



Casa abierta al tiempo

UNIVERSIDAD AUTÓNOMA METROPOLITANA

Unidad Iztapalapa

Division de Ciencias Basicas e Ingenieria

Posgrado en Ciencias (CIENCIAS Y TECNOLOGÍAS DE LA INFORMACIÓN)

IMPLEMENTACIÓN DE TÉCNICAS AVANZADAS PARA LA MONITORIZACIÓN DEL ESPECTRO MULTIBANDA EN RADIOS COGNITIVOS

TESIS PARA OBTENER EL GRADO ACADEMICO DE:

DOCTOR EN CIENCIAS

(CIENCIAS Y TECNOLOGÍAS DE LA INFORMACIÓN)

QUE PRESENTA:

YANQUELETH ANTONIO DE JESÚS MOLINA TENORIO

MATRICULA: 2173802181

CORREO: yanqueleth@xanum.uam.mx

DIRECTOR: DR. ALFONSO PRIETO GUERRERO

DEPARTAMENTO DE INGENIERIA ELECTRICA, UNIVERSIDAD AUTÓNOMA METROPOLITANA.

CO-DIRECTOR: DR. RAFAEL AGUILAR GONZÁLEZ

FACULTAD DE CIENCIAS, UNIVERSIDAD AUTÓNOMA DE SAN LUIS POTOSÍ.

JURADO

PRESIDENTE: Dr. Marco Aurelio Cárdenas Juárez

SECRETARIO: Dr. Miguel López Guerrero

VOCAL: Dr. Alfonso Prieto Guerrero

VOCAL: Dra. Anabel Martínez Vargas

VOCAL: Dr. Jorge Simón Rodríguez

Ciudad de México a 30 de septiembre de 2024

Esta tesis se presento y defendió ante el jurado del examen formado por:

Dr. Alfonso Prieto Guerrero _____

Dr. Miguel López Guerrero _____

Dr. Marco Aurelio Cárdenas Juárez _____

Dra. Anabel Martínez Vargas _____

Dr. Jorge Simón Rodríguez _____

Agradecimientos

Esta investigación se ha llevado a cabo bajo la dirección del Dr. Alfonso Prieto Guerrero y el Dr. Rafael Aguilar González, cuya profunda experiencia en sistemas de comunicación digital ha sido fundamental para guiar este trabajo hacia una comprensión más profunda de la monitorización multibanda en radios cognitivos. Además, agradezco sinceramente a los distinguidos miembros de mi comité doctoral, el Dr. Alfonso Prieto Guerrero, el Dr. Miguel López Guerrero, el Dr. Marco Aurelio Cárdenas Juárez, la Dra. Anabel Martínez Vargas y al Dr. Jorge Simón Rodríguez por su destacada trayectoria que ha enriquecido significativamente las discusiones y análisis presentados en este estudio. Sus aportaciones críticas y perspicaces han sido invaluable para dar forma a las conclusiones alcanzadas.

Esta investigación recibió financiamiento del Consejo Nacional de Humanidades, Ciencia y Tecnología de México (CONAHCYT), a través de una beca del programa de Beca CONAHCYT de posgrado en México.

Contenido

AGRADECIMIENTOS	V
CONTENIDO	VII
LISTA DE FIGURAS	IX
LISTA DE TABLAS	XIII
LISTA DE ALGORITMOS	XV
ABREVIATURAS	XVII
RESUMEN	XIX
ABSTRACT	XXI
CAPÍTULO 1. INTRODUCCIÓN	1
1.1. PLANTEAMIENTO DEL PROBLEMA	4
1.2. HIPÓTESIS	6
1.3. OBJETIVOS DEL PROYECTO	6
1.4. ESTRUCTURA DE LA TESIS	7
1.5. APORTES DE LA TESIS	7
CAPÍTULO 2. ANTECEDENTES	9
2.1. MONITORIZACIÓN DEL ESPECTRO DE BANDA ESTRECHA	10
2.2. MONITORIZACIÓN DEL ESPECTRO MULTIBANDA	11
CAPÍTULO 3. MARCO TEÓRICO	21
3.1. TRANSFORMADA <i>WAVELET</i>	21
3.2. ANÁLISIS MULTIRESOLUCIÓN	22
3.3. DIMENSIÓN FRACTAL DE HIGUCHI	25
3.4. ENTROPÍA MUESTRAL	26
3.5. MAPA DEL AMBIENTE DE RADIO	29
3.6. REDES NEURONALES	33
CAPÍTULO 4. METODOLOGÍA BASE	37
4.1. DETECCIÓN DE BORDES DEL USUARIO PRIMARIO	38
4.2. REGLA DE DECISIÓN	42

CAPÍTULO 5. DESAFÍOS DE LA MONITORIZACIÓN MULTIBANDA CON DISPOSITIVOS SDR _____	45
5.1. INTRODUCCIÓN _____	45
5.2. RECOLECCIÓN DE INFORMACIÓN _____	47
5.3. ESPECTRO MULTIBANDA _____	47
5.4. INHIBICIÓN DE RUIDO IMPULSIVO _____	50
CAPÍTULO 6. IMPLEMENTACIÓN EN TIEMPO REAL DE LA MONITORIZACIÓN DEL ESPECTRO MULTIBANDA USANDO TECNOLOGÍA SDR _____	59
6.1. METODOLOGÍA PROPUESTA _____	59
6.2. EXPERIMENTOS Y RESULTADOS DE LA IMPLEMENTACIÓN EN TIEMPO REAL _____	65
CAPÍTULO 7. MONITORIZACIÓN DEL ESPECTRO MULTIBANDA BASADA EN ENTROPÍA MUESTRAL _____	77
7.1. METODOLOGÍA PROPUESTA _____	78
7.2. SIMULACIONES Y ESCENARIO CONTROLADO EN TIEMPO REAL _____	79
7.3. RESULTADOS _____	81
CAPÍTULO 8. MONITORIZACIÓN COOPERATIVA DEL ESPECTRO MULTIBANDA BASADA EN MAPAS DE ENTORNO DE RADIO Y REDES NEURONALES _____	91
8.1. METODOLOGÍA _____	92
8.2. ENTORNO REAL DE COMUNICACIÓN INALÁMBRICA _____	103
8.3. RESULTADOS _____	105
CONCLUSIONES Y PERSPECTIVAS DE INVESTIGACIÓN _____	121
REFERENCIAS BIBLIOGRÁFICAS _____	125

Lista de figuras

Figura 1.1. Ciclo cognitivo [6].....	2
Figura 1.2. Espectro multibanda del intervalo [806,902] MHz. a) en el instante T y b) en el instante $T + 10$ s.	5
Figura 1.3. El concepto de monitorización multibanda en un RC presentado en [7].....	5
Figura 2.1. Clasificación de la monitorización del espectro. a) según Ibnkahla [17]. b) según Sharma [20].	11
Figura 3.1. Se muestra a) la PSD con dos transmisiones primarias, b) la TCW con una escala de [1,120].	22
Figura 3.2. Implementación del AMR basado en un banco de filtros.	24
Figura 3.3. a) Señal original y señal reconstruida a partir únicamente de los coeficientes de aproximación. b) Coeficientes de aproximación en el nivel 3.....	25
Figura 3.4. a) espectro evaluado compuesto de 3 ventanas (ruido, transmisión primaria y ruido). b) Resultado de aplicar la SampEn a las ventanas que componen el espectro.....	28
Figura 3.5. Ejemplo de un REM. Los puntos negros indican las ubicaciones donde se toman las medidas de potencia con base en 8 sensores. En este caso, solo se considera una fuente de transmisión con -60 dBm.	29
Figura 3.6. Concepto de red neuronal: el perceptrón multicapa.....	34
Figura 4.1. Metodología base.....	37
Figura 4.2. a) Coeficientes clasificados y los respectivos bordes de frecuencia. b) El resultado de aplicar K-means [11].....	39
Figura 4.3. Diagrama de bloques que describe el funcionamiento de la técnica de monitorización usando el algoritmo K-means.	41
Figura 4.4. a) espectro multibanda sintético con dos transmisiones OFDM. b) Ocupación del espectro, resultado de aplicar la metodología base.	43
Figura 5.1. Proceso de recolección de información con N dispositivos SDR conectados de forma secuencial, i.e. cada SDR percibe cierto intervalo de frecuencia contiguo al anterior.	47
Figura 5.2. Descripción grafica del método del Welch.	49
Figura 5.3. PSD obtenida del RTL-SDR.....	50
Figura 5.4. Operación del módulo de inhibición de ruido impulsivo.....	51
Figura 5.5. Descomposición de la PSD a través del AMR.	52

Figura 5.6. Submódulo de escalamiento de los coeficientes de detalle.	52
Figura 5.7. Operación del submódulo de eliminación de ruido.	54
Figura 5.8. Coeficientes originales y modificados a) aproximación. b) detalle.	55
Figura 5.9. Reconstrucción de la PSD después de eliminación de ruido impulsivo.	56
Figura 5.10. Diferencia entre la PSD original y la PSD modificada.	56
Figura 5.11. Diferencia entre la PSD original y la PSD modificado usando múltiples dispositivos SDR.	57
Figura 6.1. Escenario general implementado para la MEMB.	60
Figura 6.2. Etapa de percepción: Señales recibidas por los dispositivos SDR, actualizadas cada 100 ms.	61
Figura 6.3. Asignación de frecuencias portadoras de cada dispositivo conectado para conformar el espectro multibanda observado. ...	62
Figura 6.4. Estimador de la PSD a través del método de Welch.	63
Figura 6.5. Módulo de detección los UPs.	63
Figura 6.6. Señales entregadas desde el bloque "Detección de UPs.	64
Figura 6.7. Escenario implementado.	65
Figura 6.8. Rango de frecuencia percibido por los US.	68
Figura 6.9. Pasos de la implementación controlada.	68
Figura 6.10. Bloque conteniendo la adición de ruido gaussiano complejo.	69
Figura 6.11. Clasificación de ventanas detectadas con la técnica MEMB.	71
Figura 6.12. Probabilidad de éxito de cada US en la implementación controlada.	72
Figura 6.13. Probabilidad de éxito del DE.	73
Figura 6.14. Muestras en error para cada US en la implementación.	74
Figura 6.15. Muestras en error del DE.	74
Figura 6.16. Aplicación SDR-MEMB-UAMI.	75
Figura 7.1. Módulo modificado (línea verde punteada) para la detección de los UP utilizando SampEn.	79
Figura 7.2. Pasos para la simulación e implementación controlada.	80
Figura 7.3. a) Ejemplo de trama correspondiente a una transmisión OFDM con AWGN (SNR=10 dB). b) Resultado de aplicar la DFH sobre 1,000 tramas. c) Resultado de aplicar la SampEn sobre 1,000 tramas.	83
Figura 7.4. Algoritmo ExMa aplicado a los valores de la SampEn para determinar el umbral de decisión óptimo.	84
Figura 7.5. Probabilidad de éxito para diferentes umbrales propuestos para la SampEn. Los resultados se comparan con la DFH.	85

Figura 7.6. a) Clasificación de ventanas detectadas usando a) la DFH y b) la SampEn (umbral fijado en 0.38) como regla de decisión.	86
Figura 7.7. Muestras en error para el umbral propuesto para la SampEn. Los resultados se comparan con la DFH.....	87
Figura 7.8. Probabilidad de éxito en función de la SNR del entorno real controlado.	88
Figura 7.9. Muestras en error contra SNR para la implementación en tiempo real propuesta.....	89
Figura 7.10. a) Ocupación de una trama espectral utilizando la DFH y la SampEn con una $SNR=0$ dB. b) Valor calculado de la DFH y la SampEn para cada ventana detectada en el intervalo de espectro.	90
Figura 8.1. a) Propuesta del Capítulo 7. . b) Nueva propuesta.....	91
Figura 8.2. Esquema general de la metodología.....	92
Figura 8.3 Implementación de la entidad central utilizando procesamiento de señal digital clásico.	95
Figura 8.4. Entidad central que determina los parámetros para la construcción de REM y mapas de área a través de NN.....	98
Figura 8.5. Construcción del vector $PSD_rec_T \{R'_i(k)\}$	100
Figura 8.6. Construcción del vector $Edge_rec_T \{R'_i(k)\}$	101
Figura 8.7. a) US_1 observa j UP, pero UP_1 se descarta porque no alcanza el umbral. b) US_2 observa j UP, sin embargo, UP_1 y UP_j se descartan porque no están en el rango de frecuencia correcto. c) US_n observa j US, UP_1 se descartan por no tener un ancho de banda lo suficientemente grande para ser considerada como transmisión.	103
Figura 8.8. El escenario real implementado.	104
Figura 8.9. Ocupación de espectro para cada US.	105
Figura 8.10. PSD aproximada para cada US.....	106
Figura 8.11. Media de la ocupación obtenida por la entidad central.	107
Figura 8.12. Transmisión primaria en la banda de 699.48 MHz con un B de 0.4 MHz. a) REM, b) Superficie ocupada.....	108
Figura 8.13. Transmisión primaria en la banda de 700.49 MHz con un B de 0.825 MHz. a) REM, b) Superficie ocupada.....	108
Figura 8.14. Tiempo de entrenamiento para las diferentes versiones de la NN_3	110

Figura 8.15. Diferencia entre los valores reales y los obtenidos por la NN_1 a) media y desviación estándar (STD), b) media.	111
Figura 8.16. Media y STD de la precisión para detectar a) la portadora del UP_1 de las distintas variantes de la NN_2 . b) la portadora del UP_2 de las diferentes redes.	112
Figura 8.17. Media y STD de la precisión para detectar a) el B_1 de las distintas variantes. b) el B_2 de las diferentes redes.	113
Figura 8.18. Salidas de evaluación de ventanas detectadas.	114
Figura 8.19. F1 score de la NN_1	115
Figura 8.20. Resultados de la evaluación de B	116
Figura 8.21. $F1$ de NN_3	117
Figura 8.22. $F1$ y relación del tiempo de entrenamiento de a) NN_1 y b) NN_3	118
Figura 8.23. Resultado de la entidad central.	119

Lista de tablas

Tabla 2.1. Trabajos relacionados con la entropía.	13
Tabla 2.2. Trabajos recientes de CRN.	19
Tabla 4.1. Técnicas de ML usadas en la metodología base.	39
Tabla 5.1. Características de los dispositivos SDR [55].	46
Tabla 6.1. Parámetros de los dispositivos considerados.....	66
Tabla 6.2. Parámetros de la implementación controlada.	69
Tabla 7.1. Parámetros de simulación.	81
Tabla 8.1. Información que cada US comparte en la base de datos en cada tiempo de detección T_x	94
Tabla 8.2. Principales parámetros de los UP y US.....	104
Tabla 8.3. Tiempo de entrenamiento de a) NN_1 ; b) NN_2 ; c) NN_3	110

Lista de algoritmos

Algoritmo 4.1. Detección de bordes [11].....	38
Algoritmo 4.2. Regla de decisión [11].....	43
Algoritmo 5.1. Reducción de ruido.	58
Algoritmo 6.1. Adición de ruido artificial.	70
Algoritmo 7.1. Técnica de MEMB basada en SampEn.....	78
Algoritmo 8.1. Entidad central funcionando con procesamiento de señales tradicional.....	96
Algoritmo 8.2. Entidad central funcionando con redes neuronales.	98

Abreviaturas

Concepto	Abreviatura/acrónimo
Acceso múltiple por división de código	CDMA, del inglés <i>Code division multiple access</i>
Acceso múltiple por división de frecuencias ortogonales	OFDM del inglés <i>orthogonal frequency division multiplexing</i>)
Análisis multiresolución	AMR
Aprendizaje automático	ML del inglés <i>machine learning</i>
Densidad espectral de frecuencia	PSD, del inglés <i>Power spectral density</i>
Desviación estándar	STD, del inglés <i>standard deviation</i>
Detector de energía	DE
Detector de energía	DE
Dimensión fractal de Higuchi	DFH
Entropía aproximada	ApEn del inglés <i>approximate entropy</i>
Entropía biespectral	BispEn del inglés <i>bispectral entropy</i>
Entropía muestral	SampEn del inglés <i>sample entropy</i>
Entropía Rényi	RenyiEn
F1-score	F1
Falso negativo	FN
Falso positivo	FP
Internet de las cosas	IoT del inglés <i>Internet of Things</i>
Mapa de comportamiento radioeléctrico	REM del inglés <i>radio enviroment map</i>
Maximización de esperanza	ExMa, del inglés <i>Expectation maximization</i>
Millones de muestras por segundo	MMPS
Monitorización del espectro multibanda	MEMB
Multicanalización por división de frecuencias ortogonales	OFDM, del inglés <i>Orthogonal frequency division multiplexing</i>
Múltiples entradas y múltiples salidas	MIMO del inglés <i>multiple inputs multiple outputs</i>

Concepto	Abreviatura/acrónimo
Perceptrón multicapa	MLP, del inglés <i>multilayer perceptron</i>
Periférico universal de radio por software	USRP del inglés <i>universal software radio peripheral</i>
Ponderación de Distancia Inversa	IDW, del inglés <i>Inverse distance weighting</i>
Probabilidad de éxito	PE
Radio cognitivo	RC
Radio definido por software	SDR, del inglés <i>Software Defined Radio</i>
Razón señal a ruido	SNR del inglés <i>Signal to Noise Ratio</i>
Receptor	Rx
Redes de RC	CRN del inglés <i>cognitive radio networks</i>
Redes neuronales	NN del inglés <i>neural network</i>
Ruido blanco Gaussiano aditivo	AWGN, inglés <i>Additive white Gaussian noise</i>
Transformada <i>wavelet</i> continua	TCW
Transformada rápida de Fourier	FFT, del inglés <i>fast Fourier transform</i>
Transmisor	Tx
TV con espacios	TVWS del inglés <i>TV with spaces</i>
Usuario primario	UP
Usuario secundario	US
Verdadero negativo	VN
Verdadero positivo	VP

Resumen

En este trabajo de investigación se presentan tres propuestas para la monitorización del espectro multibanda. Con el objetivo de implementar técnicas novedosas basadas en métodos avanzados de procesamiento digital de señales, y aprendizaje automático en un contexto de radios cognitivos. Estas propuestas se implementaron en un entorno de comunicación real inalámbrica con el uso de dispositivos definidos por software (SDR, del inglés *Software Defined Radio*).

