 2015) la velocidad de propagación del sonido dentro del agua depende de los siguientes parámetros:

Temperatura

La temperatura es un factor que condiciona la velocidad de propagación de las ondas acústicas, por lo general el agua de océanos y lagos se encuentran entre cero a treinta grados centígrados. Sin embargo, dependiendo de las zonas geográficas la temperatura puede descender a valores bajo cero. Es por esta razón que es difícil predecir este parámetro y por tanto obtener un perfil de velocidad permanente ya que una variación de un grado centígrado representa 3,5 m/s en la velocidad del sonido.

Salinidad

La salinidad es la cantidad de sales y minerales que se encuentran disueltas en el agua, si bien es cierto este parámetro no se lo puede calcular directamente, sino que se lo realiza estableciendo una relación con la conductividad eléctrica. La tasa de variación con respecto a la velocidad del sonido es de 1,3 m/s por 1% de alteración de salinidad.

Presión

La presión se encuentra relacionada directamente con la profundidad y tiene un impacto significativo en la propagación del sonido en el agua por lo que la tasa de cambio es de 1,6 m/s por cada alteración de 10 atmósferas aproximadamente 100 metros de profundidad.

Pérdidas de propagación del sonido

Las pérdidas de propagación son fenómenos que se producen cuando se transmite un sonido a través de un medio y su intensidad disminuye al alejarse de la fuente sonora. Dichas pérdidas pueden ser ocasionadas por factores físico y ambientales que afectan a la propagación del sonido. Dentro de un ambiente subacuático estas pérdidas pueden darse por reflexión, reverberación, absorción y multitrayecto.

Reflexión

Es un fenómeno que produce el cambio de dirección de propagación de las ondas acústicas cuando se encuentra con un obstáculo. Por lo tanto, las señales recibidas entre el emisor y receptor puede ser el resultado de múltiples trayectos que por lo general en aguas poco profundas se originan reflexiones de la superficie y del fondo provocando pérdidas de energía de las fuentes sonoras.

Reverberación

Este fenómeno sucede cuando se presenta una disminución de la intensidad del sonido por la reflexión y difusión de este en un espacio cerrado. Cuando se refiere a este tipo de pérdidas dentro de

un medio acuático, el sonido disminuye debido a la reflexión y la difusión, tanto en la superficie como en las capas de agua inferiores. Debido a que cada capa tiene su propia velocidad de propagación la difusión del sonido no será homogénea. En cuanto a la reflexión, el sonido se refleja en la superficie cuando se encuentran objetos en la misma, pero de igual manera puede reflejarse con objetos debajo del agua como el fondo marino, el fondo de una piscina e incluso organismos marinos. Si este tipo de reflexiones se superponen y se acumulan, se crea un efecto de eco y reverberación que dificultará la detección del sonido original (Fuentes Quintero, 2019).

Absorción

Se refiere a la pérdida de energía cuando una onda acústica choca con un obstáculo o superficie por lo tanto parte de la energía es reflejada y otra es absorbida.

Multitrayecto

Este fenómeno se produce cuando disminuye la intensidad del sonido al propagarse en un medio, debido a la reflexión y dispersión de las ondas sonoras en diferentes direcciones. En particular, dentro de un medio acuático esto se produce cuando una onda sonora encuentra obstáculos como fondos marinos, objetos sumergidos, corrientes, entre otros, que puedan causar el desvío de cierta parte de la energía del sonido. Dicha energía puede ser absorbida, dispersada o reflejada en diferentes direcciones, provocando que la intensidad del sonido entre el emisor y receptor disminuya. Este tipo de fenómeno se presenta en ambientes como aguas profundas y abiertas, en donde las ondas tienen que propagarse a largas distancias (Remiro Gargallo, 2019).

Transductores electroacústicos

Un transductor electroacústico es un dispositivo que permite transformar las señales acústicas en energía eléctrica. Estos equipos por lo general se encuentran diseñados y fabricados con materiales magnetostrictivos o piezoeléctricos. Para el primer caso la transducción se basa en el acoplamiento de

fuerzas mecánicas y magnéticas, de tal manera que un material de este tipo genera campo magnético en respuesta a la excitación de una fuerza mecánica. Para el segundo caso un material que posee características piezoeléctricas crea una carga eléctrica cuando la superficie de dicho material se somete a una presión generada por ondas acústicas. (Sherman & Butler, 2007). Para la presente investigación el transductor electroacústico que se va a utilizar es el hidrófono.

Hidrófono

Un hidrófono es un transductor electroacústico que transforma las variaciones de presión del agua en variaciones de voltaje eléctrico. Según (Sánchez, Madrid, Felis, & Martinez, 2020), las principales características de un hidrófono son:

Sensibilidad

Es el voltaje generado en los terminales del hidrófono por la presión acústica. La sensibilidad del hidrófono está condicionada por las fuentes de ruido y vendrá determinada por la relación de la señal con respecto al ruido para bajos niveles de sonido y la evasión de sobresaturación para altos niveles de sonido.

Rango frecuencial

Es el rango de frecuencias en el que el hidrófono mantiene la sensibilidad dentro de un margen de tolerancia. El rango frecuencial recomendado para detectar fuentes acústicas dentro del agua es de 10Hz a 150 KHz.

Directividad

Es la propiedad que posee el hidrófono a ser sensible en una dirección o en otra, esto depende de la frecuencia y del tamaño del sensor.

Impedancia

Es la resistencia del hidrófono al paso de corriente alterna. Esto es importante en el momento de acoplar el hidrófono a los restantes componentes de medición o amplificación, pudiendo disminuir la relación señal/ruido en casos desfavorables. Por tanto, es importante utilizar hidrófonos con valores bajos de impedancia y que dispongan de electrónica interna para mejorar su adaptación.

Ruido propio

Señal que produce el hidrófono en ausencia de sonido, por tanto, representa el mínimo nivel de sonido que puede detectarse con el hidrófono.

Tipos de hidrófonos

Tomando en cuenta que los hidrófonos están diseñados exclusivamente para registrar sonidos en el agua, existen diversos tipos, cada uno de ellos pensados para adaptarse a las diferentes aplicaciones y condiciones del ambiente de trabajo. Según (Sherman & Butler, 2007), se define algunos de los tipos de hidrófonos más comunes utilizados en la investigación submarina los mismos que se encuentran detallados a continuación:

Hidrófonos esféricos y cilíndricos

Estos hidrófonos son ampliamente utilizados debido a su alta sensibilidad, a su respuesta plana de banda ancha, su baja impedancia, su simplicidad y la buena capacidad que tienen para soportar la presión del agua.

Hidrófonos planos

Los hidrófonos planos, son utilizados por lo general en arreglos de hidrófonos, los cuales se encuentran a una distancia muy cerca uno del otro. El arreglo permite obtener direccionalidad en la recepción de las señales deseadas y una reducción efectiva del ruido ambiente.

Hidrófonos de vector

Los hidrófonos de vector tienen la capacidad de obtener información sobre la dirección de la señal acústica incidente por lo tanto una cobertura en tres dimensiones puede ser obtenida por tres sensores de vector orientados en tres direcciones ortogonales entre sí.

Sistema Hidrofónico

Según (Sánchez, García , & López, 2002), un sistema hidrofónico es aquel compuesto por un conjunto de hidrófonos, interconectados entre sí, y conectados a un centro de procesado de la información que éstos reciben. Su utilidad radica en la capacidad de detección y localización de elementos fijos o móviles sumergidos o que operan en la superficie o en el interior del agua. Estos elementos pueden tener diversas naturalezas según el objeto de la aplicación. Los aspectos fundamentales de una estructura de hidrófonos son aquellos que definen su arquitectura física y su rango de funcionamiento. Así se define la distancia de separación, que consiste en establecer la separación entre los sensores disponibles, este es un valor importante y, sobre todo, su relación con la longitud de onda de la señal ya que dicha relación determina en gran medida el rango de frecuencias de funcionamiento. Otro punto importante por considerar es el número de elementos de hidrófonos que está compuesto el sistema ya que de ellos dependerá la capacidad de directividad de la estructura. Estos conceptos, junto con los clásicos como la frecuencia, la longitud de onda son lo que definen la estructura y comportamiento del sistema hidrofónico.

Tipos de arreglos para hidrófonos.

El patrón polar de un sólo hidrófono es relativamente ancho proporcionando bajos índices de directividad y en algunos casos puede ser nula especialmente en los transductores omnidireccionales. En la bioacústica acuática es común la utilización de este tipo de hidrófonos los cuales están diseñados para recibir fuentes de sonido desde cualquier dirección. Alcanzar un patrón polar altamente directivo como se muestra en la Figura 1, con un solo hidrófono no ha sido posible con las pruebas y estudios que

se han realizado hasta la actualidad esto debido a las propiedades intrínsecas del transductor. Se puede aproximar implementando un conjunto de hidrófonos en configuración geométrica y a esto se lo conoce como arreglo. Existen diferentes tipos de arreglos entre los que se pueden encontrar: los lineales, rectangulares planos y volumétricos (Sherman & Butler, 2007). Para la presente investigación se estudiará e implementará un arreglo lineal uniforme.

Figura 1

Patrón polar de un hidrófono direccional ideal



Nota. Tomado de Patrón polar de sensibilidad de un hidrófono direccional ideal (p.40), por Omar


Bustamante, 2015.

Arreglos lineales uniformes.

En este tipo de arreglos todos los sensores están dispuestos sobre una línea recta como se muestra en la Figura 2 donde los hidrófonos están alineados sobre el eje y. Un caso especial por su amplio uso en diferentes aplicaciones es que los sensores se encuentran separados a la misma distancia. La mencionada separación se encuentra relacionada con la longitud de onda de la frecuencia de interés.

Figura 2

Arreglo lineal uniforme



Nota. Tomado de Agrupación lineal uniforme (p. 68), por Eduardo Hernández, 2010.

Características y Limitaciones del arreglo lineal.

