

Escuela Superior Politécnica del Litoral

Facultad de Ingeniería en Electricidad y Computación

Análisis y Aplicación de Trilateración Basada en Modelos y Redes Neuronales para

Fines Educativos

Proyecto Integrador

Previo la obtención del Título de:

Ingeniero en Telecomunicaciones

Presentado por:

Daniel Alexander Alarcón Mendoza

Steven Sebastián Macías Quezada

Guayaquil - Ecuador

Año: 2023

Dedicatoria

El presente proyecto lo dedico primero a Dios, su amor y misericordia han estado siempre presentes para volverme a levantar. A mi familia, en especial a mi madre que me acompañó y apoyó incondicionalmente durante este viaje. A las personas que han podido enseñarme con paciencia lo necesario para avanzar. A mis hermanos en Cristo, especialmente a los de Spoude, de quienes las palabras de aliento nunca faltaron.

Daniel Alexander Alarcón Mendoza

El presente proyecto lo dedico a mi madre ya que sin su apoyo ni provisión a lo largo de la carrera no hubiera sido posible llegar a estas instancias. Reciba este trabajo como el fruto de su paciencia y abnegación incondicional.

Steven Sebastián Macías Quezada

Agradecimientos

Mi más sincero agradecimiento a Dios, a mis padres y hermanos por darme las fuerzas para perseverar hasta el final.

A mi madre a quien no le pude dar la satisfacción en vida de terminar la carrera, pero que siempre confió en mí y me dio el ánimo necesario para no rendirme.

Gracias a mis hermanos en Cristo, especialmente a mi hermana Euly Carreño que me acompañó y animó en medio de una gran pérdida.

Le agradezco a mi segunda madre, Juana Saá cuya ayuda ha estado presente siempre.

A mis grandes compañeros y a mis profesores, incluyendo a mi tutor Herman Veriñaz por toda su ayuda.

Daniel Alexander Alarcón Mendoza

Agradezco a Dios porque sin él ninguna obra hubiera sido posible.

Agradezco al tutor de este proyecto por su guía en el desarrollo de este trabajo.

Agradezco a PARCON por el préstamo de los módulos que sirvieron para realizar la investigación.

Agradezco a mis padres por su apoyo incondicional y provisión.

Finalmente, agradezco a todos, amigos, compañeros y conocidos por cada palabra de ánimo que me impulsaban a seguir adelante.

Steven Sebastián Macías Quezada

Declaración expresa

“Los derechos de titularidad y explotación, nos corresponde conforme al reglamento de propiedad intelectual de la institución; *Daniel Alarcón* y *Steven Macías* damos nuestro consentimiento para que la ESPOL realice la comunicación pública de la obra por cualquier medio con el fin de promover la consulta, difusión y uso público de la producción intelectual”.

Daniel Alarcón M.

Daniel Alarcón M.

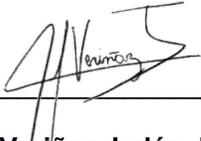
Steven Macías Q.

Steven Macías Q.

Evaluadores

M.Sc. Verónica Soto Vera

Profesora de Materia



Herman Veriñaz Jadán, Ph.D.

Tutor de proyecto

Resumen

El presente trabajo aborda el desarrollo de un sistema de posicionamiento en interiores, utilizando tanto trilateración como redes neuronales. Diseñado principalmente como una herramienta educativa, el sistema aspira a ofrecer una solución precisa y eficiente en el contexto académico. El sistema se basó en la técnica de trilateración, que utiliza las distancias entre un nodo móvil y tres nodos ancla para estimar la posición del nodo móvil. En este caso, las distancias se midieron mediante módulos Ultra Wide Band (UWB) debido a su precisión en este tipo de aplicaciones. La estimación de la posición del nodo móvil se realizó utilizando tanto un método basado en modelos geométricos como uno que emplea redes neuronales. Los resultados de las pruebas del sistema mostraron que la red neuronal logra una precisión superior a la técnica tradicional de trilateración. La media de los errores de la red neuronal es de 0.04 m, mientras que la media de los errores de la técnica tradicional es de 0.25 m. Los resultados del trabajo corroboran que la trilateración basada en redes neuronales es una técnica prometedora para el desarrollo de sistemas de posicionamiento en interiores. El sistema desarrollado es una contribución académica valiosa para el estudio de esta técnica.

Palabras Clave: trilateración, UWB, redes neuronales, posicionamiento, nodos.

Abstract

This work addresses the development of an indoor positioning system that utilizes both trilateration and neural networks. Primarily designed as an educational tool, the system aims to provide an accurate and efficient solution in an academic setting. The system relied on the trilateration technique, which uses the distances between a mobile node and three anchor nodes to estimate the position of the mobile node. The distances were measured using Ultra Wide Band (UWB) modules due to their precision for such applications. The estimation of the position of the mobile node was achieved using both a method grounded in geometric models and one employing neural networks. The experiments showed that the neural network achieves greater accuracy than the traditional trilateration method. The average error of the neural network is 0.04 m, while the average error of the traditional method is 0.25 m. These results affirm that neural network-based trilateration is an attractive method for developing indoor positioning systems. The developed system represents a valuable academic contribution to the study of this Technique.

Keywords: Trilateration, UWB, Neural Networks, Positioning, Nodes.

Índice General

Resumen	I
Abstract.....	II
Índice General.....	III
Abreviaturas.....	VII
Simbología.....	VIII
Índice de Figuras	IX
Índice de tablas.....	IX
Capítulo 1	1
1. Introducción	2
1.1 Generalidades	2
1.2 Descripción del problema.....	3
1.3 Justificación del problema.....	3
1.4 Objetivos.....	4
1.4.1 Objetivo general.....	4
1.4.2 Objetivos específicos.....	4
1.5 Marco teórico.....	5
1.5.1 Trilateración.....	5
1.5.2 Fundamentos de redes neuronales.....	7
1.5.2.1 Modelado no lineal.....	9
1.5.2.2 Mejora de la robustez.....	9
1.5.2.3 Fusión de datos.....	9
1.5.2.4 Optimización de algoritmos.....	9

1.5.3	Alternativas de protocolos de posicionamiento	9
1.5.3.1	Características de Bluetooth.....	9
1.5.3.2	Características de Wi-Fi.	10
1.5.3.3	Características de UWB.	10
1.5.4	Alternativas de métodos de estimación de distancia	11
1.5.4.1	Received Signal Strength Indicator (RSSI).	11
1.5.4.2	Time Of Flight (TOF).....	11
	Capítulo 2	12
2.	Metodología.....	13
2.1	Descripción del escenario	13
2.2	Diseño del sistema de localización	13
2.2.1	Descripción general del sistema de localización propuesto.....	13
2.2.1.1	Implementación del sistema de trilateración basado en redes neuronales....	14
2.2.1.2	Adquisición de datos (Sensores UWB).	14
2.2.1.3	Preprocesamiento de datos y limpieza de ruido.....	15
2.2.1.4	Entrenamiento de la red neuronal.....	15
2.2.1.5	Validación y ajuste de la red neuronal.	15
2.2.1.6	Inferencia de ubicación en tiempo real.....	15
2.2.1.7	Visualización y entrega de resultados.....	15
2.2.2	Diagrama de bloques del sistema de localización	15
2.2.3	Diagrama de flujo del proceso de localización	17
2.3	Comparación de tecnologías de comunicación para posicionamiento.....	20
2.3.1	Características de Bluetooth, Wi-Fi y UWB.....	20

2.3.2	Elección y beneficios de UWB para el proyecto	22
2.4	Recolección y preprocesamiento de datos.....	23
2.4.1	Descripción recolección de datos.....	23
2.5	Arquitectura, entrenamiento y evaluación de la red neuronal.....	25
2.5.1	Arquitectura de la red neuronal.....	25
2.5.2	Implementación y verificación de la red neuronal.....	26
2.5.2.1	Inicialización de Pesos.	26
2.5.2.2	Función de Pérdida y Optimizador.....	26
2.5.2.3	Entrenamiento del Modelo.....	27
2.5.3	Entrenamiento y comprobación de la red neuronal	27
2.5.3.1	Métricas que se utilizarán para evaluar la precisión de la localización y la eficacia.....	28
2.6	Consideraciones prácticas	28
2.6.1	Desafíos	28
2.6.2	Limitaciones	28
2.7	Consideraciones éticas.....	29
	Capítulo 3.....	30
3.	Resultados y análisis	31
3.1	Patrón de Radiación	31
3.2	Curvas de entrenamiento.....	36
3.3	Predicciones de la red neuronal.....	38
3.4	Histogramas	40
3.5	Desempeño	42

Capítulo 4	44
4. Conclusiones y recomendaciones	45
4.1 Conclusiones	45
4.2 Recomendaciones	45
Referencias	46

Abreviaturas

ESPOL	Escuela Superior Politécnica del Litoral
LBS	Location Based Services
UWB	Ultra Wide Band
MSE	Mean Squared Error
MAE	Mean Absolute Error
RTT	Round Trip Time
TOA	Time Of Arrival
TOF	Time Of Flight
RSSI	Received Signal Strength Indicator
GPS	Global Positioning System
GLONASS	Global'naya Navigatsionnaya Sputnikovaya Sistema
FNN	Feedforward Neural Network
ReLU	Rectified Linear Unit
CSV	Comma-Separated Values

Simbología

μA	Microamperios
mA	Miliamperios
m	Metro
m^2	Metros cuadrados
cm	Centímetro
V	Voltios

Índice de Figuras

Figura 1.1 Trilateración para determinar la posición de un objeto	6
Figura 1.2 Estructura de una red neuronal	8
Figura 2.1 Descripción general del proyecto	14
Figura 2.2 Diagrama de bloques del sistema de localización	16
Figura 2.3 Diagrama de flujo del proceso de localización.....	18
Figura 2.4 Representación del área en la que se realizaron las experimentaciones	24
Figura 2.5 Estructura de la red neuronal	26
Figura 3.1 Plano en Azimuth y elevación de la antena UWB.....	32
Figura 3.2 Gráfica de distancias teóricas vs experimentales con UWB del ancla 1	33
Figura 3.3 Gráfica de distancias teóricas vs experimentales con UWB del ancla 2	34
Figura 3.4 Gráfica de distancias teóricas vs experimentales con UWB del ancla 3	35
Figura 3.5 Curvas de pérdida en el transcurso del entrenamiento de la red neuronal	36
Figura 3.6 Curva de testing	37
Figura 3.7 Representación de valores reales vs valores predichos por la red neuronal	38
Figura 3.8 Representación de predicciones enmagnitud de error.....	39
Figura 3.9 Histograma de la magnitud de errores	41

Índice de tablas

Tabla 2.1 Características cualitativas de las tecnologías de posicionamiento	20
Tabla 2.2 Características cualitativas de los métodos de estimación de distancia	21
Tabla 3.1 Comparación de la media de la magnitud del vector de error y la desviación estándar del método clásico y del método con la red neuronal	42
Tabla 3.2 Comparación del Error Cuadrático Medio MSE y el Error Absoluto Medio MAE de ambos métodos	43

Capítulo 1

1. Introducción

1.1 Generalidades

A lo largo de la historia se han utilizado diversas técnicas para determinar las coordenadas de un objeto y han surgido avances significativos en la determinación de la posición. Ya en el siglo XVIII, se inventó un cronómetro marino de alta precisión que permitía a los navegantes determinar la longitud utilizando el cambio del tiempo entre su posición actual y la tierra. Además, se desarrollaron brújulas magnéticas para determinar la dirección en términos de longitud y latitud. Posteriormente, en el siglo XX, se utilizaron las señales de radio para estimar la posición de barcos, aviones y tropas militares a distancias lejanas. (Bertoli, 2012)

Sin embargo, fue a partir de los años 90 cuando se introdujeron los Sistemas de Posicionamiento Global (GPS), los cuales permitieron la triangulación de la posición mediante una red de satélites. A medida que avanzaba el siglo XXI, los teléfonos inteligentes incorporaron receptores GPS, y la aparición del iPhone marcó un hito al permitir la instalación de aplicaciones de terceros que aprovechaban el receptor GPS. (Bertoli, 2012)

Actualmente, se han desarrollado múltiples servicios basados en localización (Location Based Services, LBS). Debido a esto, surge la necesidad de comparar técnicas tradicionales de localización con enfoques más novedosos que involucren la inteligencia artificial, como lo es el uso de redes neuronales.

En este proyecto integrador, se pretende desarrollar un sistema de sensores que permita realizar esta comparación entre una técnica tradicional y una nueva técnica basada en redes neuronales para determinar la posición de un nodo con mayor precisión. Se evaluarán parámetros trascendentes como la precisión de localización (Villalba, 2018).

