



Universidad
Nacional
de Loja

1859
Universidad Nacional de Loja

**Facultad de la Energía, las Industrias y los Recursos Naturales no
Renovables**

Maestría en Telecomunicaciones

**Evaluación de modelos de predicción para localización de usuarios en
entornos de interiores de redes móviles 5G en bandas milimétricas
(mmWave).**

**Trabajo de Titulación previo a la
obtención del título de Magister en
Telecomunicaciones.**

AUTOR:

Ing. Alexis Damian Campoverde Romero

DIRECTOR:

Ing. Renato Benjamín Torres Carrión, Mg. Sc.

Loja-Ecuador

2024

Certificación

Loja, 22 de septiembre de 2024

Ing. Renato Benjamín Torres Carrión Mg, Sc.

DIRECTOR DEL TRABAJO DE TITULACIÓN

Certifico:

Que he revisado y orientado todo proceso de la elaboración del Trabajo de Titulación denominado: Evaluación de modelos de predicción para localización de usuarios en entornos de interiores de redes móviles 5G en bandas milimétricas (mmWave), previo a la obtención del título de **Magister en Telecomunicaciones**, de la autoría del estudiante Alexis Damian Campoverde Romero, con **cédula de identidad N° 1105079022**, una vez que el trabajo cumple con todos los requisitos exigidos por la Universidad Nacional de Loja para el efecto, autorizo la presentación para respectiva sustentación y defensa.

Ing. Renato Benjamín Torres Carrión Mg, Sc.

DIRECTOR DEL TRABAJO DE TITULACIÓN



Autoría

Yo, Alexis Damian Campoverde Romero, declaro ser autor del Trabajo de Titulación y eximo expresamente a la Universidad Nacional de Loja y a sus representantes jurídicos de posibles reclamos y acciones legales, por el contenido del mismo. Adicionalmente acepto y autorizo a la Universidad Nacional de Loja la publicación del Trabajo de Titulación en el Repositorio Digital Institucional- Biblioteca Virtual.

Firma:


Autor: Alexis Damian Campoverde Romero

Cédula de Identidad: 1105079022

Fecha: 22 de septiembre de 2024

Correo electrónico: alexis.campoverde@unl.edu.ec

Teléfono: 0981230906





Carta de autorización por parte del autor, para consulta, reproducción parcial o total y/o publicación electrónica de texto completo, del Trabajo de Titulación.

Yo, Alexis Damian Campoverde Romero, declaro ser autor del Trabajo de Titulación denominado: Evaluación de modelos de predicción para localización de usuarios en entornos de interiores de redes móviles 5G en bandas milimétricas (mmWave), como requisito para optar el título de Magíster Telecomunicaciones, autorizo al sistema Bibliotecario de la Universidad Nacional de Loja para que con fines académicos muestre la producción intelectual de la Universidad, a través de la visibilidad de su contenido de la siguiente manera en el Repositorio Institucional.

Los usuarios pueden consultar el contenido de este trabajo en el Repositorio Institucional, en las redes de información del país y del exterior con las cuales tenga convenio la Universidad.

La Universidad Nacional de Loja, no se responsabiliza por el plagio o copia del Trabajo de Titulación que realice un tercero.

Para constancia de esta autorización, suscribo, en la ciudad de Loja, a los veinte días del mes de septiembre de dos mil veinticuatro.

Firma:

Autor: Alexis Damian Campoverde Romero

Cédula de Identidad: 1105079022

Correo electrónico: alexis.campoverde@unl.edu.ec

Teléfono: 0981230906

DATOS COMPLEMENTARIOS:

Director del Trabajo de Titulación: Ing. Renato Benjamín Torres Carrión Mg. Sc.

Dedicatoria

Este trabajo de investigación es un tributo sincero a las personas que han sido mi brújula y mi ancla a lo largo de esta travesía. A mi familia, amigos y colegas, les debo el más profundo agradecimiento por su sabiduría y paciencia, por las correcciones que construyeron mi camino y por la constante inspiración que me impulsó a alcanzar nuevas alturas.

A mis padres, Lorena y Víctor Hugo, su amor incondicional y su fe inquebrantable en mí han sido las estrellas que iluminaron mi sendero. Su apoyo no solo ha sido el cimiento de mis logros, sino también el abrazo que me sostuvo en los momentos de duda. Este trabajo es, un reflejo del sacrificio y la dedicación que ustedes han invertido en mí, y es mi más sincero agradecimiento por haberme dado las alas para volar.

Dedicado a todos aquellos que no se rinden y que buscan nuevos horizontes haciendo lo que les gusta y apasiona.

Alexis Damian Campoverde Romero

Agradecimiento

A Dios, por guiarme en el camino de la vida.

A mi director de trabajo de fin de titulación, magister Renato Benjamín Torres Carrión, por orientarme en cada etapa de la investigación, por la motivación y paciencia para lograr todos los objetivos planteados.

A Sarita, cuya amistad sincera y constante ha sido una fuente de apoyo invaluable a lo largo de mi vida. Su compañía y sabias palabras han hecho una gran diferencia en mis días.

A Nico, por su amor, paciencia y dedicación inquebrantables, que ha sido una de las fuerzas impulsoras detrás de este gran logro. Su presencia constante y sus palabras de aliento han añadido una nueva profundidad y esplendor a mi vida, realzando cada momento con significado y belleza que solo ella puede ofrecer.

Alexis Damian Campoverde Romero

Índice de Contenidos

Portada.....	i
Certificación.....	ii
Autoría.....	iii
Carta de autorización por parte del autor, para consulta, reproducción parcial o total y/o publicación electrónica de texto completo, del Trabajo de Titulación.	iv
Dedicatoria.....	v
Agradecimiento.....	vi
Índice de Contenidos.....	vii
Índice de figuras:.....	ix
Índice de Anexos:.....	x
Lista de abreviaturas:.....	xi
1. Título.....	1
2. Resumen.....	2
Abstract.....	3
3. Introducción.....	4
4. Marco Teórico.....	8
4.1 Uso de ondas milimétricas (mmWave).....	8
4.1.1 Pérdidas por espacio libre.....	9
4.2 Modelos de aprendizaje automático para predicción de trayectoria y posicionamiento.....	10
4.2.1 Red neuronal con memoria de largo y corto plazo.....	11
4.2.2 Q-Learning.....	12
4.2.3 Algoritmos Genéticos.....	13
4.2.4 Random Forest.....	14
4.3 Técnicas de aprendizaje para posicionamiento en interiores.....	16
4.3.1 Tiempo de arribo y diferencia de tiempo de arribo.....	16
5. Metodología.....	23
5.1 Revisión sistemática de literatura.....	23
5.2 Desarrollo.....	24
5.2.1 Obtención de coordenadas de los UEs.....	25
5.2.2 Modelamiento de la red neuronal artificial.....	28
6. Resultados.....	30
7. Discusión.....	36
8. Conclusiones.....	39
9. Recomendaciones.....	41

10. Bibliografía	43
11. Anexos	46

Índice de figuras:

Figura 1. Clasificación de las redes inalámbricas.	5
Figura 2. Espectro radioeléctrico disponible para la tecnología 5G en distintas bandas..	8
Figura 3 Estructura de red neuronal con memoria de corto y largo plazo	11
Figura 4 Estructura del algoritmo Q learning.....	12
Figura 5 Tabla Q del algoritmo de Q learning	13
Figura 6 Estructura básica del funcionamiento de un algoritmo genético	14
Figura 7 Esquema de predicción Algoritmo Random Forest	15
Figura 8 Técnica de localización ToA(a), TDoA (b)	17
Figura 9 Técnica de localización AoA	18
Figura 10 Diagrama Prisma para la revisión sistemática de literatura	24
Figura 11 Concentración de usuarios hacia el punto de encuentro en el step 14.....	26
Figura 12 Centro Comercial de Málaga.....	27
Figura 13 UEs desplegados sobre el escenario establecido.....	28
Figura 14 Trayectoria de 10 usuarios hacia el punto de concentración.....	30
Figura 15 Posiciones reales versus la predicción de cada usuario.....	31
Figura 16 Pérdida de entrenamiento y validación en función de las épocas	32
Figura 17 Error cuadrático medio por usuario del algoritmo LSTM.....	33
Figura 18 Resultados de la predicción con el algoritmo Random Forest	34
Figura 19 Gráfica comparativa entre los valores de RMSE de los algoritmos LSMT y Random Forest	34

Índice de Anexos:

Anexos 1 Algoritmo LSMT	46
Anexos 2. Algoritmo Random Forest	51
Anexos 3. Certificado de traducción del resumen	53

Lista de abreviaturas:

Gbps Gigabits por segundo

NGNM Next generation mobile network

UE User equipment

SINR Signal interference noise ratio

GNSS Global navigation satellite system

ToA Time of arrival

AoA Angle of arrival

TDoA Time difference of arrival

RSSI Received Signal Interferencia indicator

RSRP Reference signal received power

CSI Channel state indicator

GPS Global positioning system

mmWave Millimeter wave

GHz Giga hertz

D2D Device to device

BS Base Station

ANN Artificial Neural Networks

ML Machine learning

LOS Line of sight

NLOS No line of sight

IA Inteligencia artificial

RNN Recurrent neural network

LSTM Long short term memory

1. Título

Evaluación de modelos de predicción para localización de usuarios en entornos de interiores de redes móviles 5G en bandas milimétricas (mmWave).

2. Resumen

En este trabajo investigativo se aborda la evolución y los desafíos del posicionamiento de dispositivos en redes móviles de quinta generación (5G), enfocándose en la mejora de la velocidad de transmisión y la precisión en entornos interiores. Con la tecnología 5G superando los 10 Gbps en velocidad teórica, se acerca la visión de un mundo interconectado en tiempo real. Sin embargo, la demanda creciente de servicios digitales y la necesidad de una geolocalización precisa de los dispositivos exigen una infraestructura avanzada capaz de soportar un mayor número de conexiones y mejorar la experiencia del usuario.

El estudio explora cómo las ondas milimétricas (mmWave), esenciales para el 5G, ofrecen altas tasas de datos, pero enfrentan desafíos en la propagación debido a su atenuación por obstáculos en interiores. Se revisan técnicas de posicionamiento como Time of Arrival (TOA), Time Difference of Arrival (TDOA), y Ángulo de Arribo (AoA), así como el uso de técnicas de aprendizaje automático y modelos de redes neuronales artificiales para mejorar la precisión en escenarios complejos.

El análisis del estado del arte revela que, aunque las mmWave permiten velocidades de transmisión rápidas, su uso se ve limitado por problemas como la pérdida de señal en entornos interiores y la interferencia de obstáculos. Para superar estos desafíos, se destacan técnicas avanzadas de posicionamiento y modelos de predicción basados en redes neuronales, que permiten una mayor precisión y eficiencia en la localización de dispositivos. A pesar de las mejoras que proporcionan las ondas milimétricas y técnicas avanzadas como MIMO masivo y beamforming, la señal puede atenuarse debido a obstáculos y a la acumulación de dispositivos. Estos desafíos destacan la importancia de un posicionamiento preciso en interiores para optimizar los recursos radioeléctricos y reducir el consumo energético en redes 5G.

Finalmente, se propone un modelo de red neuronal para la predicción de trayectoria.

Palabras Clave: *mmWave, 5G, posicionamiento, predicción de trayectoria, posicionamiento indoor.*

Abstract

This research addresses the evolution and challenges of device positioning in fifth-generation (5G) mobile networks, focusing on improving transmission speed and accuracy in indoor environments. With 5G technology surpassing 10 Gbps in theoretical speed, the vision of a real-time interconnected world is becoming closer. However, the growing demand for digital services and the need for precise geolocation of devices require advanced infrastructure capable of supporting a higher number of connections and enhancing user experience.

The study explores how millimeter waves (mmWave), essential for 5G, offer high data rates but face challenges in propagation due to attenuation from indoor obstacles. Positioning techniques such as Time of Arrival (TOA), Time Difference of Arrival (TDOA), and Angle of Arrival (AoA) are reviewed, along with the use of machine learning techniques and artificial neural network models to improve accuracy in complex scenarios.

The state of the art analysis reveals that, although mmWave enables fast transmission speeds, its use is limited by issues such as signal loss in indoor environments and interference from obstacles. To address these challenges, advanced positioning techniques and prediction models based on neural networks are highlighted, which allow for greater accuracy and efficiency in device localization. Despite the improvements provided by millimeter waves and advanced techniques such as massive MIMO and beamforming, the signal can be attenuated due to obstacles and device accumulation. These challenges underscore the importance of precise indoor positioning to optimize radio resources and reduce energy consumption in 5G networks.

Finally, a neural network model for trajectory prediction in indoor environments is proposed, demonstrating that the combined use of mmWave and machine learning can significantly optimize localization and resource management in 5G networks.