Según (Hernández, 2010), en los arreglos lineales existe un problema que es la aparición de máximos adicionales denominados lóbulos de difracción o también conocidos como Grating Lobes. Éstos son lóbulos no deseados similares al lóbulo principal aparecen en la región visible entre 0° a 360° . Con el objetivo de garantizar que sólo exista un lóbulo principal dentro de la región visible, apuntando en la dirección deseada, el espaciado entre sensores debe seguir un criterio el mismo que se encuentra basado en el teorema del muestreo de la teoría de la comunicación.

El teorema del muestreo indica que para evitar el solapamiento o aliasing de una señal en el dominio del tiempo esta debe ser muestreada a una tasa de frecuencia de $f_s = \frac{1}{T_s} \geq 2f_{max}$ ciclos por segundo, donde f_{max} es la frecuencia más alta del espectro de la señal y f_s la frecuencia de muestreo.

La versión espacial de acuerdo con la Figura 2 sería $f_{Ys} = \frac{1}{d} \geq 2f_{Ymax}$ donde d es el espacio entre sensores en metros.

Como $f_{Ymax} = \frac{u_{max}}{\lambda_{min}}$ y como u está acotado entre -1 y 1, su valor máximo será la unidad. Por tanto, $d \leq \frac{\lambda_{min}}{2}$, donde λ_{min} es la longitud de onda mínima asociada con la componente de frecuencia máxima. Si el espacio entre los hidrófonos satisface esta condición se evitará la aparición de los lóbulos de difracción.

El ancho del lóbulo principal, visto como la separación entre el máximo y una caída de 3dB, permite obtener la resolución angular que se puede alcanzar con el arreglo lineal uniforme. De esta manera, el ancho del lóbulo principal medido entre cruces por cero viene dado por la ecuación (1) :

$$\theta = \text{sen}^{-1} \left(\frac{\lambda}{N \cdot d} \right) \quad (1)$$

Donde N es el numero de sensores que conforman el arreglo de hidrófonos. Según esta ecuación el ancho de haz que se encuentra definido en grados disminuye conforme mayor es el número de sensores en la agrupación. Por lo tanto, a medida que se incrementan el número de elementos del arreglo, el lóbulo principal es más directivo. Por el contrario, cuando se implementa menor número de sensores en el arreglo el lóbulo principal es más ancho y en consecuencia menos directivo; este fenómeno se puede visualizar en la Figura 3.


Independientemente de la longitud del arreglo todos los patrones de haz presentan lóbulos secundarios con niveles de respuestas que pueden incidir en la detección de la fuente de sonido. Por lo tanto, los frentes de onda podrán ser detectados tanto por el lóbulo principal como los secundarios provocando imprecisión en la detección. Como consecuencia de las simetrías de muchas agrupaciones, habrá ondas acústicas propagándose a la misma velocidad como se muestra en la Figura 4, donde se visualiza fuentes sonoras desde distintas direcciones en este caso generadas desde una fuente a, b y c,

las mismas que pueden producir exactamente la misma salida, este conjunto de direcciones ambiguas conforma un cono. En este caso, la determinación de su procedencia será ambigua es decir el sistema no puede diferenciar si la fuente de sonido proviene desde arriba por la izquierda o por la derecha.

Las características y el comportamiento de un arreglo lineal parten de considerar que los hidrófonos del arreglo deben estar fijos en su posición. Existen escenarios donde los sensores están sujetos mediante sujeciones no rígidas es decir cuerdas, cables metálicos, esto les da cierto grado de libertad y a su vez conlleva una deformación de la agrupación. Las consecuencias van desde el ensanchamiento y deformación del lóbulo principal hasta lo más grave, la ubicación errónea del lóbulo principal.

Figura 3


Ancho de haz determinado por la dirección de apuntamiento y el número de sensores



Nota. Tomado de Ancho de haz en función de la dirección de apuntamiento ψ_0 y del número de sensores en un arreglo lineal uniforme (p. 70), por Eduardo Hernández, 2010.

Figura 4

Ambigüedad del arreglo lineal uniforme de sensores



Nota. Tomado de Agrupación lineal uniforme sobre la que inciden tres fuentes (p.72), por Eduardo Hernández, 2010

Algoritmo de conformación de haz

El algoritmo de conformación de haz conocido como beamforming permite la detección y localización de unidades emisoras de fuentes acústicas. Las principales técnicas de posicionamiento son:

Dirección de arribo (DOA): Permite detectar las direcciones de la fuente de llegada.

Tiempo de arribo (TOA): Detecta el instante temporal en el que se realizan las capturas de señal en cada uno de los sensores.

Matriz de amplitudes(A): Define los valores detectados para cada instante TDOA y cada dirección DOA.

En la presente investigación se analizará los conceptos teóricos y prácticos de las técnicas DOA.

Dirección de arribo

Algoritmo de Clasificación de señales múltiples

Según (Gross, 2005) y (Olmos, 2016), el algoritmo de clasificación de señales múltiples (MUSIC) es una técnica basada en la descomposición del valor propio de la matriz de covarianza de la señal recibida dando como resultado dos señales ortogonales: un subespacio de señal y un subespacio de ruido. Estos dos subespacios se usan para construir una función espectro donde se buscan los picos de las señales incidentes y se detecta las señales DOA. La implementación del algoritmo MUSIC se detalla a continuación:

El primer paso es la estimación de la matriz de covarianza de entrada que se basa en el N vector de la señal recibida. La recolección de datos que se encuentran en la señal incidente se lo calcula con la ecuación (2):

$$\hat{R}_x = E[xx^H] \quad (2)$$

El segundo paso es encontrar el valor propio que se encuentra al descomponer la matriz de covarianza de R_x , donde dichos valores propios se clasifican de acuerdo con el tamaño de las señales de entrada y para conocer el número de señales incidentes se debe conocer el número de valores propios los mismos que tienen una relación de tal manera que si el número de señales de entrada son D , el número de valores y vectores propios también es D . Por lo tanto, el número de valores y vectores propios del ruido es $M-D$, donde M es el número de elementos que está conformado el arreglo de sensores. La autocorrelación está dada por la ecuación (3):

$$\hat{R}_{xx} = \hat{A}\hat{R}_{ss}\hat{A}^H + \sigma_n^2\hat{I} \quad (3)$$

El siguiente paso es encontrar los eigenvalores de ruido de \hat{R}_{xx} . Se construye la matriz $M_x(M - D)$ con vectores propios $\hat{E}_N = [\bar{e}_1 \bar{e}_2 \bar{e}_3 \dots \bar{e}_{M-D}]$. Esta matriz de vectores propios es ortogonal al vector de arreglo de direcciones de ángulos de arribo $\theta_1, \theta_2, \dots, \theta_D$.

Se encuentra la función de pseudoespectro y el valor estimado de DOA se calcula con la ecuación (4):


$$P_{MUSIC}(\theta) = \frac{1}{a^H(\theta)E_n E_n^H a(\theta)} \quad (4)$$

Algoritmo de Estimación de Parámetros vía Técnicas de Invarianza Rotacional

Según (Gross, 2005), el algoritmo de Estimación de Parámetros vía Técnicas de Invarianza Rotacional (ESPRIT) se basa en formar dos arreglos idénticos a partir del arreglo lineal uniforme principal como se muestra en la Figura 5. Estos dos arreglos se analizan como casos separados obteniendo la invarianza rotacional del subespacio generado entre ambos arreglos lo que permite analizar el retardo entre ellos, comparar los desfases y finalmente determinar el ángulo de arribo de la señal incidente.

Figura 5

Arreglo de antenas compuesto por dos subarreglos idénticos



El primer paso del algoritmo Espirit es encontrar la matriz de covarianza espacial \hat{R}_{xx} , similar al algoritmo Music, pero a diferencia de este, los ángulos de arribo se encontrarán a partir del subespacio de las señales incidentes y no del subespacio del ruido. Luego se realiza la descomposición en valores singulares (SVD) de \hat{R}_{xx} . El cálculo de dichos valores viene dado por la ecuación (5) donde U es una

matriz $n \times L$ cuyas columnas son ortonormales, Σ es una matriz diagonal de tamaño $n \times n$ la misma que contiene los valores singulares y Q es la matriz de valores propios.

$$SVD(\hat{R}_{xx}) = U\Sigma Q^H \quad (5)$$

A partir de Σ se estima los componentes reales del ruido y las componentes de las señales incidentes, con esta evaluación se reduce la matriz de valores singulares a la matriz Q_s como se muestra en la ecuación (6). Donde L es el número de señales incidentes, \widehat{Q}_0 y \widehat{Q}_{L-1} es el vector propio de la primera y enésima señal incidente.

$$Q_s = [\widehat{Q}_0 \dots \widehat{Q}_{L-1}]_{L \times n} \quad (6)$$

A continuación, se descompone la matriz Q_s en dos submatrices que es equivalente a la división de los dos subarreglos del arreglo principal el cual se define en la ecuación (7). A estas submatrices se aplica el método de los mínimos cuadrados y el resultado se visualiza en la ecuación (8).

$$Q_s = \begin{bmatrix} \widehat{V}_0 \\ \widehat{V}_1 \end{bmatrix}_{L \times n} \quad (7)$$

$$\widehat{V}_0 - \widehat{V}_1 * \beta = 0 \quad (8)$$

El producto obtenido de la ecuación (8) se obtiene V_2 , esta se subdivide en cuatro submatrices de $L \times L$ como se muestra en la ecuación (9). Luego se calcula la matriz diagonal V_3 de acuerdo con la ecuación (10) donde V_3 y V_3^H es una matriz de vectores propios y la matriz hermitania, respectivamente.

$$V_2 = \begin{bmatrix} V_{11} & V_{12} \\ V_{21} & V_{22} \end{bmatrix} \quad (9)$$

$$-V_{12} * V_{22} = V_3 D_3 V_3^H \quad (10)$$

Finalmente se estima los ángulos de incidencia con la ecuación (11). Donde θ_l es el ángulo incidente de la enésima señal de $\arg(D_l)$ obtenido del vector propio D_3 , k es una constante de fase y d es la distancia entre los arreglos de sensores.

$$\theta_l = \sin^{-1} \left(\frac{\arg(D_l)}{k \times d} \right) \quad (11)$$

Machine learning

Al momento de hablar de machine learning o aprendizaje automático, se hace referencia al desarrollo o uso de técnicas, algoritmos y modelos matemáticos, capaces de permitir el aprendizaje a computadoras a través de datos y experiencias. Basándose en la identificación de patrones con la finalidad de realizar tareas como predicción o toma de decisiones con nuevos datos. Estos modelos son comúnmente utilizados para tareas como el reconocimiento de voz, detección de imágenes, traducción automática, clasificación de datos y decisiones automatizadas en tiempo real. En general, el aprendizaje automático se divide en tres grupos: aprendizaje supervisado, no supervisado y por refuerzo (Álvarez Vega, Quirós Mora, & Cortés Badilla, 2020).