A lo largo de este documento, se presentan los resultados de la investigación, implementación de un sistema de sensores, las técnicas empleadas y análisis comparativo. Además, se discuten las implicaciones y las posibles aplicaciones de estos avances en el ámbito de los servicios basados en localización.

1.2 Descripción del problema

Las técnicas para localización en espacios interiores son fundamentales en escenarios donde otros métodos clásicos, como Global Positioning System (GPS), Global'naya Navigatsionnaya Sputnikovaya Sistema (GLONASS) y otros similares, no funcionan eficazmente. Específicamente, la trilateración es una técnica de localización útil también en espacios interiores y emplea mediciones de la señal recibida en tres puntos de referencia distintos para determinar la posición de un objeto. Sin embargo, en varias universidades de Ecuador, estas técnicas se enseñan principalmente de manera teórica, o se utilizan algoritmos de localización obsoletos que no reflejan su potencial real. En este proyecto, el problema a resolver radica en la falta de disponibilidad de recursos y oportunidades de experimentación en escenarios controlados que permitan a los futuros profesionales adquirir experiencia práctica con técnicas modernas de posicionamiento. Estas técnicas son más eficientes ya que proporcionan una mayor precisión y velocidad al localizar un objeto. Aunque es cierto que las técnicas clásicas enseñadas en el presente son fundamentales para entender las bases de la localización y el posicionamiento, las técnicas avanzadas de análisis de datos complementan y enriquecen este conocimiento.

1.3 Justificación del problema

Es importante realizar este trabajo para incorporar técnicas modernas de posicionamiento en el currículum de las universidades. Esto permitirá que los estudiantes se mantengan a la vanguardia. Si no se adoptan estas técnicas modernas, los futuros ingenieros podrían enfrentar dificultades para innovar y competir en un campo tecnológico que busca constantemente optimizar las soluciones proporcionadas a la sociedad. La falta de recursos didácticos que faciliten la experimentación de la trilateración con técnicas modernas puede limitar la formación integral de los estudiantes. Esta limitación podría dificultar su capacidad para implementar sistemas de posicionamiento eficientes que aumentan la precisión en la estimación de la distancia de un objeto específico. Las técnicas de machine learning han logrado resultados de vanguardia en diversas áreas, incluyendo el

procesamiento de imágenes, voz y video, entre otras. De manera específica, estas técnicas también pueden aplicarse a la trilateración para mejorar la precisión en tiempo real del posicionamiento de nodos e incrementar la velocidad, especialmente cuando se manejan grandes cantidades de datos. Machine learning impacta todos los campos donde la tecnología está presente, por lo tanto, es crucial que los estudiantes de ingeniería en general tengan conocimiento de estas técnicas de redes neuronales.

1.4 Objetivos

1.4.1 Objetivo general

Implementar un sistema de posicionamiento en un ambiente de interiores para la experimentación de la trilateración usando redes neuronales y técnicas tradicionales, que sirva como un recurso didáctico para el aprendizaje práctico y evaluaciones técnicas en el ámbito académico.

1.4.2 Objetivos específicos

1. Estudiar y profundizar en el conocimiento de los métodos modernos de trilateración, las redes neuronales, así como en los fundamentos esenciales para la implementación del sistema de posicionamiento.
2. Desarrollar la red neuronal artificial capaz de calcular la posición de un móvil a partir de las distancias medidas por los módulos Ultra Wide Band (UWB).
3. Implementar un sistema de sensores y nodos para la aplicación y experimentación de las técnicas de trilateración en condiciones controladas.
4. Comparar y contrastar las técnicas de posicionamiento de trilateración basadas en redes neuronales con técnicas clásicas.

1.5 Marco teórico

1.5.1 Trilateración

La trilateración es una técnica que utiliza principios de geometría para precisar la posición de un objeto sabiendo su distancia respecto a tres puntos fijos de referencia. Es utilizada en los sistemas GPS, en los cuales, para determinar una posición, se miden distancias entre tres transmisores distintos y un receptor específico. Como ejemplo, se muestra en la Figura 1.1 un plano bidimensional simple, en el que están tres transmisores representados por satélites, todos ellos en posiciones conocidas en el espacio. Cada transmisor transmite una señal para que algún receptor GPS la recoja con una hora y distancia específicas; entonces, el primer transmisor transmite una señal que eventualmente llega a al receptor, no se sabe el ángulo, pero sí la distancia que es R_1 . Esta distancia forma un círculo igual en todas las direcciones, indicando que la posición del receptor podría estar en cualquier parte de este círculo de este radio específico.

Luego instantáneamente, el segundo transmisor emite una segunda señal a una distancia R_2 por igual en todas las direcciones hasta que llega al receptor. Entonces, el receptor podría estar en cualquier parte de ese círculo, pero esta vez, se tienen dos distancias conocidas de dos transmisores. Con dos señales transmitidas, se crean dos puntos de intersección entre los dos círculos, siendo uno de ellos la posición precisa del receptor.

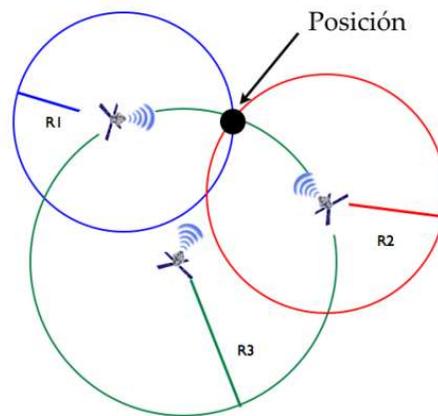
Luego interviene un tercer transmisor, que también transmite una señal en todas las direcciones formando un tercer círculo a una distancia R_3 y, que es donde se cruzan los tres círculos se posiciona el receptor.

Usando tres distancias, la trilateración puede señalar una ubicación precisa. Cada satélite está en el centro de una esfera y donde todos se cruzan es la posición del receptor GPS. A medida que se mueve la posición del receptor GPS, el radio de cada círculo (distancia) también cambiará.

En la realidad, los satélites GPS transmiten señales como una esfera. Cada satélite está en el centro de una esfera. Donde todas las esferas se cruzan determina la posición del receptor.

Figura 1.1

Trilateración para determinar la posición de un objeto



Nota. La Figura muestra la determinación de la posición de un objeto en un espacio abierto, utilizando como técnica la trilateración. Tomado de *Geolocalización en el Espacio para la Gestión de Inventario* (p.14), por M. Fernández, 2019, Universidad de Cantabria (Fernández, 2019).

En general así funciona la trilateración, tanto en espacios interiores como exteriores. Sin embargo, es importante identificar el caso que se requiere implementar. Los diversos sistemas de posicionamiento en exteriores no son suficientemente precisos para determinar la posición de un punto en espacios interiores. Esto se debe a las características intrínsecas de estos ambientes, como paredes, personas, muros y otros múltiples obstáculos que degradan las señales, ocasionando errores relevantes en los cálculos para determinar la posición de un punto. La trilateración puede ser aplicada teniendo tres posiciones cardinales de tres transmisores con respecto a un receptor.

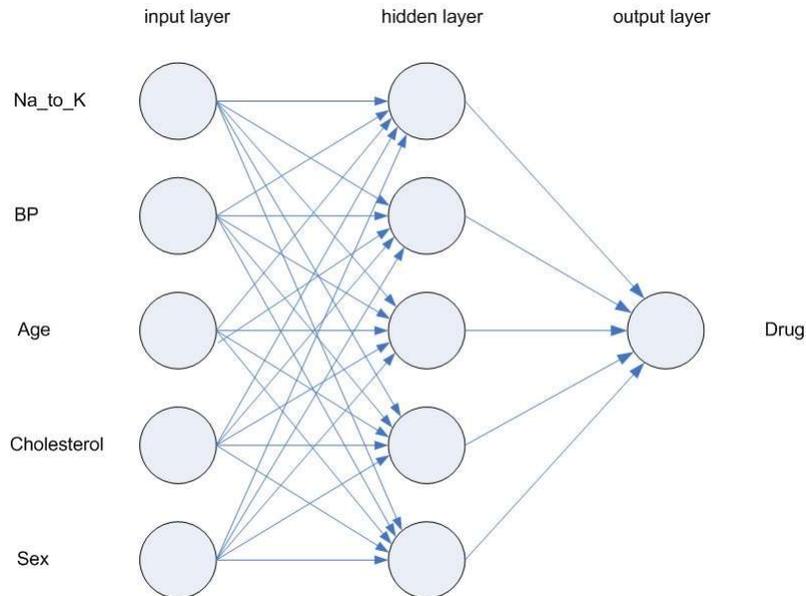
Los transmisores y el receptor tienen relojes sincronizados y transmiten constantemente dos piezas de información: su propia ubicación y la hora actual del reloj. Esta información se transmite a través del espacio a la velocidad de la luz utilizando ondas electromagnéticas. Al multiplicar el tiempo por la velocidad de la luz, el receptor puede calcular la distancia a cada transmisor.

1.5.2 Fundamentos de redes neuronales

Las redes neuronales son modelos matemáticos, específicamente funciones paramétricas, que están inspiradas en la estructura y funcionamiento del sistema nervioso humano. Las unidades fundamentales son las neuronas, las cuales suelen organizarse en capas. Una red neuronal es un modelo que imita la forma en que el cerebro humano procesa información. Trabaja mediante la interconexión de numerosas unidades de procesamiento, las cuales son versiones abstractas de las neuronas. Estas unidades de procesamiento se estructuran en capas.

Una red neuronal típica consta de tres partes principales: una capa de entrada, que contiene unidades que representan los campos de entrada, una o varias capas ocultas, y una capa de salida que produce resultados para los datos de salida deseados. Estas unidades se comunican a través de conexiones con ponderaciones ajustables. Los datos de entrada se introducen en la primera capa, y los valores se transmiten de neurona a neurona en capas sucesivas.

El aprendizaje de la red neuronal implica la evaluación de registros individuales, la generación de predicciones para cada uno de ellos y la adaptación de las ponderaciones cuando se produce una predicción incorrecta. Este proceso se repite múltiples veces, lo que permite que la red mejore sus predicciones gradualmente hasta que cumpla con uno o varios criterios de detención. (IBM, s.f.).

Figura 1.2*Estructura de una red neuronal*

Nota. La Figura muestra las capas de una red neuronal. Los datos de entrada se le proporcionan a la primera capa de la red. La capa oculta puede contener una o varias capas de neuronas las cuales contiene una función que finalmente envían algún resultado a la capa de salida. Tomado de *IBM Documentation*. (IBM, s.f.)

Al principio, todas las ponderaciones son asignadas aleatoriamente y las respuestas de la red pueden ser incoherentes. La red aprende a través del entrenamiento, donde se le presentan constantemente ejemplos con resultados conocidos, y las respuestas de la red se comparan con esos resultados. La información obtenida de esta comparación se retropropaga a través de la red, ajustando gradualmente las ponderaciones. A medida que avanza el entrenamiento, la red se vuelve cada vez más precisa en la reproducción de los resultados conocidos. Una vez que la red ha sido entrenada, se puede aplicar a casos futuros donde el resultado es desconocido (IBM, s.f.).

Las redes neuronales pueden ser utilizadas para mejorar o complementar los métodos tradicionales de triateración de diversas maneras como se indican a continuación:

1.5.2.1 Modelado no lineal. Los métodos tradicionales de trilateración suelen implicar la resolución de un sistema de ecuaciones lineales simple que involucra las distancias medidas y las coordenadas de posición de los nodos. Sin embargo, en entornos complejos esto puede no ser válido. Las redes neuronales pueden modelar relaciones no lineales y capturar mejor las sutilezas de los datos de trilateración.

1.5.2.2 Mejora de la robustez. Las redes neuronales pueden ayudar a lidiar con desafíos como el ruido, las obstrucciones o las mediciones inconsistentes en los datos de trilateración. Al aprender a partir de una variedad de ejemplos, las redes neuronales pueden adaptarse y proporcionar estimaciones más robustas en condiciones adversas.

1.5.2.3 Fusión de datos. Las redes neuronales pueden integrar datos de múltiples fuentes, como señales de GPS, Wi-Fi o Bluetooth, para mejorar la precisión y confiabilidad de las estimaciones de posición. Al combinar diferentes fuentes de información, las redes neuronales pueden proporcionar resultados más precisos y consistentes.