La primera propuesta es una técnica que utiliza el análisis multiresolución y técnicas de aprendizaje automático para la detección de bordes y la dimensión fractal de Higuchi como regla de decisión. Además esta técnica es implementada en dispositivos SDR de bajo costo. La primera técnica culminó en una aplicación (SDR-MBSS-UAMI) en la que el usuario puede manejar diferentes dispositivos SDR conectados (hasta 8) con 96% de porcentaje de probabilidad de éxito para detectar a los usuarios primarios (UP). En esta propuesta los US colaboran para detectar una banda amplia de frecuencia en la que cada dispositivo observa un intervalo de frecuencia contiguo al resto de dispositivos.

La segunda propuesta plantea una técnica de monitorización en la que la regla de decisión es la entropía muestral. Al igual que la anterior propuesta, es empleada utilizando dispositivos SDR. La segunda propuesta mejora la eficiencia para detectar al UP con una probabilidad de éxito de 98 % para detectar a los UP.

La tercera propuesta integra una red de US (usuarios secundarios, entidades de procesamiento con tecnología SDR) para detectar a los UP, tanto en el dominio de frecuencia como en ubicación geográfica en un área definida, esto se logra con ayuda de mapas de entorno radioeléctrico y redes neuronales. El resultado de la tercera propuesta es el número de UP detectados en el área, su ancho de banda, la portadora de cada UP y un mapa de área que es el espacio geográfico utilizado por cada UP detectado. Esta propuesta tiene un éxito de 96 %.

Finalmente, se puede concluir que las tres propuestas presentadas en este trabajo de investigación son viables para aplicar en la monitorización del espectro en sistemas de comunicación digital en tiempo real.

Abstract

In this research work, three proposals for monitoring the multiband spectrum are presented. With the aim of implementing novel techniques based on advanced methods of digital signal processing, and machine learning in a context of cognitive radios. These proposals were implemented in a real wireless communication environment with the use of software defined devices (SDR, Software Defined Radio).

The first proposal is a technique that uses multiresolution analysis and machine learning techniques for edge detection and the Higuchi fractal dimension as a decision rule. Furthermore, this technique is implemented in low-cost SDR devices. The first technique culminated in an application (SDR-MBSS-UAMI) in which the user can manage different connected SDR devices (up to 8) with 96% success rate to detect the primary users (UP). In this proposal, the US collaborate to detect a wide frequency band in which each device observes a frequency interval contiguous to the rest of the devices.

The second proposal proposes a monitoring technique in which the decision rule is sample entropy. Like the previous proposal, it is used using SDR devices. The second proposal improves the efficiency of detecting the UP with a success probability of 98% to detect the UP.

The third proposal integrates a network of USs (secondary users, processing entities with SDR technology) to detect UPs, both in the frequency domain and in geographical location in a defined area, this is achieved with the help of radioelectric environment maps. and neural networks. The result of the third proposal is the number of UPs detected in the area, their bandwidth, the carrier of each UP and an area map that is the geographic space used by each UP detected. This proposal has a success rate of 96%.

Finally, it can be concluded that the three proposals presented in this research work are viable to apply to spectrum monitoring in real-time digital communication systems.

Capítulo 1. Introducción

En la actualidad el espectro radioeléctrico, en general, está distribuido en licencias de uso exclusivo para operar en frecuencias fijas otorgadas por el organismo regulador de cada país. El aumento de la demanda de servicios inalámbricos como la telefonía móvil de alta velocidad y la conexión a Internet, además de una mala administración de estas licencias; ha provocado la escasez del espectro [1], [2], esto es, la limitada cantidad de frecuencias disponibles en el espectro radioeléctrico para diversas aplicaciones de comunicación.

Debido a esta problemática surge el concepto de radio cognitivo (RC) [3] como una posible solución. Este concepto fue introducido por primera vez por Mitola, y puede ser definido como un dispositivo de comunicaciones con la capacidad para aprovechar oportunamente los huecos espectrales y continuar transmitiendo de forma dinámica a través del espacio tiempo-frecuencia. El RC ha sido considerado en nuestros días como una de las soluciones sobresalientes para la escasez de espectro, siendo incluso considerado en los estándares de la IEEE, como es el caso del estándar IEEE 802.22 que propone el aprovechamiento de espacios libres en las frecuencias de espectro dedicadas a la televisión digital terrestre [4].

El RC es un enfoque tecnológico que permite a los usuarios secundarios (US, también llamados usuarios sin licencia) detectar y aprovechar de manera dinámica las frecuencias del espectro radioeléctrico que no están siendo utilizadas por los usuarios primarios (UP), también conocidos como usuarios licenciados que son aquellos que pagan por transmitir y/o recibir en una o varias frecuencias asignadas.

Cuando un US opera, lo hace bajo estas cuatro etapas o funciones [5] (ver la **Figura 1.1**):

Monitorización del espectro: el US revisa continuamente el espacio radioeléctrico para identificar las bandas de frecuencia que están desocupadas o las que tienen un nivel bajo de actividad. Con esta actividad el US no solo se percata de qué frecuencias están libres, además detecta la presencia de los UP en el espectro.

Compartición: es la etapa en la que los dispositivos cognitivos determinan y coordinan cómo compartirán el espectro radioeléctrico eficientemente y sin perjudicar a los sistemas primarios, dados los datos de la etapa de monitorización.

Decisión: en esta etapa se hace el acceso coordinado al canal para ello se toma una decisión informada de cómo acceder al canal tomando en cuenta la frecuencia en la que operará y cómo configurará sus parámetros de transmisión para comunicarse de manera efectiva.

Movilidad: es la capacidad de los US para cambiar su ubicación en frecuencia manteniendo sus funciones de monitorización y acceso al espectro.

Además el RC puede aprender con el tiempo y mejorar su capacidad para detectar bandas de frecuencia disponibles y predecir patrones de uso.

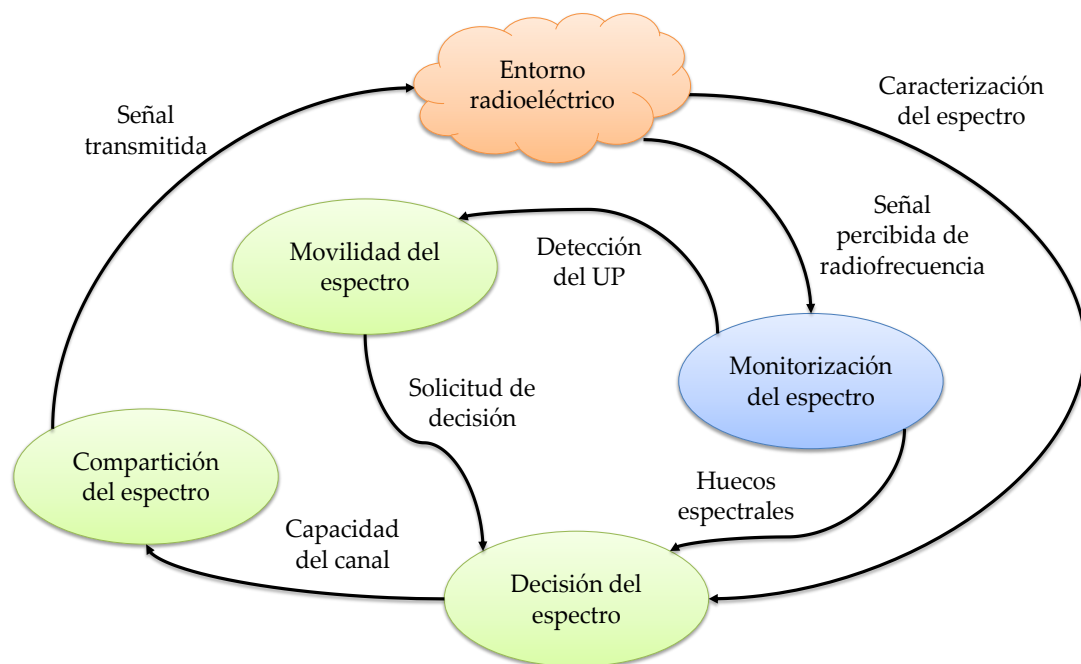


Figura 1.1. Ciclo cognitivo [6]

Este trabajo de tesis está centrado en la etapa de monitorización del espectro, permitiendo supervisar y analizar las frecuencias del espectro para determinar cómo se están utilizando y si hay interferencias, congestión o cambios en la actividad de los UP. Con base en esto, se puede garantizar un uso eficiente y ordenado del espectro radioeléctrico, además de prevenir

alguna interferencia entre los diferentes sistemas de comunicación primaria. Esta etapa es sin duda un proceso clave para salvaguardar la operación de las redes y sistemas de comunicaciones inalámbricas, siendo uno de los elementos más importantes en los RC. Para ello los US deben detectar de manera confiable la presencia de los UP sin causarles ninguna interferencia. Esto es intrínsecamente una tarea desafiante debido a que la monitorización se realiza de forma independiente por los US para no alterar la infraestructura de red del UP [7]. La monitorización del espectro en un RC es un término que implica la obtención de las características del espectro mediante múltiples dimensiones, como el tiempo, el espacio, la frecuencia y el código. Entre estas características se encuentran el tipo de modulación, la forma de onda, el ancho de banda, la frecuencia de la portadora, etc.

En general, las diferentes técnicas propuestas para la monitorización de espectro se centran en la detección del UP en una sola banda [8]. Dada la necesidad de una gestión más efectiva y eficiente de la creciente complejidad del espectro radioeléctrico debido a la demanda de diferentes aplicaciones y servicios inalámbricos, surge el concepto de la monitorización del espectro multibanda (MEMB) que se refiere a la capacidad que tiene el RC de examinar y monitorear múltiples bandas de frecuencia simultáneamente no necesariamente contiguas y estas pueden incluir diferentes tecnologías [8]. Con base en esto, los RC multibanda representan una gran alternativa para implementar redes de RC eficientes, en comparación con las redes de una sola banda, dado que tienen el potencial de revolucionar la forma en la que se utiliza y se comparte el espectro gracias a que permitirán [9]:

- Determinar una cobertura geográfica.
- La identificación de bandas libres, ocupadas.
- Detección y gestión de interferencias.
- Sincronizar información.
- Identificar patrones y prever el comportamiento del espectro.
- La gestión de frecuencias.

A lo largo de los últimos años, como se menciona más adelante, se han propuesto técnicas en entornos simulados y entornos reales de comunicación inalámbrica. En este trabajo de investigación doctoral se proponen metodologías en entornos reales implementadas en tiempo real las cuales conllevan a la solución de algunos aspectos desafiantes al trabajar con radio definido por software (SDR, del inglés *software defined radio*) como:

- La elección correcta para el estimador espectral.
- La elección de los dispositivos SDR.
- La adición de ruido debido al software.
- El manejo del espectro ante el comportamiento del *hardware*.
- Una correcta evaluación para determinar su eficiencia.
- La cooperación entre múltiples dispositivos tanto para observar un intervalo más amplio de frecuencias así como para observar el comportamiento del espectro en un área geográfica.

1.1. Planteamiento del problema

El objetivo principal de la MEMB es realizar la detección completa y detallada de cómo se utilizan las diferentes bandas frecuenciales en un área geográfica del UP desde el punto de vista de los RC. En la **Figura 1.2** se muestra un intervalo amplio de frecuencia de 96 GHz en dos instantes de tiempo diferentes, en el instante T y en el instante $T + 10$ s. En esta imagen se puede apreciar la fluctuación en el uso de la banda de 806–902 MHz de uso exclusivo para móvil y móvil aeronáutico [10]. En esta imagen se nota que las bandas licenciadas (ocupadas por UP) no siempre están ocupadas, lo que representa una oportunidad ante la escasez del espectro. La idea de la MEMB es mostrada en la **Figura 1.3**, donde un US está continuamente revisando una amplia porción del espectro con la intención de utilizar los “huecos” espectrales que han sido liberados por los UP.

Bajo esta perspectiva, la búsqueda de esquemas eficientes de monitorización del espectro no está agotada. Es importante remarcar que, en la actualidad, dadas las necesidades de *hardware* y la complejidad de las técnicas, los métodos de monitorización del espectro basados en la detección de energía son los más utilizados, aunque no necesariamente son los más eficientes. La motivación principal de este trabajo radica en la implementación y búsqueda de técnicas innovadoras para la MEMB en dispositivos SDR de bajo costo, con el objetivo de mejorar la detección espectral en sistemas de comunicación digital inalámbrica, especialmente en un enfoque de RC multibanda. Esto permitirá proveer una herramienta que fomente el análisis del espectro radioeléctrico.




Figura 1.2. Espectro multibanda del intervalo [806,902] MHz a) en el instante T y b) en el instante $T + 10$ s

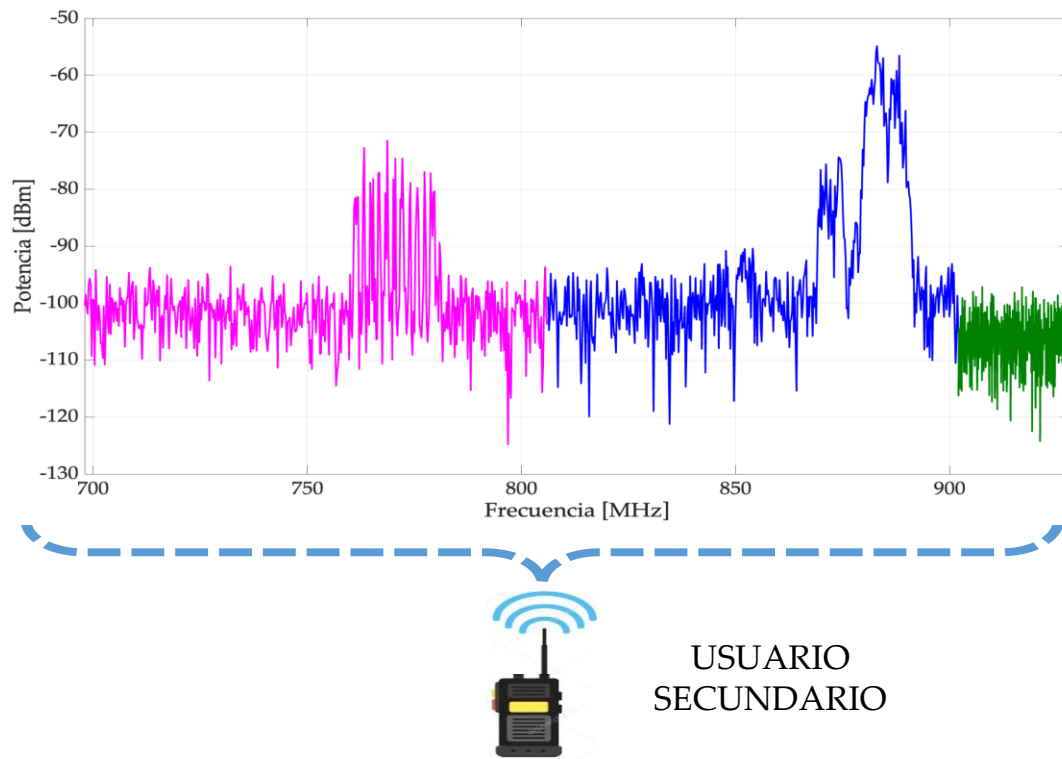


Figura 1.3. El concepto de monitorización multibanda en un RC presentado en [7]

1.2. Hipótesis

Este trabajo parte de la siguiente pregunta de investigación. ¿Como puede la implementación de técnicas de monitorización del espectro multibanda mejorar la eficiencia en el uso del espectro en radios cognitivos?

Para ello se plantea la siguiente hipótesis. La implementación de técnicas avanzadas para la monitorización del espectro multibanda en dispositivos de comunicación mejora la eficiencia en la asignación del espectro y optimiza el rendimiento del usuario secundario al proporcionar datos mas precisos sobre la ocupación del espectro, lo que permite una asignación mas efectiva de los recursos de comunicación y respondiendo de forma mas agil a las demandas cambiantes del entorno espectral en un contexto de radios cognitivos.

1.3. Objetivos del proyecto

En esta sección se presentan los objetivos generales y específicos esperados de este trabajo de investigación doctoral.

Objetivo general

Desarrollar, Implementar y evaluar dos técnicas de monitorización del espectro multibanda basadas en métodos avanzados de procesamiento digital de señales y aprendizaje automático (ML, del inglés *machine learning*). Adaptándolas para su aplicación práctica y evaluando su eficacia en entornos reales de comunicación inalámbrica en el contexto de radios cognitivos,

Objetivos específicos

- Implementar el trabajo propuesto en el trabajo de maestria [11] (técnica basada en *wavelets*, ML y la dimensión fractal de Higuchi (DFH)) en *hardware* de comunicaciones genérico (tecnología SDR) para conocer su eficiencia en un entorno real de comunicación inalámbrica.
- Desarrollar una metodología para la MEMB en dos técnicas no exploradas (e.g. entropía muestral (SampEn del inglés *sample entropy*)).

- Evaluar el desempeño de la técnica basada en la SampEn y si es factible evaluar su eficiencia en un entorno real de comunicación inalámbrica.
- Desarrollar una red de RC en un entorno real de comunicaciones para la MEMB en donde su funcionamiento sea coordinado con redes neuronales.