Key words: mmWave, 5G, positioning, trajectory prediction, indoor positioning.

3. Introducción

La evolución de las distintas generaciones de tecnologías utilizadas en sistemas móviles, han tenido un avance prometedor en cuanto a velocidad de transmisión se refiere. Los avances tecnológicos han permitido que la velocidad de transmisión teórica de la tecnología 5G, supere el orden de giga bits por segundo (Gbps). Con ello, la visión de un mundo interconectado en tiempo real a través de internet es cada vez más cercano (Gasanz i De León, 2022). La demanda de los servicios de voz, video y entretenimiento crecen continuamente debido a la constante necesidad de estar conectado a internet y la adaptación de la población al contenido digital. Por ello es necesario conocer la ubicación de los dispositivos para brindar una mejor experiencia de usuario.

Ante tal demanda, la infraestructura de las redes móviles de siguiente generación (next generation mobile network, NGMN) deberá ser capaz de soportar el incremento de dispositivos conectados a la red. La NGMN proveerá de servicios más rápidos, seguros y confiables en donde la velocidad de transmisión será mayor a 10 Gbps inclusive en escenarios de interiores como edificios, disminuyendo las interferencias electromagnéticas y permitiendo que servicios de posicionamiento sean más precisos con errores menores de hasta 1 metro (Shi et al., 2020).


El posicionamiento o geolocalización de los equipos de usuarios (user equipment, UE) es imprescindible en la tecnología de quinta generación debido a la conservación de energía y menor uso de recursos, en donde se le provee determinados recursos a cada UE de forma óptima; reduciendo así el consumo de energía, mejorando la relación señal a ruido más interferencia (signal interference noise ratio, SINR), aumentando la tasa de transmisión de datos, permitiendo que la red sea más eficiente.

En este sentido, es necesario determinar de manera precisa la ubicación de los UEs, prevaleciendo en escenarios de interiores. Si bien, el posicionamiento de un UE en escenarios exteriores se lo puede determinar haciendo uso del sistema global de navegación por satélite (global navigation satellite system, GNSS), en escenarios de interiores el posicionamiento se dificulta debido a las condiciones de propagación del escenario (Han & Peng, 2023). Para este caso es necesario el uso de diferentes técnicas de posicionamiento, como el tiempo de arribo de la señal (ToA), ángulo de arribo de ondas de radio (AoA), indicador de intensidad de la señal recibida desde la estación base hasta el UE (RRSI), nivel de referencia de potencia de señal recibida (RSRP), determinación de posicionamiento por geometría, información de estado de

canal (CSI) y múltiples haces de radiación de la antena transmisora con respecto del UE (Rastorgueva-Foi et al., 2018).

La importancia y precisión del posicionamiento de los UEs en la tecnología 5G radica en el tiempo de respuesta y velocidad de transmisión para el control y actuación en tiempo real ante los requerimientos de diversos escenarios como vehículos autónomos, sistemas basados en la nube, internet de las cosas, telemedicina entre otros. En sistemas convencionales como el sistema de posicionamiento global (global positioning system, GPS) y el GNSS, la precisión del posicionamiento es baja, llegando a errores de más de 10 metros. Para mejorar la precisión de posicionamiento se ha investigado el uso de técnicas y métodos como el uso de ondas milimétricas (mmWave) con frecuencias de entre 25 GHz y 60 GHz, MIMO masivo, beamforming, comunicaciones dispositivo a dispositivo (D2D), las cuales han permitido mejorar el desempeño de la red de manera eficiente y la precisión de posicionamiento.

Figura 1
Clasificación de las redes inalámbricas.



Tomado de (*Guide Des Fonctionnalités de Positionnement AoA | Mines, n.d.*)

El principal factor que se debe tomar en cuenta sobre el empleo de ondas milimétricas y frecuencias altas es la masiva ocupación del espectro radioeléctrico por debajo de los 6 GHz. Por otro lado, el uso de mmWave permite aumentar considerablemente la cantidad de antenas en un arreglo, mejorando la ganancia total del arreglo de antenas en una estación base (base station, BS), permitiendo el uso de nuevas técnicas de transmisión, aumentando el ancho de banda y la velocidad de transmisión. Si bien, las diversas técnicas de transmisión permiten acondicionar los lóbulos de radiación de las antenas de la BS, la señal emitida no puede penetrar

estructuras de determinados materiales. Como consecuencia de esto, la señal emitida se atenúa considerablemente (Giordani et al., 2016).

A pesar de que el empleo de mmWave mejora radicalmente la velocidad de transmisión, su empleo se ve limitado por la cantidad de obstáculos que existen en escenarios de interiores, por la acumulación de UEs en determinados puntos, por la velocidad a la que los UEs se desplazan, por la propagación por multitrayecto (multipath), el desvanecimiento de la señal y la propagación sin línea de vista. La acumulación de todos estos factores no debe pasar por desapercibida al modelar un sistema que permita el posicionamiento de UEs en este tipo de escenarios, es ahí donde se corrobora la importancia del posicionamiento de UEs en escenarios de interiores, con lo cual mejorarán los recursos radio de las Bs además de, reducir considerablemente el consumo energético de los equipos de usuario (Han & Peng, 2023).

En este estudio se detallan los siguientes apartados: en el estado del arte se describen los trabajos relacionados, en el apartado de metodología se expone el desarrollo del trabajo de investigación y el modelo de red neuronal creado para predicción de trayectoria. Seguidamente se exponen los resultados obtenidos y se los discute para llegar a las distintas conclusiones enfocadas en cada uno de los objetivos planteados.

Objetivos

Objetivo general

Evaluar modelos de predicción para localización de usuarios en entornos interiores de redes móviles 5G en bandas milimétricas

Objetivos específicos

- Analizar el estado del arte de la tecnología 5G, en especial aquellos trabajos que permitan la caracterización de escenarios de propagación en escenarios interiores, utilizando ondas milimétricas (mmwaves).
- Simular a nivel de sistema del escenario característico, para la obtención de datos y entrenamiento basado en algoritmos de aprendizaje máquina (Genetic algorithm, LSTM, Q-learning, Random Forest)
- Evaluar los modelos de predicción propuestos, validarlos con pruebas de simulación y comparar los resultados obtenidos.

4. Marco Teórico

En el siguiente apartado se recopilan los trabajos relacionados al posicionamiento de UEs, con mayor énfasis en trabajos relacionados con el uso de mmWave y técnicas de predicción de posicionamiento con modelos de aprendizajes con base en redes neuronales artificiales (Artificial Neural Networks, ANN) y machine learning (Machine Learning, ML) en escenarios de interiores haciendo uso de ondas milimétricas.

4.1 Uso de ondas milimétricas (mmWave)

Las mmWaves cuyas frecuencias de operación de entre 30 GHz y 300 GHz son fundamentales para el despliegue de la tecnología de quinta generación. En donde el espectro radio eléctrico utilizado inicia en 6 GHz, considerando el rango de frecuencias desde 24,25 GHz hasta 52,6 GHz como la banda de orden milimétrico, con ancho de banda entre 50 MHz y 400 MHz (Del Peral-Rosado et al., 2018), como se observa en la figura 2.

Figura 2

Espectro radioeléctrico disponible para la tecnología 5G en distintas bandas

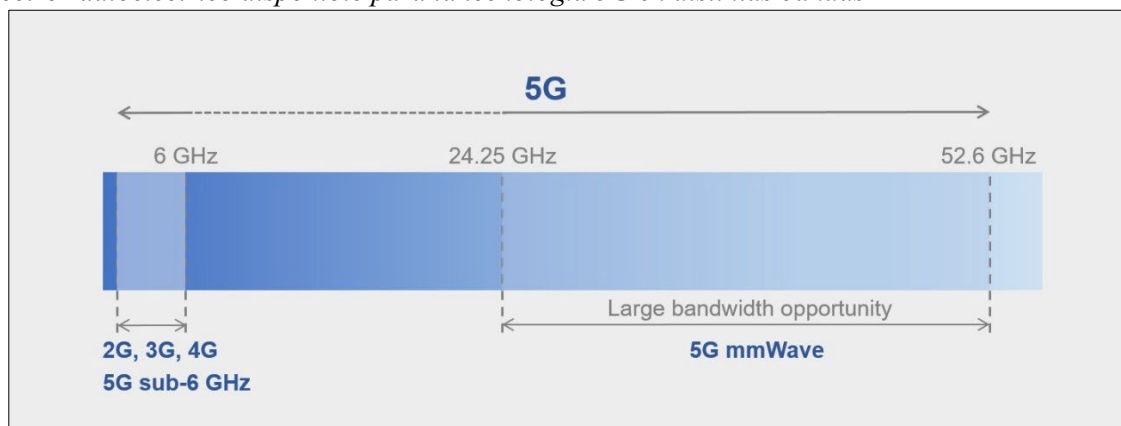


Figura tomada de (Gasanz i De León, 2022))

Si bien, las bandas de frecuencia de mmWave permiten un rendimiento (throughput) de alta velocidad, se atenúan notablemente ante cualquier variación física que se presente, además de reflejarse en la mayoría de los obstáculos visibles que se interpongan en la trayectoria de propagación de la señal.

Las tecnologías de mmWave mejoran las comunicaciones inalámbricas al permitir altas tasas de datos y baja latencia, lo cual es crucial para aplicaciones como la realidad aumentada

(AR). Estas aplicaciones generan información adicional en tiempo real, que se entrega al usuario de manera inmediata. Para lograr esto, se utilizan plataformas de computación en el borde asociadas a puntos de acceso mmWave, lo que permite procesar y entregar la información cerca del usuario, cumpliendo con los requisitos de baja latencia necesarios para una experiencia fluida (Sakaguchi et al., 2017).

4.1.1 Pérdidas por espacio libre

La propagación de las distintas señales electromagnéticas se degrada a medida que aumenta la distancia y por ende la relación señal a ruido empeora. En escenarios de interiores el trayecto de estas señales se puede ver obstaculizadas por distintos factores como el material y la estructura de las paredes, la ubicación, cantidad de obstáculos, y la velocidad de los terminales.

Para la localización en entornos de interiores, las características del canal son importantes para definir con precisión los parámetros de predicción de ubicación, lo que a su vez afecta la exactitud del posicionamiento. Es de suma importancia entender el entorno operativo del sistema de comunicación antes de modelar el canal inalámbrico. Los escenarios específicos de localización permiten una evaluación más precisa y eficiente. En entornos interiores, el canal inalámbrico se caracteriza por una alta aleatoriedad debido a la densa red de estaciones base 5G, la presencia de obstáculos y el movimiento impredecible de los terminales, lo que complica el proceso de modelado (Han & Peng, 2023).

Otro factor importante que afecta el canal inalámbrico en interiores es el efecto de multi trayecto. Este fenómeno ocurre cuando la señal toma diferentes trayectos durante su propagación, lo que hace que se recepan varias versiones de la misma señal, provocando interferencias. El efecto de multi trayecto es notable en entornos de interiores, donde las señales se reflejan, refractan y dispersan entre las estructuras y obstáculos, creando así múltiples trayectorias (Luque Quispe, 2020).

El modelo de pérdida de trayectoria para un entorno de interiores, que considera la distancia tridimensional entre el UE y la BS, usa una variable aleatoria gaussiana con media cero y una desviación estándar σ . Esta desviación estándar depende de si hay o no una línea de vista (line of sight, LOS) entre el UE y la BS. Si existe una LOS, la desviación estándar considera un valor de 3.0. Si no existe una LOS (no line of sight, NLOS), la desviación estándar considera un valor de 8.03.

El modelo de pérdida de trayectoria para NLOS se calcula usando una fórmula específica. Sin embargo Alhory et al., (2020), en su trabajo de investigación menciona que el modelo de pérdida de trayectoria para NLOS representado en esa fórmula no está ajustado.

Por ello, las ecuaciones utilizadas para LOS y NLOS quedan como sigue:

$$PL_{LOS} = 32.4 + 17.3 \log_{10}(d3D) + 20 \log_{10}(fc) + X(\mu, \sigma) \quad (1)$$

$$PL'_{NLOS} = 17.30 + 38.3 \log_{10}(d3D) + 24.9 \log_{10}(fc) + X(\mu, \sigma) \quad (2)$$

$$PL_{NLOS} = \max(PL_{LOS}, PL'_{NLOS}) \quad (3)$$

4.2 Modelos de aprendizaje automático para predicción de trayectoria y posicionamiento

El uso de sistemas de posicionamiento basados en 5G, combinados con redes neuronales convolucionales (Convolutional neural network, CNN), se está explorando como una alternativa prometedora a las tecnologías de posicionamiento interior existentes. Estas tecnologías son cruciales en entornos industriales, donde la precisión en la localización de activos es esencial para la eficiencia operativa. El enfoque de aprendizaje automático mediante CNN permite que el sistema aprenda a calcular la posición del emisor directamente a partir de la señal recibida, lo que podría mejorar la precisión en condiciones cambiantes y en posiciones NLOS durante el entrenamiento. Este enfoque también sugiere que es posible entrenar un modelo de CNN que no dependa de un mapeo directo entre huellas y ubicaciones, lo que podría ser crucial para mejorar la robustez del sistema en entornos dinámicos.