Aprendizaje supervisado

El aprendizaje supervisado se basa en entrenar un modelo utilizando un conjunto de datos con etiquetas; es decir datos que han sido clasificados o etiquetados previamente. Para el entrenamiento; el modelo recibe datos de entrada conocidos como características o variables independientes, con sus respectivas etiquetas o variables dependientes, con esta técnica se busca el modelo que mejor se adapte en aprender la relación existente entre ambas variables, con la finalidad de generalizar una relación entre entradas y salidas, que pueda trabajar con datos nuevos y sea capaz de predecir o clasificar las salidas en función de las nuevas entradas (Carlos, Lerache, & Sattolo, 2020).

Aprendizaje no supervisado

Este tipo de aprendizaje entrena un modelo usando un conjunto de datos que no han sido previamente etiquetados o clasificados. Por lo que, a diferencia del aprendizaje supervisado, el modelo no recibe ninguna salida deseada, siendo su objetivo encontrar patrones o estructuras significativas

dentro del conjunto de datos. Este tipo de algoritmos son utilizados comúnmente para agrupar clústeres, reducir la dimensión de datos, detectar valores atípicos, entre otros (Bell, 2022).

Aprendizaje por refuerzo

Es un tipo de aprendizaje automático que se basa en el uso de un agente de software, el cual aprende a tomar decisiones óptimas en un entorno dinámico y complejo. El agente recibe la información en forma de estados, acciones y recompensas. Una vez que el agente ha tomado una acción recibe una recompensa en función a la acción tomada. El objetivo de este tipo de aprendizaje es aprender una política de toma de decisiones con la finalidad de maximizar una recompensa a largo plazo. Este tipo de aprendizaje es utilizado comúnmente en la robótica, los juegos, la optimización de rutas, la gestión de recursos, la planificación de tareas, entre otros. Es decir, en tareas donde se requiere tomar decisiones secuenciales, y cuando no se dispone de datos etiquetados o de una función objetivo (Díaz, 2019).

Técnicas de aprendizaje supervisado

Este tipo de técnicas se basa en datos donde se conoce la respuesta correcta o el resultado deseado. Es decir, proporcionan al algoritmo un conjunto de datos con entradas y salidas esperadas con el objetivo de aprender la relación subyacente entre ambos parámetros y obtener un modelo el cual se pueda utilizar para predecir salidas correspondientes a entradas nuevas. A continuación, se detalla las principales técnicas de aprendizaje supervisado que serán utilizadas en el presente proyecto.

Regresión Lineal

Esta técnica de aprendizaje supervisado se basa en usar un valor numérico continuo, como una variable de respuesta, en función de varias características o también conocidas como variables predictoras. El objetivo de esta técnica es buscar modelar la relación entre las dos variables mediante una ecuación lineal, minimizando el error de predicción entre los valores reales y la línea de regresión.

Una vez que se tenga una línea de regresión óptima se puede utilizar la ecuación que la representa para predecir la variable de respuesta de nuevos valores (Maulud, 2020).

Arboles de decisión

Es una técnica de aprendizaje supervisado que es utilizada comúnmente para clasificar o predecir un valor en función de un conjunto de variables predictoras. Como su nombre lo indica, en esta técnica se construye una estructura en forma de árbol, en donde cada inicio de ramificación representa una pregunta sobre las variables predictoras, mientras que cada hoja representa la clasificación o predicción deseada. Para lograr una correcta clasificación, esta técnica hace uso de una división recursiva. Es decir, selecciona la característica más relevante para la predicción en cada paso. El objetivo de esta técnica es crear una estructura de árbol con el menor número de ramificaciones posibles pero que sea capaz de generar predicciones con datos nuevos (Jijo, 2021).

Redes neuronales

Esta técnica basa su funcionamiento en la estructura y funcionamiento del cerebro humano. Es decir, se compone por numerosas capas de neurona, las cuales se encuentran interconectadas entre sí, siendo capaces de procesar la información a medida que se les presenta. Dentro del aprendizaje supervisado, esta técnica es utilizada para realizar predicciones partiendo de datos de entrada etiquetados. Lo que implica dotar a la red de un conjunto de datos etiquetados con la salida correcta previamente a su entrenamiento, con el objetivo de que la red pueda aprender a predecir la salida correcta a partir de los datos de entrada.

Durante el entrenamiento la red busca ajustar los pesos y sesgos tratando de minimizar el error entre sus predicciones y las etiquetas correctas, con el objetivo de que una vez entrenada la red, pueda utilizarse para realizar predicciones con datos de entrada nuevos (Choi, 2020).

Procesos gaussianos

Al igual que las redes neuronales, esta técnica de aprendizaje supervisado es usada para realizar predicciones partiendo de datos de entrada que han sido etiquetados previamente. El fundamento básico en un proceso gaussiano es asumir las funciones de predicciones como distribuciones de probabilidad gaussianas. Es decir, en lugar de predecir únicamente una salida por cada entrada, esta predice una distribución de probabilidades sobre posibles salidas. El entrenamiento de esta técnica se basa en aprender los parámetros del modelo mediante el uso de los datos etiquetados, dichos parámetros determinan la forma de la distribución de probabilidad utilizada para las predicciones. Una de las ventajas de los procesos gaussianos es que se pueden utilizar cuando se tienen pocos datos de entrenamiento debido a que permite realizar predicciones con incertidumbre incluso cuando se tiene pocos datos (López Pérez, 2021).

Máquinas de vectores de soporte (SVM)

Esta técnica se utiliza comúnmente para realizar la clasificación de datos. El principal objetivo de los SVM es lograr encontrar un hiperplano el cual separe los datos en dos clases, con la finalidad de que se maximice la distancia entre el hiperplano y los puntos más cercanos de cada clase. Es decir, busca un hiperplano óptimo que separe los datos de entrada en dos clases distintas, de tal forma que la distancia mínima entre el hiperplano y cualquier punto de datos de las dos clases sea máxima. Por lo general esta técnica es utilizada para problemas de clasificación binaria y multiclase (Bennett-Lenane, 2022).

Evaluación de modelos

Este proceso es fundamental dentro de machine learning. Debido a que permite determinar la precisión y el rendimiento de un modelo de aprendizaje automático. Utilizando diferentes técnicas y métricas que permitan evaluar un modelo. Una de las principales técnicas es evaluar el desempeño del modelo mediante el error obtenido en el entrenamiento (Baquerizo, 2022).

Error en regresión

El error dentro de la regresión cumple un rol importante. Tiene como objetivo medir la precisión del modelo al momento de predecir valores nuevos de salida en función de los valores de entrada. Se dice que un modelo realiza mejor la predicción cuando los errores se minimizan. Según (H. Awada, 2022), los errores más comunes al momento de evaluar un modelo de regresión es el error cuadrático medio (RMSE), el coeficiente de determinación (R-Square) y el error absoluto medio (MAE).

Error Cuadrático Medio (RMSE)

El error cuadrático medio o RMSE, indica el nivel de concentración de los datos sobre la curva de mejor ajuste. Su objetivo es buscar un modelo que sea capaz de realizar las mejores predicciones posibles sobre la variable dependiente. Matemáticamente el RMSE, se describe como la raíz cuadrada de los cuadrados de la desviación estándar de los valores residuales del modelo, la fórmula que lo representa es:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (12)$$

Donde:

y_i : Es el valor real de la variable dependiente.

\hat{y}_i : Es el valor predicho por el modelo.

n : Es el número total de muestras.

Tomando en cuenta que el RMSE es una medida de precisión, en cuanto menor sea el valor, la capacidad del modelo para predecir valores con datos nuevos, será mejor. Esta métrica es comúnmente utilizada para evaluar los modelos de problemas de regresión, los cuales buscan predecir valores continuos.

Coefficiente de determinación (R-Squared)

Esta métrica es una medida que indica la capacidad de explicar la variabilidad total de la relación entre las variables independientes con las variables dependientes. Es decir, mide la capacidad del modelo entrenado para explicar la variabilidad de los datos. según la ecuación (13) la escala del R-Squared va de 0 a 1. Un valor de 1 significa que el modelo es una representación perfecta e indica que explica toda la variabilidad de los datos, mientras que un valor de 0 demuestra que el modelo entrenado no representa mejor alguna en relación con los datos de entrada. Si se tiene valores negativos, se indica que el modelo no cumple la tarea propuesta. Matemáticamente se representa por:

$$R^2 = 1 - \frac{SSR}{SST} \quad (13)$$

Donde:

SSR: Es la suma de los cuadrados de las desviaciones entre los valores predichos por el modelo y los valores reales de la variable dependiente.

SST: Es la suma de los cuadrados de las desviaciones entre los valores reales de la variable dependiente y su media.

Esta métrica es comúnmente utilizada para evaluar la calidad del ajuste de los modelos de regresión lineal que se han entrenado y comprara entre sí.

Error Absoluto Medio (MAE)

El MAE, es una medida que indica el promedio entre los valores predichos y los valores reales de un modelo de regresión lineal. Esta medida es utilizada para evaluar la calidad de ajuste del modelo, se interpreta como el promedio en que las predicciones y los valores reales difieren entre sí.