1.4. Estructura de la tesis

Este trabajo está organizado de la siguiente forma. En el Capítulo 2 se presentan los conceptos referentes a las técnicas de monitorización como: antecedentes, clasificaciones, y fundamentos encontrados en la literatura. En el Capítulo 3 se mencionan las bases teóricas y conceptos utilizados en las metodologías propuestas. El trabajo previo que corresponde al trabajo desarrollado en la tesis de maestría se presenta en el Capítulo 4. En el Capítulo 5 se presentan los desafíos y soluciones al trabajar con dispositivos SDR de bajo costo. En el Capítulo 6 se presenta la implementación en tiempo real de la MEMB utilizando dispositivos SDR. El Capítulo 7 se presenta la entropía muestral como una técnica viable para la MEMB en un entorno real de comunicaciones. En el Capítulo 8 se presenta el uso del mapa de entorno radioeléctrico (REM del inglés *radio environment map*) y redes neuronales (NN del inglés *neural network*) para la construcción de una red de RC para la MEMB cooperativa en tiempo real. Finalmente, se presentan las conclusiones y perspectivas de investigación.

1.5. Aportes de la tesis

Durante el desarrollo de esta tesis, se han realizado importantes contribuciones al campo de MEMB en RC. Estas contribuciones se han plasmado en la publicación de cuatro artículos en revistas indexadas.

Artículo 1.

“Real-Time Implementation of Multiband Spectrum Sensing Using SDR Technology”

Este artículo presenta un avance significativo en la implementación en tiempo real de una técnica de MEMB usando dispositivos SDR. Dando una nueva perspectiva sobre el uso del entorno real de comunicaciones inalámbricas.

Los resultados obtenidos fueron prometedores para el uso de tecnología SDR en un entorno real de comunicaciones [12].

Artículo 2.

“Multiband Spectrum Sensing Based on the Sample Entropy”

Este artículo aborda la propuesta, análisis e implementación de una técnica de MEMB en un entorno real de comunicaciones inalámbricas en dispositivos SDR. Aquí se usa la entropía muestral para determinar la presencia y ausencia del US en un intervalo amplio de frecuencia ofreciendo una nueva metodología para la detección del UP en el espectro. Este enfoque ha sido integrado en [13].

Artículo 3.

“Cooperative Multiband Spectrum Sensing Using Radio Environment Maps and Neural Networks”

En este artículo se presenta un entorno cooperativo para la MEMB usando procesamiento digital de señales clásico, redes neuronales y mapas de entorno radioeléctrico. Lo que ha resultado en el conocimiento del comportamiento del espectro en un intervalo amplio de frecuencia y el uso de este intervalo en una área específica [14].

Capítulo 2. Antecedentes

En este capítulo, se incluye una revisión exhaustiva y actualizada de los avances más significativos y recientes en la monitorización del espectro. Esta revisión involucra un análisis detallado de la literatura científica relevante, así como de las tecnologías, metodologías y enfoques teóricos más prominentes que han sido utilizados y discutidos por la comunidad especializada.

En el estado actual de la tecnología, la monitorización del espectro va más allá de la simple detección de señales. Incluye la identificación de patrones complejos, la caracterización de interferencias, la adaptación dinámica a entornos cambiantes y la optimización del uso del espectro disponible. Además, con la evolución de las tecnologías 5G y 6G, esta se torna aún más esencial para garantizar la eficiencia espectral y la coexistencia armoniosa de diversas tecnologías y servicios.

Este estado del arte aborda aspectos clave como la detección y clasificación de señales, la adaptación dinámica, las redes de radio cognitivo y el uso de inteligencia artificial para mejorar la eficiencia espectral. También se exploran enfoques emergentes, como la monitorización multibanda y la utilización de tecnologías de radio definida por software para alcanzar un espectro más dinámico y eficiente.

La detección puede ser realizada por un solo US o por varios US de manera cooperativa para mejorar su precisión general [15]. La detección de espectro se puede clasificar de maneras diferentes como se muestra en la **Figura 2.1**. Algunos autores, como Sharma en [16], deciden clasificar las técnicas de detección en según sus características. Estas características pueden ser si las técnicas son cooperativas o no cooperativas, por el conocimiento previo de la señal percibida por los US o por detección (ver la **Figura 2.1b**).

Este estudio del estado del arte está focalizado en las técnicas con las características indicadas en la **Figura 2.1a** (según el ancho de banda). Estas técnicas están clasificadas a su vez como detección por banda estrecha y banda ancha. Para este estudio del estado del arte se consideran técnicas basadas en el ancho de banda. Con base en lo anterior, las técnicas de detección de banda estrecha explotan las oportunidades espectrales en un

rango de frecuencia estrecho, mientras que la detección de banda ancha se centra en explotar un rango de frecuencias más amplio.

2.1. Monitorización del espectro de banda estrecha

En la literatura se han propuesto muchos algoritmos de detección de banda estrecha como el detector de energía [17], la basada en forma de onda [18], a través de la detección de características cicloestacionarias [17], la detección por radio identificación [19], [20]. La mayoría de técnicas de banda única da como resultado decisiones binarias únicas y no se puede obtener información para diferentes oportunidades de subbandas dentro del espectro. Además este tipo de técnicas de detección de espectro se consideran no cooperativas. Los algoritmos no cooperativos son simples, rentables y fáciles de implementar en un entorno de tiempo real. La detección de banda estrecha puede lograr, hasta cierto punto, la detección de banda ancha mediante la cooperación entre US, lo que algunos autores, como Ibnkahla, clasifican como técnicas en serie o en paralelo (ver la **Figura 2.1a**) [21].

Actualmente, existen en la literatura muchos trabajos relacionados con las técnicas de monitorización. Por ejemplo, en [22] los autores proponen un método de detección de espectro adaptativo de doble umbral basado en un modelo de Markov para entornos con una relación señal a ruido (SNR, del inglés *signal noise ratio*) baja. Esta propuesta reduce significativamente el consumo de energía y procesamiento para la detección de espectro en comparación con el esquema tradicional de banda única. Otro trabajo publicado recientemente es el [23], en el que los autores proponen un detector de señales ciego basado en el concepto de entropía para detectar una subbanda del espectro de potencia.

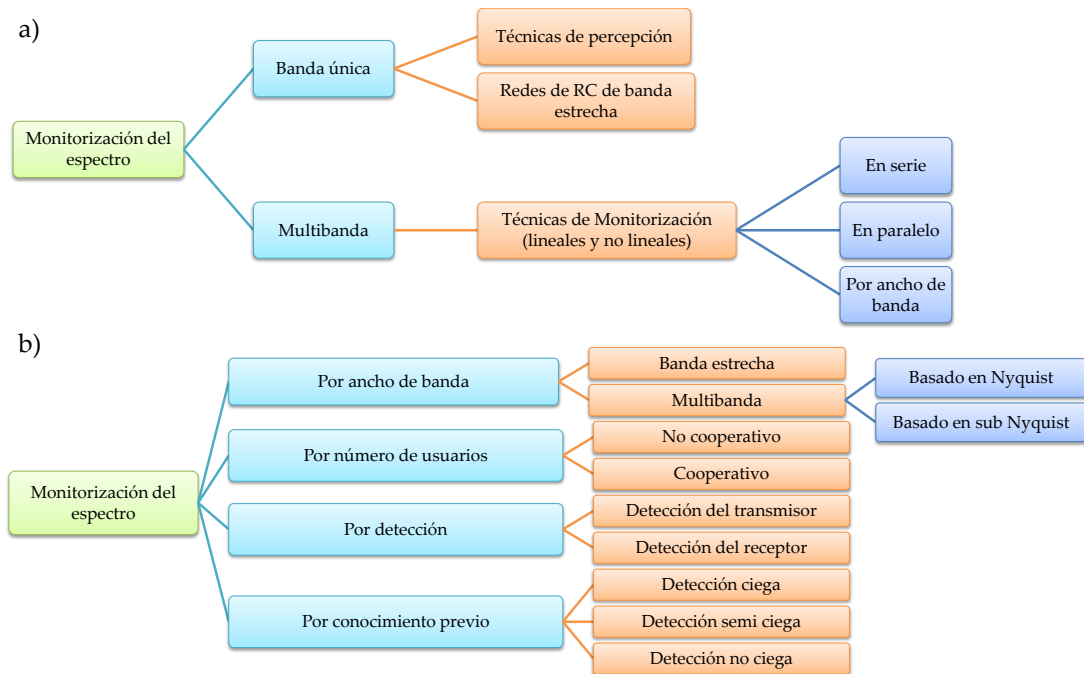


Figura 2.1. Clasificación de la monitorización del espectro. a) según Ibnkahla [21]. b) según Sharma [16].

Dados los RC de banda estrecha se pueden formar las redes cooperativas de RC de banda única o banda estrecha que tienen como propósito la detección conjunta del UP en el espectro, el estudio del entorno espectral o comunicación inalámbrica eficiente. Además las redes radios cognitivos (CRN, del inglés *cognitive radio network*) evitan el problema de la terminal oculta en bandas de frecuencias específicas [7].

Las CRN pueden tener diferentes configuraciones [7]:

- **Centralizada:** cuando una entidad central recolecta y comparte información con los US. Usualmente en este tipo de configuración la entidad central realiza el procesamiento.
- **Distribuida:** cuando las entidades secundarias se comunican entre sí para compartir información.
- **Híbrida:** cuando existe una entidad central que puede recibir y transmitir información de los US y además cada US puede compartir información con sus iguales incluyendo la entidad central.

2.2. Monitorización del espectro multibanda

La MEMB se refiere a la práctica de analizar el espacio radioeléctrico de múltiples bandas de frecuencia de manera simultánea o secuencial para

identificar actividades de radiofrecuencia, interferencias, congestión, etc. En la actualidad es una tarea desafiante implementar las técnicas de MEMB en entornos simulados o entornos reales de comunicación inalámbrica. Una primera introducción al concepto de detección de espectro multibanda aparece en [24]. Aquí, los autores unen múltiples detectores de banda estrecha para maximizar el rendimiento de los US, lo que limita la interferencia con los UP. Después de eso, varias contribuciones aparecieron en la literatura, por ejemplo en [25] donde los autores consideran un algoritmo asíncrono de acceso dinámico al espectro en el canal de banda ancha dividido en varios canales de banda estrecha para encontrar el tiempo óptimo del período de detección. En [7] se presenta una revisión documental (*review*) de la detección de espectro multibanda aplicada a los servicios de próxima generación. En esta contribución, se clasifican las técnicas de detección de usuarios más representativas. Para el caso de la detección de *wavelets* discretas, los autores mencionaron que este método proporciona un buen análisis de las singularidades del espectro. En [26] los autores consideraron la limitación de *hardware* para los US en la detección de espectro multibanda. Además, de acuerdo con el estado del tráfico, un algoritmo propuesto selecciona la mejor estrategia de detección de espectro. Una mejora de este trabajo aparece en [27], aquí se considera la correlación de canales para adaptar la propuesta a escenarios prácticos como la televisión abierta. En [28], se presenta un método de acceso probabilístico en la detección de espectro multibanda. Sus resultados muestran cómo esta clasificación mejora las tasas de datos en comparación con los métodos de detección de espectro clásicos. Otro trabajo que destaca en la MEMB es [29]. En este artículo, se utiliza el método de rango medio para detectar el nivel de energía óptimo en la región difusa, que es el área entre el umbral de energía bajo y alto, para un detector de energía (DE) de doble umbral. En [30] se propone una técnica de muestreo por compresión que puede reducir efectivamente el costo de adquisición de señales, cuyo objetivo principal es adquirir con precisión la señal para la detección.

En el caso del internet de las cosas (IoT del inglés *Internet of Things*) donde muchos dispositivos están transmitiendo, es importante detectar los espacios de espectro disponibles para mantener un buen rendimiento de la red. Por ejemplo, en [31] los autores presentan una solución para minimizar el número de canales que deben ser detectados por los nodos de IoT pero manteniendo los requisitos de probabilidad de detección. Los resultados muestran una reducción importante en el consumo de energía en comparación con las otras alternativas de detección de espectro similares.

En este proyecto de tesis se exploran técnicas basadas en la entropía, específicamente la entropía muestral. En algunos trabajos publicados se utilizaron medidas similares, por ejemplo, en [32] utilizaron entropía aproximada (ApEn, del inglés *approximate entropy*), entropía biespectral (BispEn, del inglés *bispectral entropy*), SampEn y entropía Rényi (RenyiEn, del inglés *Renyi entropy*) en detección espectral de banda única. En este trabajo, los resultados muestran que BispEn superó a las otras tres medidas de entropía, mejorando la detección en al menos 5 dB. En [33], una técnica basada en ApEn, con niveles desconocidos de SNR en una sola banda, muestra una detección favorable considerando la cicloestacionariedad de la señal. En [34] se desarrolla una propuesta para la detección basada en la entropía de la señal recibida, utilizando un filtrado adaptado adecuadamente. Las medidas de entropía que se han utilizado en la MEMB como se resumen en la **Tabla 2.1**.

Tabla 2.1. Trabajos relacionados con la entropía y la monitorización del espectro.

Título	Entropía	Descripción	Resultados
<i>A Comparative Study of Different Entropies for Spectrum Sensing Techniques [32].</i>	ApEn; BispEn; SampEn; RenyiEn;	En este trabajo se utilizaron ApEn, BispEn, SampEn y RenyiEn en la monitorización del espectro de banda única.	Los resultados muestran que BispEn superó a las otras tres medidas de entropía, mejorando la detección en al menos 5 dB
<i>Entropy-based spectrum sensing in cognitive radio [34].</i>	ApEn	Es una técnica basada en la ApEn, con niveles desconocidos de SNR en una sola banda	Muestra una detección favorable considerando la cicloestacionariedad de la señal

Título	Entropía	Descripción	Resultados
<i>A Novel Blind Signal Detector Based on the Entropy of the Power Spectrum Subband Energy Ratio [23].</i>	ApEn	Se propone un detector de señal ciego basado en la entropía para detectar una subbanda del espectro de potencia	Este método no necesita estimar la intensidad del ruido ni requiere información previa de la señal a detectar, por lo que es un detector de señal completamente ciego.
<i>Rényi Entropy-Based Spectrum Sensing in Mobile Cognitive Radio Networks Using Software Defined Radio [35].</i>	RenyiEn	Se implementa un sistema para comunicaciones móviles utilizando una red de SDR. Aquí, para la detección de PU, se utiliza RenyiEn directamente sobre los espectros de las señales recibidas sin conocimiento previo de sus características	La probabilidad de detección del sistema es del 96 % con una relación SNR de 10 dB

Uno de los desafíos en la MEMB es considerar la cooperación de los diferentes US para determinar la ocupación del entorno radioeléctrico. Algunos de los trabajos que abordan la cooperación se mencionan a continuación. En [36] los autores consideraron una optimización genética en un escenario de detección colaborativa multibanda. La propuesta resolvió los problemas de detección de manera eficiente y aumentó la velocidad de datos. En [37] se considera el problema crítico de la terminal oculta (en este caso la UP oculta), y proponen una distribución espacial específica de los US para contrarrestar este problema. En [38], se propone un marco para la asignación de recursos y la detección cooperativa de espectro multibanda para IoT en redes cognitivas 5G. Aquí se enfatiza que asignar un número óptimo de canales a detectar en el espectro multibanda puede disminuir significativamente el consumo de energía en comparación con los enfoques de detección de espectro existentes. En [39] proponen un algoritmo de detección cooperativa con un enfoque de muestreo a una tasa inferior a la

frecuencia de Nyquist para diseñar un sistema con costos y consumo de energía significativamente reducidos. En [40], se han propuesto esquemas de detección de espectro de banda ancha individuales y cooperativos para reducir el consumo de energía en la adquisición, procesamiento y transmisión de señales. En [41] se propone un algoritmo basado en una arquitectura multicanal de baja velocidad para detectar bordes de frecuencia utilizando *wavelets* en un contexto multibanda para CRN.

También en este estado del arte se incluyen algunos trabajos recientes que implican la MEMB en entornos simulados. Con base en lo anterior se han propuesto muchas técnicas para la MEMB derivadas del procesamiento de señales digitales o ML, como *wavelets* discretas, detección comprimida, detectores de energía, métodos ciegos o semiciegos; esencialmente en escenarios simulados [42], [43], [44], [45], [46], [47], [48]. En [49] se presenta una nueva técnica de MEMB basada en el análisis multiresolución y el ML para la detección de bordes y la dimensión fractal de Higuchi como regla de decisión binaria que identifica qué es ruido y qué es una posible transmisión del UP con un porcentaje promedio de certeza del 98 % para detectar el inicio y el final de una transmisión de UP para una SNR superior a 0 dB. Estos resultados se obtuvieron en un entorno simulado en la plataforma MATLAB.

Finalmente, dentro de este estado del arte se abordan trabajos relacionadas con la implementación de técnicas cooperativas para la MEMB implementadas en entornos reales de comunicación inalámbrica [12], [50], [51], [52], [53], [54]. Una parte importante de los aportes relacionados con el RC se implementan considerando dispositivos USRP (del inglés *universal software radio peripheral*). Sin embargo, en este trabajo de tesis se muestra que los dispositivos SDR de bajo costo pueden ser útiles para implementar una contribución teórica en tiempo real con un buen rendimiento y sin una inversión considerable [55], [56] en comparación con el alto costo económico que podrían representar los dispositivos USRP [57], [58].

La versatilidad de los SDR permite avisorar su posible aplicación en la mejora de las comunicaciones de onda corta [21–23]. Por ejemplo, para facilitar la revisión del espectro, la detección de interferencias, la asignación eficiente de la distribución de frecuencias, la prueba del funcionamiento de los sistemas repetidores y la medición de sus parámetros eléctricos, la identificación de intrusos en el espectro y la caracterización del ruido en diferentes bandas espectrales. Además, ligado a estas características principales y su relativo bajo costo, los dispositivos SDR cuentan con la flexibilidad que les otorga la

programación de sus funciones con software libre, logrando múltiples posibilidades como la construcción de Tx, Rx o multiplexores [23 - 24].