La inteligencia artificial (Inteligencia artificial, IA) es una disciplina dedicada a crear sistemas y máquinas que puedan replicar las capacidades cognitivas humanas, en donde se hace uso de algoritmos y técnicas avanzadas para que las máquinas puedan realizar tareas que normalmente requieren habilidades humanas, tales como el razonamiento y el aprendizaje. El objetivo principal es crear sistemas que puedan interpretar, aprender y tomar decisiones de manera similar a como lo haría un ser humano.

Por otro lado, las redes neuronales recurrentes (Recurrent Neural Networks, RNN) son redes creadas para trabajar con datos de tipo secuenciales. Gracias a esa recurrencia existente de tipo bucle, la red puede almacenar información a lo largo de la secuencia de datos para futuras operaciones o actuaciones de acuerdo con su configuración (Lu, 2019).

4.2.1 Red neuronal con memoria de largo y corto plazo

La red neuronal LSTM (Long Short Term Memory, LSTM) es una técnica que permite predecir series temporales a lo largo del tiempo, proporcionando una alta precisión de predicción. Siendo esta una versión mejorada de las RNN con mejor capacidad de retención de información ya que cuentan con bloques de memoria.

Es un tipo de red neuronal recurrente diseñada para aprender dependencias a largo plazo en secuencias de datos. A diferencia de las RNN tradicionales, que pueden tener problemas con el desvanecimiento del gradiente, las redes LSTM utilizan una estructura de puerta que permite controlar el flujo de información. Esta estructura incluye la puerta de entrada, la puerta de salida y la puerta de olvido, que ayudan a decidir qué información se debe mantener o descartar a lo largo del tiempo como se puede observar en la figura 3.

Figura 3
Estructura de red neuronal con memoria de corto y largo plazo

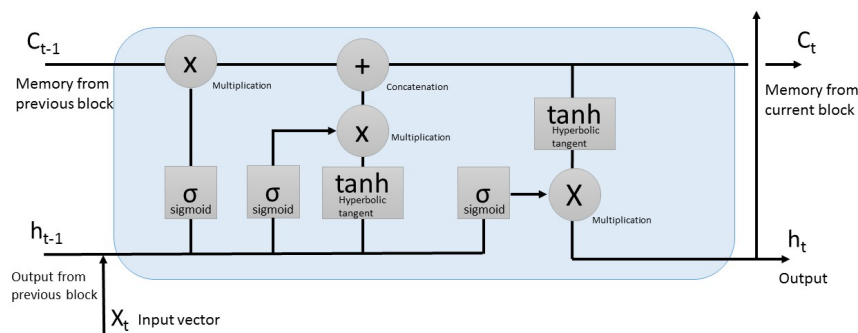



Figura tomada de (Violos et al., 2020)

Son útiles en tareas como el procesamiento de lenguaje natural y la predicción de series temporales, donde es crucial recordar información de eventos pasados, sin embargo, su entrenamiento puede ser más lento debido a la complejidad de su arquitectura, lo que a menudo requiere más tiempo de computación en comparación con otras redes neuronales más simples (Chin et al., 2020).

A continuación, se describe en un flujograma el algoritmo que se implementará, el cual detalla de manera secuencial los pasos necesarios para llevar a cabo el proceso en estudio. Este algoritmo no solo establece la lógica detrás de la solución propuesta, sino que también permite visualizar de forma clara y ordenada las interacciones y decisiones involucradas. La

representación en flujograma facilitará la comprensión de las distintas etapas del procedimiento, así como la identificación de posibles áreas de mejora y optimización en la implementación de este.



4.2.2 Q-Learning

Q-learning es una técnica de aprendizaje automático que permite a un agente mejorar sus decisiones a medida que interactúa con su entorno, en lugar de seguir reglas predefinidas, el agente aprende a encontrar las mejores acciones para tomar en diferentes situaciones a través de la experiencia y la retroalimentación. Este método se basa en la idea de que el agente puede aprender una función de valor, conocida como función Q, que estima la calidad de una acción en un estado determinado. La función Q se actualiza iterativamente a medida que el agente explora el entorno y recibe recompensas o penalizaciones por sus acciones como se puede observar en la figura 4.

Figura 4
Estructura del algoritmo Q learning





Figura tomada de (Hattem & Foudil, 2007)

El algoritmo utiliza una tabla Q , donde cada entrada representa el valor de una acción específica en un estado dado como se puede ver en la figura 5. A través de la exploración y la explotación, el agente ajusta los valores en la tabla Q utilizando la ecuación de Bellman, que combina la recompensa inmediata con el valor futuro esperado de las acciones, esto permite al agente aprender políticas que maximizan la recompensa total a largo plazo. Es útil en problemas donde el modelo del entorno no es conocido, y se puede aplicar en diversas áreas, como robótica, juegos y optimización de procesos (Wang et al., 2019).

Figura 5
Tabla Q del algoritmo de Q learning



4.2.3 Algoritmos Genéticos

Los algoritmos genéticos son técnicas de optimización que se basan en los principios de la evolución biológica, como la selección natural y la herencia genética. En lugar de evaluar cada posible solución a un problema uno por uno, estos algoritmos utilizan estrategias inspiradas en la biología para encontrar la mejor solución posible.

Los algoritmos genéticos son técnicas de optimización inspiradas en la biología evolutiva, que utilizan mecanismos similares a la selección natural, el cruzamiento y la mutación para

resolver problemas complejos. Representan las soluciones potenciales como cromosomas, evaluando su calidad mediante una función de aptitud. En cada generación, los cromosomas más aptos se seleccionan para reproducirse, combinándose mediante cruzamiento y alterándose con mutación para explorar nuevas áreas del espacio de soluciones como se puede observar en la figura 6. Este proceso iterativo de selección, cruzamiento y mutación continúa hasta que se alcanza una solución satisfactoria o se cumple un criterio de parada, como un número máximo de generaciones. Los algoritmos genéticos son eficaces para explorar grandes espacios de soluciones y encontrar óptimos globales en problemas complejos y no lineales (*Algoritmos Genéticos. Daniel Gutiérrez, 2023.*).

Figura 6
Estructura básica del funcionamiento de un algoritmo genético




Figura tomada de (da Cunha Pires Soeiro et al., 2023)

4.2.4 Random Forest

El algoritmo de Random Forest, presentado por (Breiman, 2001), ha demostrado ser extremadamente eficaz como una técnica general para clasificación y regresión. Este método, que combina múltiples árboles de decisión aleatorios y promedia sus predicciones, ha mostrado un rendimiento sobresaliente en situaciones donde hay muchas más variables que observaciones. Además, su versatilidad le permite aplicarse a problemas a gran escala, adaptarse a diversas tareas específicas y proporcionar medidas sobre la importancia de las variables. El proceso consiste en crear automáticamente varios árboles de decisión a partir de un conjunto de datos de entrenamiento que tiene n observaciones y m variables explicativas.

Cada árbol se construye dividiendo los datos en nodos sucesivos, utilizando la variable que más reduce la desigualdad de Gini en cada división. Estos árboles se desarrollan hasta su nivel máximo sin recortes, lo que permite captar patrones muy complejos. Sin embargo, este enfoque puede llevar a un sobreajuste de los datos con los que se entrena.

Figura 7
Esquema de predicción Algoritmo Random Forest





Figura tomada de (Segura et al., 2022).

A continuación, se describe en un flujograma el algoritmo que se implementará, el cual detalla de manera secuencial los pasos necesarios para llevar a cabo el proceso en estudio. Este algoritmo no solo establece la lógica detrás de la solución propuesta, sino que también permite visualizar de forma clara y ordenada las interacciones y decisiones involucradas. La representación en flujograma facilitará la comprensión de las distintas etapas del procedimiento, así como la identificación de posibles áreas de mejora y optimización en la implementación de este.



4.3 Técnicas de aprendizaje para posicionamiento en interiores

A medida que el número de dispositivos móviles aumenta, el tráfico total y la demanda por mayor velocidad de navegación también lo hace. En tecnologías inferiores a la quinta generación (5G), la emisión y propagación de las señales de radio desde las BS se dan con presencia o ausencia de dispositivos conectados a dicha BS. Entendido esto, dicha propagación representa un gasto innecesario de recursos de la red. Gracias al avance tecnológico, con ayuda de ML, ANN y la inteligencia artificial (IA) se podrá conocer la ubicación exacta y posterior del dispositivo dentro de la red y así gestionar eficientemente los recursos en función de la de la carga, demanda y servicios.

4.3.1 Tiempo de arribo y diferencia de tiempo de arribo

El TOA (Time of arrival, TOA) se puede medir cuando una señal es enviada por el UE y recibida en varias BSs. A partir de estas mediciones, se pueden estimar las distancias desde cada estación base multiplicando por la velocidad de la luz, cada medición de TOA genera un círculo en el que podría encontrarse el UE, y luego se puede usar el método de lateración para determinar la ubicación exacta (Shamaei & Kassas, 2021).

Por otro lado, el TDoA (Time difference of arrival, TDOA) se mide cuando la señal transmitida es recibida en pares de BS. Una medición de TDOA define una hipérbola, en la que el dispositivo puede estar ubicado en uno de los focos, que son dos de las BS, se elige una BS

como referencia para obtener las mediciones de TDOA respecto a las otras BSs (Sheikh et al., 2021).

A diferencia del TOA, no es necesario conocer el tiempo exacto de la transmisión de la señal, lo que facilita el proceso al evitar problemas con la sincronización precisa de los relojes entre las estaciones base.

Figura 8
Técnica de localización ToA(a), TDoA (b)




Figura tomada de (Brena et al., 2017)

4.3.2 Ángulo de arribo (AoA)

La técnica de posicionamiento de ángulo de arribo (ángulo de arribo, AoA) utiliza relaciones geométricas simples para estimar la ubicación del usuario en la intersección de las líneas formadas al medir los ángulos de llegada de las señales de radio intercambiadas entre el UE y varias estaciones base (BS), esta técnica se conoce como triangulación (Arbula & Ljubic, 2020).

El AoA se puede medir con la ayuda de antenas directivas o arreglos de antenas, mientras que se requieren al menos dos estaciones base para determinar la ubicación en 2D como se observa en la figura 8 (Laoudias et al., 2018).

Figura 9
Técnica de localización AoA




Figura tomada de (Xu, 2021).

La técnica de posicionamiento AoA utiliza antenas en arreglo para calcular las señales que llegan a diferentes antenas y así determinar la ubicación precisa, sin embargo, lograr una alta precisión con este método presenta varios desafíos. La dificultad principal radica en cómo se organiza el arreglo de antenas, cómo se eliminan las señales de ruido y cómo se maneja el tiempo de conmutación de RF (Xu, 2021).

4.3.3 Intensidad de señal recibida (Received Signal Strength, RSS)

Las técnicas de localización que utilizan RSS miden la intensidad de la señal en dB, desde un nodo hacia varios dispositivos. Esta información se combina con un modelo de propagación para calcular la distancia entre el nodo y los dispositivos.

Esta técnica tiene limitaciones en cuanto a precisión debido al entorno en la propagación de las señales de radio. Para mejorar la precisión, el mapa de RSS, que traduce la intensidad de la señal en estimaciones de distancia, necesita calibrarse para cada antena individual.

Idealmente, esto se haría midiendo los valores de RSSI en todos los puntos de referencia posibles y actualizando el mapa regularmente, sin embargo, esto no es práctico en entornos que cambian constantemente y son complejos (Arigye et al., 2022).

4.3.4 Proximidad

La técnica de localización por proximidad se basa en nodos emisores de radiofrecuencia (RF) para determinar cuándo un receptor está dentro del alcance de un emisor. Al detectar que la intensidad de la señal recibida (Received Signal Strength, RSS) supera un umbral establecido,

se considera que el nodo con la señal más fuerte es el más cercano, los umbrales de recepción se pueden ajustar para identificar la ubicación de un objeto en áreas definidas como inmediata, cercana o lejana (Hayward et al., 2022).