Matemáticamente, se calcula como la media de las diferencias absolutas entre los valores reales y los predichos por el modelo, mediante la siguiente ecuación:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (14)$$

Donde:

y_i : Es el valor real de la variable dependiente.

\hat{y}_i : Es el valor predicho por el modelo.

n : Es el número total de muestras.

Métodos de validación

El proceso de validación dentro de machine learning es de gran importancia, debido a que permite determinar y evidenciar si el modelo ha sido correctamente entrenado. Para cual se hace uso de datos nuevos que no han sido empleados en el entrenamiento y se valida si los valores predichos son aceptables con la finalidad de determinar si el modelo necesita ser o no ajustado. Según (Pal, 2020), los principales métodos es la validación cruzada k-fold y la validación holdout.

Validación Cruzada k-fold

Dentro del aprendizaje automático, esta es una de las técnicas comúnmente utilizada para evaluar el rendimiento de un modelo y evitar el sobreajuste (overfitting) en los datos de entrenamiento. El método k-fold se basa en dividir el conjunto total de datos en k subconjuntos del mismo tamaño también conocidos como folds. A continuación, se entrena y evalúa el modelo k veces. Cada entrenamiento se realiza utilizando un subconjunto diferente como prueba y los $k-1$ subconjuntos restantes como entrenamiento. La principal ventaja que presenta este método de validación es que hace uso de todo el conjunto de datos para entrenar y evaluar el modelo, lo que ayuda a mejorar la precisión y reducir la varianza del modelo.

Validación Holdout

Al igual que el anterior método, esta técnica permite evaluar el desempeño del modelo ante nuevos datos de entrada. Se basa en dividir el conjunto de datos en dos partes: una de ellas es utilizada para entrenar el modelo y la otra para evaluar el rendimiento. Generalmente la división del conjunto de datos viene dada por una proporción fija por ejemplo 70/30 o 80/20. Tomando en cuenta que la parte utilizada en el entrenamiento del modelo debe ser la parte más grande, mientras que la menor son los datos que se utilizan para evaluar el rendimiento del modelo. Para la evaluación se hace uso de métricas como la precisión, el recall, la F1-score, entre otros, que permiten determinar si el modelo es óptimo o no ante datos no vistos previamente.

Capítulo III: Materiales y métodos

Materiales

Los materiales necesarios para desarrollar el presente proyecto de investigación son:

PowerVision PowerRay

El vehículo que se utilizó para las pruebas de campo fue el dron de fabricación china, PowerVision PowerRay (Figura 6). Es un vehículo subacuático avanzado y versátil, comúnmente utilizado para la exploración submarina. Tiene la capacidad de sumergirse hasta a una profundidad de 30 metros, grabar video en formato 4k y tomar fotos de alta calidad. Gracias a sus pequeñas dimensiones y al modo de manejo a distancia, permite tener una buena maniobrabilidad tanto en una piscina como en un lago.

Figura 6

Vehículo subacuático PowerVision PowerRay



DolphinEar DE200

Los sensores utilizados para captar el sonido de los motores del dron por debajo del agua fueron los hidrófonos DolphinEar DE200 (Figura 7). Son dispositivos acústicos utilizados comúnmente para escuchar y grabar sonidos submarinos. Este tipo de hidrófonos utiliza una tecnología de alta calidad, que es capaz de capturar sonidos emitidos por delfines u otros animales marinos. Son resistentes al agua y su diseño le permite soportar profundidades de hasta 200 metros. Comúnmente son utilizados por biólogos marinos para estudiar la comunicación entre animales marinos, así como el impacto generado

por los humanos en los ecosistemas marinos. También son utilizados para la seguridad marítima, ya que permiten detectar la presencia de barcos o submarinos cercanos no identificados.

Figura 7

Hidrófono DolphinEar DE200



Behringer U-Phoria UMC404HD

Para la adquisición de las señales de audio, se hizo uso de la tarjeta de sonido de fabricación alemana, U-Phoria UMC404HD de la marca Behringer (Figura 8). Es una interfaz de alta calidad con conexión USB que es utilizada para la grabación y reproducción de audio. Cuenta con cuatro canales de grabación, cada uno con preamplificador de micrófono de alta calidad. Adicional, es compatible con múltiples softwares de grabación y producción de audio profesional.

Figura 8

Interfaz de sonido Behringer U-Phoria UMC404HD



Audacity

Para la grabación y recorte de los audios obtenidos en cada una de las pruebas de campo. Se utilizó el software de uso libre y gratuito Audacity. Es un programa utilizado ampliamente para grabar y editar pistas de audio de alta calidad. Se encuentra disponible en versiones para Windows, Mac y Linux. Cuenta con una amplia gama de herramientas y características, incluyendo la capacidad de grabar audio en vivo mediante un micrófono o una interfaz de entrada y la capacidad de exportar el audio grabado en una variedad de formatos.

AutoCAD 2024

Una vez realizada la toma de datos en la piscina y en el lago. Se utilizó AutoCAD, un software de diseño asistido por computadora que tiene la capacidad de editar y crear dibujo en 2D y en 3D. Ofrece al usuario una amplia gama de herramientas como líneas, arcos, polilíneas, círculos, elipses, entre otros que son de gran utilidad en el diseño de dibujos técnicos. Por lo cual se hizo uso de este software para lograr digitalizar las trayectorias trazadas por el movimiento del dron y obtener de manera precisa los ángulos formatos entre el dron y el arreglo de hidrófonos.

Matlab 2023a

En cuanto para el desarrollo de los algoritmos de beamforming y el entrenamiento de machine learning. Se hizo uso del software Matlab, el cual es considerado como uno de los entornos de programación numérica más idóneos para el análisis de datos, modelado matemático, simulación, visualización y desarrollo de algoritmos. Comúnmente es utilizado por ingenieros y científicos en diversas áreas, ya que proporciona una amplia gama de herramientas y bibliotecas. Además de contar con funciones predefinidas para el procesamiento de señales, imágenes, control de sistemas y simulaciones en tiempo real. Lo que hace que este software sea utilizado en la investigación y en la industria.

Metodología

El procedimiento para la presente investigación se lo ha dividido en las siguientes etapas:

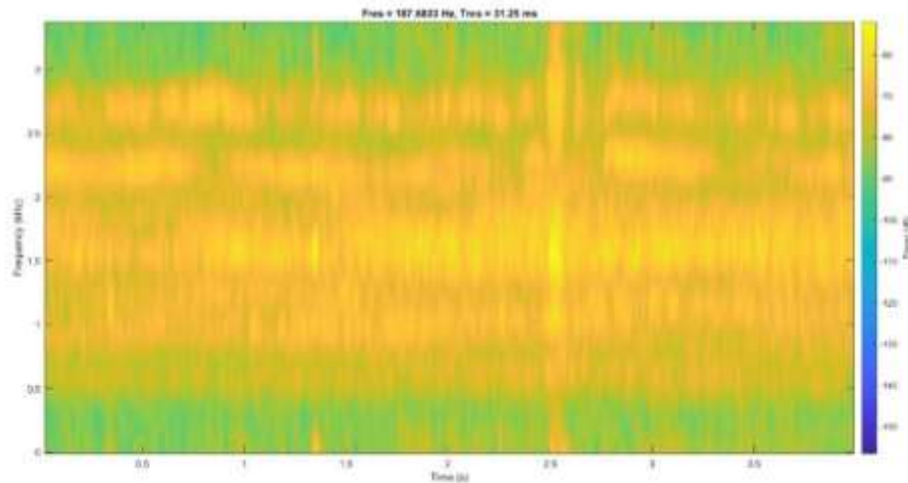
- a) Diseño del arreglo lineal uniforme de hidrófonos.
- b) Adquisición y procesamiento de señales para algoritmos Music y Espirit para el medio controlado y no controlado.
- c) Generación de base de datos y entrenamiento de modelos para machine learning en el campo ideal y no ideal.

Diseño del arreglo lineal uniforme de hidrófonos

El primer paso para diseñar el arreglo lineal uniforme es identificar el rango de frecuencias que emiten los motores del dron subacuático, para esto se tomó una muestra de cuatro segundos del dron navegando en la piscina y se obtiene el espectrograma (Figura 9). Donde se puede concluir que el rango de funcionamiento se encuentra entre los 250 Hz y 2500 Hz.

Figura 9

Rango de frecuencias del sonido de los motores del dron subacuático



El siguiente paso es obtener la longitud de onda del rango de frecuencias para esto es necesario identificar la velocidad de propagación en el interior del agua en este caso tanto para el medio ideal y no ideal se utilizó la velocidad de 1435 m/s (Bustamante, 2015).

Luego se estableció la longitud de onda para 2500 Hz:

$$\lambda = \frac{c}{f} = \frac{1435 [m/s]}{2500 [1/s]} = 0,574 [m]$$

Para 250 Hz:

$$\lambda = \frac{c}{f} = \frac{1435 [m/s]}{250 [1/s]} = 5,74 [m]$$

La distancia entre los hidrófonos debe cumplir la siguiente relación:

$$d < \frac{\lambda}{2}$$

Esta relación debe cumplir para ambos casos tanto para 250 Hz como para 2500 Hz por lo tanto el valor que cumple es la distancia de:

$$d < \frac{0,574 [m]}{2}$$

$$d < 0,287 [m] \approx 28,7 [cm]$$

La distancia de 28,7 cm es la separación que debe existir entre cada uno de los hidrófonos. La implementación del arreglo para el medio ideal se observa en la Figura 10. En esta figura se observa que los hidrófonos se encuentran montados de forma fija a una estructura de madera, junto a un mástil que permite anclar hacia la piscina. La distancia establecida entre hidrófonos se la toma desde el punto central de los hidrófonos.

Figura 10

Arreglo lineal uniforme para el medio controlado



La implementación del arreglo de hidrófonos para el entono no ideal se visualiza en la Figura 11, en este caso se implementó una estructura que permita sujetarse al piso durante las pruebas.