1.5.2.4 Optimización de algoritmos. Las redes neuronales también pueden utilizarse para optimizar los algoritmos de trilateración existentes. Al aprender de los datos de entrenamiento, las redes neuronales pueden descubrir configuraciones óptimas de parámetros o mejorar la eficiencia computacional de los algoritmos, lo que lleva a un mejor rendimiento en tiempo real.

1.5.3 Alternativas de protocolos de posicionamiento

1.5.3.1 Características de Bluetooth. Bluetooth Low Energy permite un posicionamiento continuo sin agotar rápidamente la batería del dispositivo. Está ampliamente disponible en dispositivos móviles, computadoras y otros dispositivos electrónicos, lo que facilita la implementación de soluciones de posicionamiento basadas en

Bluetooth. Además, es compatible con una amplia gama de dispositivos y sistemas operativos, lo que permite una interoperabilidad flexible.

Su precisión en comparación con otras tecnologías puede ser limitada, al igual que su alcance si es comparado con tecnologías como Wi-Fi, lo que restringiría el área de cobertura del sistema de posicionamiento. Puede verse afectado por la presencia de otros dispositivos electrónicos y obstáculos en el entorno.

1.5.3.2 Características de Wi-Fi. Wi-Fi aprovecha la infraestructura de red inalámbrica existente en muchos entornos, lo que facilita la implementación del posicionamiento en interiores sin necesitar de una infraestructura adicional. También puede ofrecer una cobertura amplia en interiores, especialmente cuando se utilizan múltiples puntos de acceso.

Su precisión es limitada en comparación a otras tecnologías específicamente diseñadas para el posicionamiento de alta precisión ya que puede estar sujeto a interferencias de otros dispositivos inalámbricos en el área.

1.5.3.3 Características de UWB. El protocolo UWB o ancho de banda extremadamente amplio utiliza pulsos de radio de corta duración, lo que permite una alta resolución en la medición del tiempo de vuelo (Time of Flight, TOF) de las señales y, por lo tanto, una mayor precisión en el posicionamiento en interiores, permitiendo la localización de objetos con una precisión de centímetros. Debido a su capacidad para medir con precisión el TOF de las señales, puede proporcionar una precisión de posicionamiento muy alta, incluso en entornos con obstáculos y reflejos.

Además, utiliza técnicas de modulación y filtrado para mejorar la inmunidad al ruido y la interferencia, lo que contribuye a una mayor confiabilidad del posicionamiento en entornos complejos. Su rango de funcionamiento efectivo es de varios metros a decenas de

metros, lo que permite cubrir áreas extensas con un número limitado de anclas o balizas (International Telecommunication Union, 2016).

1.5.4 Alternativas de métodos de estimación de distancia

1.5.4.1 Received Signal Strength Indicator (RSSI). Este método se basa en la medición de la potencia de la señal recibida desde un emisor. La potencia de la señal disminuye a medida que la distancia entre el emisor y el receptor aumenta, lo que permite estimar la distancia relativa entre ellos. La atenuación de la señal debido a la propagación inalámbrica y los obstáculos en el entorno afecta directamente la medición del RSSI. Las interferencias electromagnéticas pueden afectar la precisión de la medición del RSSI y, por lo tanto, la estimación de la distancia.

Su precisión es limitada debido a su sensibilidad a múltiples posibles condiciones del entorno, incluyendo el entorno físico, como paredes, muebles y otros objetos, los cuales pueden afectar la propagación de la señal y, por lo tanto, la precisión para estimar distancias (Yang, 2013).

1.5.4.2 Time Of Flight (TOF). Para la determinación de distancias, el tiempo de vuelo (TOF) es muy potente al emitir luz en lugar de sonido. TOF mide la distancia entre un sensor y un objeto, basado en la diferencia de tiempo entre la emisión de una señal y su regreso al sensor, después de ser reflejada por un objeto. Se pueden utilizar varios tipos de señales (también llamadas portadoras) con el principio de tiempo de vuelo, siendo las más comunes el sonido y la luz.

Los sensores TOF directos envían pulsos cortos de luz que duran solo unos pocos nanosegundos y luego miden el tiempo que tarda parte de la luz emitida en regresar, mientras que los indirectos, envían luz modulada continua y miden la fase de la luz reflejada para calcular la distancia a un objeto.

Capítulo 2

2. Metodología

2.1 Descripción del escenario

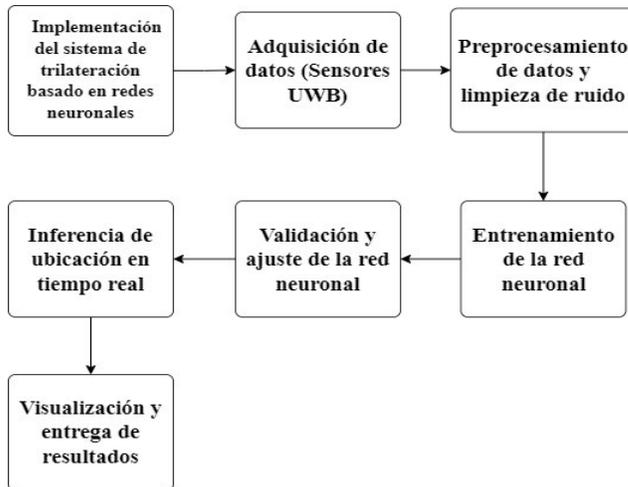
El escenario elegido para llevar a cabo esta investigación es un entorno de ambientes interiores, que abarca una variedad de espacios cerrados como oficinas, edificios residenciales, centros comerciales y otras instalaciones similares. Estos espacios presentan desafíos únicos en términos de comunicación y localización, ya que suelen tener obstáculos físicos, como paredes y muebles, que pueden afectar la calidad de la señal.

La investigación se llevó a cabo mediante la aplicación de técnicas de aprendizaje automático y redes neuronales. Estas herramientas permitirán el análisis de grandes conjuntos de datos y la identificación de patrones que conduzcan a una mayor precisión en la trilateración.

2.2 Diseño del sistema de localización

2.2.1 Descripción general del sistema de localización propuesto

El sistema de localización propuesto contiene dos procesos generales en los cuales se ejecutan acciones principales que permiten la funcionalidad integral del sistema. Los dos procesos generales son: la obtención de distancias entre el nodo móvil con cada uno de los nodos ancla utilizando módulos UWB y, la determinación de la posición del nodo móvil mediante trilateración basada tanto en redes neuronales como en un método matemático tradicional. Para esto, la Figura 2.1 muestra el proceso general en que consta la adquisición y el procesamiento de datos obtenidos, el entrenamiento y la validación de la red neuronal y la entrega de datos.

Figura 2.1*Descripción general del proyecto*

Nota. La Figura muestra el diagrama general en el que se describen las etapas del proceso de implementación del sistema de trilateración basado en redes neuronales en ambientes interiores.

2.2.1.1 Implementación del sistema de trilateración basado en redes neuronales. Para realizar este estudio, se considera un área en ambiente interior de 2x4 metros cuadrados. En este espacio, se colocan tres módulos UWB previamente configurados, en ubicaciones que se mantendrán fijas durante todas las mediciones. Se utiliza un cuarto módulo como el nodo móvil del sistema de trilateración. Adicionalmente, se prepara un algoritmo de modelo de red neuronal para que sea entrenada con los datos recopilados.

2.2.1.2 Adquisición de datos (Sensores UWB). En esta etapa, se recopilan las mediciones de distancia utilizando los sensores fijos UWB y el nodo móvil UWB. Estas mediciones se utilizan como entrada para el sistema de trilateración.

2.2.1.3 Preprocesamiento de datos y limpieza de ruido. Antes de utilizar los datos recopilados, es necesario realizar operaciones de preprocesamiento, como filtrado y eliminación de ruido, para mejorar la calidad de las mediciones y reducir posibles interferencias.

2.2.1.4 Entrenamiento de la red neuronal. Se utiliza el conjunto de datos previamente recopilado y preprocesado para entrenar la red neuronal. Durante esta etapa, la red neuronal aprende a mapear las mediciones de distancia a las ubicaciones correspondientes en el entorno de ambientes interiores.

2.2.1.5 Validación y ajuste de la red neuronal. Después del entrenamiento, se realiza una validación de la red neuronal utilizando datos adicionales para evaluar su rendimiento y ajustar los parámetros si es necesario. Esto garantiza que la red neuronal sea capaz de generalizar y proporcionar resultados precisos.

2.2.1.6 Inferencia de ubicación en tiempo real. Una vez que la red neuronal ha sido validada, se utiliza para realizar inferencias de ubicación en tiempo real. Esto implica procesar las mediciones de distancia actuales y generar las coordenadas estimadas de la ubicación del nodo móvil en tiempo real.

2.2.1.7 Visualización y entrega de resultados. Los resultados de la inferencia de ubicación se visualizan y entregan de una manera comprensible para el usuario final. Pueden presentarse en forma de coordenadas espaciales o en un mapa gráfico, facilitando la interpretación de la ubicación del nodo móvil.

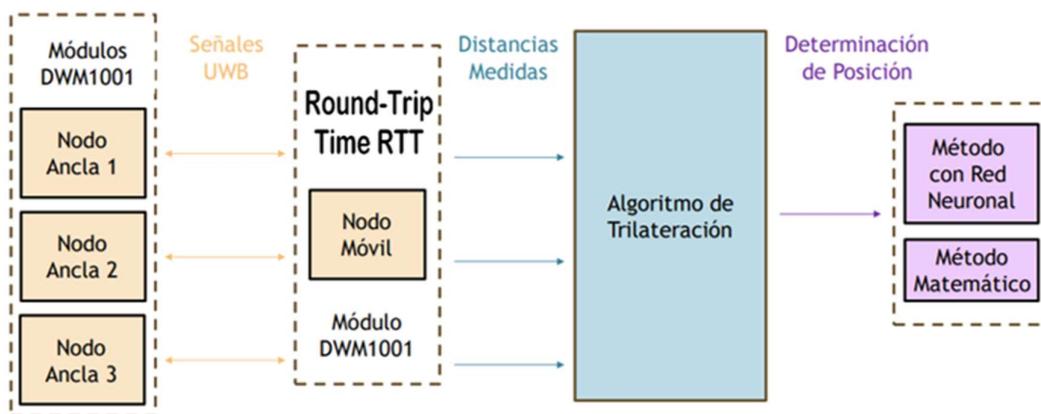
2.2.2 Diagrama de bloques del sistema de localización

Para la implementación del sistema de localización, se diseñó un diagrama de bloques en el que están representadas las componentes individuales del sistema. En la

primera fase del proceso del diagrama de bloques de la Figura 2.2, se mide el tiempo que tarda una señal de radiofrecuencia en viajar desde un transmisor hasta un receptor y luego regresar al punto de origen. Este tiempo total, denominado Round Trip Time (RTT), se divide por 2 para obtener el tiempo de vuelo (TOF) de la señal. Con la velocidad de la luz y el TOF, se estima la distancia entre los nodos. Este proceso se repite para cada uno de los otros dos nodos ancla. De esta manera, se obtienen tres distancias diferentes entre el nodo móvil y cada uno de los nodos ancla.

Figura 2.2

Diagrama de bloques del sistema de localización



Nota. La Figura muestra el diagrama de bloques del proceso de funcionamiento del sistema que determina la posición de un nodo tanto con una red neuronal como por un método tradicional.

Estas distancias son enviadas desde el nodo móvil a la computadora, ambos dispositivos están conectados mediante un cable USB a micro USB. Para ingresar los datos recogidos, se utiliza el programa Tera Term, el cual es un programa de emulación de terminal utilizado para acceder y administrar dispositivos remotos a través de conexiones seriales o de red. Tera Term permite que la computadora se comunique con nodo móvil (módulo DWM1001) utilizando una conexión serial.