En [63], los autores analizan la capacidad de detección y desarrollan un sistema autoconfigurado con redes de inteligencia dinámicas sin causar ninguna interferencia al UP. En este trabajo también se mencionan en el análisis cuantitativo dos técnicas de detección de espectro: la detección de energía y la detección de ruido blanco de banda limitada. Se han realizado algunas contribuciones importantes relacionadas con la mejora de la eficiencia del espectro en TV con espacios (TVWS del inglés *TV with spaces*) considerando dispositivos de bajo costo y una complejidad computacional reducida. Una buena aproximación a este tema aparece en [64], aquí, los autores utilizaron un prototipo asequible para detectar TVWS. Los resultados mostraron que el prototipo portátil era capaz de detectar bandas de frecuencia desocupadas de 500 MHz a 698 MHz en zonas urbanas. Además, en [65] se presentó un prototipo capaz de detectar hasta diez canales de televisión. El dispositivo sensor se examinó en un entorno real y se calculó una ocupación del espectro del 30.25%.

En [66], se examinó un modelo de detección de energía, combinado con ruido y actividad de los usuarios primarios. Esta propuesta se probó en una estación de detección de código abierto de bajo costo. El modelo propuesto detectó TVWS con un 9.6% más de precisión que los modelos actuales. En [6-7] se presenta un método MBSS con una regla de decisión basada en la entropía de muestra SampEn, en este trabajo se implementa esta técnica en escenarios simulados y controlados en tiempo real con dispositivos SDR, obteniendo resultados sobresalientes en términos de probabilidad de detección variando la SNR. En [35], se implementa un sistema para comunicaciones móviles, utilizando una red de SDR. Aquí, para detectar al UP, RenyiEn se utiliza directamente en los espectros de las señales recibidas sin conocimiento previo de sus características.

En [67] se utilizan dispositivos SDR y USRP para implementar un sistema de comunicación para detectar interferencias que funciona significativamente mejor que el DE en la detección de interferencias débiles y ofrece la capacidad de detectar valores de interferencia de 8 a 10 dB más bajos. En [68] se presentan resultados experimentales de la implementación del *hardware* USRP para la detección de brechas en el espectro con la ventaja de requerir menos muestras que el DE y obtener el mismo rendimiento. En [69], se propone una nueva arquitectura de plataforma SDR que implementa

diferentes técnicas de modulación y esta arquitectura muestra ganancias favorables con una ventaja sobre las técnicas tradicionales, como los sistemas de multicanalización espacial de múltiples entradas y múltiples salidas (MIMO del inglés *multiple inputs multiple outputs*). En [70], se presenta una arquitectura de red RC distribuida en la que cada RC conoce la información del estado de la red local y realiza detección de espectro, estimación de canal para encaminamiento conjunto y acceso a canal sujeto a una topología de red realista y efectos de canal físico.

Los autores en [71] presentan un sistema RC en un entorno real en el que los nodos pueden comunicarse con otros nodos a través de: (i) una comunicación directa con la estación base en la macrocélula, lo que ayuda a mejorar el rendimiento de la red; o (ii) una comunicación dispositivo a dispositivo que mejora la eficiencia del espectro, mediante el cual el tráfico se descarga de macroceldas a celdas pequeñas, utilizando dos plataformas USRP combinadas con el kit de herramientas de software de radio GNU. Algunos otros trabajos relacionados con la implementación de técnicas de monitorización se presentan en [72], donde los autores utilizan USRP con una raspberry para desarrollar una red inalámbrica distribuida en la que los nodos pueden comunicarse entre sí de forma independiente y estos pueden tomar decisiones de forma autónoma.

En [73], se propone un banco de pruebas a pequeña escala para el acceso dinámico al espectro en una red RC para encontrar un canal común para la comunicación entre dos dispositivos (*peer to peer*, usando USRP) también se presenta una técnica para el acceso dinámico al espectro. En [74] se presenta una aplicación didáctica de analizador de espectro con múltiples funciones que utiliza un dispositivo SDR de muy bajo costo.

Además de conocer el comportamiento de los UP en el dominio de la frecuencia, y para evitar el problema del terminal oculto (pero no el único), es necesario conocer el comportamiento de este espectro radioeléctrico en su área geográfica de influencia específica. Por este motivo, resulta pertinente la idea de incluir una herramienta geográfica construida con la información radioeléctrica proporcionada por los US emitida desde un entorno real. Bajo esta perspectiva, en los últimos años, la capacidad de construir REM ha cobrado gran importancia. Un REM es “una herramienta que combina información recopilada del entorno radioeléctrico, como intensidad de la señal recibida, mediciones de interferencia, condiciones de propagación, etc.,

para ubicaciones y frecuencias específicas, con el objetivo de construir un mapa que proporcione una visión general de la cobertura de la red” [75].

De esta manera, los REM que permiten caracterizar la posición, directividad, potencia y tipo de modulación de los UP se han convertido en una tarea desafiante en el diseño de CRN (CRN del inglés *cognitive radio networks*) [76]. De hecho, en [77] los REM se utilizan para localizar a los UP relevantes en una región geográfica de interés, caracterizando sus posiciones, directividades, potencias y tipos de modulación. Asimismo, en [78], se ha considerado que los REM detectan el espectro basándose en un algoritmo adaptativo de detección de espectro comprimido, aportando información espacial a la red, que tiene la cualidad de adaptarse al entorno radioeléctrico. Los REM son una herramienta muy flexible como se muestra en [79], donde se utilizan en combinación con ML, para determinar el área de cobertura efectiva que percibe una red de sensores cognitivos, estimándose correctamente en alrededor del 92 %.

Otra herramienta importante, hoy en día gracias a la potencia informática y la cantidad de datos disponibles, son las NN ampliamente utilizadas desde el reconocimiento de patrones y la clasificación de imágenes hasta la predicción del comportamiento de los mercados financieros y la conducción autónoma de vehículos [80].

En el contexto de la detección de espectro, por ejemplo en [81], se implementa una NN para obtener la información local de la detección de espectro para un solo nodo (características espaciales y características temporales). La información (características extraídas) de múltiples nodos alimenta otra NN permitiendo un resultado de cooperación en la CRN. Basado en ambos paradigmas, REM y NN, en este trabajo se propone una nueva metodología en el contexto de un CRN, considerando la implementación de un método de MEMB que involucra una red integrada por dispositivos SDR de bajo costo, en un entorno de comunicaciones inalámbricas. Finalmente en la **Tabla 2.2** se mencionan algunos trabajos recientes que abordan la cooperación de RC y el ML.

Tabla 2.2. Trabajos recientes de CRN.

Título	Descripción	Aporte
<i>Cooperative spectrum sensing in cognitive radio networks using machine learning techniques</i> [82].	Presenta una técnica para comprobar la disponibilidad de espectro basada en un enfoque cooperativo. Las unidades secundarias transfieren la señal modulada presente en el canal a la unidad primaria que estima el espectrograma de la misma y lo envía a un modelo de red neuronal entrenado para detectar si se trata de una señal o de ruido.	La eficiencia del enfoque de detección cooperativa se analiza en función de la precisión en la detección y la probabilidad de detección en múltiples niveles de relación señal/ruido. Entorno simulado
<i>Graph Learning-Based Cooperative Spectrum Sensing in Cognitive Radio Networks</i> [83].	Se propone un método de aprendizaje de grafos, aquí se usa una matriz de probabilidad para representar las correlaciones de las US, y se formula un problema de aprendizaje. Luego se recopilan US con altas correlaciones para implementar la cooperación en la detección del espectro.	Los resultados numéricos demuestran la superioridad del detector propuesto en comparación con los detectores de última generación. Se analizan las probabilidades de detección y falsa alarma del detector propuesto. Entorno simulado

Título	Descripción	Aporte
<i>Experimental SDR implementation of cooperative spectrum sensing in cognitive radio networks [84].</i>	Se implementaron y validaron varios algoritmos de detección de espectro local usando USRP. El banco de pruebas realizado se basa en una arquitectura cliente-servidor. En el que se han considerado varios escenarios realistas para validar la implementación de SDR.	los resultados teóricos y de simulación de CSS han sido validados experimentalmente Implementado en USRP

Es esencial destacar las diferencias entre la propuesta presentada en esta tesis y el estado del arte, resaltando así la contribución significativa al campo. En contraste con las soluciones actuales, las innovaciones desarrolladas en este estudio se distinguen por varias características clave. Se implementaron dos técnicas utilizando tecnología SDR en un entorno real de comunicaciones en tiempo real con un intervalo de actualización de 100 ms, logrando una eficacia notable en la detección de UP. Además, estas técnicas de MEMB fueron desarrolladas para operar de manera colaborativa, facilitando la detección del UP en áreas geográficas específicas y evaluando su ocupación en el dominio de Fourier.

Capítulo 3. Marco teórico

En este capítulo se describen brevemente las técnicas de procesamiento digital de señales que son utilizadas por los diferentes algoritmos desarrollados para la detección de UP en el esquema multibanda. Estas técnicas son utilizadas tanto en la detección directa de los UP como en las reglas de decisión involucradas en las metodologías propuestas y descritas en los capítulos posteriores.

3.1. Transformada *wavelet*

La transformada de *wavelet* proporciona una representación multiresolución que analiza la señal con resolución diferente a diferentes frecuencias. Se diseña para producir alta resolución en el tiempo y baja resolución en frecuencia para señales de alta frecuencia, baja resolución en el tiempo y alta resolución en frecuencia para señales de baja frecuencia. La transformada *wavelet* continua (TCW) de una función $f(x)$ se define como [85]:

$$TCW_f(s, \tau) = \int_{-\infty}^{\infty} f(x) \psi_{s, \tau}^*(x) dx \quad (3.1)$$

donde $*$ representa el complejo conjugado y $\psi_{s, \tau}(x)$ representa una familia de funciones normalizadas y generadas a partir de la traslación y el escalamiento de una función inicial $\psi(x)$, llamada *wavelet* madre, definida por:

$$\psi_{s, \tau}(x) = \frac{1}{\sqrt{s}} \psi\left(\frac{x - \tau}{s}\right) \quad (3.2)$$

donde s y τ son los factores de escala y traslación, respectivamente. Sólo se utilizan factores de escala $s > 0$. Las *wavelets* se dilatan cuando la escala $s > 1$ y se contraen cuando $s < 1$. Un valor alto de este factor ($s > 1$) corresponde a una vista global de la señal (expansión de la *wavelet*) mientras que un factor de escala bajo ($s < 1$) corresponde a detalles de la señal (se comprime la *wavelet*). De esta manera, se ofrece una alternativa a las representaciones de tiempo-frecuencia: el plano tiempo (o traslación) - escala. En la **Figura 3.1a** se muestra un claro ejemplo de la ventaja de la TCW, para determinar la

precisión para detectar singularidades en el plano frecuencia – escala. En esta figura se puede apreciar la densidad espectral de potencia (PSD, del inglés *power spectral density*) de una señal (ver la **Figura 3.1b**) que contiene dos UP y justo donde aparecen singularidades en la señal se puede apreciar que en la TCW se marcan los conos de discontinuidad.




Figura 3.1. Se muestra a) la PSD con dos transmisiones primarias, b) la TCW con una escala de [1,120].

La TCW es una herramienta poderosa para el análisis de señales y permite descomponer la una señal en sus partes de frecuencia y tiempo, esto permite la detección de patrones. Sin embargo, una de las fortalezas de las técnicas propuestas en esta tesis es la implementación en tiempo real ya que la TCW no es una técnica viable ya que el costo computacional para obtenerla es bastante alto. Con base en lo anterior y con el punto de vista práctico se utiliza el análisis multiresolución que tiene una relación directa con la TCW en una escala diádica.

3.2. Análisis multiresolución

El análisis multiresolución (AMR) fue introducido por Mallat en 1989 [86]. Esta idea, que involucra espacios vectoriales incrustados, permite la descomposición (y reconstrucción) de una señal $f(x)$ utilizando una base ortonormal (o biortogonal). El AMR corresponde a una versión discreta de la

TCW. Además, el AMR se implementa usando un algoritmo rápido llamado *à trous*, donde se realiza una división de los coeficientes, obteniéndose los coeficientes de aproximación $a_L(x)$ y los coeficientes de detalle $d_j(x)$. Los $a_L(x)$ son los valores altos de la escala correspondiente a las componentes de baja frecuencia de la señal, por lo tanto, está asociada a la función de escalamiento que se determina con un filtro pasa bajos. Los $d_j(x)$ son los valores bajos de la escala correspondientes a las componentes de alta frecuencia, y está asociada a la función *wavelet* que se determina como un filtro pasa altas. Esta idea compleja tiene una fácil interpretación a través de un esquema de banco de filtros digitales, como se muestra en la **Figura 3.2**. La ecuación de descomposición está dada por:

$$f(x) = a_L(x) + \sum_{j=1}^L d_j(x) \quad (3.3)$$

donde $a_L(x)$ son los coeficientes de aproximación en el nivel L y $d_j(x)$ son los coeficientes de detalle que van de los niveles 1 a L . De esta manera, la señal se filtra en octavas (es decir, cada banda se divide por dos iterativamente). Los coeficientes de aproximación permiten, en el proceso de reconstrucción, tener una versión suave de la señal original $f(x)$. Los coeficientes de detalle dan a la señal reconstruida las características finas.

Con base a estas propiedades, el AMR es utilizado en la etapa de MEMB para obtener la tendencia del espectro multibanda en los coeficientes de aproximación, eliminando en el proceso de reconstrucción, la contribución de los coeficientes de detalle (que contienen el ruido añadido a la señal transmitida o simplemente el piso de ruido obtenido en la estimación de la PSD). De igual forma, estos coeficientes de detalle son utilizados para la creación de un bloque que aminora los efectos del ruido impulsivo generado por los dispositivos utilizados en la implementación de escenarios reales.

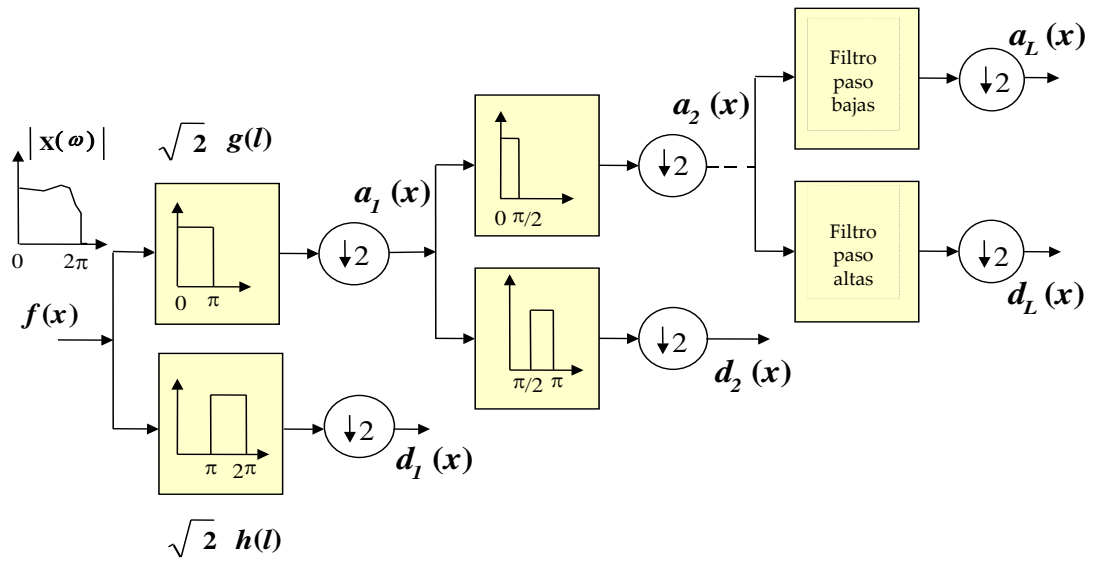


Figura 3.2. Implementación del AMR basado en un banco de filtros

Es importante mencionar que el AMR y la TCW están vinculados a través de los coeficientes de detalle. Estos últimos corresponden a una versión discreta de la TCW en puntos de muestreo específicos: la escala diádica. El AMR es una herramienta que nos permite obtener diferentes resultados que están intrínsecamente relacionados: señal reconstruida a la señal original, los coeficientes de detalle y aproximación. En la **Figura 3.3** se muestra el resultado de aplicar AMR a una señal sintetizada con un nivel de descomposición igual a 3, en específico los coeficientes de aproximación obtenidos en este último nivel. En este caso se observa cómo utilizando únicamente los coeficientes de aproximación, la reconstrucción de la señal a partir de estos, permite obtener la tendencia de la misma.