4.3.5 Trabajos relacionados

En su trabajo Mogyorósi et al., (2022), menciona que, se puede utilizar la señal de downlink y uplink para determinar la posición del UE. El posicionamiento se lo puede determinar mediante técnicas de triangulación, en donde se toma como referencia la ubicación del UE en determinada área de cobertura conociendo la ubicación de la BS, el cual solo se puede realizar en escenarios de exteriores y no densos. Por lo cual, también menciona que se puede hacer uso de las técnicas de localización basadas en el ángulo de arribo de la señal (angle of arrival, AoA), el ángulo de partida de la señal (angle of departure, AoD) o los dos en conjunto, tanto en el uplink como en el downlink mediante el nivel de señal recibida (received signal strength, RSS).

Por su parte Alhory et al., (2020), presenta un enfoque geométrico novedoso para la identificación de ubicación en interiores utilizando tecnología 5G de onda milimétrica (mmWave), centrándose en la formación de haces y el Indicador de Fuerza de Señal Recibida (RSSI). El modelo propuesto, conocido como Modelo de Haz Único (Single beam model, SBM), permite que un dispositivo móvil determine con precisión su ubicación en entornos interiores al seleccionar el mejor haz de múltiples estaciones base y utilizar datos de RSSI. El modelo fue validado a través de simulaciones, logrando un error promedio de distancia de 1.7 metros para dispositivos estacionarios y 2.4 metros para dispositivos móviles. A demás se destacan los desafíos de la localización en interiores debido a la pérdida de señal y la dispersión multipath, y enfatiza la eficiencia del SBM en la reducción de sobrecarga y complejidad en comparación con métodos existentes. El artículo está estructurado para proporcionar antecedentes sobre sistemas 5G en interiores, trabajos relacionados, detalles del modelo, evaluación del rendimiento y conclusiones.

La investigación presenta un algoritmo novedoso para la identificación de ubicación en interiores para sistemas 5G mmWave, utilizando formación de haces y fuerza de señal recibida. Se llevaron a cabo dos escenarios de prueba: uno con equipos de usuario (UE) estacionarios y otro con UE móviles. Para UE estacionarios, el error promedio de distancia fue de 0.75 metros en condiciones de línea de vista (LOS) y 1.74 metros en condiciones mixtas de LOS y no línea de vista (NLOS). Para UE móviles, el error promedio fue de 2.4 metros mientras se movía a lo largo de un camino rectangular. El estudio concluye que el algoritmo propuesto estima

efectivamente la ubicación del UE, con planes para trabajos futuros que busquen mejorar la precisión a través de un modelo de múltiples haces.

Bajo esta lógica Rastorgueva-Foi et al., (2018), propone un modelo de posicionamiento usando el nivel de potencia recibida de la señal de referencia del haz y filtrado Kalman en bandas milimétricas. Se utiliza un filtro Kalman de dos etapas para mapear en 3D el posicionamiento del UE, no obstante, no se menciona que el sistema propuesto sea para escenarios de interiores, sino que se aplica en escenarios de exteriores.

Turkmen et al., (2021), presenta un método innovador para predecir la movilidad de los usuarios en entornos interiores. Este método emplea un modelo de cadena de Markov, cuya matriz de transición es inicializada mediante aprendizaje Q. La simulación, que considera seis estados y distintos niveles de aleatoriedad en el movimiento de los usuarios, muestra que la inicialización basada en aprendizaje Q mejora significativamente la precisión de la predicción, especialmente cuando el movimiento de los usuarios es menos aleatorio. Este enfoque supera a los métodos tradicionales y resalta la importancia de hacer predicciones precisas de movilidad para gestionar eficazmente las transferencias en redes ultradensas, donde los movimientos de los usuarios suelen tener objetivos específicos. La predicción de la ubicación se realiza utilizando cadenas de Markov, que modelan el movimiento del usuario en un entorno interior. Se establece una matriz de transición que refleja las probabilidades de que un usuario se desplace de un área a otra, basándose en su historial de movilidad y patrones de comportamiento.

Este enfoque permite anticipar la trayectoria del usuario antes de que abandone el entorno interior, facilitando así la gestión de las transferencias de conexión entre redes. Cabe resaltar que el método propuesto para la predicción de la movilidad en entornos interiores implica la creación de una matriz de transición que refleja las probabilidades de que un usuario se desplace de un área a otra, considerando que los movimientos de los usuarios son orientados a objetivos y no completamente aleatorios. A medida que el usuario se mueve, se actualizan las probabilidades de los movimientos salientes desde un área específica hacia las áreas vecinas. Esto se hace en un esquema de múltiples etapas, donde se incrementa la probabilidad de movimiento hacia el área objetivo y se disminuyen las probabilidades de movimiento hacia otras áreas. El estudio se llevó a cabo durante un período de 100 días, en el cual se evaluó la efectividad del método propuesto para la predicción de la movilidad en entornos interiores. Durante este tiempo, se utilizó un enfoque de aprendizaje Q para inicializar la matriz de

transición, lo que permitió comparar la precisión de las predicciones con soluciones anteriores. Se simularon un total de 500 episodios, variando el número de iteraciones, y se establecieron recompensas específicas para los movimientos del usuario, con un enfoque particular en los estados que representaban puertas y la salida del entorno. Esto permitió analizar cómo el modelo se comportaba en diferentes escenarios de movilidad y cómo se ajustaba a los patrones de movimiento observados durante el período de estudio.

En el trabajo de investigación de Malmstrom et al., (2019), se menciona el uso de técnicas de aprendizaje automático, específicamente redes neuronales y bosques aleatorios, para estimar la posición de los UE en condiciones de NLOS dentro de entornos urbanos. Para ello se utilizaron datos de un banco de pruebas 5G en el orden de ondas milimétricas proporcionado por Ericsson, el estudio se centra en las mediciones de la potencia de la señal de referencia recibida (BRSRP) de los mejores haces. Los hallazgos clave indican que los bosques aleatorios superaron a las redes neuronales, logrando errores de posicionamiento de menos de 10 metros en el 80% de los casos de prueba, lo que es comparable a la precisión del GPS.

Además, se identificó que un número limitado de características, especialmente las diferencias en BRSRP, eran cruciales para un posicionamiento preciso. La selección aleatoria de datos mostró un mejor rendimiento que la selección consecutiva, probablemente debido a la diversidad de trayectorias en los datos de entrenamiento. También se evaluaron dos detectores de razón de verosimilitud generalizada (GLRT) para identificar condiciones NLOS, encontrando que las diferencias en BRSRP proporcionaron una tasa de detección más alta que las diferencias en la dirección de salida (DOD). El estudio sugiere realizar evaluaciones adicionales con conjuntos de datos más grandes y múltiples puntos de transmisión para mejorar la precisión del posicionamiento en entornos urbanos.

Para mejorar la precisión de posicionamiento en sistemas de comunicación de mmWave en redes 5G, especialmente en escenarios de no línea de vista (NLOS), Gante et al., (2020), en su estudio proponen un enfoque jerárquico de una red neuronal convolucional (Convolutional neural network ,CNN) para segmentar el espacio de salida y manejar patrones de datos específicos. Se presenta la red de convolución temporal (Temporal convolutional network, TCN) como una alternativa efectiva a las LSTM, logrando una precisión de posicionamiento con un error promedio de solo 1.78 metros en entornos exteriores realistas.

El estudio enfatiza la importancia de la calidad de los datos de las huellas digitales formada por haces (Beamformed fingerprint, BFF) y el uso de múltiples BFFs para mitigar el ruido.

Además, se discuten los desafíos en la implementación de TCNs, que utilizan convoluciones dilatadas y bloques residuales para procesar datos secuenciales, mostrando un rendimiento superior en comparación con métodos tradicionales. El documento también describe un sistema de posicionamiento que incluye la transmisión de señales, adquisición de datos, inferencia mediante aprendizaje profundo y estimación de posición, destacando la importancia de las tasas de muestreo y el diseño de patrones de formación de haces.


5. Metodología

5.1 Revisión sistemática de literatura

Se revisó el estado del arte y de la técnica correspondiente a los diferentes modelos de predicción de trayectoria para la ubicación de equipos de usuarios dentro de una red 5G en escenarios de interiores y en escenarios desde exteriores hacia interiores. En primera instancia se recopilaron los trabajos relacionados a la tecnología de quinta generación en escenarios de interiores. Seguidamente se recopilaron los trabajos relacionados a la predicción de trayectoria y posicionamiento de usuarios mediante ANN, ML y AI.

La metodología utilizada en este trabajo de fin de máster se fundamenta en un enfoque cuantitativo, experimental y computacional para la predicción de trayectorias de usuarios en un entorno interior bajo una red 5G operando en frecuencias superiores a 25 GHz. Para asegurar la obtención de los artículos más relevantes y de alto impacto en los temas de interés de nuestra investigación, se utilizó el método de diagrama PRISMA, que nos permitió realizar una revisión sistemática y exhaustiva de la literatura disponible, diferenciando cuidadosamente entre los estudios que podían ser útiles y aquellos que no lo eran.

Figura 10
 Diagrama Prisma para la revisión sistemática de literatura



5.2 Desarrollo

La investigación se inició con la selección de documentos mediante el método PRISMA, lo que permitió una revisión exhaustiva de la literatura relevante. A continuación, se recopiló información de diversos autores que habían abordado temas similares o relacionados con el problema de investigación planteado. Posteriormente, se seleccionó el escenario característico en función del que se implementó en MATLAB, proporcionando así una base sólida para el estudio. Además, se emplearon técnicas avanzadas como redes neuronales LSTM, algoritmos

genéticos y algoritmos de decisiones tipo árbol como random forest, para desarrollar modelos de predicción de trayectorias y posiciones futuras de los usuarios. En donde se determinó que el algoritmo de aprendizaje Q-learning y algoritmos genéticos no pueden ser utilizados para predicción de trayectoria o siguiente posición debido a que los resultados obtenidos son con base en acciones predeterminadas y recompensas que se le otorga por cada acción realizada además de que los algoritmos genéticos están diseñados para encontrar soluciones óptimas a problemas dados, no para modelar dinámicamente cómo cambiarán las posiciones o movimientos futuros basados en datos históricos.

5.2.1 Obtención de coordenadas de los UEs

El proceso inicia con la modificación de scripts base en el software de simulación MATLAB R2023b, adaptando los modelos existentes para reflejar las características específicas de la red 5G de alta frecuencia. Esta adaptación incluyó ajustes en los parámetros de simulación para crear un entorno de prueba que imitará las condiciones reales de la red 5G. Una vez realizado el ajuste, se procedió a la ejecución de simulaciones para obtener los datos de posición de los usuarios, que se almacenaron en las variables `ues_pos_x` y `ues_pos_y`.


Figura 11
Concentración de usuarios hacia el punto de encuentro en el step 14



En la figura 10 podemos observar los usuarios que se han generado en el escenario. Los íconos de color azul representan los usuarios que se están congregando en el centro comercial en donde se observa de color rojizo las BS de la red 5G a una frecuencia de 25 GHz.


El escenario de prueba se encuentra en un área de 300 por 300 metros, ubicada en un centro comercial en Málaga, España como se puede observar en la figura 12. Este espacio ha sido cuidadosamente seleccionado por su tamaño y ubicación estratégica, lo que permite realizar una amplia variedad de pruebas en un entorno controlado y dinámico. El centro comercial ofrece una infraestructura moderna y accesible, ideal para evaluar diferentes aspectos del proyecto o producto en condiciones que reflejan un entorno comercial real, garantizando resultados relevantes y aplicables.

Figura 12
Centro Comercial de Málaga



Se ha implementado un modelo de usuarios aleatorios basado en el algoritmo de movilidad desarrollado en MATLAB. Este algoritmo simula el movimiento de los usuarios desde un punto exterior al centro comercial hasta un área específica dentro del centro comercial, donde se ha establecido un punto de concentración como se puede observar en la figura 13, en donde se han desplegado usuarios random identificados con el ícono de color azul sobre el escenario. Según el algoritmo, los usuarios se desplazan de manera que replican patrones de movilidad realistas y variados, lo que permite observar cómo se comportan en diferentes situaciones y ubicaciones. Este enfoque asegura que los datos obtenidos reflejen escenarios de tráfico y flujo de personas que podrían ocurrir en un entorno comercial real, proporcionando información valiosa para la evaluación y ajuste del sistema en prueba.

Figura 13
UEs desplegadas sobre el escenario establecido



5.2.2 Modelamiento de la red neuronal artificial

Los datos de coordenadas fueron esenciales como datos de entrada para el siguiente paso del análisis.

Utilizando técnicas de aprendizaje automático, los valores obtenidos se emplearon para entrenar una red neuronal LSTM (Long Short-Term Memory), Códigos genéticos. Los modelos se entrenaron con el objetivo de obtener las posiciones futuras de los usuarios en función de sus trayectorias actuales.