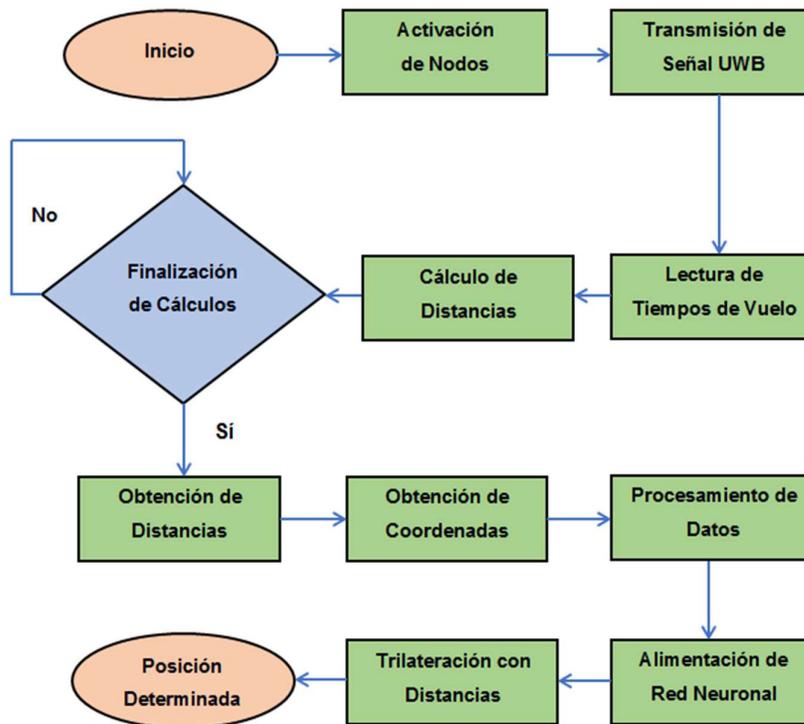
Estos datos son enviados a un archivo de texto para luego ser tomados por cada uno de los algoritmos de trilateración implementados. Una vez que los datos ingresan a los algoritmos, son procesados para evaluar la efectividad de cada uno de los algoritmos y obtener finalmente resultados con los cuales se puedan realizar análisis y comparaciones.

2.2.3 Diagrama de flujo del proceso de localización

En esta sección, el diagrama de flujo que se observa en la Figura 2.3 muestra la secuencia de pasos realizados en un orden lógico que hicieron posible el funcionamiento del sistema de localización. En el inicio, se enciende el nodo móvil, se lo conecta con la computadora y se configura la conexión serial en el programa Tera Term. Una vez configurada la conexión, se encienden los nodos ancla. Luego se inicia la recolección de datos mediante un pulsador presente en el nodo móvil y, en un corto instante, se transmiten las señales UWB, se leen los tiempos de ida y vuelta (entre el nodo móvil con los tres nodos ancla), internamente se calculan las distancias utilizando la velocidad de la luz

Figura 2.3

Diagrama de flujo del proceso de localización



Nota. La Figura muestra el diagrama de flujo del proceso del sistema de sensores con el que se determina la posición de un nodo móvil con trilateración basada en una red neuronal.

. Los cálculos de tiempo de vuelo y distancias se realizan para un nodo ancla a la vez, es decir, primero se calcula el tiempo de vuelo y la distancia del nodo ancla 1, después de eso se calcula el tiempo de vuelo y distancia del ancla 2 y posteriormente se calcula el tiempo de vuelo y distancia del ancla 3.

Los módulos UWB realizan cincuenta mediciones en un punto por cada ancla fija. Estas mediciones se las guarda en un archivo csv. Las distancias son promediadas y almacenadas en un archivo de texto previo a ser procesadas en el algoritmo de trilateración y luego en la red neuronal. Para calcular la posición del móvil mediante el método analítico, dadas las coordenadas del móvil y las distancias de éste a cada ancla, se propone resolver el siguiente sistema de ecuaciones:

$$2 \begin{bmatrix} x_3 - x_1 & y_3 - y_1 \\ x_3 - x_2 & y_3 - y_2 \end{bmatrix} \begin{bmatrix} x^* \\ y^* \end{bmatrix} = \begin{bmatrix} (d_1^2 - d_3^2) - (x_1^2 - x_3^2) - (y_1^2 - y_3^2) \\ (d_2^2 - d_3^2) - (x_2^2 - x_3^2) - (y_2^2 - y_3^2) \end{bmatrix} \quad (2.1)$$

Donde las variables a encontrar son x^* y y^* que son la posición del móvil. Los x_i y y_i corresponden a la posición de los nodos ancla y los d_i son las distancias medidas por los UWB. La ecuación 2.1 se deriva de las relaciones geométricas que deben satisfacer tanto el nodo móvil como el nodo ancla, en el escenario ideal donde las mediciones de distancia, d_i , no contienen errores. (Pozo, 2019).

Para obtener la posición mediante la red neuronal, se entrena la red ingresando en ella las distancias y las coordenadas de las posiciones reales. El setenta por ciento de las mediciones obtenidas a través de los módulos UWB, junto con las coordenadas reales del nodo móvil correspondientes a las 200 posiciones medidas en el área de experimentación, son utilizadas para alimentar la red neuronal.

Estas mediciones se configuran como un conjunto de entrenamiento con tres variables de entrada, que representan las distancias a tres nodos ancla, y dos variables de salida, que representan las coordenadas del nodo móvil. El restante treinta por ciento se utiliza para probar la red con datos no conocidos y comprobar su correcto funcionamiento.

2.3 Comparación de tecnologías de comunicación para posicionamiento

2.3.1 Características de Bluetooth, Wi-Fi y UWB

Tabla 2.1

Características cualitativas de las tecnologías de posicionamiento

Características	Bluetooth	Wi-Fi	UWB
Precisión	Limitada	Menor	Alta
Resistencia a obstáculos	Poca resistencia	Poca resistencia	Atraviesa obstáculos
Alcance	Menor	Gran alcance	Limitado
Consumo de energía	Bajo	Bajo	Bajo, medio
Disponibilidad en dispositivos	Amplia	Amplia	Limitada
Costo	Menos costoso	Menos costoso	Más costoso
Influencia de interferencias	Media	Susceptible	Evita interferencias
Rango de funcionamiento	Decenas de metros	Áreas extensas	Metros o decenas de metros

Nota. Esta tabla muestra las características relevantes de las tres tecnologías que pueden darles ventajas o desventajas para determinar la posición. (Rfwireless-world.com, s.f.) , (Rfwireless-world.com, s.f.), (Rfwireless-world.com, s.f.), (Rahayu, 2008), (Santhanam M. , s.f.). (Banger, 2023)

En relación con la Tabla 2.1, Bluetooth puede ser más adecuado para aplicaciones con alcance limitado y eficiencia energética, pero en cuanto a precisión, al igual que Wi-Fi, es más deficiente que la precisión de UWB y puede carecer de la precisión necesaria para la determinación precisa de distancias en interiores.

Aunque Wi-Fi proporciona un alcance más amplio y una mayor velocidad de datos, UWB ofrece alta precisión en la medición de distancias y es especialmente adecuado para aplicaciones que requieren alta precisión en interiores, aunque puede ser más costoso y menos común en comparación con Bluetooth y Wi-Fi.

Tabla 2.2

Características cualitativas de los métodos de estimación de distancia

Características	RSSI	RTT
Precisión	No es altamente precisa	Alta
Resistencia a obstáculos	No, se atenúa la señal	No la influyen los obstáculos
Influencia de interferencias	Sí, atenuación de la señal	No la influyen las interferencias
Costo	Poco costoso	Más costoso
Sincronización de reloj	No es necesario	Sensible a la sincronización
Línea de vista	Necesaria	Necesaria

Nota. Se muestran las características de RSSI y RTT para estimar distancias. (Shojaifar, s.f.), (Mejía, 2021), (Lee, 2020)

Como se observa en la Tabla 2.2, las ventajas principales de utilizar la técnica de estimación RSSI (potencia recibida) son que su implementación se torna sencilla, su consumo de energía es bajo y no requiere sincronización de reloj precisa como sí lo requiere la técnica de estimación de distancia basada en RTT. Como desventajas, RSSI es sensible a interferencias y su precisión es limitada debido a atenuación, por lo tanto, es propensa a errores.

Por otro lado, aunque RTT consume más energía y su hardware es más complejo, su alta precisión para estimar de distancias especialmente en ambientes interiores, su resistencia a atenuación y multipath y el ser menos vulnerable a interferencias, la hace más propicia para este proyecto.

2.3.2 Elección y beneficios de UWB para el proyecto

Para ese proyecto se utiliza la tecnología UWB, específicamente por cuatro características que se presentan como ventajas sobre las otras tecnologías y que están presentes en la Tabla 2.1. La característica de precisión es alta para la tecnología UWB, es decir, que esta tecnología es mucho más precisa en comparación con Bluetooth y Wi-Fi.

Acerca de la resistencia a obstáculos, la tecnología UWB los atraviesa con mayor facilidad, lo que facilita que la señal no sea significativamente distorsionada.

El alcance es limitado ya que UWB está diseñada para distancias más cortas en comparación con las otras dos tecnologías. Sin embargo, con respecto al proyecto que se realiza, se trata de un ambiente interior con un área menor al máximo alcance que UWB ofrece y, por lo tanto, no se configuraría como una desventaja.

Con relación a las interferencias, esta tecnología es menos propensa a ser afectada, especialmente en espacios en los cuales la medida de la distancia entre los nodos se puede alterar por la presencia de señales de otros dispositivos que están presentes en el mismo espacio. Esto es debido a que el uso de frecuencias más altas y un mayor ancho de banda lo hacen menos propenso a las interferencias que normalmente se observan en bandas

superpobladas utilizadas por otros sistemas de comunicación. Además, serán tres módulos fijos de los cuales se van a calcular distancias, y sería óptimo si ninguna de estas distancias altera al cálculo de las otras. (Davies, 2021)

Con respecto al consumo de corriente también es bajo medio, puede lograr consumir hasta 12-15 μA y su consumo aumenta hasta los 112 mA el nodo móvil está transmitiendo. Los módulos UWB que funcionan con baterías de hasta 3.7 V.

Cabe recalcar que la tecnología UWB es más cara como lo indica la Tabla 2.1, pero en este proyecto se utilizan solo cuatro módulos DW1001, lo cual no es un alto número de módulos y, por lo tanto, los gastos no ascenderían demasiado.

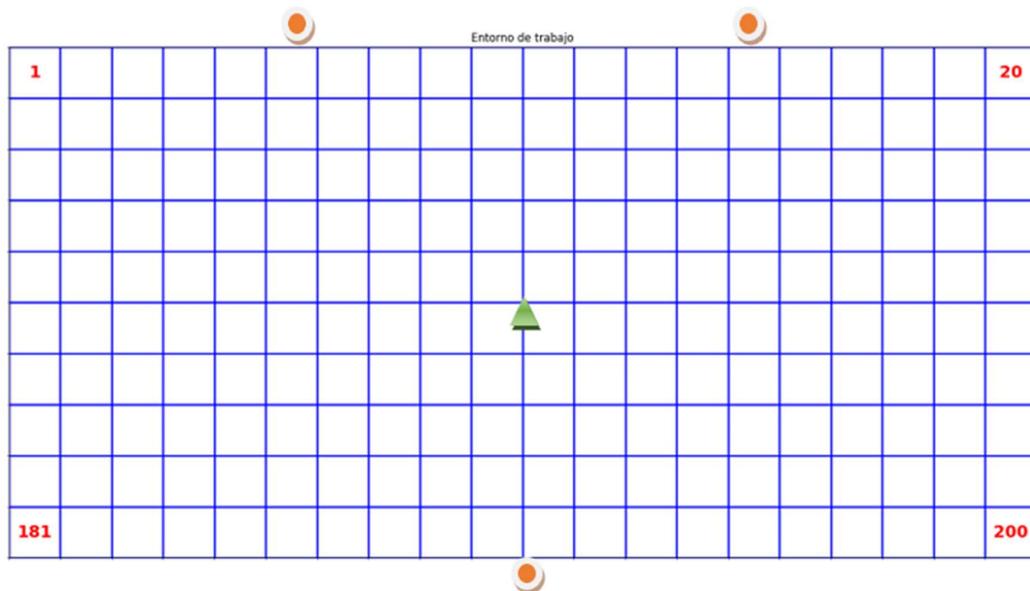
2.4 Recolección y preprocesamiento de datos

2.4.1 Descripción recolección de datos

La Figura 2.4 muestra el área sobre la que se llevó a cabo la experimentación y se realizaron las pruebas para recolectar los datos. El área abarca 4m x 2m y está dividida en 200 cuadros pequeños con un área de 20cm x 20cm, numerados de izquierda a derecha y descendiendo. Los nodos ancla que están representados por los puntos anaranjados de la Figura 2.4 están ubicados en posiciones fijas como se observa. Las posiciones establecidas para este trabajo empiezan en el vértice superior izquierdo del área, es decir, que esa es la posición ($x=0\text{m}$, $y=0\text{m}$). Los nodos ancla que están en la parte superior del área de experimentación, son el nodo ancla 1 y el nodo ancla 3. La posición del ancla 1 es ($x=2.7\text{m}$, $y=0\text{m}$), y la del nodo ancla 3 es ($x=1.3\text{m}$, $y=0\text{m}$). Por otro lado, la posición del nodo ancla 2 es ($x=2\text{m}$, $y=-2\text{m}$), teniendo en cuenta que el valor negativo es por convención ya que está abajo del valor $y=0\text{m}$. La flecha verde que se observa en el centro representa al nodo móvil que se va moviendo en cada uno de los 200 vértices.