Figura 11

Arreglo lineal uniforme para el medio no controlado



Adquisición y procesamiento de señales para algoritmos Music y Espirit.


Adquisición de las señales de audio y cálculo de ángulos teóricos.

Pruebas en el medio controlado.

Para las pruebas en el medio controlado se utilizó una piscina con las siguientes dimensiones: 13,60 metros de largo y 5,60 metros (Figura 12). En esta figura se visualiza que el arreglo lineal de hidrófonos se colocó en la parte media de la piscina a 2,8 metros de los extremos, sumergido a 1 metro de la superficie. Luego se hizo navegar el dron subacuático recorriendo una trayectoria horizontal paralela al arreglo de sensores y sumergido de igual forma a 1 metro de la superficie. Estas pruebas se lo realizaron a una distancia de 3, 5, 7, 9, 11 y 13 metros, obteniendo así 6 trayectorias. Finalmente, para el procesamiento de datos se tomó una muestra de cuatro segundos de audio y video de las trayectorias mencionadas.

Figura 12

Pruebas en el medio controlado (piscina)



Las grabaciones de audio y video ayudan a visualizar el recorrido que realiza el dron a lo ancho de la piscina permitiendo calcular el tiempo que se demora en completar la distancia de 5,60 metros y de esta manera obtener la velocidad del dron considerando que realiza un movimiento rectilíneo uniforme. Como el objetivo es calcular los ángulos teóricos de arribo hacia el arreglo de hidrófonos, el

cálculo de la velocidad permite obtener la posición del dron en los diferentes instantes de tiempo. Posteriormente, se identifica la posición del dron como se muestra en la Figura 13, donde se puede visualizar como se encuentra distribuido los ángulos de incidencia del arreglo lineal uniforme donde el cuadrante de la derecha corresponde a los ángulos de 0 a 90 grados y el cuadrante de la izquierda de 0 a -90 grados. Por lo tanto, la base para determinar los ángulos será la trayectoria trazada desde el ángulo de 0 grados hacia las diferentes posiciones del dron; este cálculo se visualiza en la Tabla 1.

Figura 13

Posición del dron en cada instante de tiempo a una distancia de 3 metros en la piscina

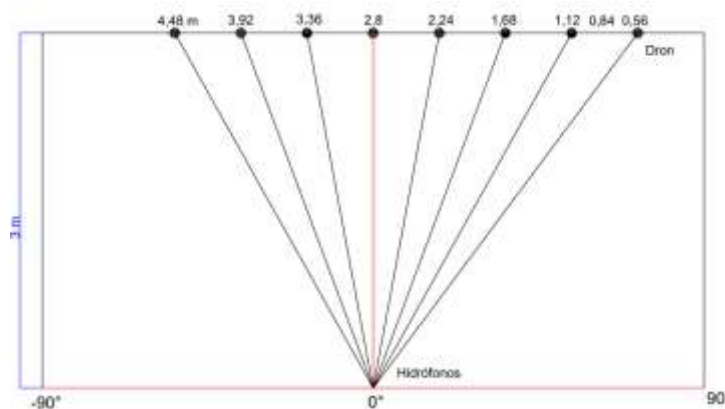


Tabla 1

Ángulo de arribo obtenido a la distancia de 3 metros en la piscina

Tiempo (s)	Distancia (m)	Angulo Teórico (grados)
0,5	0,56	37
1	1,12	29
1,5	1,68	20
2	2,24	11
2,5	2,8	0
3	3,36	-11
3,5	3,92	-20
4	4,48	-29

Pruebas en el medio no controlado

Para las pruebas en el medio no controlado se utilizó un lago, el mismo que posee las siguientes dimensiones 29,4 metros de ancho y 80 metros de largo. El área de pruebas se dividió con una cuerda que contiene boyas que se encuentran separadas 1 metro entre sí (Figura 14), esto permite detectar la posición de dron en cada instante de tiempo durante su movimiento. Se realizó una grabación de audio de 8 segundos y las distancias de prueba que se utilizó fue de 3, 5, 7, 9, 11 y 13 metros paralelos al arreglo lineal uniforme, obteniendo un total de 6 trayectorias. El procedimiento de cálculo de los ángulos de arribo teóricos se lo realizó de igual forma como en el medio controlado.

Figura 14

Pruebas en el medio no controlado (lago)



En la Figura 15 se observa la posición del dron en cada instante de tiempo donde la línea amarilla corresponde el punto de inicio del movimiento del dron, además se visualiza el punto de colocación del arreglo lineal de hidrófonos que es a 1,5 metros del punto de partida y sumergido a 80 cm de la superficie por consiguiente el dron se hizo navegar a la profundidad mencionada. En la Tabla 2

se muestra los ángulos teóricos de arribo. Este procedimiento se realizó para cada una de las distancias propuestas.

Figura 15

Posición del dron a una distancia de 3 metros en el lago




Tabla 2

Ángulo de arribo obtenido a la distancia de 3 metros en el lago

Tiempo (s)	Distancia (m)	Angulo teórico (grados)
1	0,75	-14
2	1,50	0
3	2,25	14
4	3,00	27
5	3,75	37
6	4,50	45
7	5,25	51
8	6,00	56

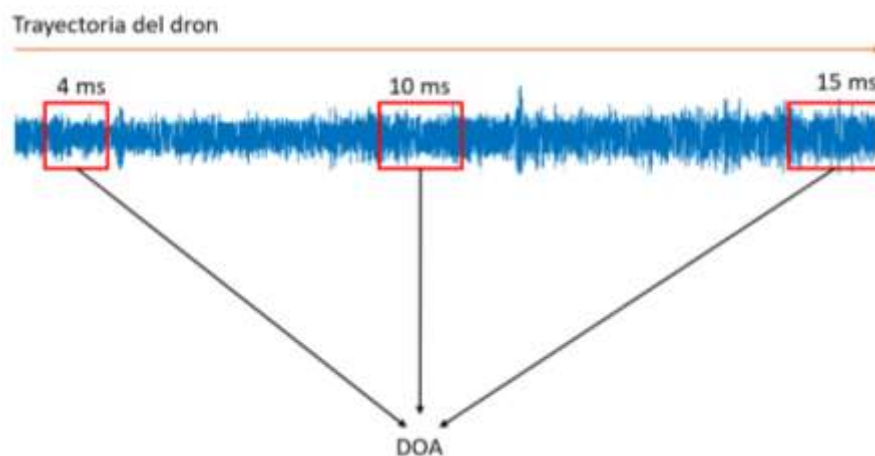
Procesamiento para las señales de audio y método de evaluación del ángulo de arribo

Antes de analizar los algoritmos Music y Espirit es necesario estudiar las señales incidentes sobre el arreglo lineal uniforme. Como se indicó anteriormente el rango de funcionamiento de los

motores del dron subacuático este definido entre 250 Hz y 2500 Hz, por lo tanto, se aplica un filtro Pasabanda al conjunto de señales de audio recibidas por los hidrófonos. Este proceso se lo realiza con el comando bandpass que tiene por defecto Matlab, el cual aplica un filtro de orden mínimo con una atenuación de banda de parada de 60 dB y compensa el retardo introducido por el filtro (Matlab, 2022). Una vez filtrada la señal se continua con el proceso de localización de los ángulos, para determinarlos es necesario dividir el audio en ventanas, estas contienen un número de muestras que se procesarán en los algoritmos y detectarán el ángulo de arribo de la señal incidente. Al tener una fuente acústica móvil, en cada instante de tiempo los ángulos cambian de acuerdo con la velocidad del dron por lo que si se propone ventanas fijas dificultaran el proceso de detección. Para facilitar el procedimiento primero se definió tiempos fijos los mismos que se detallan en la Tabla 1 para la piscina y Tabla 2 para el lago, luego en cada periodo de tiempo se varió la longitud de las ventanas entre 4 ms, 10 ms y 15 ms hasta encontrar el ángulo indicado como se visualiza en la Figura 16. Este procedimiento se realizó para todas las distancias y en los dos escenarios propuestos.

Figura 16

Método de evaluación de los ángulos de arribo (DOA)



Generación de base de datos y entrenamiento de modelos para machine learning en el medio ideal y no ideal.

Base de datos y segmentación de la señal

Para la presente investigación el tipo de machine learning que se realizó fue de un aprendizaje supervisado. El primer paso es definir la base de datos el mismo que está compuesto por el conjunto de datos de las variables y el conjunto de datos predictores. Los datos que corresponden a las variables se los obtiene de los audios filtrados de los algoritmos de beamforming. A estos se los dividió en ventanas de 20 ms, 60 ms y 100 ms con solapamiento del 50%, 80% y 90%; para cada uno de los casos de segmentación se realizó el entrenamiento en el dominio del tiempo y de la frecuencia con la aplicación de Regression Learner de Matlab y se seleccionó el modelo y caso de segmentación aquel que obtuvo el menor valor RMSE.

Cabe recalcar que se realizó un modelo donde se incluyen todas las distancias de 3 a 13 metros tanto para el medio ideal como no ideal.


Recorte de ventanas iniciales.

Para la segmentación de la señal se aplicó el comando buffer de Matlab, el mismo que al realizar este procedimiento genera ventanas con valores nulos para poder completar la división de ventanas en el rango especificado (Figura 17).

En esta figura se puede observar el proceso de división de dos ventanas, la primera ventana (color rojo) genera valores iniciales nulos con respecto a la segunda ventana (color azul) por lo tanto es necesario descartar estas muestras de la base de datos para evitar errores en el entrenamiento.