Esta metodología computacional permite evaluar con precisión la capacidad de la red neuronal para realizar predicciones en un entorno simulado, proporcionando una base sólida para la evaluación de la efectividad de la predicción en escenarios de red 5G con frecuencias de operación en el orden de ondas milimétricas. La integración de estas técnicas cuantitativas,

experimentales y computacionales asegura una aproximación rigurosa y detallada al análisis de trayectorias en redes avanzadas para una mejor y eficiente administración de recursos.

En el escenario de prueba de 300 por 300 metros dentro del centro comercial en Málaga, se han generado un total de 13,543 usuarios distribuidos en 32 etapas temporales. Estos usuarios se han congregado en el centro comercial siguiendo el algoritmo de movilidad, y luego han salido del punto de concentración en tiempos específicos.

Para cada uno de estos usuarios, se han registrado coordenadas en los ejes X e Y que reflejan su posición en el espacio del centro comercial. Estas coordenadas servirán como datos de entrada para la red neuronal que se detallan en el Anexo 1 que corresponde al código de Python para LSTM y en el Anexo 2 que corresponde al código de Python para el código genético. Estos datos permitirán entrenar y validar el modelo, proporcionando información precisa sobre el movimiento y la distribución de los usuarios en el escenario de prueba. Para entrenar la red neuronal se han tomado 10 usuarios y 10 pasos temporales debido a que en determinado momento los usuarios se quedan estáticos y en otro momento empieza a salir del punto de concentración.

6. Resultados

En el marco de este trabajo de fin de máster, se abordaron objetivos clave relacionados con la predicción de trayectorias de usuarios en un entorno de red 5G con frecuencias superiores a 25 GHz, utilizando técnicas avanzadas de simulación y aprendizaje automático. A continuación, se presentan los resultados y argumentos correspondientes a los objetivos planteados:

Para simular el entorno de prueba, se utilizó el software MATLAB R2023b, adaptando scripts existentes para reflejar las características específicas de la red 5G operando en frecuencias superiores a 25 GHz. El entorno de prueba se situó en un centro comercial en Málaga, España, con un área de 300 por 300 metros, elegido por su capacidad para replicar un entorno dinámico y realista. Se generaron 13,543 usuarios distribuidos en 32 etapas temporales, con sus movimientos simulados desde un punto exterior hacia una zona de concentración dentro del centro comercial.

Los datos obtenidos, que consisten en coordenadas X e Y de los usuarios, fueron fundamentales para el siguiente paso del análisis. La simulación proporcionó una base sólida de datos espaciales que reflejan las trayectorias y patrones de movilidad de los usuarios en el entorno de prueba como se observa en la figura 14.

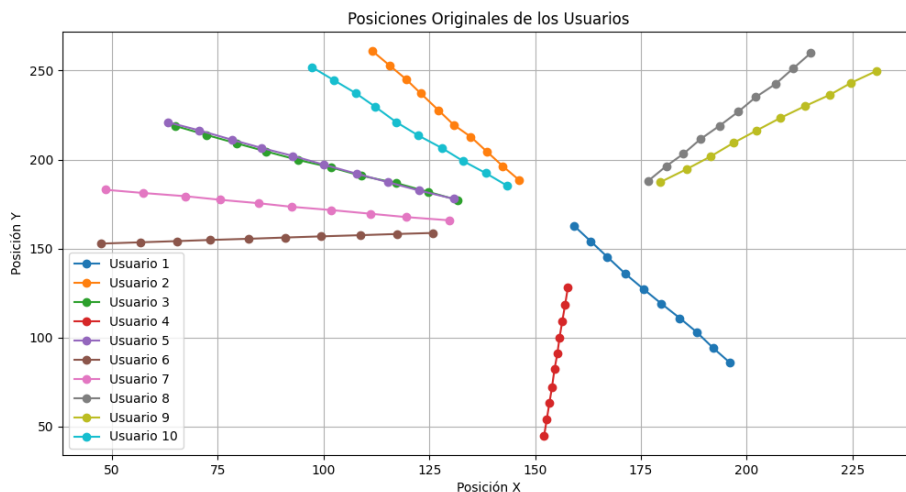
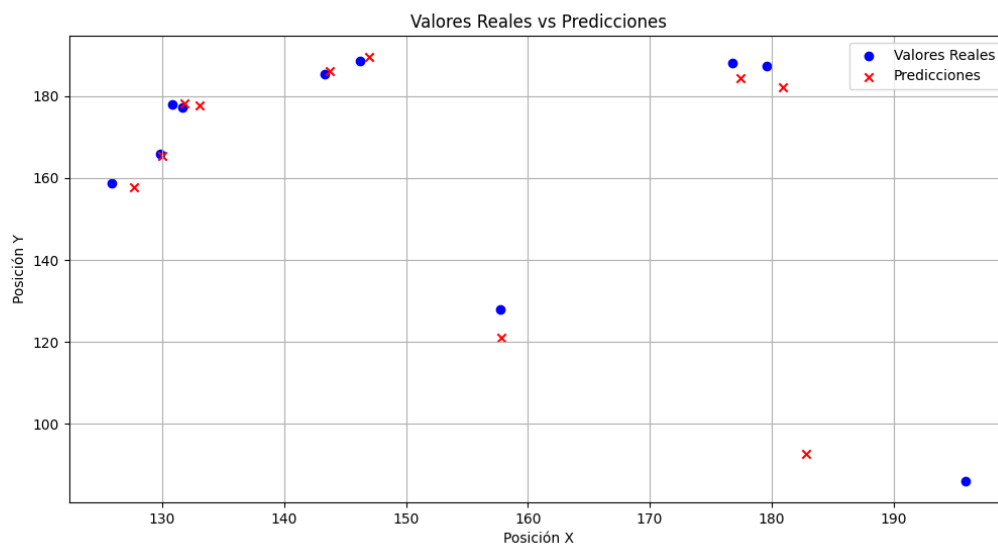


Figura 14
Trayectoria de 10 usuarios hacia el punto de concentración



Los datos de coordenadas se utilizaron para entrenar una red neuronal LSTM (Long Short-Term Memory), con el objetivo de predecir las posiciones futuras de los usuarios en función de sus trayectorias actuales. El modelo LSTM se entrenó con mil épocas y un tamaño de lote inicial de 64, pero debido a que el entrenamiento no mostró mejoras significativas después de 100 épocas y no hubo cambios en la predicción con tamaños de lote de 64 y 32, se fijó el tamaño de lote en 32. Este ajuste fue necesario para optimizar el rendimiento del modelo. Dando como resultado una predicción precisa como se puede ver en la figura 15.

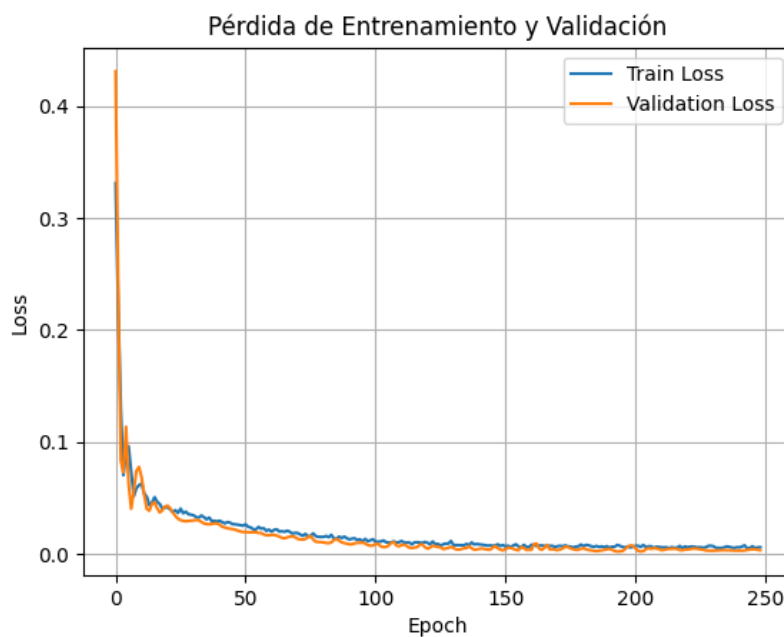
Figura 15
posiciones reales versus la predicción de cada usuario

Los resultados indicaron que la red neuronal LSTM fue capaz de capturar patrones de movilidad en el entorno simulado, proporcionando una herramienta útil para predecir trayectorias en redes 5G.

La metodología empleada, combinando simulación computacional y técnicas avanzadas de aprendizaje automático, permitiendo evaluar con precisión la capacidad predictiva del modelo en un contexto realista. Esta aproximación detallada y cuantitativa asegura una evaluación rigurosa y proporciona información valiosa para la gestión eficiente de recursos en redes avanzadas.

Figura 16

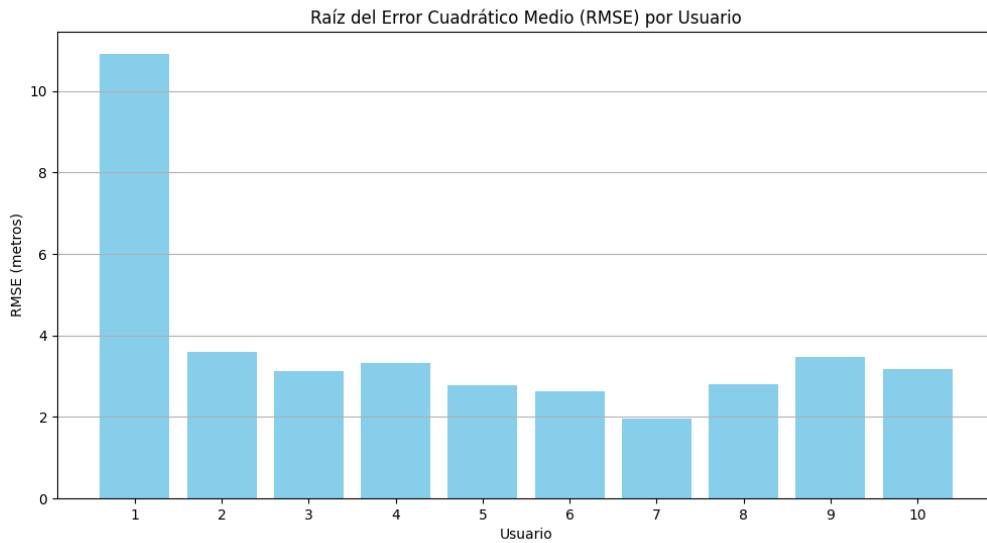
Pérdida de entrenamiento y validación en función de las épocas



De igual manera como se observa en la figura 16, se puede observar la pérdida de entrenamiento y validación en función de cada época. A medida que aumentan las épocas en cada una de las iteraciones el error de predicción disminuye considerablemente dando un resultado de RMSE de 4.48 metros.

Figura 17

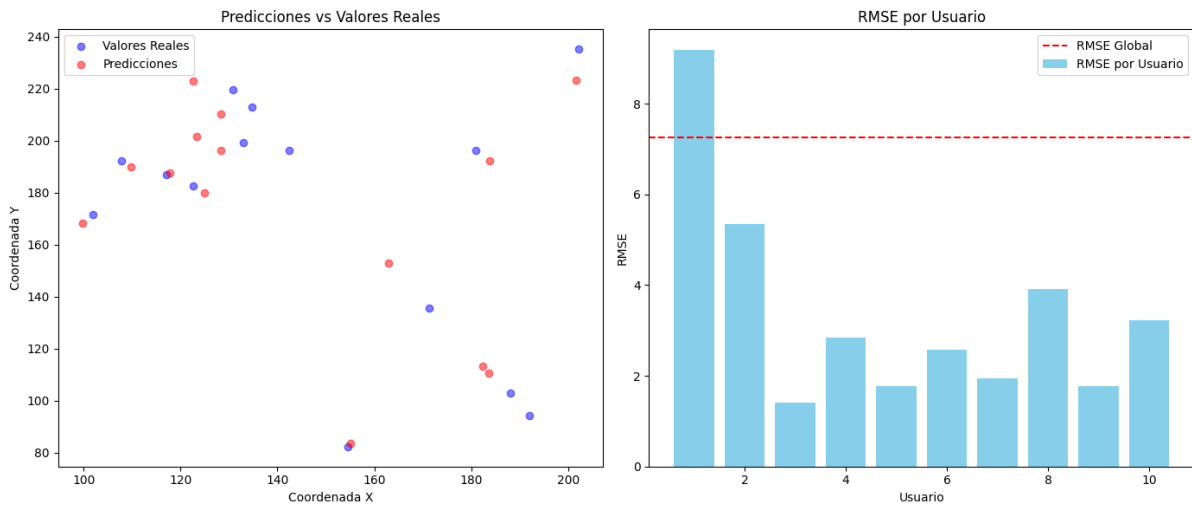
Error cuadrático medio por usuario del algoritmo LSTM



En el análisis de datos utilizando el algoritmo Random Forest, los resultados muestran que el modelo ha sido bastante efectivo al proporcionar predicciones cercanas a los valores reales. El Error Cuadrático Medio (RMSE) obtenido es de aproximadamente 7.27, lo que indica que, en promedio, las predicciones del modelo se desvían solo alrededor de 7.27 unidades de las coordenadas verdaderas. Este nivel de precisión sugiere que Random Forest ha logrado captar correctamente las tendencias en los datos y ha ofrecido estimaciones precisas. La capacidad del modelo para manejar relaciones complejas y su estabilidad frente a posibles problemas de sobreajuste han sido factores clave para alcanzar estos resultados positivos.