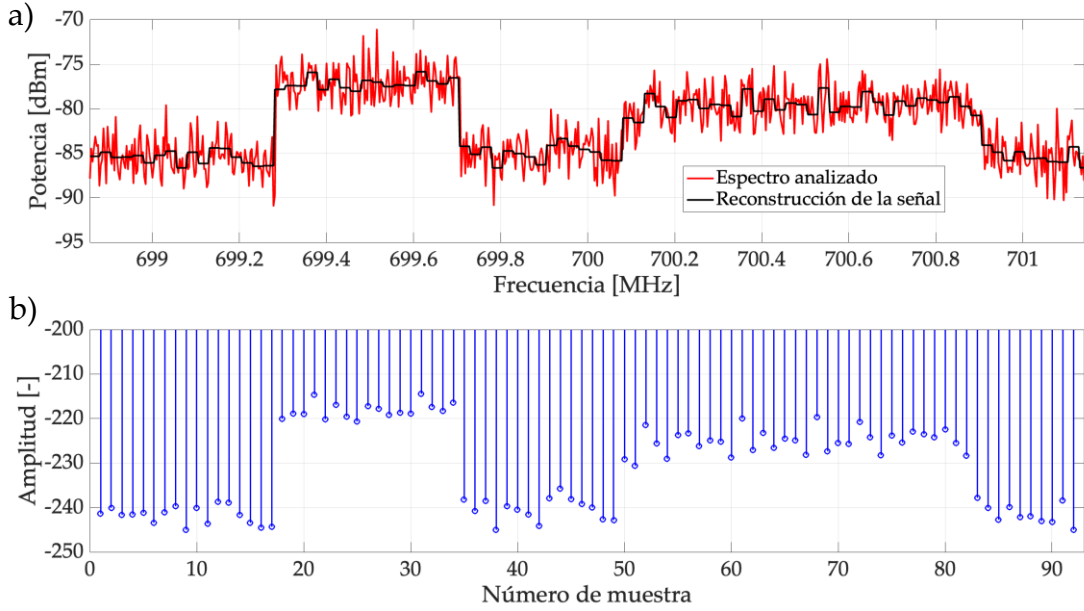


Figura 3.3. a) Señal original y señal reconstruida a partir únicamente de los coeficientes de aproximación. b) Coeficientes de aproximación en el nivel 3.

3.3. Dimensión fractal de Higuchi

En general, una curva fractal tiene la propiedad de que cada parte de la curva puede considerarse una imagen reducida del todo [87]. La dimensión fractal es un índice que describe la regularidad de una serie temporal (en general, un vector de N puntos ordenados secuencialmente). Higuchi [88] modifica el método propuesto en [89] para calcular la dimensión fractal y aplicarlo no solo a los datos simulados sino también a series temporales derivadas de fenómenos naturales con comportamiento turbulento, obteniendo un valor estable de la dimensión fractal.

El método propuesto por Higuchi [88] considera una serie temporal de N puntos (o en general una sucesión ordenada de N puntos) $x(1), x(2), x(3), \dots, x(N)$. A partir de esta serie se construye una nueva sucesión x_k^m definida por:

$$x_k^m = \left\{ x(m), x(m+k), x(m+2k), \dots, x\left(m + \left\lfloor \frac{N-m}{k} \right\rfloor k\right) \right\} \quad (3.4)$$

$$m = 1, 2, \dots, k$$

donde $\lceil \cdot \rceil$ denota la parte entera, m y k son números enteros que indican el tiempo inicial y el intervalo de tiempo, respectivamente. La pendiente de la curva $L_m(k)$ en (3.4), en escala logarítmica, corresponde a la DFH.

$$L_m(k) = \left\{ \frac{N-1}{\left\lceil \frac{N-m}{k} \right\rceil k} \left(\sum_{i=1}^{\left\lceil \frac{N-m}{k} \right\rceil} |x(m+ik) - x(m+(i-1)k)| \right) \right\} / k \quad (3.5)$$

3.4. Entropía muestral

La SampEn fue inicialmente introducida por Richman y Moorman [90], para evaluar la complejidad de las series temporales fisiológicas, diagnosticando estados patológicos. La SampEn cuantifica la irregularidad de una sucesión de puntos y estima la probabilidad condicional de que dos sucesiones de m puntos consecutivos, que son similares entre sí (dentro de una tolerancia dada r), sigan siendo similares cuando se incluye un punto consecutivo más. La SampEn se obtiene mediante los siguientes pasos:

Considerando la secuencia $X = [x(1), x(2), x(3), \dots, x(N)]$ de longitud N (como en el caso de la DFH cada sucesión representa una trama espectral, obtenida por cada uno de los dispositivos utilizados o simuladas en su caso),

1. Construir un vector V_P con m puntos consecutivos tomados de X , i.e.;

$$V_P = [X(P), X(P+1), \dots, X(P+m-1)] \quad (3.6)$$

donde P varía en el intervalo $(1 \leq P \leq N-m)$, y m es la longitud de las secuencias a comparar, también llamada *dimensión de incrustación*.

2. Para cada P se define:

$$C_P^m = \frac{1}{N-m-1} \sum_{h=1, h \neq P}^{N-m} \Theta(r - \|V_P - V_h\|_1) \quad (3.7)$$

donde r , obtenido por $r = s \times std(X)$, es la tolerancia para aceptar coincidencias, s es un parámetro de escala y $std(X)$ es la desviación estándar del vector X . $\Theta(\cdot)$ es la función heaviside, dada por:

$$\Theta(X(P)) = \begin{cases} 0, & X(P) < 0 \\ 1, & X(P) \geq 0 \end{cases} \quad (3.8)$$

y $\|\cdot\|_1$ es la distancia de Chebyshev, definida como:

$$\|V_P - V_h\|_1 = \max(|X(P) - X(h)|, \dots, |X(P+m-1) - X(h+m-1)|) \quad (3.9)$$

donde C_P^m representa la proporción de V_h , $P \neq h$ cuyas distancias a V_P son menores que r .

3. Para cada P se define:

$$C_P^{m+1} = \frac{1}{N-m-1} \sum_{h=1, h \neq P}^{N-m} \Theta(r - \|V_P - V_h\|_1) \quad (3.10)$$

donde C_P^{m+1} representa la proporción correspondiente a la dimensión de $m+1$. C_P^m y C_P^{m+1} tienen el mismo molde, pero los vectores de empotramiento en ambos casos están definidos en espacios diferentes.

4. Promediar todos los escalares de incrustación, para obtener:

$$U^m = \frac{1}{N-m} \sum_{P=1}^{N-m} C_P^m \quad (3.11)$$

y

$$U^{m+1} = \frac{1}{N-m} \sum_{P=1}^{N-m} C_P^{m+1}. \quad (3.12)$$

5. La SampEn se calcula como:

$$SampEn = -\ln\left(\frac{U^{m+1}}{U^m}\right) \quad (3.13)$$

La SampEn representa el logaritmo natural negativo de la probabilidad condicional de que dos secuencias similares para m puntos sigan siendo similares en el siguiente punto, donde las coincidencias adecuadas no se incluyen en el cálculo de probabilidad. Por tanto, un valor más bajo de SampEn indica una mayor autosimilitud de la sucesión estudiada, mientras que un valor más alto de SampEn indica una mayor complejidad de la sucesión. Por ejemplo, en la **Figura 3.4a** se muestra un espectro con SNR=10 dB que puede ser dividido en 3 ventanas, tal que las muestras [1,230] corresponden a ruido, las muestras [231,500] corresponden a una transmisión del UP y las muestras [501,720] corresponden a ruido. En la **Figura 3.4b** se muestra el valor medio de aplicar la SampEn a 1,000 tramas del espectro para las diferentes ventanas (la SampEn ≈ 2 corresponde a ruido y la SampEn ≈ 1 es una posible transmisión del UP). Con esto, se confirma la eficiencia de la SampEn para distinguir una transmisión primaria del ruido.




Figura 3.4. a) espectro evaluado compuesto de 3 ventanas (ruido, transmisión primaria y ruido). b) Resultado de aplicar la SampEn a las ventanas que componen el espectro.

3.5. Mapa del ambiente de radio

El REM es una técnica utilizada en investigación de las telecomunicaciones para representar la distribución de energía en un área específica dada, emitida por diferentes fuentes de radio. Un REM se construye recopilando mediciones de potencia en diferentes puntos de un área específica e interpolándolas, para producir una representación gráfica (mapa) de la distribución (o cobertura) de potencia de las señales emitidas, como se muestra en la **Figura 3.5**. Estos mapas se utilizan generalmente para evaluar y predecir el comportamiento de las señales de radio en un entorno determinado, lo cual es importante para la planificación de la capacidad, el diseño y la resolución de problemas relacionados con la interferencia en un sistema de comunicación. Los REM han sido utilizados en aplicaciones donde los dispositivos pueden usar la información proporcionada por el REM para seleccionar la frecuencia más adecuada para transmitir datos y evitar interferencias con otros dispositivos en la misma ubicación [91]. En este trabajo de tesis los REM se utilizan para ubicar geográficamente a un UP, determinando su área activa y evitar la terminal oculta.




Figura 3.5. Ejemplo de un REM. Los puntos negros indican las ubicaciones donde se toman las medidas de potencia con base en 8 sensores. En este caso, solo se considera una fuente de transmisión con -60 dBm.

La recopilación y la interpolación de los valores de potencia son los dos procesos que desempeñan un papel esencial en la construcción de un mapa correcto. En este caso, los métodos de interpolación [92] son críticos para estimar correctamente un valor desconocido entre dos o más puntos conocidos (puntos de medición). En otras palabras, un REM es simplemente una estimación suavizada de la distribución de potencia basada en unos pocos valores conocidos de potencia medida. Dos métodos de interpolación son ampliamente utilizados para construir los REM, la Ponderación de Distancia Inversa (IDW, del inglés *Inverse distance weighting*) y el de Kriging. Ambos métodos se explican a continuación.

Método IDW

El método de interpolación de ponderación de distancia inversa [93], [94] es una técnica simple y fácil de implementar, ampliamente utilizada en aplicaciones como la estimación de precipitaciones, la interpolación de datos topográficos y la estimación de la contaminación del aire. De hecho, IDW es un método clásico de interpolación en el análisis espacial y uno de los más utilizados en interpolación geo estadística y matemática [95].

El método IDW estima el valor de una variable en un punto específico basándose en valores conocidos en puntos cercanos. Este método se basa en la idea de que los puntos cercanos tienen un mayor impacto en la estimación que los puntos más distantes. Para ello, IDW utiliza una fórmula que asigna un peso a cada punto conocido en función de la distancia entre estos y el punto desconocido. Los pesos se determinan considerando el inverso de la distancia, de esta forma los puntos más cercanos tienen pesos más altos y los más lejanos tienen pesos más bajos. En los siguientes pasos se describe de manera formal y breve el método IDW:

Considere el vector transpuesto de n puntos $\mathbf{z} = (z(s_1), \dots, z(s_n))^T$, conformado por observaciones de un proceso aleatorio. En nuestro caso, \mathbf{z} contiene la potencia promedio en cada punto de la región muestreada considerada (ver la **Figura 3.5**):

$$\{z(s) : s \in D\}; D \subset \mathbb{R}^2 \quad (3.14)$$

Cuyas coordenadas geográficas s_1, \dots, s_n , son conocidas La estimación final se obtiene mediante la suma ponderada de los valores conocidos en los puntos cercanos, dada por [94]:

$$Z(s) = \frac{\sum_{i=1}^n \left(\frac{w_i(s_i)}{d(s_i, s)^p} \right)}{\sum_{i=1}^n \frac{1}{d(s_i, s)^p}} \quad (3.15)$$

donde $Z(s)$ es el valor estimado de la variable en el punto desconocido s , z_i es el valor conocido de la variable en el i -ésimo punto s_i , $d(s_i, s)$ es la distancia euclidiana entre el punto desconocido s y el punto s_i , $p \in \mathbb{R}$ es un parámetro de suavizado que controla la influencia de los puntos conocidos sobre los valores estimados y $w_i(s_i)$ es el peso asignado a cada punto conocido s_i , que toma en cuenta la incertidumbre en los datos conocidos. En la práctica, se suele utilizar un valor de $p = 2$ o $p = 3$. Los valores estimados de $Z(s)$ darán como resultado una malla de puntos desconocidos. Sin embargo, este método tiene algunas limitaciones, como la tendencia a suavizar la variabilidad de los datos y producir una estimación inexacta en áreas donde hay pocos puntos conocidos. En este trabajo específico, $Z(s)$ representa la PSD en los diferentes puntos alrededor del área monitorizada.

Método de Kriging

El método de Kriging [96] es una técnica de interpolación derivada de la teoría variable regionalizada. Depende de expresar la variación espacial de la propiedad en términos del variograma, y minimiza los errores de predicción que se estiman [97]. El objetivo de Kriging es encontrar la estimación que sea más precisa y tenga la menor incertidumbre. Para ello, el método Kriging considera no solo el valor de la variable en los puntos conocidos, sino también la distribución de la variable en el espacio y su correlación con los puntos conocidos. El método de Kriging se puede establecer de la siguiente manera [96]:

Considerando los mismos puntos y región mencionados en la ecuación. (3.14) y que cada coordenada geográficas s está compuesta por la parte

conocida μ y un valor de incertidumbre asociado a cada una de ellas, donde $\delta(\cdot)$ es un proceso estocástico de media cero.

$$z(s) = \mu + \delta(s); s \in D \quad (3.16)$$

Obteniendo la función de covarianza de dicho vector:

$$C(s, u) \equiv \text{cov}(z(s), z(u)); s, u \in D \quad (3.17)$$

Así, el mejor predictor lineal no sesgado de la posición desconocida $z(s_0)$, se obtiene minimizando el error cuadrático medio [98]:

$$E \left(z(s_0) - \sum_{i=1}^n \lambda_i z(s_i) \right)^2 \quad (3.18)$$

con $\lambda_1, \dots, \lambda_n$, sujetos a

$$\sum_{i=1}^n \lambda_i = 1 \quad (3.19)$$

Utilizando el método de los multiplicadores de Lagrange, se calculan los valores óptimos. Para ello, el error de predicción cuadrático medio (ec. (3.18)) se obtiene mediante:

$$\begin{aligned} E(z(s_0) - \hat{z}(s_0))^2 &= \\ &= C(s_0, s_0) - c^T C^{-1} c + (1 - c^T C^{-1} \mathbf{1})^2 (\mathbf{1}^T C^{-1} \mathbf{1})^{-1} \end{aligned} \quad (3.20)$$

donde

$$c \equiv (C(s_0, s_1), \dots, C(s_0, s_n))^T \quad (3.21)$$

$$C \equiv (C(s_h, s_j)), \quad (3.22)$$

además,

$$\hat{z}(s_0) = \gamma^T \Gamma^{-1} Z + (1 - \gamma^T \Gamma^{-1} \mathbf{1}) (\mathbf{1}^T \Gamma^{-1} \mathbf{1})^{-1} (\mathbf{1}^T \Gamma^{-1} Z) \quad (3.23)$$

$$\begin{aligned} E(z(s_0) - \hat{z}(s_0))^2 &= \\ &= \gamma^T \Gamma^{-1} \gamma - (1 - \gamma^T \Gamma^{-1} \mathbf{1})^2 (\mathbf{1}^T \Gamma^{-1} \mathbf{1})^{-1}, \end{aligned} \quad (3.24)$$

donde $\gamma \equiv (\gamma(s_0, s_1), \dots, \gamma(s_0, s_n))^T$, Γ es una matriz de $n \times n$ cuya enésimo elemento (i, j) es $\gamma(s_i, s_j)$, $\mathbf{1}$ es un vector columna de tamaño n y

$$2\gamma(s_i, s_j) \equiv C(s_i, s_i) + C(s_j, s_j) - 2C(s_i, s_j) \quad (3.25)$$

se denomina variograma [$\gamma(s_i, s_j)$ se denomina semivariograma [98]]. El variograma, una herramienta muy útil en el modelado de variables espaciales, proporciona una descripción de cómo se relacionan (correlacionan) los datos con la distancia. De esta forma, el método Kriging permite realizar la interpolación espacial, utilizando los datos muestreados y la información del variograma para estimar la varianza de los valores de la variable en los puntos no muestreados [99], [100]. En resumen, Kriging es un método más preciso que otros métodos de interpolación como IDW o la interpolación cúbica [95], adecuado para aplicaciones en las que los datos tienen una cierta dependencia espacial.

3.6. Redes neuronales

Las NN son un tipo de modelo de inteligencia artificial que se inspira en la estructura y funcionamiento del cerebro humano. Estas redes están formadas por muchos nodos, también conocidos como "neuronas", que se conectan entre sí a través de "sinapsis". Cada neurona recibe entradas de otras neuronas, procesa estas entradas a través de una función de activación y envía su salida a otras neuronas, como se muestra en la **Figura 3.6**. La combinación de entradas y conexiones entre neuronas permite que una red neuronal aprenda tareas complejas de los datos de entrenamiento seleccionados. En general, las redes neuronales son una herramienta muy

poderosa para el ML porque pueden modelar relaciones complejas entre entradas y salidas haciendo inferencias precisas a partir de datos reales. Sin embargo, para estas tareas se requiere una gran cantidad de datos de entrenamiento, siendo computacionalmente intensivos (y a veces imposibles) de entrenar y usar en implementaciones en tiempo real [101].




Figura 3.6. Concepto de red neuronal: el perceptrón multicapa

En este trabajo se utiliza el perceptrón multicapa (MLP, del inglés *multilayer perceptron*), como se muestra en la **Figura 3.6**. Este tipo de red neuronal artificial consta de una capa de entrada, una o más capas ocultas y una capa de salida. En el MLP, las neuronas de cada capa están conectadas a las neuronas de la siguiente capa y utilizan una función de activación para determinar la salida de la neurona. La información fluye en una sola dirección, desde la capa de entrada a la capa de salida, pasando por las capas ocultas, que son las capas intermedias entre la entrada y la salida [102]. La fórmula general para calcular la salida de un perceptrón multicapa viene dada por [103]:

$$O = f\left(\sum(W_{i,j} I_i) + b\right), \quad (3.26)$$

donde O es la salida del perceptrón multicapa, f es la función de activación, que puede ser una función escalonada, sigmoide, ReLU, etc., $W_{i,j}$ son los pesos sinápticos que conectan la entrada I_i a la neurona actual, I_i es la entrada del multicapa perceptrón y b es el sesgo, donde $i = 1, \dots, n$ y $j = 1, \dots, k$,

siendo n el número de características de entrada a la NN (correspondiente al número de neuronas en la capa de entrada), k el número de neuronas en una capa oculta dada, y m el número de salidas (es decir, número de neuronas en la capa de salida de la NN).