Figura 17

Segmentación de la señal con el comando buffer




Cálculo de los ángulos teóricos

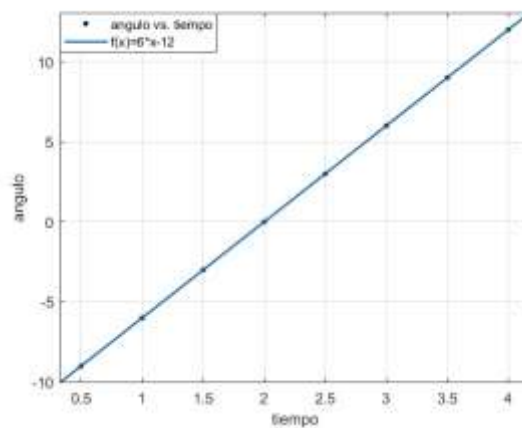
El conjunto de datos predictores corresponde a los ángulos teóricos de arriba, estos se encuentran condicionados por el número de ventanas y solapamiento que se aplique, ya que para el entrenamiento se requiere que tanto los datos de las variables como los predictores sean de las mismas dimensiones. Por lo tanto, con los ángulos teóricos obtenidos para los algoritmos de beamforming se encuentra una función mediante ajuste de curvas que se aproxime a las condiciones de los ángulos calculados, esto se lo realizó con la aplicación de Curve Fitter de Matlab. En la Figura 18 se observa el ajuste de curvas realizado con series de Fourier a una distancia de 3 metros y en la Figura 19 se observa un ajuste de tipo polinómica realizado a la distancia de 9 metros en el medio controlado, en ambos casos se logra un R-square de 0.99. Con las ecuaciones obtenidas se genera el conjunto de datos de los ángulos de arriba tanto para la piscina como para el lago.

Figura 18

Ajuste de curvas realizada con series de Fourier a la distancia de 3 metros (piscina)

**Figura 19**

Ajuste de curvas polinómica realizada a la distancia de 9 metros (piscina)




Etiquetado de datos

Con la base de datos definida se etiqueta las variables y los datos predictores como se muestra en la Figura 20, donde los audios procesados por los hidrófonos corresponden a las variables y se colocan en una matriz de forma ordenada como se visualiza en la figura mencionada y los ángulos teóricos corresponden a los datos predictores colocándolos al final de la matriz. Para el caso del dominio

del tiempo una vez dividida por ventanas y el solapamiento respectivo se pasa directamente a etiquetar los datos y continuar con el entrenamiento. Para el caso del dominio de la frecuencia, se divide por ventanas con el porcentaje de solapamiento, se encuentra la transformada de Fourier de la matriz de las señales de audio generadas, se toma la primera parte de la simetría generada por la transformada de Fourier, se calcula la magnitud, para finalmente etiquetar y entrenar los datos.

Figura 20

Etiqueta de datos para el entrenamiento de machine learning



Entrenamiento y validación de datos

Como ya se mencionó anteriormente el entrenamiento se realizó con la aplicación de Regression Learner de Matlab y el método de validación que se eligió es la validación cruzada k-fold con un valor de k igual a 5. Los modelos de entrenamiento utilizados son los siguientes:

- Modelos de Regresión Lineal
- Árboles de regresión
- Máquinas vectoriales de soporte
- Regresión del proceso Gaussiano
- Regresión de aproximación de Kernel
- Conjunto de árboles
- Redes Neuronales

Capítulo IV: Resultados y Discusión

En el presente capítulo se presenta los resultados obtenidos durante los análisis realizados a los algoritmos propuestos. En la primera parte se aborda los resultados de beamforming, luego el análisis para machine learning tanto para el dominio del tiempo como de la frecuencia y finalmente se realiza una comparación de rendimiento entre las técnicas utilizadas para la detección del ángulo de arribo.

Resultados de beamforming.

Para los resultados de beamforming primero se analiza las pruebas realizadas en el medio controlado donde se verifica las métricas obtenidas en lo que respecta a RMSE, MAE y R-Squared, luego se estudia los resultados en el medio controlado analizando de igual forma las métricas mencionadas, para finalmente comparar el rendimiento de los algoritmos de Music y Espirit en ambos escenarios.


Medio controlado.

Las pruebas de los algoritmos de beamforming en este caso el Music y Espirit se aplicaron para cada una de las distancias propuestas de forma independiente como se visualiza en la Figura 21. Se obtuvo el valor medio de todas las distancias obteniendo para Music un RMSE de 8,20, MAE de 6,47 y R-Squared de 0,24. Para el Espirit un valor RMSE de 8,25, MAE de 6,72 y R-Squared de 0,23.

A partir de los 7 metros se pudo observar que los valores de RMSE para ambos algoritmos son iguales esto se debe al ancho de haz del arreglo de hidrófonos que de acuerdo a la ecuación 1 es de $\pm 15^\circ$ y en la práctica es de $\pm 20^\circ$ lo cual el dron al colocarse en este rango de ángulos los algoritmos detectan el valor de 0° , por lo tanto para que este ancho de haz tenga mayor resolución se debe aumentar el número de hidrófonos como se evidencia en la Figura 3 que al aumentar a 16 sensores en el caso de estudio se obtendría un ancho de haz de $\pm 3,6^\circ$.

Figura 21

Pruebas de los algoritmos Music y Espirit en el campo ideal (piscina)



Medio no controlado

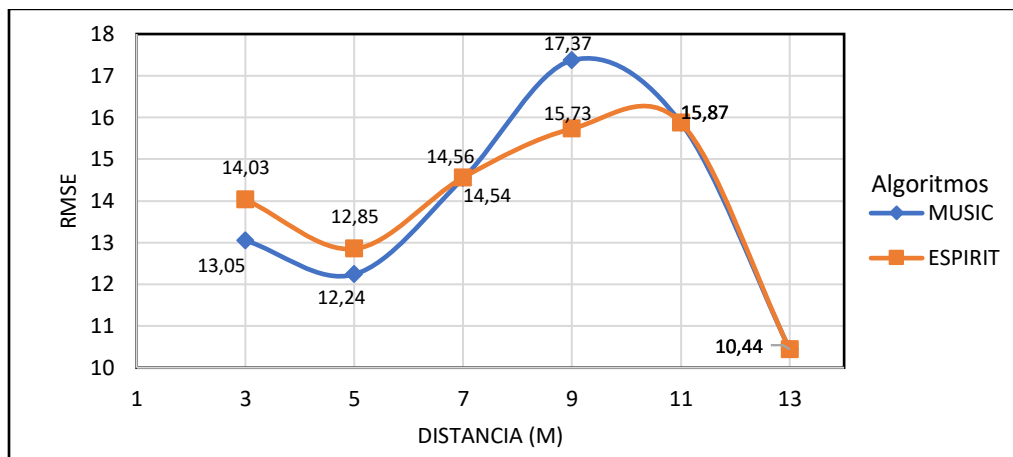
Los resultados obtenidos utilizando los algoritmos de beamforming en el lago se visualizan en la Figura 22. De igual manera que en la piscina se obtiene los errores medios de todas las distancias, alcanzando para el algoritmo Music un valor de RMSE de 13.92, un MAE de 11 y R-Squared de 0.32. Para el Espirit un valor de RMSE de 13.91, MAE de 11.29 y R-Squared de 0.33. Los valores RMSE a partir de la distancia de 11 metros son iguales y esto se debe al ancho de haz explicado en el apartado de la piscina que en este caso el valor práctico encontrado fue de $\pm 30^\circ$.

Con los resultados obtenidos se evidencia que para el algoritmo de Music existe una pérdida de rendimiento del 69,8% y para el Espirit del 68,6% al trabajar en lago con respecto a la piscina, esto se debe a que la región de incidencia del sonido con respecto al arreglo lineal aumenta, provocando mayor porcentaje de error en la detección del dron.

En lo que respecta a la longitud de ventana para la detección de ángulos se estableció en la práctica que la ventana con la que se detectó con mayor frecuencia los ángulos de arriba fue de 4ms.

Figura 22

Pruebas de los algoritmos Music y Espirit en el campo no ideal (lago)



Resultados de machine learning

Medio controlado

Resultados en el dominio del tiempo.

En el entrenamiento de machine learning en el dominio del tiempo realizado en la piscina, los resultados óptimos de RMSE en cada una de las longitudes de las ventanas entrenadas se obtuvo para el solapamiento del 90% como se puede evidenciar en la Figura 23. Para este caso se utilizó el modelo de Regresión de Procesos Gaussianos con el proceso Cuadrático Rotacional. Para la longitud de ventana de 100 ms se obtuvo un RMSE de 13.08, MAE de 9.88 y R-Squared de 0.04. Para 60 ms un valor de RMSE de 11.74, MAE de 8.88 y R-Squared de 0.23. Para 20 ms se obtuvo un valor de RMSE 7.84, MAE de 5.65 y R-Squared de 0.69, siendo este el mejor resultado obtenido. El resultado del entrenamiento realizado de este caso se observa en la Figura 24 donde se grafica los valores verdaderos versus los predichos y en donde se determina que no existe un ajuste adecuado del modelo por los errores altos que presenta. El tiempo medio de entrenamiento de machine learning en el dominio del tiempo fue de 9 horas.