El modelo Random Forest utilizado para predecir coordenadas temporales ha mostrado buenos resultados. Después de dividir los datos en secuencias y entrenar el modelo, el Error Cuadrático Medio (RMSE) calculado indica que el modelo hace predicciones precisas. Los gráficos muestran que las predicciones se alinean bien con los valores reales, y el histograma de errores muestra que los errores están distribuidos de manera uniforme. Estos resultados demuestran que el modelo Random Forest es eficaz para predecir coordenadas basadas en datos secuenciales.

Figura 18
Resultados de la predicción con el algoritmo Random Forest



En la figura 18 podemos observar la comparativa entre los valores obtenidos en cada uno de los algoritmos implementados.

Figura 19
Gráfica comparativa entre los valores de RMSE de los algoritmos LSTM y Random Forest



Los resultados obtenidos en la simulación de modelos para la predicción de siguiente posición muestran que el modelo LSTM ofrece un mejor desempeño en comparación con el

modelo Random Forest. El error cuadrático medio global para el LSTM es de 4.48 metros, lo que indica una precisión promedio superior en la predicción. Por otro lado, el Random Forest presenta un RMSE global de 7.27.

Al analizar los RMSE individuales de los modelos, se observa que, aunque el LSTM muestra una mayor dispersión en los valores individuales en un rango de 1.97 metros a 10.91 metros, su desempeño global sigue siendo mejor que el del Random Forest, cuyos valores individuales varían entre 1.41 metros y 9.18 metros. Estos resultados sugieren que el LSTM maneja mejor la complejidad de los datos en general, proporcionando una mayor precisión global en las predicciones.

7. Discusión

El objetivo general de esta investigación fue evaluar modelos de predicción para la localización de usuarios en entornos interiores de redes móviles 5G operando en bandas milimétricas. Los resultados obtenidos muestran que la combinación de simulación avanzada y técnicas de aprendizaje automático, como las redes neuronales LSTM y Random Forest, pueden ser efectivas para predecir trayectorias en estos entornos complejos. La simulación detallada en un entorno de prueba realista y la aplicación de modelos de predicción han demostrado la capacidad de las técnicas actuales para capturar patrones de movilidad y mejorar la precisión en la predicción de posiciones futuras de los usuarios. Este enfoque no solo valida la aplicabilidad de los modelos en contextos prácticos, sino que también ofrece una base sólida para futuras investigaciones en la optimización de redes 5G en escenarios interiores.

La simulación del entorno característico en MATLAB R2023b y el uso de algoritmos de aprendizaje automático, como las redes neuronales LSTM y Random Forest, han proporcionado una base sólida para el entrenamiento y la predicción. La simulación del movimiento de 13,543 usuarios en un centro comercial permitió generar un conjunto de datos espaciales representativo. La aplicación de los modelos para predecir trayectorias futuras ha demostrado ser efectivos, aunque se encontraron desafíos relacionados con la optimización del código, como el tamaño del lote en el entrenamiento. Estos ajustes fueron cruciales para mejorar el rendimiento del modelo. La capacidad de los modelos de aprendizaje automático para captar patrones de movilidad y proporcionar predicciones precisas valida la eficacia de las técnicas empleadas y demuestra el valor de la simulación detallada en la obtención de datos significativos.

La evaluación y validación de los modelos de predicción propuestos, incluyendo la comparación entre los resultados obtenidos y las simulaciones realizadas, han mostrado que los modelos evaluados tienen una capacidad notable para prever posiciones futuras en redes 5G. La validación con pruebas de simulación ha demostrado que los modelos, especialmente las redes LSTM y Random Forest, son capaces de adaptarse a la dinámica del entorno y ofrecer predicciones precisas. La comparación entre posiciones reales y predicciones, así como el análisis de la pérdida de entrenamiento y validación, refuerza la capacidad de los modelos para mejorar la gestión de recursos en redes avanzadas. Estos resultados denotan la importancia de integrar técnicas de simulación y aprendizaje automático en la evaluación de modelos de

predicción para redes 5G, y proporcionan una base para futuras investigaciones en la optimización y expansión de estas técnicas.

Por otro lado, los resultados obtenidos en el trabajo de fin de máster sobre la predicción de trayectorias de usuarios en una red 5G operando a frecuencias superiores a 25 GHz, se destacan varias observaciones y contrastes entre los modelos de predicción utilizados: la red neuronal LSTM y el algoritmo Random Forest.

La red neuronal LSTM demostró ser efectiva para capturar patrones de movilidad en el entorno simulado. Los ajustes realizados en el tamaño del lote y las épocas del entrenamiento contribuyeron a optimizar la precisión del modelo. Aunque el modelo logró realizar predicciones precisas, el proceso de entrenamiento reveló algunos desafíos, como la necesidad de ajustar el tamaño del lote y la observación de que las mejoras en la precisión se estabilizaron después de 100 épocas. Este comportamiento es indicativo de que el modelo estaba alcanzando un punto de convergencia en la capacidad predictiva. La disminución significativa en el error de predicción con el aumento de las épocas, como se observa en la figura 16, resalta la eficacia de la red LSTM para aprender y generalizar patrones de movilidad. Sin embargo, el tiempo de entrenamiento y los recursos computacionales requeridos para obtener resultados óptimos pueden ser consideraciones importantes para su aplicación en entornos de producción.

El algoritmo Random Forest mostró un rendimiento notable con un Error Cuadrático Medio (RMSE) de aproximadamente 7.27. Este resultado sugiere que el modelo fue capaz de manejar relaciones complejas en los datos y proporcionar estimaciones precisas sin sobre ajustarse, como se puede ver en la figura 17. La estabilidad y capacidad del Random Forest para gestionar datos secuenciales con precisión es un punto fuerte, y su desempeño uniforme en la predicción de coordenadas es un indicativo de su eficacia.

Comparando ambos modelos, la LSTM y el Random Forest, tienen sus ventajas y desventajas. La LSTM, con su capacidad para capturar patrones temporales, resulta valiosa en la predicción de trayectorias en entornos con alta variabilidad temporal. Sin embargo, su entrenamiento puede ser más intensivo en términos de tiempo y recursos. Por otro lado, Random Forest proporciona una solución efectiva con un error de predicción relativamente bajo y menor complejidad computacional durante el entrenamiento. Su capacidad para generalizar sin sobreajuste también es destacable.

En resumen, tanto la red LSTM como el algoritmo Random Forest ofrecen enfoques válidos para la predicción de trayectorias en redes 5G. La elección del modelo puede depender de las

necesidades específicas del entorno y los requisitos computacionales. Mientras que la LSTM es ventajosa para capturar patrones secuenciales complejos, Random Forest se destaca por su precisión y estabilidad. La combinación de estos modelos y técnicas puede ser una estrategia eficaz para abordar diferentes aspectos de la predicción de trayectorias en redes avanzadas

8. Conclusiones

En el presente trabajo se ha llevado a cabo un análisis exhaustivo del estado del arte relacionado con la tecnología 5G, con un enfoque particular en la caracterización de escenarios de propagación en interiores utilizando ondas milimétricas (mmWave). A través de una revisión detallada de la literatura científica y técnica disponible, se ha obtenido una comprensión profunda de los desafíos y avances en este campo emergente.

La investigación revela que, si bien la tecnología 5G promete una mejora significativa en términos de velocidad y capacidad de red, la propagación de ondas milimétricas en entornos interiores presenta complejidades únicas que deben ser abordadas. Los trabajos revisados destacan que, debido a la alta frecuencia de las ondas mmWave, las características de propagación son notablemente diferentes a las de frecuencias inferiores. Los estudios han identificado que las ondas mmWave sufren una mayor atenuación y pérdida de señal debido a obstáculos como paredes y muebles, lo que afecta significativamente la cobertura y la calidad de la señal en espacios cerrados.

Se han comparado y evaluado diversos modelos de propagación, desde enfoques empíricos y deterministas hasta modelos basados en simulación, revelando que no existe un único modelo óptimo para todas las situaciones. Los modelos existentes, como los propuestos por la ITU-R y el 3GPP, ofrecen diferentes niveles de precisión y aplicabilidad, y su efectividad puede variar dependiendo de las condiciones específicas del entorno interior.

Así como la importancia de utilizar técnicas avanzadas de modelado y simulación, tales como la adaptación de scripts en software especializado como MATLAB y la aplicación de modelos de aprendizaje automático, para capturar de manera precisa las complejas interacciones de las ondas mmWave en entornos interiores. Estas técnicas permiten una mejor estimación de la propagación de la señal y pueden ayudar a optimizar el diseño de redes 5G para mejorar la cobertura y el rendimiento en escenarios cerrados.

La red neuronal LSTM fue eficaz en la captura de patrones temporales en la movilidad de usuarios, aunque enfrentó desafíos relacionados con el ajuste de hiperparámetros y el tiempo de entrenamiento. La precisión mejoró significativamente con más épocas, aunque el modelo alcanzó una convergencia después de un cierto número de épocas.

El algoritmo Random Forest mostró un rendimiento estable con un Error Cuadrático Medio (RMSE) relativamente bajo, indicando su capacidad para manejar relaciones complejas en los datos y ofrecer estimaciones precisas sin sobre ajustarse.

Finalmente, los resultados demuestran que el modelo LSTM supera al Random Forest en términos de precisión global, con un RMSE promedio significativamente menor, 4.48 metros frente a 7.27 metros. A pesar de una mayor variabilidad en los errores individuales, el LSTM logra una mejor capacidad de generalización en el conjunto de datos evaluado. Este resultado resalta la eficacia del LSTM para captar patrones complejos y hacer predicciones más precisas en comparación con el Random Forest. Sin embargo, la variabilidad observada en los resultados individuales del LSTM sugiere que se debe prestar atención a casos específicos donde el modelo podría tener dificultades, y considerar ajustes adicionales para mejorar la consistencia en todas las instancias del conjunto de datos.

9. Recomendaciones

- Se recomienda investigar modelos de propagación más específicos para frecuencias superiores a los 25 GHz para entornos interiores, como el modelo de propagación de la ITU-R M.2135, que podría ofrecer una mejor representación de la atenuación y dispersión de señales en estos escenarios.
- Comparar y contrastar distintos modelos de predicción de trayectoria, incluyendo no solo LSTM, sino también otros enfoques como las redes neuronales convolucionales (CNN), redes neuronales generativas (GANs) y técnicas de aprendizaje profundo para evaluar cuál modelo ofrece la mejor precisión y eficiencia en escenarios interiores con 5G.
- Realizar una revisión y optimización continua de los parámetros de simulación en MATLAB para asegurar que reflejan con precisión las condiciones reales de la red 5G. Realizar pruebas adicionales con diferentes configuraciones de parámetros puede mejorar la fiabilidad y validez de las simulaciones.
- Ajustar y personalizar el modelo LSTM y Random Forest para adaptarse mejor a las características específicas del entorno interior, como la densidad de obstáculos y la variabilidad en la propagación de ondas mmWave. Experimentar con diferentes configuraciones y parámetros de los modelos puede optimizar sus capacidades predictivas.
- Investigar cómo diferentes condiciones ambientales, como variaciones en la densidad de obstáculos y la presencia de interferencias, afectan la precisión del modelo de predicción. Incorporar estas variables en el análisis puede ofrecer una visión más completa sobre la robustez del modelo en escenarios diversos.
- Para mejorar la precisión de los modelos y permitir una evaluación más exhaustiva de grandes volúmenes de datos, se sugiere aumentar la capacidad de procesamiento de la computadora utilizada en las simulaciones. Un incremento en la capacidad computacional facilitará el manejo de conjuntos de datos más extensos, lo que puede llevar a una mejor calidad de las predicciones y a un análisis más robusto. Esto es especialmente relevante para modelos complejos como LSTM, que pueden beneficiarse significativamente de una mayor potencia de procesamiento para optimizar el entrenamiento y la validación con datos más completos y representativos.
- Aumentar el número de muestras por usuario, es decir, ampliar el rango de movilidad en pasos más allá de los 32 pasos utilizados en la simulación actual. La cantidad actual

de pasos puede ser insuficiente para capturar con precisión la variabilidad y las características individuales de cada usuario, lo que limita la precisión de las predicciones. Incrementar el número de muestras permitirá obtener una representación más completa del comportamiento del usuario, mejorando así la precisión y la confiabilidad de las predicciones generadas por el modelo.