Figura 2.4

Representación del área en la que se realizaron las experimentaciones



Nota. La Figura muestra la división del área de experimentaciones en 200 áreas cuadradas de 20 cm por lado. Cada cruce representa las posiciones del nodo móvil.

La captura de datos con módulos UWB requiere una línea de vista directa entre las antenas para evitar errores en la asignación de datos. El proceso comienza con el nodo móvil enviando un paquete de encuesta al nodo ancla. Este paquete es recibido por el nodo ancla y luego es enviado de regreso al nodo móvil. El tiempo total que toma este proceso se denomina RTT (tiempo de ida y vuelta) y se utiliza para estimar la distancia entre los nodos. (Woxuwireless, s.f.). Se considerarán 50 datos en cada posición para cada ancla y se obtendrá un promedio de esta. En cada cuadrícula se medirá en el vértice superior izquierdo ya que los valores de esas coordenadas son conocidos en lugar de tomar el valor central. El área sobre la cual se realizarán los cálculos será de 8 metros cuadrados, es decir $2 \times 4 \text{ m}^2$.

2.5 Arquitectura, entrenamiento y evaluación de la red neuronal

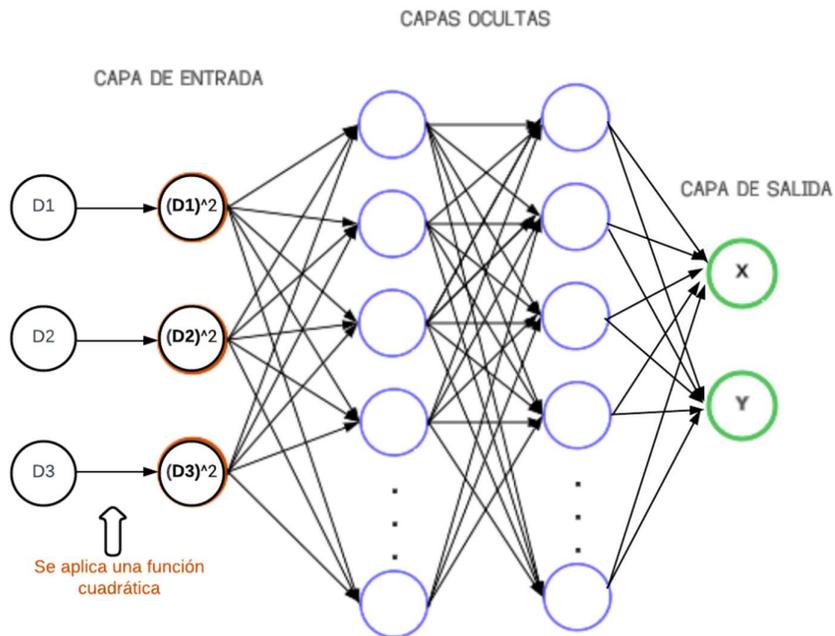
2.5.1 Arquitectura de la red neuronal

El tipo de red neuronal utilizado es de tipo Feedforward Neural Network (FNN), también conocidas como redes neuronales totalmente conectadas. Como se observa en la Figura 2.5, estas redes tienen una estructura de capas en la que las señales fluyen en una sola dirección, desde la capa de entrada a través de una o más capas ocultas hasta la capa de salida (Ian Goodfellow, 2016; Ian Goodfellow, 2016). El objetivo de este modelo es predecir las coordenadas (x, y) de la ubicación de un objeto en función de las distancias $(D1, D2, D3)$ medidas desde el objeto hasta tres puntos de referencia.

La arquitectura del modelo se detallan a continuación:

Según la Figura 2.5, el modelo consta de varias capas lineales (fully connected) con funciones de activación Rectified Linear Unit (ReLU), que son muy utilizadas en redes neuronales y otros modelos de aprendizaje profundo. Estas funciones de activación introducen la no linealidad y toman un valor de entrada "x" para devolver "x" si "x" es mayor que cero y cero si "x" es menor o igual que cero. Un punto destacable es esta red es la función cuadrática que la diferencia de una red estándar ya que junto con los diferentes parámetros proporciona una notable mejoría en la predicción de la posición. Los detalles de las capas son los siguientes:

- Capa o función cuadrática
- Capa de entrada (fc1): 3 características de entrada $(D1, D2, D3)$ y 64 unidades.
- Capa oculta (fc2): 64 unidades de entrada y 32 unidades ocultas.
- Capa de salida (fc3): 32 unidades de entrada y 2 unidades de salida (x, y) .

Figura 2.5*Estructura de la red neuronal*

Nota. Estructura de la red neuronal que consta de la capa de entrada con tres características (D1, D2 y D3), capas ocultas y una capa de salida con dos características (X e Y).

2.5.2 Implementación y verificación de la red neuronal

2.5.2.1 Inicialización de Pesos. Los pesos de las capas lineales se inicializan con ceros utilizando Kaiming Uniform (He initialization), que es una técnica de inicialización estándar para los pesos de las capas lineales.

2.5.2.2 Función de Pérdida y Optimizador. La función de pérdida utilizada es el Mean Squared Error (MSE), que compara las predicciones del modelo con los valores reales. El optimizador utilizado es Adam con una tasa de aprendizaje (learning rate) de 0.0008. El MSE se define como se observa en la ecuación 2.2:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2. \quad (2.2)$$

Donde n es el número total de muestras procesadas, y_i es el valor real y \hat{y}_i es la predicción realizada por la red neuronal.

2.5.2.3 Entrenamiento del Modelo. El bucle de entrenamiento recorre varios epochs. En cada epoch:

- Se calcula la pérdida en cada lote de datos del conjunto de entrenamiento y se realiza la retropropagación del gradiente para actualizar los pesos.
- Se calcula la pérdida en cada lote de datos del conjunto de prueba para evaluar el rendimiento del modelo.
- Se calcula la pérdida promedio para el entrenamiento y la prueba en el epoch actual y se almacenan en listas.

2.5.3 Entrenamiento y comprobación de la red neuronal

Los datos provistos por los módulos UWB son recopilados y almacenados en un archivo Comma-Separated Values (CSV) donde serán convertidos en instancias de Pytorch previo a ingresar a la red neuronal. Cabe recalcar que un archivo CSV es utilizado para almacenar y representar datos que están separados por comas. Estos datos son obtenidos así desde el programa Tera Term y llevados a una base de datos en Excel. Luego serán divididos en conjuntos para ser utilizados en etapas de entrenamiento y prueba. La separación de estos conjuntos será completamente aleatoria para garantizar que no se le esté proveyendo algún patrón a la red y sea capaz de predecir posiciones en cualquier lugar. El 70% de los datos se utilizarán para entrenar el modelo. Esta etapa se llama trainig.

Durante el entrenamiento habrá un 30% de datos que la red no verá para aprender a predecir valores. Esta reserva se usará para evaluar el rendimiento de la red neuronal en la etapa llamada testing. Una vez la red haya finalizado de iterar se procederá a visualizar la

curva de entrenamiento para corroborar que haya aprendido a predecir valores durante el entrenamiento. De no ser así se modificarán los parámetros necesarios para corregir el funcionamiento. Éstos pueden ser el learning rate, el batch size o el número de épocas.

2.5.3.1 Métricas que se utilizarán para evaluar la precisión de la localización y la eficacia. En este proyecto integrador, se llevará a cabo una evaluación de la precisión de localización y la eficacia de las distintas técnicas de aprendizaje automático. Para lograr este propósito, se emplearán métricas fundamentales, entre las cuales se incluyen la comparación de la desviación estándar y la media del error, el Error Absoluto Medio (MAE) y el Error Cuadrático Medio (MSE). Estas métricas brindarán una evaluación integral y detallada de la calidad y el rendimiento de las diversas técnicas, lo que permitirá una comprensión profunda de su capacidad para estimar con precisión las ubicaciones y la consistencia en la generación de predicciones.

2.6 Consideraciones prácticas

2.6.1 Desafíos

Durante la captura de datos, surgieron problemas derivados de mediciones anómalas de distancias, resultado del uso inadecuado de los módulos UWB. Se tomó en cuenta el patrón de radiación de estos módulos, con la potencia de transmisión máxima ubicada a 45° a la izquierda. Para optimizar su desempeño, se dispuso que se colocaran a una altura de 24 cm en posición vertical, en lugar de estar en contacto directo con el suelo.

2.6.2 Limitaciones

La trilateración se distingue por el uso de nodos ancla con posiciones conocidas. En contraste, la red neuronal no requiere tener conocimiento de las posiciones de las anclas, siempre y cuando estas no experimenten cambios. Si las ubicaciones de las anclas se

modifican y se lleva a cabo una nueva recopilación de datos, la red neuronal podría ofrecer predicciones inexactas. No hemos incorporado métodos para abordar esta eventualidad en el diseño de la red neuronal propuesta. Por lo tanto, su correcto funcionamiento depende de la estabilidad de las posiciones de los nodos ancla.

2.7 Consideraciones éticas

Se utilizan módulos UWB, específicamente el modelo DWM1001. Este hardware ha sido diseñado para cumplir con las normativas de radiofrecuencia y se ha utilizado de acuerdo con las especificaciones del fabricante. (Qorvo, s.f.)

Los datos recogidos en este proyecto son de naturaleza no personal, consistiendo en mediciones de ubicación y tiempo de llegada de un nodo móvil. Estos datos se almacenan de forma segura y se utilizan exclusivamente para los fines educativos de este proyecto.

Este proyecto tiene como objetivo principal proporcionar una herramienta educativa para enseñar sobre la localización y las técnicas de aprendizaje automático. Se espera que tenga un impacto social positivo al mejorar la educación en estos temas. Además, al utilizar tecnología de bajo consumo energético (módulos UWB), el impacto ambiental del proyecto es mínimo.

Capítulo 3

3. Resultados y análisis

3.1 Patrón de Radiación

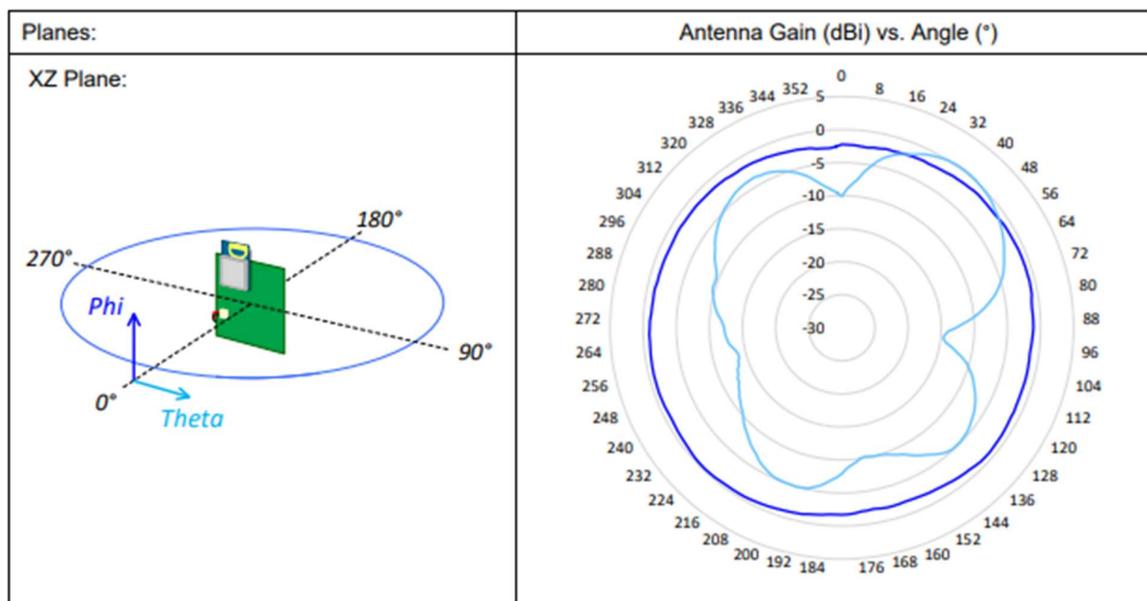
Después de realizar mediciones experimentales utilizando dispositivos UWB en un área de 8 metros cuadrados, se procesaron los datos con el fin de emplearlos en los cálculos de trilateración. Estos cálculos se llevaron a cabo tanto utilizando el método analítico clásico como a través del entrenamiento de una red neuronal implementada en Python.