Figura 23

Prueba de machine learning en el tiempo (piscina)

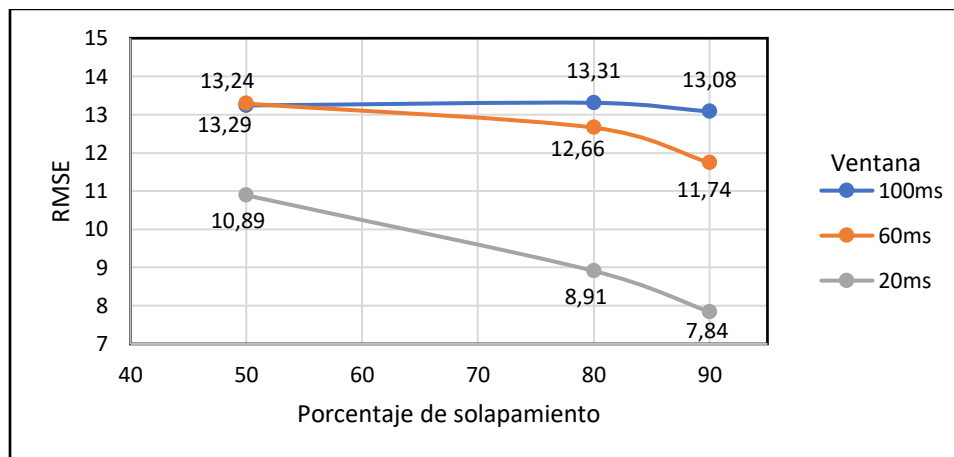
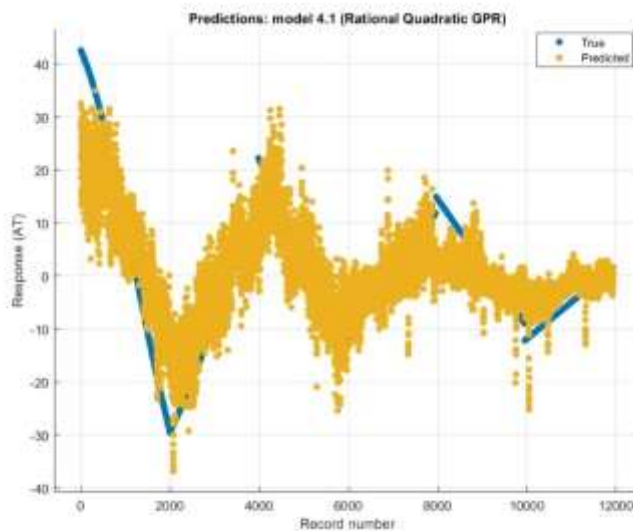


Figura 24

Entrenamiento en el tiempo con una ventana de 20 ms y 90% de solapamiento (piscina)



Resultados en el dominio de la frecuencia

El entrenamiento realizado en el dominio de la frecuencia utilizando machine learning se puede visualizar en la Figura 25 donde los resultados fueron los siguientes. Para el 50% de solapamiento el

mejor resultado obtenido fue para la longitud de la ventana de 60 ms con un RMSE de 6.73, un MAE de 4.9 y R-Squared de 0.75 utilizando el modelo de la red neuronal estrecha. Para el solapamiento del 80% el resultado óptimo fue para la longitud de ventana de 100 ms con un RMSE de 4.08, MAE de 2.85, R-Squared de 0.91 con el modelo de Bicapa de Redes Neuronales. Finalmente, para el porcentaje de solapamiento del 90% se obtienen los siguientes resultados. Para una longitud de ventana de 20 ms un valor de RMSE de 4.32, MAE de 2.69 y R-Squared de 0.90 con el modelo de Tricapa de Redes Neuronales. Para 60 ms el resultado obtenido fue un RMSE de 3.2, MAE de 2.17 y R-Squared de 0.94 con el modelo de Bicapa de Redes Neuronales. Para 100 ms se alcanzó un valor de RMSE de 2.92, un MAE de 1.99 y un R-Squared de 0.95 con el modelo de Bicapa de Redes Neuronales, siendo este último el que se obtuvo mejores resultados, en la Figura 26 se observa el resultado de este entrenamiento donde se grafica los valores verdaderos con los predichos determinando así que el ajuste del modelo es adecuado y óptimo. El tiempo medio de entrenamiento en el dominio de la frecuencia para todos los modelos fue de 1 hora.

Figura 25

Prueba de machine learning en la frecuencia (piscina)


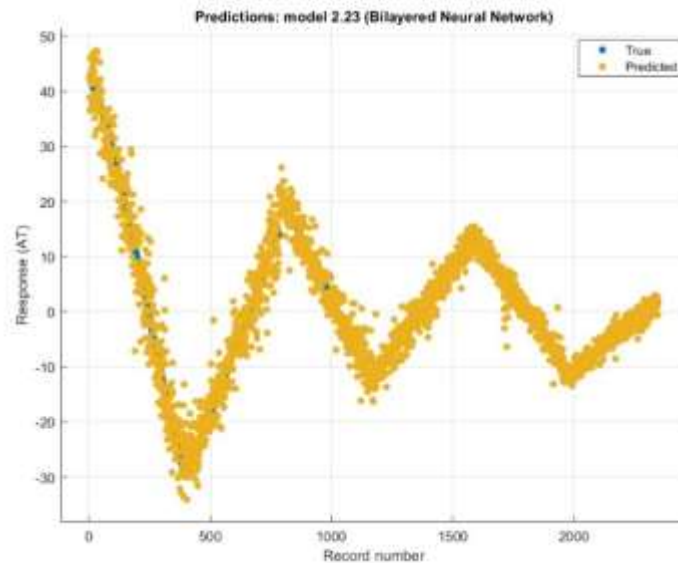


Figura 26

Entrenamiento en el dominio de la frecuencia para una ventana de 100 ms y 90% de solapamiento (piscina)



Con los resultados obtenidos se puede establecer que el rendimiento de los modelos de machine learning cuando se trabaja en el dominio de la frecuencia con respecto al tiempo mejora en un 62,8%, razón por la cual en el siguiente apartado donde se analiza los resultados en el lago sólo se verifica los resultados en el dominio de la frecuencia.

Medio no controlado

Resultados en el dominio de la frecuencia

El entrenamiento realizado en el dominio de la frecuencia utilizando machine learning se puede visualizar en la Figura 27. Los resultados fueron los siguientes: para el solapamiento del 50% el mejor resultado se obtuvo para una longitud de ventana de 100 ms con un RMSE de 5.61, MAE de 4.38 y R-Squared de 0.87 utilizando el modelo de Regresión de Procesos Gaussianos con el proceso Cuadrático Rotacional. Para el solapamiento del 80% el resultado óptimo fue para la longitud de ventana de 100 ms

con un RMSE de 3.3, MAE de 2.5 y R-Squared de 0.96 utilizando el modelo de Regresión de Procesos Gaussianos con el proceso Cuadrático Rotacional.

Para el solapamiento del 90% para una ventana de 20 ms se obtuvo un valor de RMSE de 3.03, un MAE de 2.27 y R-Squared de 0.96 con el modelo de Bicapa de Redes Neuronales. Para 60 ms un valor de RMSE de 2.35, un MAE de 1.72 y R-Squared de 0.98 con el modelo de Tricapa de Redes Neuronales. Para 100 ms se obtuvo un valor RMSE de 2.32, un MAE de 1.66 y R-Squared de 0.98 con el modelo de Tricapa de Redes Neuronales, siendo este el resultado con el menor porcentaje de errores.

El resultado del entrenamiento se lo visualiza en la Figura 28, donde se grafica los valores verdaderos vs los predichos y en este caso el ajuste del modelo es óptimo. Todos los modelos mencionados se entrenaron en una media de 3 horas.

Figura 27

Pruebas de machine learning en la frecuencia (lago)


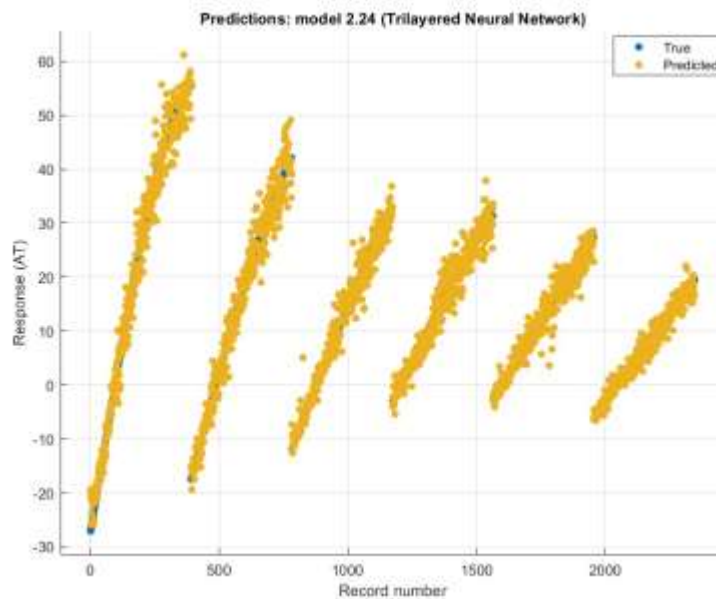


Figura 28

Entrenamiento en el dominio de la frecuencia para una ventana de 100 ms y 90% de solapamiento (lago)



Al comparar los resultados obtenidos en el lago con respecto a la piscina en el dominio de la frecuencia se puede establecer que el rendimiento mejora en un 20,5%, esto se debe a que en el escenario no controlado se tiene un mayor número de datos ya que se toma una muestra de audio mayor con respecto a la piscina provocando que el ajuste de los modelos sea eficiente.

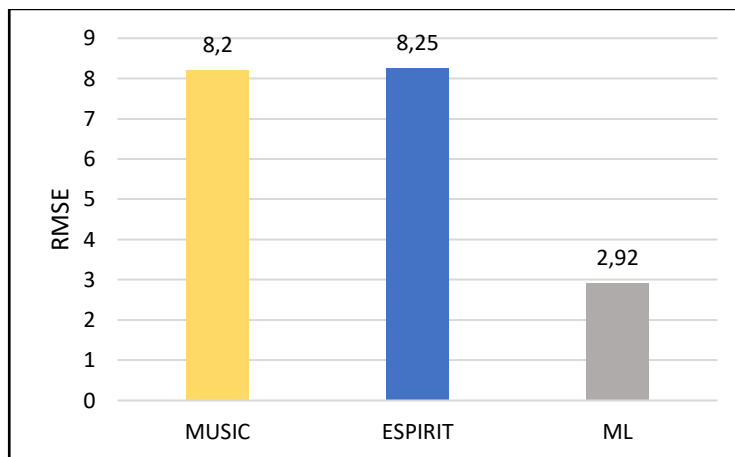
Comparación de los algoritmos beamforming y machine learning.