La fórmula se aplica a cada neurona en cada capa de la red, incluida la capa de entrada, las capas ocultas y la capa de salida. Cada neurona en una capa oculta toma como entrada la salida de todas las neuronas en la capa anterior (es decir, suponiendo una red completamente conectada), y la salida de una neurona en la capa de salida es la salida final de la red. Durante la fase de entrenamiento, los pesos y el sesgo se ajustan para minimizar el error entre la salida de la red y la salida deseada. Esto se hace mediante un algoritmo de aprendizaje, como el algoritmo de retropropagación [104], que actualiza los pesos y el sesgo en la dirección del gradiente descendente [105]. Aunque existen otros algoritmos y enfoques de entrenamiento como: propagación del gradiente resiliente o algoritmos genéticos.

Capítulo 4. Metodología base

En este capítulo se resume el trabajo desarrollado anteriormente y que conforma la base de las técnicas propuestas en esta tesis. La metodología de base, desarrollada en el trabajo previo de maestría, incluye dos grandes bloques el primero basado en el análisis multiresolución y ML para la detección de bordes que permiten la ubicación de posibles UP y un segundo bloque conteniendo la regla de decisión basada en la DFH para determinar la existencia de un UP o no, como se muestra en la **Figura 4.1**. En las siguientes secciones se describen ambos bloques.

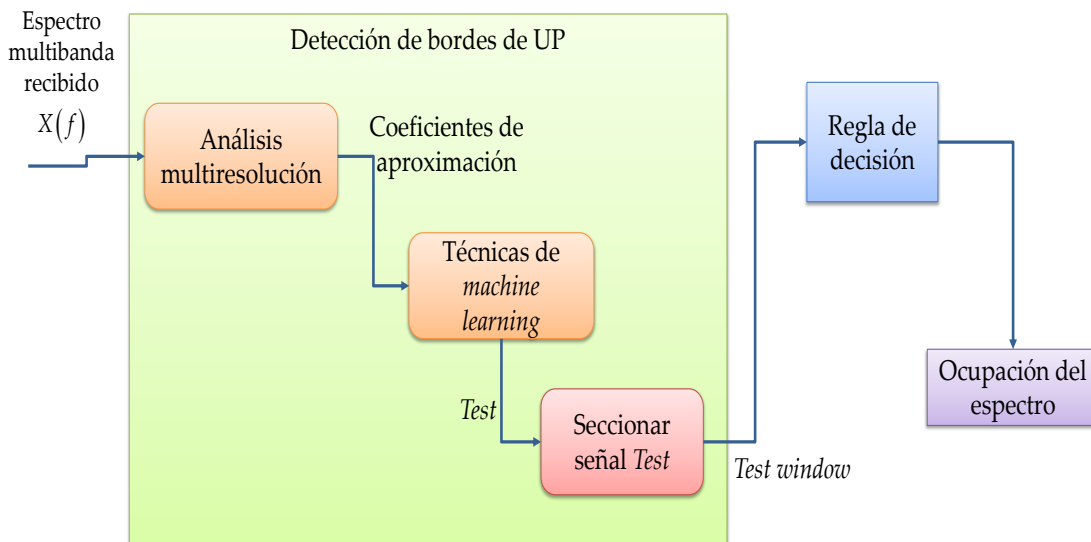


Figura 4.1. Metodología base

4.1. Detección de bordes del usuario primario

En este bloque se detectan singularidades en el espectro a través del AMR y ML mediante la siguiente metodología:

Algoritmo 4.1. Detección de bordes [11].

- Paso 1. El espectro multibanda recibido por el US, $X(f)$, se descompone a través del AMR hasta un nivel L , lo que proporciona los coeficientes de aproximación y de detalle respectivos (ver la ec. (3.3)).
- Paso 2. Considerando únicamente los coeficientes de aproximación obtenidos, el espectro se reconstruye eliminando de esta manera el ruido de banda ancha y manteniendo solo la tendencia (o forma suave $X_{app}(f)$) del espectro multibanda.
- Paso 3. En este paso se ejecuta un algoritmo de ML que permite la clasificación de los coeficientes de aproximación, dando como resultado la señal "Test". En párrafos siguientes se especifican los algoritmos de ML utilizados.
- Paso 4. Los bordes de frecuencia y las ventanas dinámicas se determinan a partir de la señal *Test*. Los bordes son el resultado del cambio de un estado a otro (de uno a cero y viceversa) de los coeficientes de aproximación. La señal "Test window" se obtiene al seccionar la señal *Test* a partir de estos cambios de estado.
-

El resultado de aplicar el **Algoritmo 4.1** usando algunos de los métodos de ML mencionados en la **Tabla 4.1** para clasificar los coeficientes de aproximación se indica en la **Figura 4.2**. Además, en la **Figura 4.2a** se muestra cómo se integran las ventanas dinámicas y los bordes de frecuencia (círculos y flechas en color verde). En la **Figura 4.2b**, se puede observar la potencia de los coeficientes en el eje Y, donde 1 corresponde a baja potencia (BP, puntos en color rojo) y 0 a una alta potencia (AP, puntos en color azul). Para este ejemplo, K-means clasifica correctamente los coeficientes de aproximación normalizados y reescalados de un espectro multibanda aleatorio. Además en esta figura se puede apreciar el comportamiento de la señal *Test* y las ventanas de prueba, que son el cambio de estado de la señal *Test* que es

donde ocurre un cambio en los coeficientes marcados por círculos en color verde.

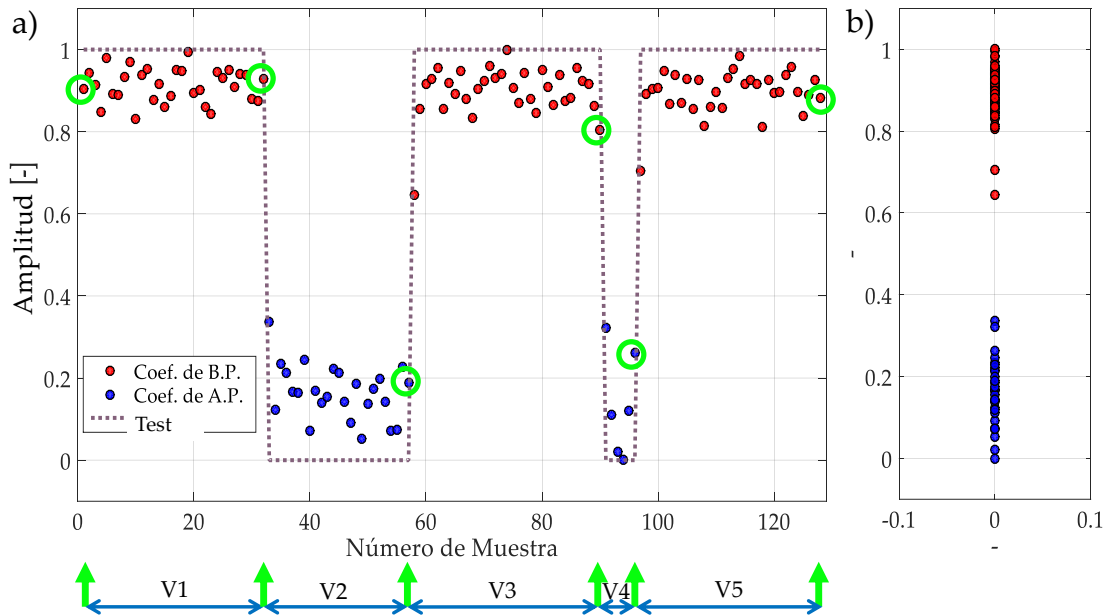


Figura 4.2. a) Coeficientes clasificados y los respectivos bordes de frecuencia. b) El resultado de aplicar K-means [11].

Tabla 4.1. Técnicas de ML usadas en la metodología base.

Algoritmo de ML	Tipo de técnica	Desempeño para SNR > 0 dB	Muestras en error (promedio)
NN con umbral manual	Supervisada	97.5 %	3
NN con umbral por ExMa	No supervisada	98 %	2.5
K-means	No supervisada	99 %	2

En la versión que utiliza una NN se requiere de un usuario que elija un umbral para clasificar los coeficientes de aproximación que servirán como muestras de entrenamiento para la NN. En la versión que utiliza la NN con maximización de esperanza (ExMa, del inglés *expectation maximization*) ya no se requiere que un usuario clasifique los coeficientes de aproximación, ya que

con el algoritmo ExMa hace una clasificación de los coeficientes y con esta clasificación se entrena a la NN. La idea de utilizar ExMa es tener un algoritmo que se entrene de forma autónoma y no requiera la intervención de un tercero. En la versión de K-means se busca a través la elección de clusters que no exista igualmente la dependencia de un tercero. Estos *clusters* son organizados para separar ruido y una posible transmisión (cuando el espectro analizado contiene algún UP) o solo ruido.

Para el trabajo de tesis se decidió utilizar el algoritmo de K-means gracias al excelente desempeño mostrado en las pruebas. Por ello se incluye y actualiza el **Algoritmo 4.1** en su paso 3 para todo lo que resta del trabajo de investigación aquí propuesto:

Paso 3 Con la señal reconstruida a partir únicamente de los coeficientes de aproximación (i.e. $X_{app}(f)$) se hace la selección del número de clusters en función de un umbral colocado en -90 dBm definido en [49]. Con los coeficientes de aproximación normalizados y reescalados se realiza la clasificación dando como resultado la señal *Test*.

La técnica de K-means es un método no supervisado utilizado en este trabajo como un clasificador de los coeficientes de aproximación de un espectro multibanda aleatorio a través de los coeficientes de aproximación, normalizados y reescalados. El diagrama de bloques de este proceso está esquematizado en la **Figura 4.3**.

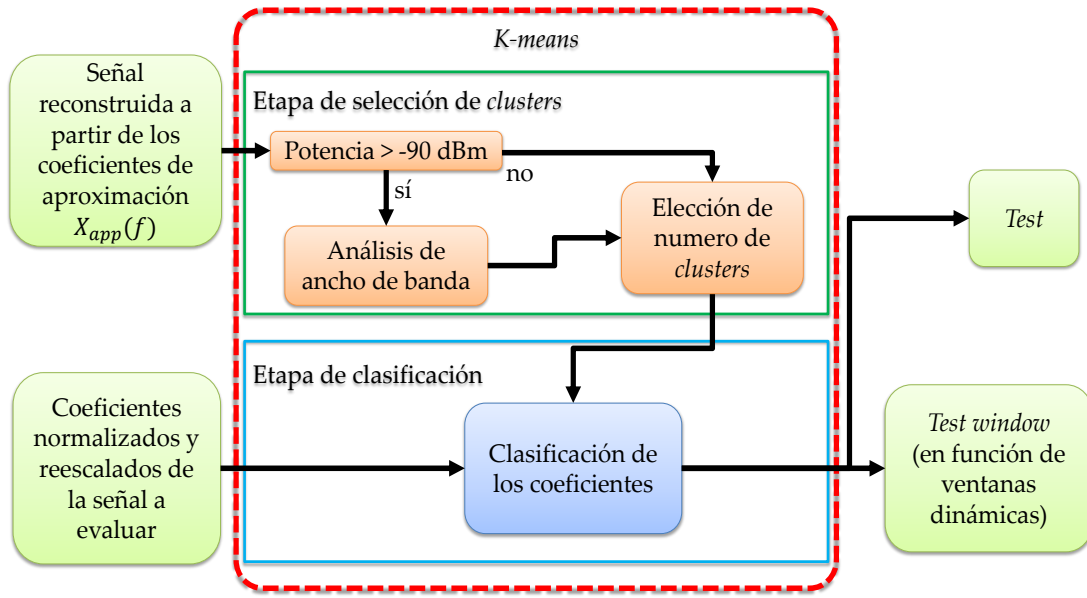


Figura 4.3. Diagrama de bloques que describe el funcionamiento de la técnica de monitorización usando el algoritmo K-means

El objetivo es clasificar los coeficientes de aproximación en dos grupos (o *clusters*), uno que infiere la transmisión de UP y otro correspondiente al ruido, en ambos casos considerando que el espectro multibanda contiene transmisiones del UP. Por otro lado, estos coeficientes deben clasificarse en un único grupo cuando el espectro multibanda sólo contiene ruido. Sin embargo, una de las desventajas que presenta el algoritmo K-means, es que es necesario, a priori, indicar el número de clusters en los que se debe realizar la clasificación. Esto representa un problema, ya que las tramas evaluadas por el algoritmo son completamente aleatorias. Con base en esto, para decidir en cuántos *clusters* se deben clasificar los coeficientes es necesario estudiar previamente el comportamiento de la señal $X_{app}(f)$. Por ello se propone, como se muestra en la **Figura 4.3**, evaluar primero la posible presencia de un UP de forma simple a través de un detector de energía cuyo umbral se coloca en -90 dBm. Si la señal no sobrepasa este umbral, el número de clusters será 1. Por otro lado, si la transmisión excede el umbral, tenemos 3 posibles opciones que se resuelven con un pequeño análisis del ancho de banda. En el cual se considera que la trama (i) contiene ruido impulsivo porque el ancho de banda de la transmisión detectada es muy pequeño, entonces el número de clusters será de 1. (ii) una transmisión primaria dado que para considerar una transmisión del UP el ancho de banda debe ser de al menos 7 muestras \times 0.1 [MHz], para este caso el número de clusters será de 2. Finalmente (iii) cuando

coexisten una transmisión primaria y ruido impulsivo. En este caso el número de *clusters* será de 2.

4.2. Regla de decisión

La dimensión fractal de Higuchi devuelve un valor en el intervalo $[1,2]$, donde el valor máximo significa que la serie evaluada no tiene similitud consigo misma (completamente irregular). Sin embargo, para el valor mínimo, la autosimilitud en la serie evaluada es grande (por ejemplo, una señal periódica). A partir de simulaciones, la DFH para una señal similar al ruido blanco será un valor que tiende a 2. Esta importante característica es la base de la regla de decisión propuesta en las metodologías implementadas en este trabajo de tesis; con el fin de diferenciar la transmisión del UP del ruido mismo, todo esto en el dominio de la frecuencia. De hecho, ignorando el efecto de un ruido gaussiano aditivo en una transmisión del UP, la transmisión inalámbrica clásica tiene formas que pueden considerarse regulares: una transmisión NRZ-CDMA (del inglés *non return to zero - code division multiple access* tiene una forma que involucra un seno cardinal o un símbolo OFDM (del inglés *orthogonal frequency division multiplexing*), en la recepción su PSD tiene una forma de un pulso con pequeños cambios en su amplitud debido al traslape de las funciones de Dirichlet (muy parecidas a senos cardinales) en cada una de las sub portadoras que conforman el símbolo. De esta manera, aplicando la DFH a este tipo de forma, en general se tendrá un valor cercano a 1, permitiendo a un US poder diferenciar claramente la transmisión de un UP del ruido. Esta premisa fue verificada con simulaciones detalladas presentadas en [47].

La metodología de este bloque se describe en los siguientes pasos:

Algoritmo 4.2. Regla de decisión [11].

Paso 1. Si la señal *Test* en cada ventana dinámica (segmento de señal del espectro) corresponde a 1, es prácticamente seguro que la transmisión corresponde a ruido y la DFH se aplica directamente a la señal original $X(f)$. En el caso contrario, las ventanas analizadas son muy probablemente una transmisión del UP y la DFH será calculada sobre $X_{app}(f)$.

Paso 2. Para cada ventana *Test window*, si la DFH calculada es inferior a 1.85 (umbral de decisión), se detecta una transmisión de un UP. En otro caso, no se detecta ningún UP (solo ruido).

Paso 3. Dada la DFH para cada ventana dinámica se conforma la ocupación del espectro que es la representación binaria del espectro analizado $X(f)$.

En la **Figura 4.4** se puede apreciar el resultado de aplicar la metodología base, es decir la ocupación del espectro en la que se puede observar dónde ocurre una singularidad y además si este borde corresponde a el inicio o fin de una posible transmisión primaria o a ruido.




Figura 4.4. a) espectro multibanda sintético con dos transmisiones OFDM. b) Ocupación del espectro, resultado de aplicar la metodología base.

Esta técnica de MEMB destaca por sus ventajas [11]:

- Es una técnica ciega que no requiere conocer previamente el intervalo que se esté monitorizando ni las características del UP.
- Detecta al UP con un 98 % de eficacia para valores de $\text{SNR} \geq 0$ dB.
- Fue desarrollada en un entorno simulado.
- Se probó su eficiencia en casos desafiantes con señales reales dando resultados contundentes para ser implementada.

Capítulo 5. Desafíos de la monitorización multibanda con dispositivos SDR

5.1. Introducción

Durante las últimas décadas, las telecomunicaciones han estado en constante evolución. Entre los aportes tecnológicos más relevantes se encuentra el procesador digital. Este dispositivo ofrece a los equipos de radio la flexibilidad de un sistema programable. En otras palabras, el comportamiento de un sistema de comunicación puede modificarse simplemente cambiando su software. Este beneficio introdujo un nuevo paradigma de radio llamado radio definido por *software* (SDR). Bajo este paradigma, la tarea de configurar el comportamiento del radio se transfiere al software, dejando al *hardware* solo para implementar el *front end* de radiofrecuencia. Con esto, el radio deja de ser estático. Es decir, el comportamiento de sus circuitos es programable y se convierte en un elemento dinámico, que puede cambiar sus características operativas, tales como ancho de banda, modulación, tasa de codificación; incluso es posible modificarlas durante el tiempo de ejecución según lo controle el software [106].