Con el objetivo de obtener mediciones lo más fieles posibles a los valores reales, se consideró el patrón de radiación de las antenas UWB. También fue identificado el ángulo en horizontal donde la potencia de la señal era más intensa, el cual resultó ser 45° como se muestra en imagen derecha de la Figura 3.1, en la que la línea celeste cubre un mayor espacio en 45° . Se intentó dirigir la antena de cada nodo ancla a un ángulo de entre 0° a 90° con respecto al nodo móvil para obtener distancias más exactas. No se dirigieron exactamente a 45° los tres nodos ancla con respecto al nodo móvil porque la medición en cada punto fue realizada teniendo ubicados todos los nodos ancla al mismo tiempo. Es importante recalcar que este patrón de radiación de la imagen derecha es así si la posición de los módulos es como se observa en el plano XZ a la izquierda, es decir, que los módulos estén ubicados en forma vertical. Este proceso se repitió en cada punto de medición.

Además, se realizó una fase previa de filtrado de datos para excluir mediciones aberrantes. Cada medición se basó en cincuenta lecturas distintas para cada ancla fija, lo que significa que se tomaron 150 mediciones por cada punto. Posteriormente, calculamos el promedio de las distancias obtenidas entre el ancla móvil y cada ancla fija. Estos datos promediados fueron utilizados en los métodos de trilateración, tanto en su enfoque clásico como en el basado en redes neuronales.

Figura 3.1

Plano en Azimuth y elevación de la antena UWB



Nota. Se evidencia el patrón de radiación de la antena UWB en Azimuth y elevación.

Tomado de (Qorvo, s.f.)

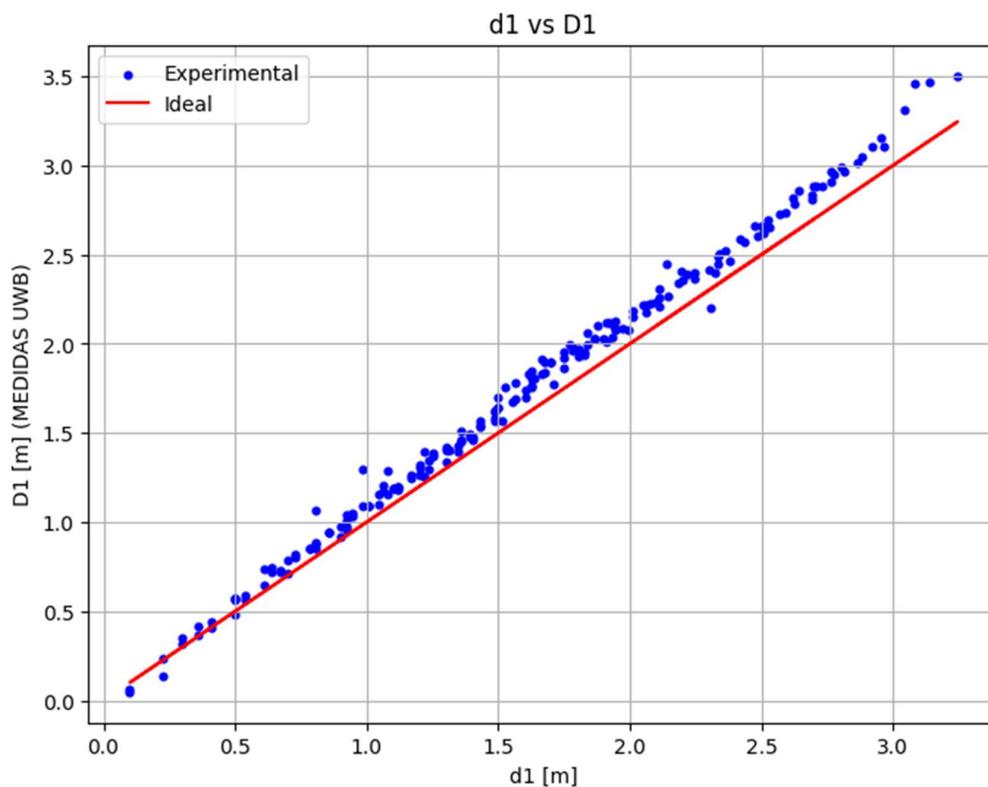
A continuación, se observa en las siguientes tres Figuras (3.2, 3.3, 3.4) el comportamiento en el plano "d vs D", donde la d representa las mediciones ideales de la distancia del nodo móvil a un nodo ancla específico y la D representa las distancias obtenidas mediante los módulos UWB. Este comportamiento tiene naturaleza lineal. Es decir que, en esta gráfica se comparan los valores ideales de distancias que se deberían haber obtenido en un escenario ideal con los valores experimentales que fueron adquiridos con los módulos UWB.

En cada Figura, la línea roja representa los valores ideales de distancias y los puntos azules representan las distancias obtenidas en la realidad con los módulos utilizados. La observación de estas gráficas refleja la precisión de las mediciones realizadas por los módulos UWB, que funcionan mediante el tiempo de ida y vuelta o RTT.

En la Figura 3.2 se muestra la comparación entre valores ideales y experimentales “d1 vs D1”es con relación a la distancia en cada punto de medición entre el nodo móvil y el nodo ancla 1. Los ángulos de dirección ente estos dos nodos, variaron entre 0° a 45°, resultando distancias experimentales no muy erróneas. Es evidente que mientras mayor es la distancia entre estos dos módulos, las distancias experimentales se dispersan más y se alejan de la línea roja (distancias ideales). Aunque las distancias obtenidas no son iguales a las distancias en un escenario ideal, no son tan inexactas ya que no se alejan lo suficiente.

Figura 3.2

Gráfica de distancias teóricas vs experimentales con UWB del ancla 1

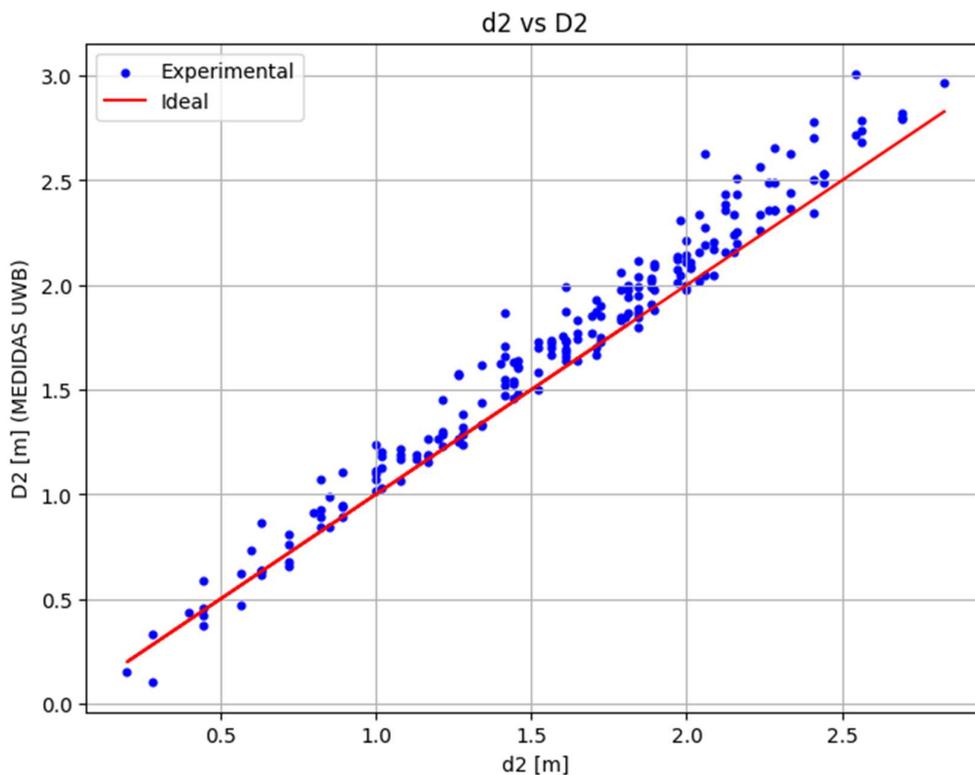


Nota. La gráfica representa las mediciones de distancias reales con los módulos UWB tomando en cuenta el nodo ancla 1 y la línea de los valores ideales.

En la Figura 3.3, la comparación entre valores ideales y experimentales “d2 vs D2” es entre el nodo móvil y el nodo ancla 2. Los ángulos de dirección ente estos dos nodos, variaron entre aproximadamente 45° a 90°, resultando distancias experimentales un poco más erróneas que las del nodo ancla 1. En este caso las distancias experimentales se dispersan más cuando los nodos están más lejos entre sí (a más de dos metros de distancia). A pesar de eso, la dispersión se presenta en toda la gráfica, con ciertas concentraciones cuando el espacio entre estos dos nodos estuvo dentro del rango de 1.5 m a 2 m. Aunque las distancias obtenidas están más dispersas, fueron útiles para probar la efectividad del sistema de localización del nodo móvil con la red neuronal.

Figura 3.3

Gráfica de distancias teóricas vs experimentales con UWB del ancla 2

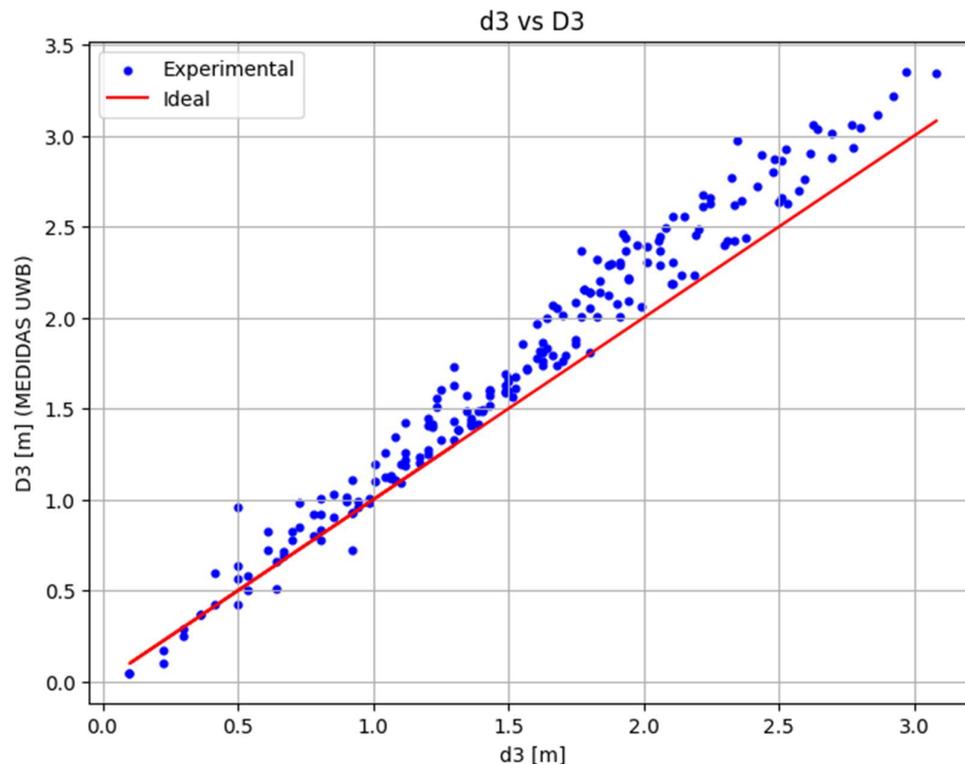


Nota. La gráfica representa las mediciones de distancias reales con los módulos UWB tomando en cuenta el nodo ancla 2 y la línea de los valores ideales.

Con respecto a la Figura 3.4, la comparación entre valores ideales y experimentales “d3 vs D3” es entre el nodo móvil y el nodo ancla 3. Los ángulos de dirección entre estos dos nodos, variaron entre aproximadamente 40° a 70°, resultando distancias experimentales quizás más dispersas que las de los nodos ancla anteriores. En este caso las distancias experimentales se dispersan más cuando los dos nodos se alejan entre sí. Aunque las distancias obtenidas con el ancla 3 son aún más dispersas, fueron valores útiles para probar la efectividad de la trilateración basada en la red neuronal. Aunque los nodos 2 y 3 exhibieron desviaciones leves hacia valores más altos, siguieron una tendencia sobre la función lineal.

Figura 3.4

Gráfica de distancias teóricas vs experimentales con UWB del ancla 3



Nota. La gráfica representa las mediciones de distancias reales con los módulos UWB tomando en cuenta el nodo ancla 3 y la línea de los valores ideales.