10. Bibliografía

- Alhory, O., Shoushara, O., Alsuri, H., Alshunnaq, M., & Awad, F. (2020a). 5G mmWave Indoor Location Identification Using Beamforming and RSSI. 2020 11th International Conference on Information and Communication Systems, ICICS 2020, 91–95. <https://doi.org/10.1109/ICICS49469.2020.239532>
- Arigye, W., Pu, Q., Zhou, M., Khalid, W., & Tahir, M. J. (2022). RSSI Fingerprint Height Based Empirical Model Prediction for Smart Indoor Localization. *Sensors*, 22(23), 1–22. <https://doi.org/10.3390/s22239054>
- Brena, R. F., García-Vázquez, J. P., Galván-Tejada, C. E., Muñoz-Rodríguez, D., Vargas-Rosales, C., & Fangmeyer, J. (2017). Evolution of Indoor Positioning Technologies: A Survey. *Journal of Sensors*, 2017. <https://doi.org/10.1155/2017/2630413>
- Chin, W. L., Hsieh, C. C., Shiung, D., & Jiang, T. (2020). Intelligent Indoor Positioning Based on Artificial Neural Networks. *IEEE Network*, 34(6), 164–170. <https://doi.org/10.1109/MNET.011.2000096>
- Del Peral-Rosado, J. A., Saloranta, J., Destino, G., López-Salcedo, J. A., & Seco-Granados, G. (2018). Methodology for simulating 5G and GNSS high-accuracy positioning. *Sensors (Switzerland)*, 18(10), 1–25. <https://doi.org/10.3390/s18103220>
- Gante, J., Falcão, G., & Sousa, L. (2020). Deep Learning Architectures for Accurate Millimeter Wave Positioning in 5G. *Neural Processing Letters*, 51(1), 487–514. <https://doi.org/10.1007/s11063-019-10073-1>
- Gasanz i De León, V. (2022). Comparativa entre las tecnologías LTE y 5G (mmWave) en espacios interiores Tesis de Grado Presentada para la Facultad de Escola Tècnica d ' Enginyeria de Telecomunicació de Barcelona Universitat Politècnica de Catalunya por Víctor Gasanz de León En cump.
- Giordani, M., Mezzavilla, M., & Zorzi, M. (2016). Initial Access in 5G mmWave Cellular Networks. *IEEE Communications Magazine*, 54(11), 40–47. <https://doi.org/10.1109/MCOM.2016.1600193CM>
- Han, X., & Peng, L. (2023a). Frontiers in Computing and Intelligent Systems Research on Intelligent Indoor Positioning Technology based on 5G. 5(1), 73.

- Hayward, S. J., van Lopik, K., Hinde, C., & West, A. A. (2022). A Survey of Indoor Location Technologies, Techniques and Applications in Industry. *Internet of Things (Netherlands)*, 20(August), 100608. <https://doi.org/10.1016/j.iot.2022.100608>
- Laoudias, C., Moreira, A., Kim, S., Lee, S., Wirola, L., & Fischione, C. (2018). A survey of enabling technologies for network localization, tracking, and navigation. *IEEE Communications Surveys and Tutorials*, 20(4), 3607–3644. <https://doi.org/10.1109/COMST.2018.2855063>
- Lu, L. (2019). LSTM. 52.
- Malmstrom, M., Skog, I., Razavi, S. M., Zhao, Y., & Gunnarsson, F. (2019). 5G positioning - A machine learning approach. 2019 16th Workshop on Positioning, Navigation and Communication, WPNC 2019. <https://doi.org/10.1109/WPNC47567.2019.8970186>
- Mogyorósi, F., Revisnyei, P., Pašić, A., Papp, Z., Törös, I., Varga, P., & Pašić, A. (2022). Positioning in 5G and 6G Networks—A Survey. *Sensors*, 22(13), 1–25. <https://doi.org/10.3390/s22134757>
- Rastorgueva-Foi, E., Costa, M., Koivisto, M., Leppänen, K., & Valkama, M. (2018). User Positioning in mmW 5G Networks Using Beam-RSRP Measurements and Kalman Filtering. 2018 21st International Conference on Information Fusion, FUSION 2018, 1150–1156. <https://doi.org/10.23919/ICIF.2018.8455289>
- Sakaguchi, K., Haustein, T., Barbarossa, S., Strinati, E. C., Clemente, A., Destino, G., Pärssinen, A., Kim, I., Chung, H., Kim, J., Keusgen, W., Weiler, R. J., Takinami, K., Ceci, E., Sadri, A., Xian, L., Maltsev, A., Tran, G. K., Ogawa, H., ... Heath, R. W. (2017). Where, when, and how mmwave is used in 5G and beyond. *IEICE Transactions on Electronics*, E100.C(10), 790–808. <https://doi.org/10.1587/transele.E100.C.790>
- Shi, L., Shi, D., Zhang, X., Meunier, B., Zhang, H., Wang, Z., Vladimirescu, A., Li, W., Zhang, Y., Cosmas, J., Ali, K., Jawad, N., Zetik, R., Legale, E., Satta, M., Wang, J., & Song, J. (2020). 5G Internet of Radio Light Positioning System for Indoor Broadcasting Service. *IEEE Transactions on Broadcasting*, 66(2), 534–544. <https://doi.org/10.1109/TBC.2020.2981755>
- Turkmen, A., Ansari, S., Klaine, P. V., Zhang, L., & Imran, M. A. (2021). Indoor mobility prediction for mmWave communications using Markov chain. *IEEE Wireless*

Communications and Networking Conference, WCNC, 2021-March.
<https://doi.org/10.1109/WCNC49053.2021.9417348>

Wang, R., Onireti, O., Zhang, L., Imran, M. A., Ren, G., Qiu, J., & Tian, T. (2019). Reinforcement Learning Method for Beam Management in Millimeter-Wave Networks. 2019 UK/China Emerging Technologies, UCET 2019, August, 21–22.
<https://doi.org/10.1109/UCET.2019.8881841>

Xu, G. (2021). Method of Enhancing the Accuracy of Indoor Positioning (RSSI to UL-AOA). Journal of Physics: Conference Series, 1871(1). <https://doi.org/10.1088/1742-6596/1871/1/012076>

11. Anexos

Anexos 1 Algoritmo LSMT

```
import numpy as np
import matplotlib.pyplot as plt
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import LSTM, Dense, Dropout, Bidirectional
from tensorflow.keras.callbacks import EarlyStopping, ReduceLROnPlateau
import tensorflow as tf
from sklearn.preprocessing import MinMaxScaler

# Coordenadas
coordenadas = np.array([

[[159.1835025, 162.7757726], [163.1416203, 153.9982463], [167.0070884, 145.3766042], [171.350808, 135.6746838], [175.6147427, 127.1587582], [179.7899002, 119.0429011], [184.1919723, 110.829751], [188.169662, 102.9993434], [192.0208755, 94.15885891], [195.8954887, 86.06181585]], # Usuario 1
[[111.5212342, 261.0510458], [115.5548191, 252.9902989], [119.4619486, 245.2206202], [122.936718, 237.2330741], [127.1558112, 227.7182079], [130.7660778, 219.4745144], [134.7992411, 212.7573846], [138.6554176, 204.3127346], [142.3767954, 196.2251669], [146.2062994, 188.4776614]], # Usuario 2

[[65.00981913, 218.8682622], [72.44041822, 213.7444822], [79.49749291, 209.0819753], [86.47874328, 204.5254468], [93.88484859, 199.8142683], [101.8260518, 195.54064], [108.9091651, 190.9008464], [117.1220824, 186.784323], [124.6612229, 181.8723674], [131.6727824, 177.2173429]], # Usuario 3

[[152.1164318, 44.68417598], [152.7627833, 54.19151621], [153.3677497, 63.10466424], [153.981891, 72.0532786], [154.5934799, 82.38474211], [155.2720656, 91.16796661], [155.7535537, 99.78677291], [156.4182674, 109.1995349], [157.0899274, 118.5795351], [157.7314361, 128.0201348]], # Usuario 4

[[63.12970219, 221.006876682087], [70.70866952, 216.346290636995], [78.30574456, 211.151237203248], [85.35194249, 206.499959864906], [92.78314601, 202.010648929260], [100.1061194, 197.075475013219], [107.784954, 192.053311228898], [115.2214451, 187.266212049512], [122.535894, 182.602130524112], [130.8653361, 177.863902938299]], # Usuario 5

[[47.4868708622009, 152.744670785237], [56.7169244733081, 153.469266151224], [65.3848600132164, 154.150860840216], [73.2429430473436, 154.798830960964], [82.3615592334443, 155.452886404162], [90.9069809679116, 156.150703455098], [99.3988725566426, 156.802723592445], [108.611653731843, 157.461495663344], [117.456735528431, 158.158568755521], [125.883093861530, 158.727609139504]], # Usuario 6

[[48.4329204880911, 183.017980305125], [57.4443019107909, 181.180127584720], [67.3452327987970, 179.385691444115], [75.5948690503043, 177.352197872549], [84.5811985603310, 175.460517939137], [92.4772833760754, 173.426267613195], [101.852884906049, 171.588509594497], [111.207406492519, 169.503481486819], [119.583663316816, 167.636873511610], [129.819558244124, 165.813035774276]], # Usuario 7

[[215.089743607277, 259.789216485246], [211.003133162743, 251.290700019251], [206.799835390225, 242.478244703547], [202.130642108867, 235.089895264503], [197.967909826653, 226.814341596704], [193.584362220028, 219.009884200002], [189.04010041745, 211.417639591363], [185.055391648793, 203.247264548126], [180.950797145798, 196.254788414467], [176.800610006919, 188.142579308775]], # Usuario 8

[[230.593346318517, 249.713848515841], [224.606896311581, 243.059576068812], [219.695181395912, 236.436361478827], [213.692191285013, 229.936005066518], [207.
```

```

841967892829,223.254101503143],[202.240776433023,216.212388160670],[196.851
321646853,209.334805007797],[191.347069311775,201.591047513808],[185.740751
382434,194.523331897056],[179.594431388969,187.315258024936]], # Usuario 9

[[97.3342391095272,251.823909466907],[102.361384171718,244.702852988489],[1
07.602642746479,237.310793164312],[112.288311733738,229.528217927907],[117.
126413088834,221.114863643648],[122.423320765950,213.472523065465],[127.967
093344928,206.458589542261],[132.909926759098,199.238576561517],[138.291766
540175,192.414716199625],[143.340417174214,185.337860271355]] # Usuario 10
])

# Normalización de Datos
scaler = MinMaxScaler()
coordenadas_reshape = coordenadas.reshape(-1, 2)
coordenadas_normalized =
scaler.fit_transform(coordenadas_reshape).reshape(coordenadas.shape)

# Dividir los datos en secuencias para cada usuario
def prepare_data(coordenadas, time_steps=3):
    X, y = [], []
    for user_coords in coordenadas:
        for i in range(len(user_coords) - time_steps):
            X.append(user_coords[i:i + time_steps])
            y.append(user_coords[i + time_steps])
    return np.array(X, dtype=np.float32), np.array(y, dtype=np.float32)

# Preparar los datos
X, y = prepare_data(coordenadas_normalized, time_steps=3)

# Verificar las formas después de la preparación
print(f"Forma de X después de preparación: {X.shape}")
print(f"Forma de y después de preparación: {y.shape}")

if X.size == 0 or y.size == 0:
    raise ValueError("X o y están vacíos después de la preparación de los
datos.")

# Cambiar la forma de X para que sea compatible con el modelo
X = X.reshape(-1, 3, 2)
y = y.reshape(-1, 2)

# Dividir los datos en entrenamiento, validación y prueba
split_idx_train = int(0.8 * len(X)) # 80% para entrenamiento
split_idx_val = int(0.9 * len(X)) # 10% para validación

X_train = X[:split_idx_train]
y_train = y[:split_idx_train]
X_val = X[split_idx_train:split_idx_val]
y_val = y[split_idx_train:split_idx_val]
X_test = X[split_idx_val:]
y_test = y[split_idx_val:]

print(f"Forma de X_train: {X_train.shape}")
print(f"Forma de y_train: {y_train.shape}")

# Graficar datos originales para cada usuario
def plot_positions(coordenadas, title, filename):
    plt.figure(figsize=(12, 6))
    for i, user_coords in enumerate(coordenadas):
        plt.plot(user_coords[:, 0], user_coords[:, 1], marker='o',
label=f'Usuario {i + 1}')