SDR se define como "radio en el que algunas o todas las funciones de la capa física están definidas por software" [106]. En los dispositivos SDR, los módulos de software se ejecutan en tiempo real en plataformas de microprocesadores o procesadores de señales digitales. Además, la mayoría de los dispositivos se diseñan con base en FPGA para transmitir o recibir señales de radio. Las principales características operativas de los SDR se pueden modificar en tiempo de ejecución: el sistema se puede reconfigurar fácilmente para realizar diferentes funciones según sea necesario. Debido a estas características, se pueden crear transmisores (Tx) o receptores (Rx) para cualquier tipo de señal a través de funciones de software o firmware [26, 27].

Los SDR se pueden utilizar en varias tecnologías de radiofrecuencia, como Bluetooth, WLAN, GPS, Radar, WiMAX, LTE. La rápida evolución de los sistemas de comunicaciones inalámbricas y sus estándares hace que las actualizaciones de software de la estación base sean una solución más atractiva que la costosa reposición de estaciones, tanto para el sector militar como para el sector comercial. Por ejemplo, la actualización del software de

los equipos de comunicación satelital desplegados permitiría cambios en la funcionalidad de comunicación y múltiples usos durante la vida útil del satélite [107]. Los SDR abren una gama de posibilidades al hacer que los tipos de aplicaciones de radio existentes sean más fáciles de implementar y al permitir nuevos tipos de aplicaciones. En particular, el poder de cómputo y la flexibilidad del SDR se pueden aprovechar para desarrollar RC [108], [109].

En este trabajo de investigación se propone la implementación de técnicas MEMB basadas en el uso de dispositivos de comunicación de propósito general. Como estudios de caso se utilizarán el SDR-RTL [110], el HackRF One [111] y el LimeSDR Mini [112]. En la **Tabla 5.1** se muestran las principales características de estos dispositivos.

Tabla 5.1. Características de los dispositivos SDR usados en este trabajo [58].

Dispositivo	HackRF One	RTL-SDR	LimeSDR Mini
Rango de frecuencia	[1 MHz - 6 GHz]	[22 MHz - 2.2 GHz]	[10 MHz - 3.5 GHz]
Ancho de banda [MHz]	20	3.2	30.72
Bits por muestra	8	8	12
Frecuencia de muestreo ¹	20 MMPS	3.2 MMPS	30.72 MMPS
Canales Tx	1	0	1
Canales Rx	1	1	1
Uso del canal	<i>Half duplex</i>	-	<i>Full duplex</i>
Potencia de transmisión	10 dBm (15 dBm @ 2.4 GHz)	-	Max 10 dBm (Dependiendo de la frec.)

¹MMPS, millones de muestras por segundo

En las siguientes secciones se menciona a detalle cómo fueron utilizados los dispositivos SDR y los desafíos que se presentaron a lo largo de este trabajo de tesis.

5.2. Recolección de información

En el bloque de recolección de información se acondicionan las señales recibidas por los dispositivos SDR, actualizando su percepción cada 100 ms. Cada dispositivo SDR entrega una señal compleja $r_i(n) = x_{Ii}(n) + jx_{Qi}(n)$ con $i = 1, 2, \dots, N$ para los N dispositivos conectados secuencialmente, i.e. cada SDR percibe cierto intervalo de frecuencia contiguo al anterior. Básicamente, para cada dispositivo SDR considerado, se establecen tres parámetros: la frecuencia de muestreo, la frecuencia central (de recepción) y la ganancia como se muestra en la **Figura 5.1**. Para los dispositivos utilizados, se tiene una frecuencia de muestreo de 20 MHz para el HackRF One, 3.2 MHz para el RTL-SDR y 30.72 MHz para el LimeSDR. En el Capítulo 6 se detallan estos tres parámetros.

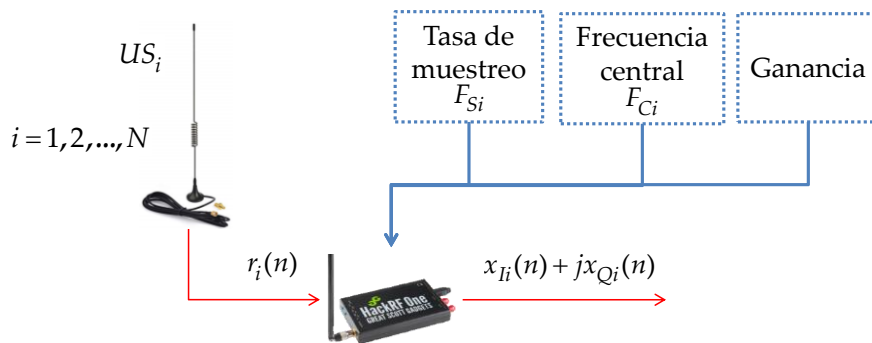


Figura 5.1. Proceso de recolección de información con N dispositivos SDR conectados de forma secuencial

5.3. Espectro multibanda

Con la señal percibida $r_i(n)$, tal que $n = 1, 2, 3, \dots$, por cada dispositivo i , se estima la PSD (este proceso se describirá mejor en el Capítulo 6.) a través del método de Welch [113] (también llamado método del periodograma). Para ello se divide cada trama de señal de 100 ms en bloques o ventanas sucesivas más pequeñas, estimando el periodograma, i.e. la magnitud al cuadrado de la transformada rápida de Fourier (FFT, del inglés *fast Fourier transform*) para cada bloque, y promediando sobre el número total de ventanas que forman

cada trama. Es decir, $r_i(n)$ se divide en segmentos de longitud L considerando ventanas de la señal $r_i(n)$, en donde la m -ésima ventana está denotada por:

$$\begin{aligned} r_{i,m}(n) &= w(n)r_i(n+(m-1)R); \\ n &= 0, 1, \dots, L-1; \quad m = 1, 2, \dots, K; \end{aligned} \quad (5.1)$$

donde R corresponde al tamaño de la ventana analizada tal que $R \leq L$. Si $R=L$ entonces la ventana analizada $r_{i,m}(n)$ será contigua a la ventana $r_{i,m\pm 1}(n)$. Sin embargo, si $R < L$ las ventanas $r_{i,m}(n)$ y $r_{i,m\pm 1}(n)$ serán segmentos superpuestos de longitud L . K denota el número de ventanas disponibles en la trama total y $w(n)$ es la ventana de ponderación que en el caso por defecto corresponde a una ventana rectangular (i.e., las muestras originales no son modificadas). El periodograma para cada una de las tramas completas para cada uno de los dispositivos conectados i , está dado por:

$$P_{r_{i,m}}(k) = \left| \text{FFT}(r_{i,m}(k)) \right|^2 = \frac{i}{L} \left| \sum_{n=0}^{L-1} r_{i,m}(n) e^{\frac{-j2\pi nk}{L}} \right|^2, \quad k = 0, 1, 2, \dots, L-1 \quad (5.2)$$

y el estimador por Welch para la PSD está dado por:

$$R_i(k) = \frac{1}{K} \sum_{m=1}^K P_{r_{i,m}}(k) \quad (5.3)$$

En otras palabras, es solo un promedio de periodogramas a lo largo del tiempo en cada trama de puntos $r_i(n)$ cada 100 ms, este proceso se puede apreciar en la **Figura 5.2**.

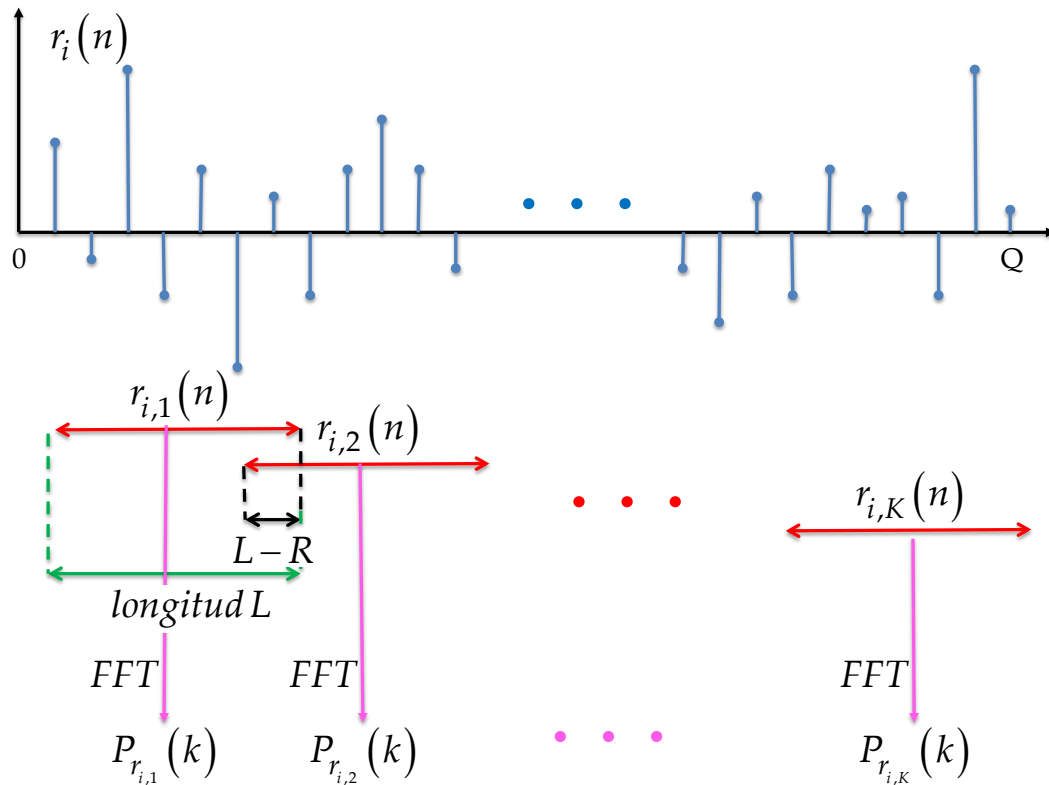


Figura 5.2. Descripción grafica del método del Welch

Cuando $\omega(n)$ es la ventana rectangular, los periodogramas se forman a partir de bloques de datos sucesivos que no se superponen. Para otros tipos de ventanas, las tramas de análisis normalmente se superponen. En esta implementación, se utiliza una ventana de Hamming superpuesta al 50 % y se elige el número de muestras contenidas en $R_i(k)$ según el dispositivo: 512, 1024, 2048 o 4096 muestras para RTL-SDR. Para el caso de HackRf One y LimeSDR Mini, el número de muestras puede ser 1024, 2048, 4096 o 8192. Estos datos esenciales representan un compromiso en la implementación en tiempo real entre tener muchas muestras para localizar al UP con gran precisión o eligiendo pocas muestras sacrificando la precisión para localizar la transmisión del UP para reducir el tiempo de ejecución y la asignación de recursos computacionales.

En la **Figura 5.3** se puede observar que al obtener la PSD de la señal percibida por el RTL-SDR hay un crecimiento en la orillas del espectro, esto es un comportamiento propio del RTL dado que el ruido puede introducirse en los componente electrónicos. Esto debido a que al ser dispositivos económicos suelen estar asociados a componentes de menor calidad y menor nivel de

sofisticación tecnológica además los componentes más económicos suelen carecer de blindaje electromagnético adecuado y aislamiento de señales. Con este espectro la técnica de MEMB no otorga resultados adecuados debido al cambio tan abrupto de la PSD presentado en las orillas de la ventana percibida. La solución planteada a este problema fue omitir 1/8 parte del inicio y 1/8 parte del final de la PSD, lo que significa que se está omitiendo 1/4 parte de la trama original. Con este procesamiento se evita la distorsión en la señal al principio y al final. Debido a este fenómeno, los RTL-SDR solo perciben 2.4 MHz de ancho de banda.

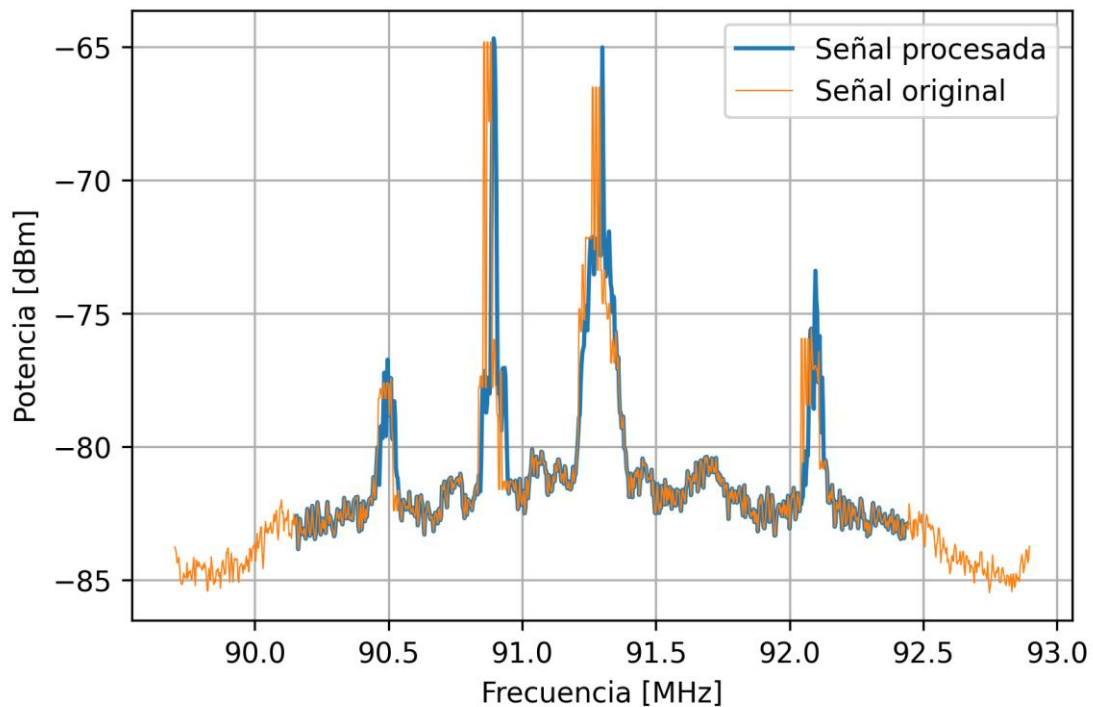


Figura 5.3. PSD obtenida del RTL-SDR

5.4. Inhibición de ruido impulsivo

Debido a la naturaleza de los dispositivos utilizados en este trabajo, la adición de un ruido clásico (espectro plano) se ve perturbada por la aparición de picos en la estimación de la PSD. Estos picos se denominan ruido impulsivo y en general son más significativos con los dispositivos SDR que los observados por un analizador de espectro comercial. La eliminación de este tipo de ruido debe ser necesaria para mejorar el desempeño de la técnica de MEMB propuesta. Se han propuesto muchos métodos para mitigar este ruido, incluso técnicas novedosas como la detección comprimida [114] o un método

recursivo de mínimos cuadrados basado en la variante del espacio de estado [115].

En este trabajo de investigación se propone un módulo de eliminación de ruido impulsivo, que sin duda es una propuesta novedosa para mitigar cambios bruscos indeseables en la señal PSD que será procesada por la técnica MEMB. El funcionamiento de este módulo se muestra en la **Figura 5.4**. La eliminación del ruido impulsivo a lo largo de cada trama se realiza mediante los coeficientes de aproximación y detalle emitidos por un AMR [86] actuando sobre la estimación de la PSD.

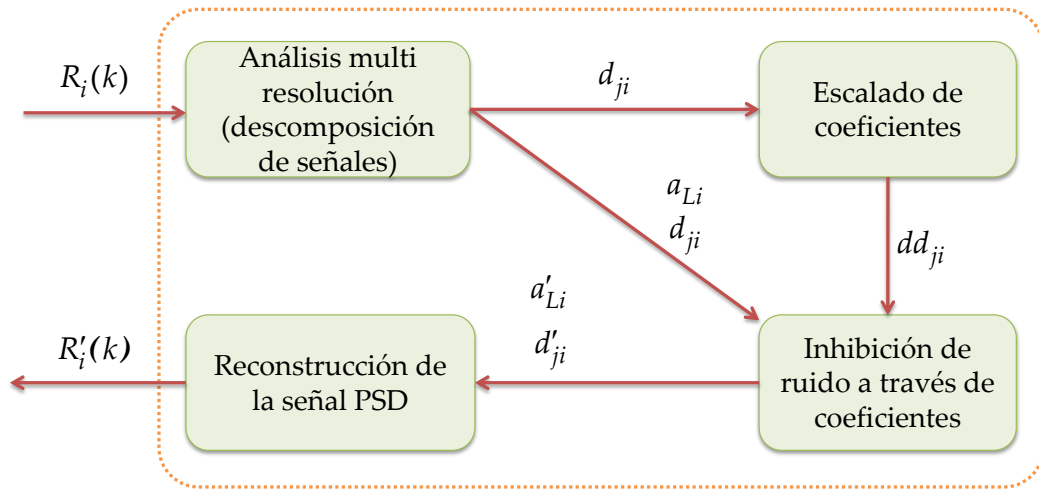


Figura 5.4. Operación del módulo de inhibición de ruido impulsivo

En las siguientes secciones se menciona en detalle el funcionamiento de cada submódulo que conforma el módulo de eliminación de ruido impulsivo.

Análisis multiresolución: descomposición de la PSD

Primero, a la señal $R_i(k)$ (PSD en escala lineal, resultado de aplicar el estimador de Welch) se le aplica secuencialmente el AMR al i -ésimo dispositivo, resultando los coeficientes de aproximación a_{Li} en el nivel de descomposición L y los coeficientes de detalle d_{ji} en los niveles que van desde $j = 1, 2, \dots, L$, y dado por [86]:

$$R_i(k) = a_{Li} + \sum_{j=1}^L d_{ji} \quad (5.4)$$

Los coeficientes de detalle corresponden a la transformada discreta de *wavelet* de $R_i(k)$ en una escala diádica. Es bien sabido que los coeficientes de detalle de la descomposición de una señal vía AMR mantienen la información sobre singularidades (cambios bruscos en la señal) como es el caso del ruido impulsivo. Por ello, la propuesta se basa en modificar estos coeficientes de detalle para mitigar este problema generado por el ruido impulsivo. Para ello, la propuesta sólo considera un nivel de $L=1$, es decir, los coeficientes de aproximación a_{1i} y los coeficientes de detalle d_{1i} . El espacio *wavelet* construido a partir del AMR es la *wavelet* Haar, función óptima [47] en la detección de discontinuidades, esto se muestra en la **Figura 5.5**.