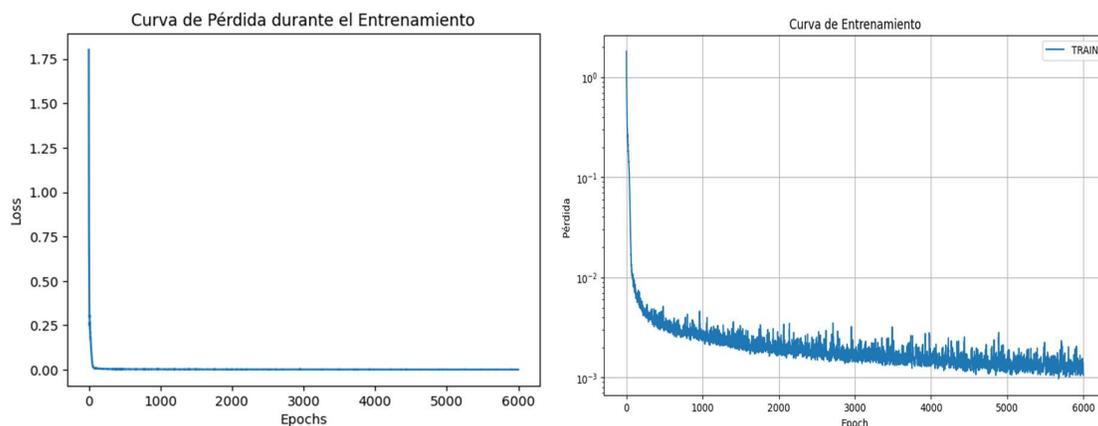
3.2 Curvas de entrenamiento

Un parámetro crucial en el entrenamiento es el número de épocas o "epochs". Las épocas indican cuántas veces el algoritmo procesa todo el conjunto de datos de entrenamiento. En este estudio, se utilizaron 6000 épocas para entrenar el modelo, y la Figura 3.5 muestra la evolución del rendimiento del modelo a lo largo de estas épocas.

Al analizar la curva de entrenamiento (parte izquierda de la Figura 3.5), se observa un decrecimiento inicial pronunciado, lo que indica que el modelo hizo ajustes significativos al principio para reducir la pérdida. Tras este rápido decrecimiento, la pérdida disminuye lentamente, sugiriendo que el modelo está convergiendo hacia una solución óptima. Para una visualización más clara de este comportamiento en las primeras épocas, se presentó una gráfica semilogarítmica (parte derecha de la Figura 3.5).

Figura 3.5

Curvas de pérdida en el transcurso del entrenamiento de la red neuronal



Nota. Curvas de pérdida durante el entrenamiento de la red neuronal en las que se observa el comportamiento de las predicciones.

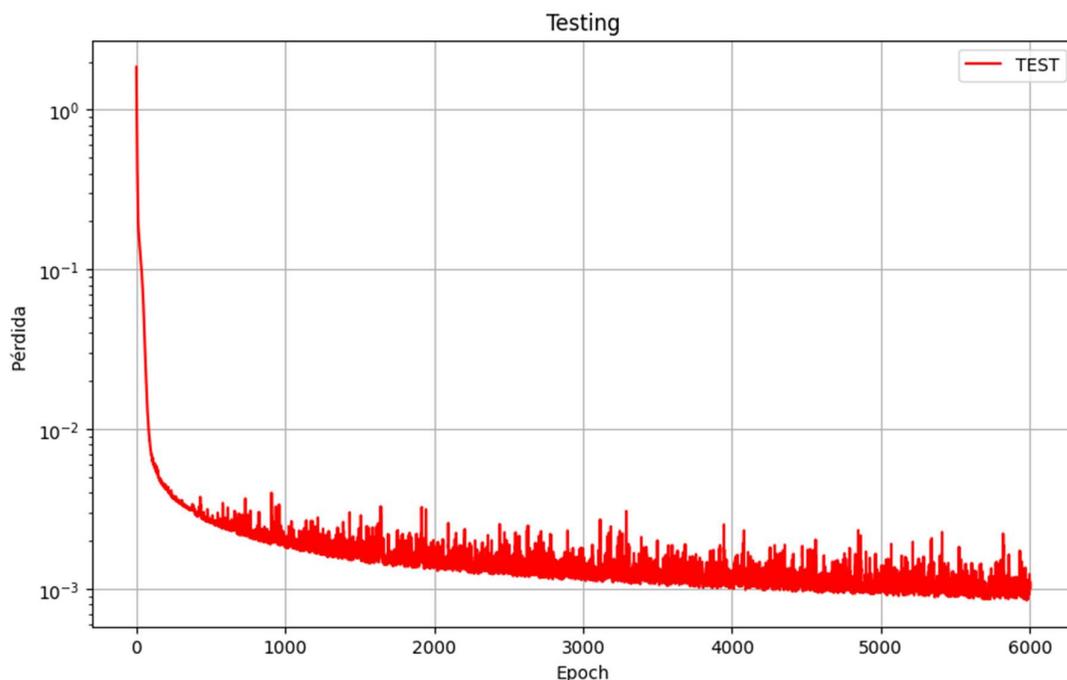
En la gráfica semilogarítmica de la Figura 3.5 se observa que inicialmente las pérdidas son muy grandes, pero a partir de la época 5000 la curva se torna más horizontal,

lo que indica que se han minimizado las pérdidas y que las predicciones se parecen las a la de los datos reales. Debido a que las pérdidas alcanzan valores cercanos a las milésimas, es un indicador de que el entrenamiento ha dado resultado.

La Figura 3.6 de testing que se observa a continuación, es muy similar a la curva de entrenamiento. Sin embargo, esta curva es realizada con los datos de prueba, los cuales la red no vio durante el entrenamiento. La similitud en las gráficas comprueba que el modelo se ajusta no sólo a los datos de entrenamiento, sino que también hace predicciones precisas con datos no vistos antes. Si la red no predice correctamente los valores cuándo se la evalúa con datos de prueba, entra en un estado conocido como “overfitting” lo que significa que solo se ajusta a los datos de entrenamiento, pero no realiza buenas predicciones.

Figura 3.6

Curva de testing



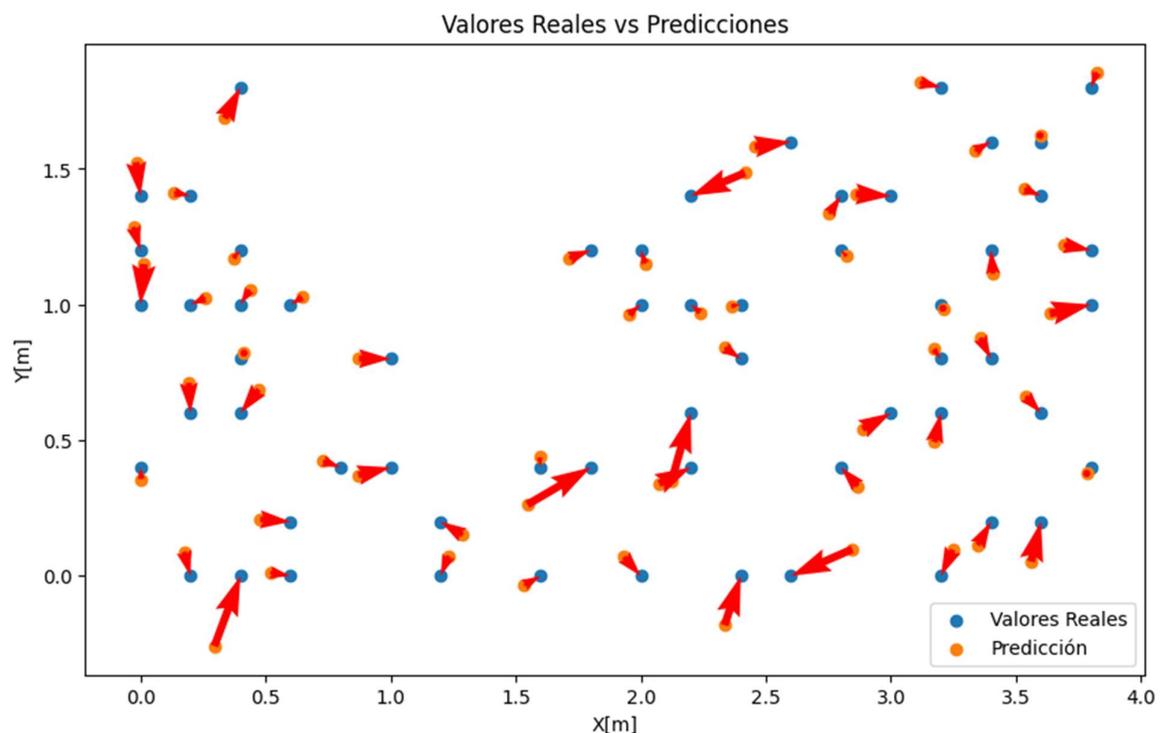
Nota. Curva resultante de los datos de prueba no utilizados en el entrenamiento.

3.3 Predicciones de la red neuronal

Para comprobar visualmente las predicciones de la red neuronal en contraste con los valores reales se realizó la gráfica de Valores Reales vs Predicciones como se muestra en la Figura 3.7. Según se observa, en su mayoría las predicciones (de color anaranjado) están muy cercanas a los valores reales (color azul). La flecha roja que parte desde la predicción indica la dirección que debe tomar para alcanzar su valor real. Si la flecha es de mayor magnitud indica que un mayor error ya que está más alejada de alcanzar su valor real. En la Figura se aprecia que en su mayoría las predicciones son bastante acertadas.

Figura 3.7

Representación de valores reales vs valores predichos por la red neuronal

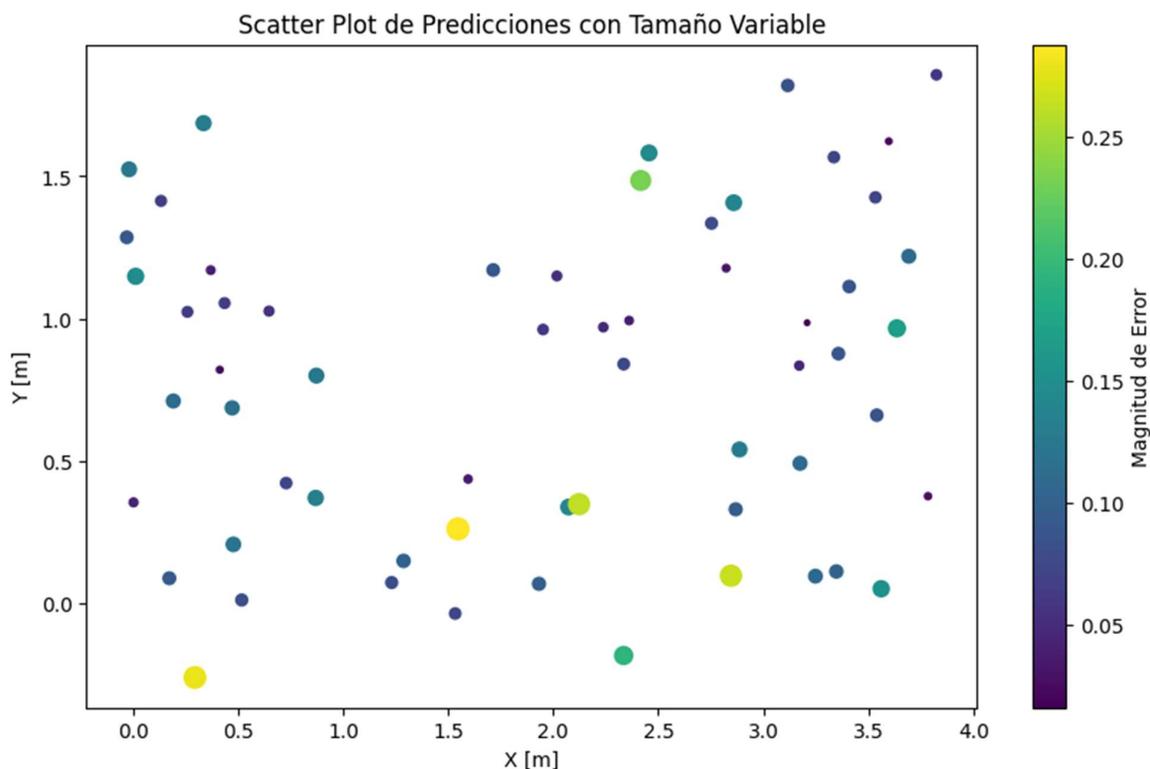


Nota. Se muestra el comportamiento de la red neuronal y se comparan entre los valores de posiciones experimentales y valores de posiciones correctas del nodo móvil.