```

```

plt.xlabel('Posición X')
plt.ylabel('Posición Y')
plt.title(title)
plt.legend()
plt.grid()
plt.savefig(filename)
plt.show()

plot_positions(coordenadas, 'Posiciones Originales de los Usuarios',
'grafica_posiciones_originales.png')

# Definir una función de pérdida personalizada
def loss_custom(y_true, y_pred):
    mse_loss = tf.reduce_mean(tf.square(y_true - y_pred))
    return mse_loss

# modelo LSTM
def crear_modelo():
    model = Sequential([
        Bidirectional(LSTM(200, return_sequences=True),
input_shape=(X_train.shape[1], X_train.shape[2])),
        Dropout(0.6),
        LSTM(200),
        Dropout(0.6),
        Dense(2, kernel_regularizer=tf.keras.regularizers.l2(0.01))
    ])
    model.compile(optimizer='adam', loss=loss_custom)
    return model

model = crear_modelo()

# Definir callbacks
early_stopping = EarlyStopping(monitor='val_loss', patience=55,
restore_best_weights=True)
reduce_lr = ReduceLRonPlateau(monitor='val_loss', factor=0.5, patience=20,
min_lr=1e-6)

# Entrenamiento del modelo
history = model.fit(X_train, y_train, validation_data=(X_val, y_val),
epochs=1000, batch_size=32, callbacks=[early_stopping, reduce_lr])

# Modelo guardado
model.save('mi_modelo.keras')

# Graficar la historia del entrenamiento
def plot_training_history(history, filename):
    plt.figure()
    plt.plot(history.history['loss'], label='Train Loss')
    plt.plot(history.history['val_loss'], label='Validation Loss')
    plt.xlabel('Epoch')
    plt.ylabel('Loss')
    plt.legend()
    plt.title('Pérdida de Entrenamiento y Validación')
    plt.grid()
    plt.savefig(filename)
    plt.show()

plot_training_history(history, 'grafica_entrenamiento.png')

# Realizar una predicción con el modelo entrenado para cada usuario

```

```

def predict_for_user(user_coords, model, time_steps=3):
    last_sequence = user_coords[-time_steps:] # Tomar las últimas
    coordenadas para la predicción
    last_sequence = np.array(last_sequence).reshape(1, time_steps, 2)
    next_point = model.predict(last_sequence)[0]
    return next_point

# Obtener una predicción para cada usuario
all_predictions = []
for user_coords in coordenadas_normalizadas:
    prediction = predict_for_user(user_coords, model, time_steps=3)
    all_predictions.append(prediction)

# Convertir las predicciones a un array para fácil manejo
all_predictions = np.array(all_predictions)

# Convertir las predicciones de nuevo a la escala original
all_predictions = scaler.inverse_transform(all_predictions)

# Imprimir las predicciones y los valores reales
def print_predictions_vs_real(coordenadas, all_predictions):
    for i in range(len(coordenadas)):
        print(f"Usuario {i + 1}:")
        print(f"  Valores Reales: {coordenadas[i][-1]}")
        print(f"  Predicción: {all_predictions[i]}")
        print()

print_predictions_vs_real(coordenadas, all_predictions)

# Calcular RMSE
def calculate_rmse(y_true, y_pred):
    mse = np.mean(np.square(y_true - y_pred))
    rmse = np.sqrt(mse)
    return rmse

# Convertir coordenadas originales a escala normalizada para comparación
coordenadas_originales_norm = scaler.transform(coordenadas.reshape(-1,
2)).reshape(coordenadas.shape)

# Calcular RMSE para cada usuario
rmse_values = []
for i in range(len(all_predictions)):
    true_value = coordenadas[i][-1] # Último valor real en la escala
    original
    pred_value = all_predictions[i] # Predicción en la escala original
    rmse = calculate_rmse(true_value, pred_value)
    rmse_values.append(rmse)
    print(f"RMSE para Usuario {i + 1}: {rmse} metros")

# Calcular RMSE total
all_true_values = np.array([coords[-1] for coords in coordenadas]) #
Última coordenada real de cada usuario
total_rmse = calculate_rmse(all_true_values, all_predictions)
print(f"RMSE total de la simulación: {total_rmse} metros")

# Graficar el error para cada usuario
def plot_error_per_user(rmse_values, filename):
    plt.figure(figsize=(12, 6))
    plt.bar(range(1, len(rmse_values) + 1), rmse_values, color='skyblue')
    plt.xlabel('Usuario')
    plt.ylabel('RMSE (metros)')

```

```

plt.title('Raíz del Error Cuadrático Medio (RMSE) por Usuario')
plt.xticks(range(1, len(rmse_values) + 1))
plt.grid(axis='y')
plt.savefig(filename)
plt.show()

plot_error_per_user(rmse_values, 'grafica_error_por_usuario.png')

# Graficar predicciones vs valores reales para el primer usuario (puedes
ajustar esto para otros usuarios)
def plot_predictions_vs_real(y_true, y_pred, title, filename):
    plt.figure(figsize=(12, 6))
    plt.scatter(y_true[:, 0], y_true[:, 1], c='blue', label='Valores
Reales', marker='o')
    plt.scatter(y_pred[:, 0], y_pred[:, 1], c='red', label='Predicciones',
marker='x')
    plt.xlabel('Posición X')
    plt.ylabel('Posición Y')
    plt.title(title)
    plt.legend()
    plt.grid()
    plt.savefig(filename)
    plt.show()

# Ajusta esto para mostrar las predicciones del primer usuario
plot_predictions_vs_real(
    np.array([coords[-1] for coords in coordenadas]), # Última coordenada
real de cada usuario
    all_predictions, # Predicciones desnormalizadas
    'Valores Reales vs Predicciones',
    'grafica_predicciones.png'
)

```

Anexos 2. Algoritmo Random Forest

```
import numpy as np
from sklearn.ensemble import RandomForestRegressor
from sklearn.metrics import mean_squared_error
from sklearn.model_selection import train_test_split
import matplotlib.pyplot as plt

# Coordenadas
coordenadas = np.array([
    [159.1835025, 162.7757726], [163.1416203, 153.9982463], [167.0070884,
145.3766042], [171.350808, 135.6746838],
    [175.6147427, 127.1587582], [179.7899002, 119.0429011], [184.1919723,
110.829751], [188.169662, 102.9993434],
    [192.0208755, 94.15885891], [195.8954887, 86.06181585]], # Usuario 1
    [[111.5212342, 261.0510458], [115.5548191, 252.9902989], [119.4619486,
245.2206202], [122.936718, 237.2330741],
    [127.1558112, 227.7182079], [130.7660778, 219.4745144], [134.7992411,
212.7573846], [138.6554176, 204.3127346],
    [142.3767954, 196.2251669], [146.2062994, 188.4776614]], # Usuario 2
    [[65.00981913, 218.8682622], [72.44041822, 213.7444822], [79.49749291,
209.0819753], [86.47874328, 204.5254468],
    [93.88484859, 199.8142683], [101.8260518, 195.54064], [108.9091651,
190.9008464], [117.1220824, 186.784323],
    [124.6612229, 181.8723674], [131.6727824, 177.2173429]], # Usuario 3
    [[152.1164318, 44.68417598], [152.7627833, 54.19151621], [153.3677497,
63.10466424], [153.981891, 72.0532786],
    [154.5934799, 82.38474211], [155.2720656, 91.16796661], [155.7535537,
99.78677291], [156.4182674, 109.1995349],
    [157.0899274, 118.5795351], [157.7314361, 128.0201348]], # Usuario 4
    [[63.12970219, 221.00687668], [70.70866952, 216.34629064],
    [78.30574456, 211.1512372], [85.35194249, 206.49995986],
    [92.78314601, 202.01064893], [100.1061194, 197.07547501], [107.784954,
192.05331123], [115.2214451, 187.26621205],
    [122.535894, 182.60213052], [130.8653361, 177.86390294]], # Usuario 5
    [[47.48687086, 152.74467079], [56.71692447, 153.46926615],
    [65.38486001, 154.15086084], [73.24294305, 154.79883096],
    [82.36155923, 155.4528864], [90.90698097, 156.15070346], [99.39887256,
156.80272359], [108.61165373, 157.46149566],
    [117.45673553, 158.15856876], [125.88309386, 158.72760914]], #
Usuario 6
    [[48.43292049, 183.01798031], [57.44430191, 181.18012758], [67.3452328,
179.38569144], [75.59486905, 177.35219787],
    [84.58119856, 175.46051794], [92.47728338, 173.42626761],
    [101.85288491, 171.58850959],
    [111.20740649, 169.50348149], [119.58366332, 167.63687351],
    [129.81955824, 165.81303577]], # Usuario 7
    [[215.08974361, 259.78921649], [211.00313316, 251.29070002],
    [206.79983539, 242.4782447],
    [202.13064211, 235.08989526], [197.96790983, 226.8143416],
    [193.58436222, 219.0098842],
    [189.04001004, 211.41763959], [185.05539165, 203.24726455],
    [180.95079715, 196.25478841],
    [176.80061001, 188.14257931]], # Usuario 8
    [[230.59334632, 249.71384852], [224.60689631, 243.05957607],
    [219.6951814, 236.43636148],
    [213.69219129, 229.93600507], [207.84196789, 223.2541015],
    [202.24077643, 216.21238816],
    [196.85132165, 209.33480501], [191.34706931, 201.59104751],
    [185.74075138, 194.5233319],
    [179.59443139, 187.31525802]], # Usuario 9
```

```

    [[97.33423911, 251.82390947], [102.36138417, 244.70285299],
 [107.60264275, 237.31079316],
    [112.28831173, 229.52821793], [117.12641309, 221.11486364],
 [122.42332077, 213.47252307],
    [127.96709334, 206.45858954], [132.90992676, 199.23857656],
 [138.29176654, 192.4147162],
    [143.34041717, 185.33786027]] # Usuario 10
])

# Dividir los datos en secuencias para cada usuario
def prepare_data(coordenadas, time_steps=3):
    X, y = [], []
    for user_coords in coordenadas:
        for i in range(len(user_coords) - time_steps):
            X.append(user_coords[i:i + time_steps].flatten())
            y.append(user_coords[i + time_steps])
    return np.array(X, dtype=np.float32), np.array(y, dtype=np.float32)

# Preparar los datos
X, y = prepare_data(coordenadas, time_steps=3)

# Dividir los datos en conjuntos de entrenamiento y prueba
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2,
random_state=42)

# Crear y entrenar el modelo Random Forest
model = RandomForestRegressor(n_estimators=100, random_state=42)
model.fit(X_train, y_train)

# Realizar predicciones
y_pred = model.predict(X_test)

# Calcular el RMSE
rmse = np.sqrt(mean_squared_error(y_test, y_pred))
print(f"Error cuadrático medio (RMSE): {rmse}")

# Graficar resultados
plt.figure(figsize=(12, 6))

# Graficar predicciones vs valores reales
plt.subplot(1, 2, 1)
plt.scatter(y_test[:, 0], y_test[:, 1], color='blue', label='Valores
Reales', alpha=0.5)
plt.scatter(y_pred[:, 0], y_pred[:, 1], color='red', label='Predicciones',
alpha=0.5)
plt.xlabel('Coordenada X')
plt.ylabel('Coordenada Y')
plt.title('Predicciones vs Valores Reales')
plt.legend()

# Graficar errores
errors = np.sqrt(np.sum((y_test - y_pred) ** 2, axis=1))
plt.subplot(1, 2, 2)
plt.hist(errors, bins=20, color='gray', edgecolor='black')
plt.xlabel('Error')
plt.ylabel('Frecuencia')
plt.title('Distribución de Errores')

plt.tight_layout()
plt.show()

```

Anexos 3. Certificado de traducción del resumen

Loja, 22 de Septiembre del 2024

El suscrito, Mgs. Marlon Vinicio Freire Romero, **DOCENTE DE INGLÉS DE LA UNIDAD EDUCATIVA FISCOMISIONAL “DANIEL ALVAREZ BURNEO”**, a petición de la parte interesada y en forma legal,

CERTIFICA

Que el señor **Alexis Damian Campoverde Romero**, con cédula de identidad número **1105079022**, estudiante de la Maestría en Telecomunicaciones, de la Facultad de Energía, las Industrias y los Recursos Naturales no Renovables de la Universidad Nacional de Loja, completó satisfactoriamente la presente traducción de español a inglés del resumen del trabajo de investigación denominado: **Evaluación de modelos de predicción para localización de usuarios en entornos de interiores de redes móviles 5G en bandas milimétricas (mmWave)**.

Traducción que fue revisada minuciosamente por mi persona. En consecuencia, se da valiez a la presentación de la misa. Es todo en cuanto puedo certificar en honor a la verdad, pudiendo el interesado hacer uso del presente documento.

Atentamente,



Marlon Vinicio Freire Romero

C.I: 0705204592

Registro de senescyt No.1031-2021-2355169