Medio controlado

Una vez obtenidos los resultados de RMSE de las técnicas utilizadas para la detección del dron en la piscina se realiza una comparación de este valor como se muestra en la Figura 29, estableciendo que machine learning trabajando las señales de audio en el dominio de la frecuencia mejora su rendimiento con respecto a los algoritmos de beamforming en un 64,5%.

Figura 29

Comparación de valores RMSE entre los algoritmos de beamforming y machine learning (ML) (piscina)




Medio no controlado

Los resultados de comparar los algoritmos de detección del ángulo de arribo en el lago se muestran en la Figura 30, por consiguiente, los modelos de machine learning en el dominio de la frecuencia mejora su rendimiento con respecto a beamforming en un 83,33%.

Figura 30

Comparación de valores RMSE entre los algoritmos de beamforming y machine learning (ML) (lago)



Capítulo VI: Conclusiones y Trabajos Futuros

Conclusiones

En el presente trabajo de investigación se diseñó e implementó un arreglo lineal de hidrófonos para la adquisición de las señales acústicas emitidas por el dron subacuático tanto para el medio controlado, así como también para el no controlado, identificando que las características y el comportamiento del arreglo lineal permitieron establecer que los hidrófonos deben permanecer fijos en su posición para evitar la deformación del lóbulo principal y la detección errónea de la posición del dron.

Para determinar el tamaño de datos necesarios que permitan un adecuado funcionamiento computacional y que posea las características necesarias para evaluar los algoritmos de beamforming y machine learning se generó una base de datos de las señales acústicas obtenidas en los dos escenarios de prueba.

Se realizó la programación de los algoritmos de beamforming mediante el uso del software Matlab donde se determinó la posición del dron mediante el ángulo de arribo en los escenarios de prueba, evidenciando que los algoritmos Music y Spirit no son eficientes para localizar el dron tanto en la piscina como en el lago ya que de acuerdo con los resultados obtenidos presentan errores significativos y su rendimiento decae conforme crece la región de incidencia de las señales de audio hacia el arreglo lineal uniforme de hidrófonos.

Se efectuó el entrenamiento de los modelos de machine learning mediante la aplicación Regression Learner de Matlab en la cual se ejecutaron pruebas tanto en el dominio del tiempo como de la frecuencia obteniendo en este último el menor porcentaje de errores y un rendimiento óptimo computacional.

En las pruebas realizadas de machine learning se pudo establecer que se obtiene mejores resultados cuando el solapamiento de las ventanas es mayor al 80%. En lo que respecta a la longitud de

ventana se obtiene resultados eficientes cuando la ventana es menor o igual a 20 ms para el tiempo y mayor o igual a 60 ms para la frecuencia.

Se comparó el desempeño de los algoritmos utilizados para la presente investigación estableciendo que machine learning mediante la utilización de los modelos de Redes Neuronales posee un rendimiento óptimo y es efectivo en la detección de la posición del dron en los escenarios propuestos.

Trabajos futuros

Los resultados del presente trabajo de investigación demostraron que los algoritmos basados en machine learning en función del dominio de la frecuencia, presentan un alto potencial al momento de predecir el ángulo de posicionamiento del AUV respecto al arreglo de hidrófonos en ambos escenarios. Por lo cual, como siguiente paso se contemplaría la implementación del algoritmo de detección en un dispositivo compacto capaz recolectar los datos, procesarlos y detectar la ubicación del vehículo en tiempo real.

Adicional, una línea de investigación sería el implementar el mismo arreglo lineal en los escenarios propuestos, pero con un mayor número de hidrófonos. Teniendo como objetivo evidenciar si existe o no una mejora respecto a la resolución del lóbulo detector generado por el arreglo.

Como siguiente línea de investigación, se plantearía el diseño y la implementación de diferentes formas de arreglos de hidrófonos para la adquisición de la señal de audio. Debido a que dependiendo la forma ya sea circular, rectangular o esférica, variarán parámetros como la directividad y la resolución espacial, pudiendo acoplarse a nuevos estudios en diversos escenarios.

Referencias

- A. B. Gershman, V. I. (10 de 1995). Experimental results of localization of moving underwater. *IEEE Transactions on Signal Processing*, 43(10), 2249-2257. doi:10.1109/78.469863
- Álvarez Vega, M., Quirós Mora, L., & Cortés Badilla, M. (2020). Inteligencia artificial y aprendizaje automático en medicina. *Revista Medica Sinergia*, e557-e557.
- Arias, A., & Arias, N. (2016). Algoritmo para la detección clasificación y localización de embarcaciones, teniendo en cuenta sus condiciones de operación, estimación de a distancia al receptor y diferentes escenarios de ruido ambiente. Medellín, Colombia: Universidad de San Buena Aventura Medellín.
- B. Wehbe, M. H. (2017). Experimental evaluation of various machine learning regression. *IEEE International Conference on Robotics and Automation (ICRA)*, (págs. 4885-4890). doi:10.1109/ICRA.2017.7989565
- Baquerizo, N. C. (2022). Evaluación de algoritmos de machine learning en la clasificación de imágenes satelitales multiespectrales, caso: Amazonia Peruana. *Ciencia Latina Revista Científica Multidisciplinar*, 4946-4963.
- Bell, J. (2022). *Machine Learning and the City: Applications in Architecture and Urban Design*. WILEY.
- Bennett-Lenane, H. G. (2022). Machine learning methods for prediction of food effects on bioavailability: A comparison of support vector machines and artificial neural networks. *European Journal of Pharmaceutical Sciences*, 168.
- Bustamante, O. (2015). Diseño y construcción de un arreglo lineal de hidrófonos portátil y de bajo costo para el monitoreo de mamíferos marinos. Mexico: Instituto Politécnico Nacional.
- Carlos, B., Lerache, J., & Sattolo, I. (2020). Reconocimiento de emociones a través de expresiones faciales con el empleo de aprendizaje supervisado aplicando regresión logística. *XXVI Congreso*

- Argentino de Ciencias de la Computación (CACIC)* (págs. 491-500). Red de Universidades con Carreras en Informática.
- Carrera, E. V., & Guevara, D. E. (01 de 2023). Passive Positioning of Autonomous Underwater Vehicles. *ResearchGate*, 314-325. doi:10.1007/978-3-031-24971-6_23
- Choi, R. Y.-C. (2020). Introduction to machine learning, neural networks, and deep learning. *Translational Vision Science & Technology*, 14-14.
- D. F. Nsalo Kong, C. S. (08 de 2021). A New Low-Cost Acoustic Beamforming Architecture. *Journal of Marine Science and Engineering*, 9(8), 8. doi:10.3390/jmse9080868
- Díaz, A. (2019). *Aprendizaje por refuerzo para control de sistemas dinámicos*. Santiago de Cali: Universidad Autónoma de Occidente.
- Fischer, J. (03 de 2021). Acoustic localization of a buoyancy driven model using a beamforming hydrophone. *Applied Acoustics*, 174, 107798. doi:10.1016/j.apacoust.2020.107798
- Fouts, J., & Spanias, A. (2008). *Narrowband DOA estimation for antenna array*.
- Fuentes Quintero, J. D. (2019). *Propuesta de la luffa cylindrica como absorbente acústico aplicable a recintos con fenómenos de reverberación*. Bogotá: Universidad La Gran Colombia.
- Gross, F. (2005). *Smart Antennas for Wireless Communications*. The McGraw Hill.
- H. Awada, J. H. (2022). COVID-19 Future Forecasting Using Machine Learning Models. *International Arab Conference on Information Technology (ACIT)* (págs. 1-8). Abu Dhabi, United Arab Emirates: IEEE Xplore.
- Hernández, E. (2010). *Nuevos Algoritmos de Localización, Seguimiento e Identificación de Fuentes en Escenarios con Agrupaciones de Sensores Concentradas y Distribuidas*. Las Palmas de Gran Canaria, España.
- J. Jiang, Z. W. (02 de 2022). Detection of underwater acoustic target using beamforming and. *Applied Acoustics*, 189, 108626. doi:10.1016/j.apacoust.2021.108626

- Jijo, B. T. (2021). Classification based on decision tree algorithm for machine learning. *Journal of Applied Science and Technology Trends*, 20-28.
- Lawrence, L., Austin, F., & Sanders, J. (2011). *Fundamentos de la Acústica*. Mexico: Limusa.
- López Pérez, E. (2021). *Aprendizaje supervisado basado en Procesos Gaussianos*. Valladolid: Universidad de Valladolid.
- Matlab. (2022). bandpass. The MathWorks Inc.
- Maulud, D. &. (2020). A review on linear regression comprehensive in machine learning. *Journal of Applied Science and Technology Trends*, 140-147.
- Ministerio de Defensa. (2018). *Ministerio de Defensa Nacional*. Obtenido de <https://www.defensa.gob.ec/>
- Olmos, B. (2016). Diseño y simulación de un modelo heurístico para determinar la zona de concentración de equipos de usuario usando arreglos de antenas . Escuela Politécnica Nacional .
- Pal, K. &. (2020). Data classification with k-fold cross validation and holdout accuracy estimation methods with 5 different machine learning techniques. *In 2020 fourth international conference on computing methodologies and communication (ICCMC)* (págs. 83-87). Erode, India: IEEE.
- Remiro Gargallo, A. V. (2019). *Técnicas numéricas aplicadas a la propagación de sonido en el medio marino*. Valencia: Universitat Politècnica de València.
- Sánchez, F., García , A., & López, C. (2002). Descripción de un sistema hidrofónico. Aspectos de implementación y algoritmo de conformación de haz.
- Sánchez, M., Madrid, E., Felis, I., & Martinez, R. (2020). *Guía de buenas prácticas para la medición de sonido submarino*. Murcia: Centro Tecnológico Naval y del Mar (CTN).
- Sherman, C., & Butler, J. (2007). *Tranducers and arrays for underwater sound*. EUA: Springer.
- Z. Xu, H. L. (08 de 2020). A Modified Differential Beamforming and Its Application for DOA Estimation. *IEEE Sensors Journal*, 20(16), 8890-8902. doi:10.1109/JSEN.2020.2988025