El gráfico de la Figura 3.8 permite visualizar las predicciones en función de la magnitud de error en un espacio bidimensional. Los puntos de colores y diámetros variables permiten identificar visualmente las áreas donde las predicciones tienen mayores o menores errores. Los puntos con menor magnitud de error son de un color más oscuro, mientras que los puntos con mayor magnitud de error serán de un color más claro. Por su parte, el tamaño de los diámetros indica que los puntos con magnitudes de error más grandes tienen un diámetro mayor, mientras que los puntos con magnitudes de error más pequeñas tienen un diámetro más pequeño. En su mayoría se observan puntos oscuros y de pequeño diámetro lo cual corroboran el buen comportamiento de la red neuronal.

Figura 3.8

Representación de predicciones en magnitud de error



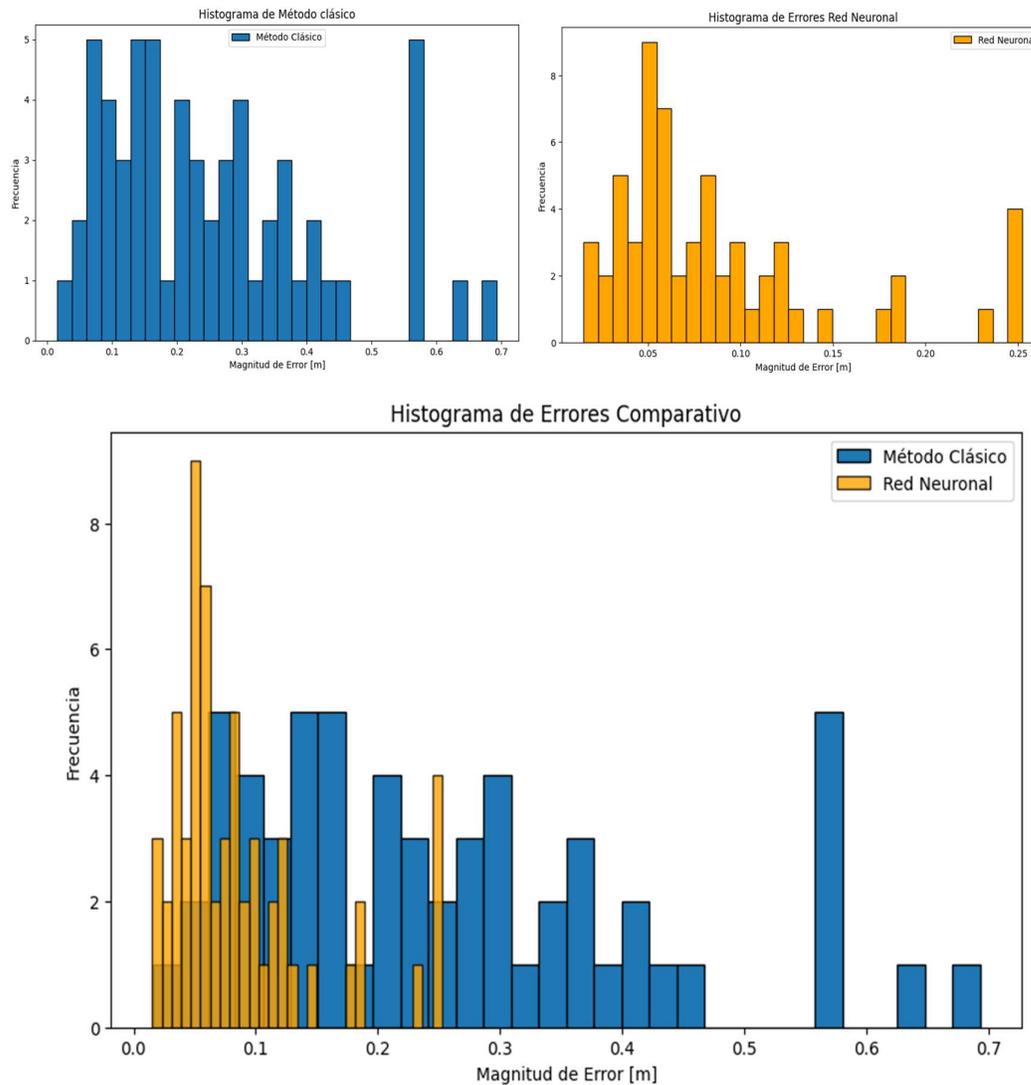
Nota. Se muestra el comportamiento de la red neuronal mediante la magnitud del error de las predicciones tomando en cuenta los colores y diámetros de cada punto.

3.4 Histogramas

En la Figura 3.9 se observa un histograma en la parte superior izquierda que corresponde al comportamiento de los resultados obtenidos mediante el método clásico. Este histograma muestra que la mayoría de los errores se encuentran hacia la izquierda, indicando una alta frecuencia de errores pequeños. En la parte superior derecha observamos el histograma correspondiente a la red neuronal está sesgado hacia la izquierda. En el histograma combinado, el método clásico presenta una mayor frecuencia de errores de mayor magnitud en comparación con la red neuronal. Además, el error más grande producido por la red neuronal es relativamente pequeño, especialmente cuando se compara con el rango de errores del método clásico.

Figura 3.9

Histogramas de la magnitud de errores



Nota. Representación y comparación de errores de método tradicional y método con red neuronal mediante histogramas, tomando en cuenta la frecuencia y la magnitud de error.

3.5 Desempeño

Tabla 3.1

Comparación de la media de la magnitud del vector de error y la desviación estándar del método clásico y del método con la red neuronal

Método	Media [m]	Desviación estándar [m]
Clásico	0.2547	0.1635
Red Neuronal	0.0391	0.0253

Nota. Datos obtenidos del procesamiento de datos de los algoritmos.

En la Tabla 3.1 se presenta las estadísticas comparativas entre los métodos Clásico y el de la Red Neuronal. Para el método Clásico, la media de la magnitud del vector de error 0.2547 m con desviación estándar de 0.1635 m indica una dispersión mayor en los resultados. En contraste, el método de la Red Neuronal muestra una media más baja de 0.0391 m y una desviación estándar de 0.0253 m , lo que sugiere mayor consistencia y precisión en las predicciones. Estos resultados respaldan la superioridad de la Red Neuronal al reducir la dispersión y mejorar la fiabilidad en comparación con el método Clásico.

Tabla 3.2

Comparación del Error Cuadrático Medio MSE y el Error Absoluto Medio MAE de ambos métodos

Método	MSE [m ²]	MAE [m]
Clásico	0.0458	0.1620
Red Neuronal	0.0011	0.0251

Nota. Datos obtenidos del procesamiento de datos de los algoritmos para comparar el MSE.

En la Tabla 3.2 se comparan los métodos a través del Error Cuadrático Medio (MSE) y el Error Absoluto Medio o Mean Absolute Error (MAE). Para el método clásico, el MSE es de 0.0458 m^2 y el MAE de 0.1620 m sugieren una mayor discrepancia entre las predicciones y los valores reales. En contraste, el método red neuronal muestra un MSE mucho más bajo de 0.0011 m^2 y un MAE de 0.0251 m , indicando una mejor precisión y ajuste de las predicciones. Estos resultados resaltan que la red neuronal supera al método Clásico al reducir significativamente los errores y mejorar la calidad de las estimaciones.

Es importante aclarar que el cálculo de errores se los realizó con el mismo conjunto de mediciones correspondientes a los datos destinados a la etapa de prueba de la red neuronal.

Capítulo 4

4. Conclusiones y recomendaciones

4.1 Conclusiones

- La red neuronal, con una media de errores de 0.04 m, demuestra una precisión superior al método clásico de trilateración, que presenta una media de errores de 0.25 m. Similarmente, los valores de error cuadrático medio (MSE) y error absoluto promedio (MAE) mejoran notablemente con la red neuronal, disminuyendo a 0.0011 m² y 0.0251 m² respectivamente.
- Los resultados del proyecto corroboran que la trilateración basada en redes neuronales es un avance en los sistemas de posicionamiento en términos de eficiencia y precisión, lo que se considera un aporte académico y un recurso educativo disponible para futuras implementaciones.
- El algoritmo desarrollado es adaptable, porque puede ajustarse para diferentes configuraciones y datos, y es accesible ya que permite realizar análisis estadísticos mediante gráficos, facilitando así su uso para fines educativos.

4.2 Recomendaciones

- Para mejorar la estimación del método clásico, se recomienda considerar un ajuste lineal mediante una regresión basada en las gráficas de d versus D . Este ajuste podría ser beneficioso para mejorar la precisión en distancias que superen el metro.
- Se recomienda evaluar el desempeño de la red neuronal cambiando la posición de los nodos ancla, ya que este enfoque puede ofrecer un análisis de interés.
- Para trabajos futuros se recomienda realizar mayor número de mediciones que entrene la red neuronal, de este modo se mejoran las predicciones de la red.
- Realizar estudios a profundidad de las características del módulo que se va a utilizar. Datos como la frecuencia de transmisión, la precisión de datos y el patrón de radiación son importantes para realizar una configuración adecuada para lo que se busca.

Referencias

- Banger, E. R. (14 de 02 de 2023). *DigitalThinkerHelp*. . Obtenido de 15 advantages and disadvantages of Bluetooth.: <https://digitalthinkerhelp.com/advantages-disadvantages-bluetooth/>
- Bertoli, D. G. (2012). *ESTUDIO, IMPLEMENTACIÓN Y ANÁLISIS*. Leganés. Obtenido de https://e-archivo.uc3m.es/bitstream/handle/10016/15909/pfc_debora_gomez_bertoli_2012.pdf?sequence=1&isAllowed=y
- Davies, M. (24 de 03 de 2021). *UWB: Pros and cons of ultra-Wideband technology*. Obtenido de <https://www.konsyse.com/articles/uwb-pros-and-cons-of-ultra-wideband-technology/>
- Fernández, M. (2019). *Geolocalización en el Espacio para la Gestión de Inventario*. Universidad de Cantabria.
- Ian Goodfellow, Y. B. (2016). *Deep Learning*. MIT Press. Obtenido de <http://www.deeplearningbook.org>
- IBM. (s.f.). *IBM*. Obtenido de Redes neuronales con IBM SPSS Modeler: <https://www.ibm.com/docs/es/spss-modeler/saas?topic=networks-neural-model>
- International Telecommunication Union*. (16 de Enero de 2016). Obtenido de Characteristics of ultra-wideband technology: https://www.itu.int/dms_pubrec/itu-r/rec/sm/R-REC-SM.1755-0-200605-!!!PDF-E.pdf
- Lee. (2020). Obtenido de LinkedIn: <https://www.linkedin.com/pulse/reliable-use-rssitof-judge-distance-advantages-ranging-yong-lee>
- Mejía. (2021). *Terabee*. Obtenido de <https://www.terabee.com/time-of-flight-principle/>
- Pozo, M. (2019). *Evaluación y comparación de algoritmos de posicionamiento basados en tecnología Ultra Wide Band*.
- Qorvo. (s.f.). *Qorvo*. Obtenido de <https://www.qorvo.com/products/d/da007950>
- Rahayu, Y. R. (2008). *Ultra wideband technology and its applications*.

Rfwireless-world.com. (s.f.). Obtenido de Advantages of Bluetooth: <https://www.rfwireless-world.com/Terminology/Bluetooth-advantages-and-disadvantages.html>

Rfwireless-world.com. (s.f.). Obtenido de Advantages and disadvantages of UWB.: <https://www.rfwireless-world.com/Terminology/Advantages-and-disadvantages-of-UWB.html>

Rfwireless-world.com. (s.f.). Obtenido de Advantages and Disadvantages of wireless communication: <https://www.rfwireless-world.com/Terminology/Advantages-and-Disadvantages-of-wireless-communication.html>.

Santhanam, M. (. (s.f.).

Santhanam, M. (s.f.). *Uwb technology and its applications – a survey*. Obtenido de <https://www.diva-portal.org/smash/get/diva2:469434/FULLTEXT01.pdf>

Shojaifar, A. U. (s.f.). *Evaluation and Improvement of the RSSI- based Localization Algorithm*. Obtenido de <https://www.diva-portal.org/smash/get/diva>

Villalba. (2018). *Sistema de Posicionamiento en Interiores*. Universidad Técnica de Madrid.

Woxuwireless. (s.f.). Obtenido de https://uwb.woxuwireless.com/views/blog/UWB_Localization.html

Yang, Z. Z. (2013).). *From RSSI to CSI: Indoor localization via channel response*.