Figura 5.5. Descomposición de la PSD a través del AMR

Escalado de coeficientes

Posteriormente, se realiza un escalado a los coeficientes de detalle d_{ji} de cada dispositivo i . En este proceso se asigna un 0 al coeficiente de menor valor, un 1 al coeficiente de mayor valor y un valor entre 0 y 1 al resto de coeficientes d_{ji} en función de su valor original. Dando como resultado la señal dd_{ji} (ver la **Figura 5.6**).




Figura 5.6. Submódulo de escalamiento de los coeficientes de detalle

Inhibición de ruido a través de coeficientes

Para reducir los cambios bruscos (ruido impulsivo) en la PSD, se reasignarán los valores de los coeficientes de detalle y aproximación. Esta tarea es la más importante de este bloque de reducción de ruido. El diagrama de flujo que describe este submódulo se muestra en la **Figura 5.7**.

Una vez escalados los coeficientes de detalle dd_{ji} para cada dispositivo i , se aplica una condición de doble umbral, $L_1 < dd_{ji} < L_2 \mid L_1 = 0.01, L_2 = 0.4$, a los coeficientes escalados dd_{ji} , siendo estos índices (los índices de los coeficientes dd_{ji} que cumplan con esta doble condición) no consecutivos. Los índices que cumplan ambas condiciones se almacenarán en la variable ind . A los coeficientes de detalle dd_{ji} de las localidades ind y las que están alrededor, anterior y siguiente, se les asignará el valor de 1×10^{-15} . De esta manera, los coeficientes de detalle se están *apagando*, para que estos componentes no afecten a la siguiente señal a reconstruir, que es donde existe el ruido a inhibir. En el resto de las localidades se asignará el valor original de dd_{ji} .

Con el procesamiento anterior, los índices de los coeficientes de detalle coinciden con los índices de los coeficientes de aproximación, los cuales también se tienen que modificar para eliminar algunos cambios bruscos al momento de reconstruir la señal, esta coincidencia se debe a que el nivel de descomposición es $L = 1$. Para modificar los coeficientes de aproximación a'_{Li} , se replica una colonia cercana de tres muestras de coeficientes de aproximación en los índices mencionados, esta colonia de coeficientes son el coeficiente de aproximación que coincide con el coeficiente de detalle, un coeficiente de aproximación anterior y un coeficiente de aproximación siguiente. En el resto de las localidades de d'_{ji} se asignará el valor original de

a_{Li} .

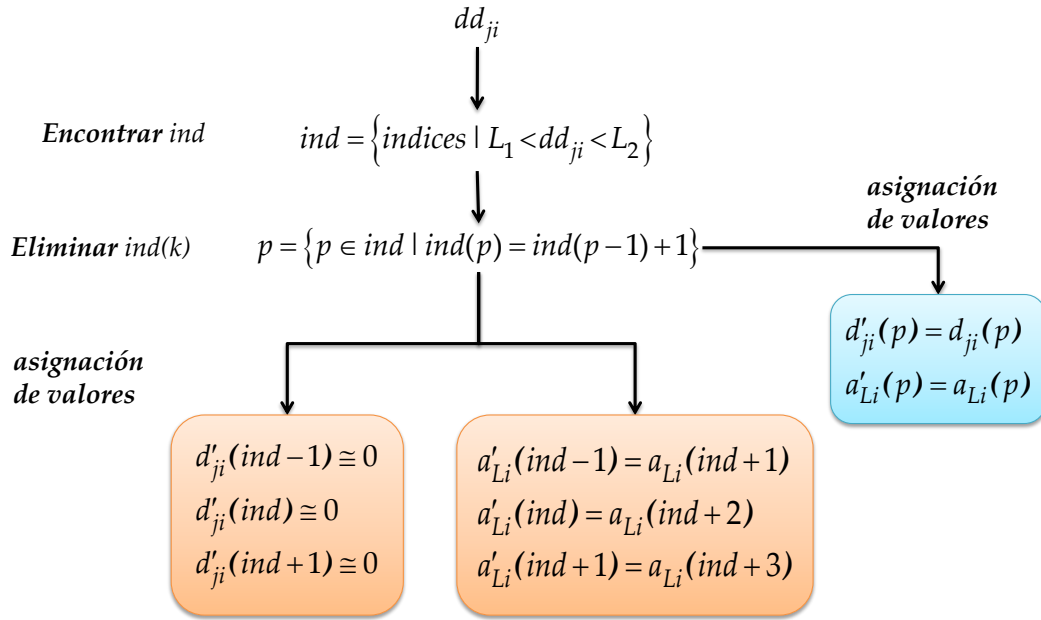


Figura 5.7. Operación del submódulo de eliminación de ruido

El resultado de este bloque corresponde a los coeficientes de aproximación a'_{Li} y los coeficientes de detalle d'_{ji} con las atenuaciones correspondientes para eliminar las diferentes variantes de ruido mencionadas anteriormente. La **Figura 5.8** muestra un ejemplo de la diferencia entre los coeficientes originales y los modificados por este bloque.

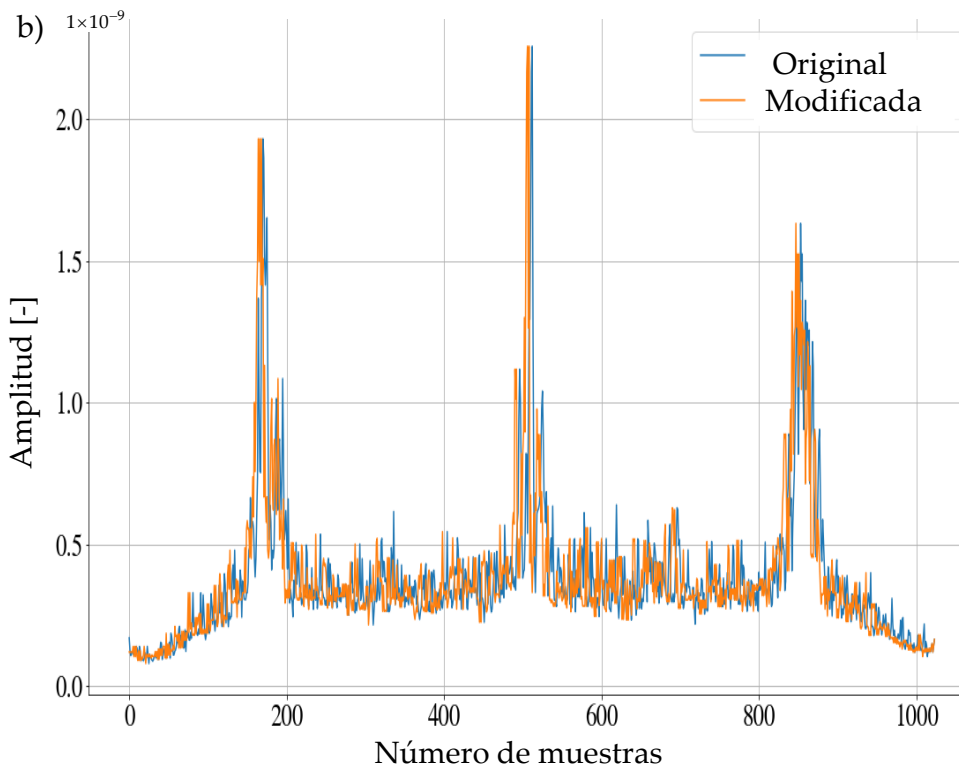
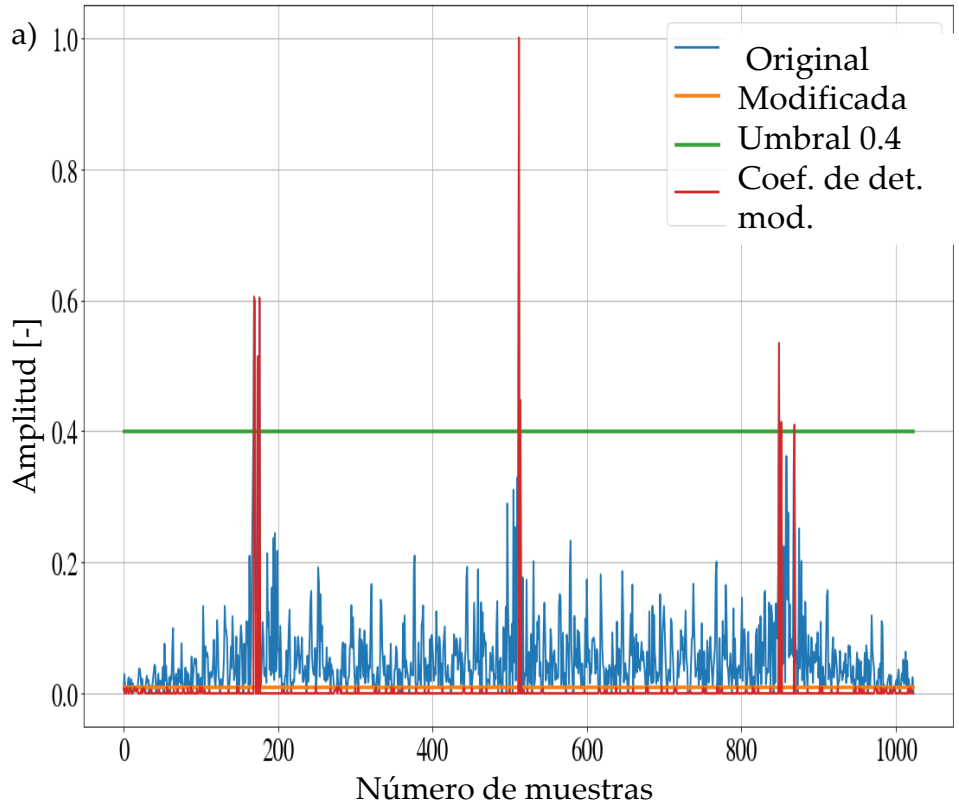


Figura 5.8. Coeficientes originales y modificados a) aproximación. b) detalle.

Reconstrucción de señal PSD

En este bloque, los nuevos coeficientes se utilizan como parámetro de entrada. Con ellos, se realiza una reconstrucción de *wavelets* (nuevamente usando Haar). El resultado de la reconstrucción es la señal $R'_i(k)$, que es la PSD con la atenuación de las diferentes variantes de ruido en una escala lineal. Este procesamiento se puede ver en la **Figura 5.9**.



Figura 5.9. Reconstrucción de la PSD después de eliminación de ruido impulsivo

Tomando el ejemplo anterior, el resultado de aplicar el submódulo de reconstrucción *wavelet* se muestra en la **Figura 5.10** en escala logarítmica. En esta figura es posible distinguir los cambios entre la PSD original y la PSD que ha sido modificada por el módulo de inhibición de ruido.

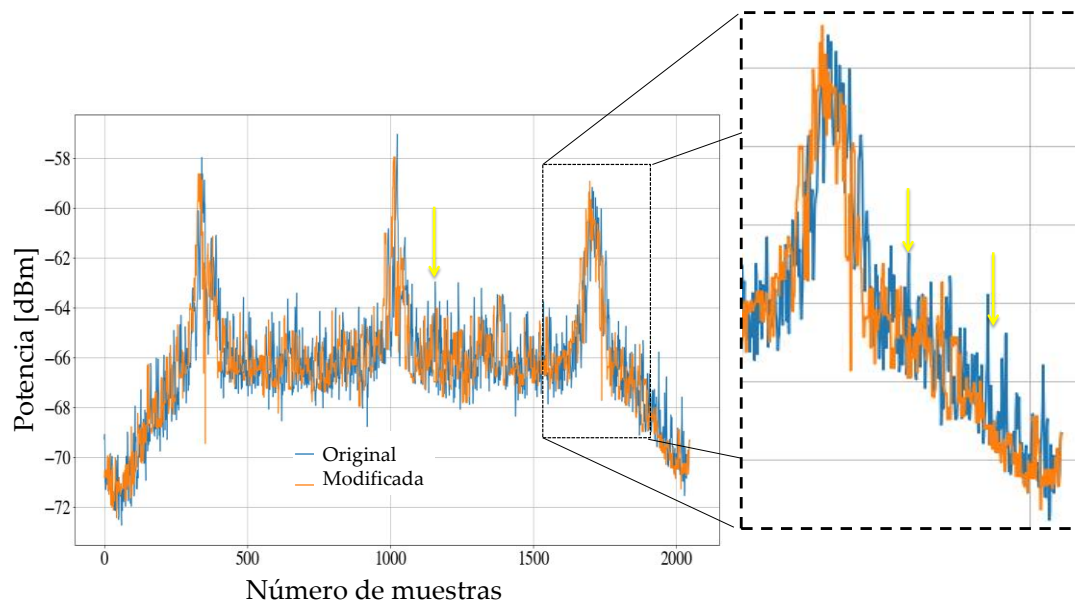


Figura 5.10. Diferencia entre la PSD original y la PSD modificada

Otro ejemplo se muestra en la **Figura 5.11**. Esta misma diferencia se observa aquí utilizando 2 dispositivos RTL-SDR con $F_{CT} = 90.8$ MHz, banda utilizada

exclusivamente para la radiodifusión [10]. Además, es posible analizar un rango de frecuencias mayor en función del número de dispositivos SDR conectados.

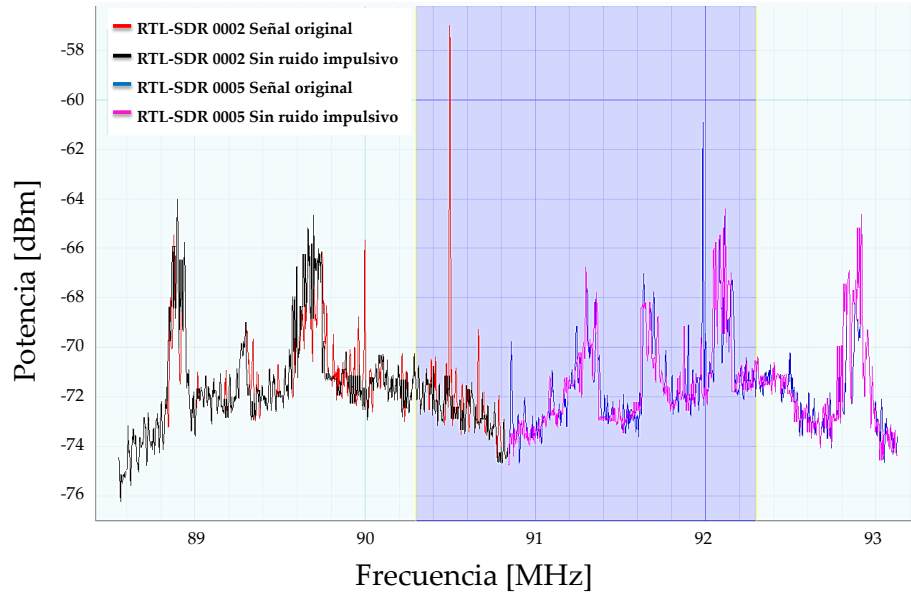


Figura 5.11. Diferencia entre la PSD original y la PSD modificada usando múltiples dispositivos SDR

En los ejemplos que se muestran en la **Figura 5.10** y la **Figura 5.11**, hay diferentes PSD que muestran dos desafíos. En la **Figura 5.10** se muestra la abundancia de ruido de alta frecuencia con cambios muy bruscos y en la **Figura 5.11** se exhibe la abundancia de ruido impulsivo, en ambos casos el inhibidor de ruido funciona correctamente.

Algoritmo de reducción de ruido impulsivo

El pseudocódigo utilizado para el bloque de reducción de ruido impulsivo, es el siguiente:

Algoritmo 5.1. Reducción de ruido.

1. **Function** *noise_reduction*($R_i(k)$):
2. $L_1 = 0.01$
3. $L_2 = 0.4$
4. $a_{Li}; d_{ji} = \text{pywt.wavedec}(R_i(k), 'db1', L=1)$
5. $a'_{Li} \leftarrow a_{Li}$
6. $d'_{ji} \leftarrow d_{ji}$
7. $dd_{ji} = \text{reescal}(d_{ji})$
8. $ind = \text{find}(d_{ji} > L_1 \ \& \ d_{ji} > L_2)$
9. **for** p **in range** ($\text{len}(ind)-1, 2, -1$):
10. $aux = ind[p-1]$
11. **if** $ind[p] == aux + 1$
12. $ind = \text{delete}(ind, [p-1])$
13. $d'_{ji}(ind-1) = 1 \times 10^{-15}$
14. $d'_{ji}(ind) = 1 \times 10^{-15}$
15. $d'_{ji}(ind+1) = 1 \times 10^{-15}$
16. $a'_{Li}(ind-1) = a_L(ind+1)$
17. $a'_{Li}(ind) = a_L(ind+2)$
18. $a'_{Li}(ind+1) = a_L(ind+3)$
19. $R'_i(k) = \text{pywt.waverec}(a'_{Li}; d'_{ji}, 'db1', 'symmetric')$
20. **return** ($R'_i(k)$)

Capítulo 6. Implementación en tiempo real de la monitorización del espectro multibanda usando tecnología SDR

En este capítulo se detalla la implementación en tiempo real de la metodología descrita previamente [11]. Para ello la técnica MEMB deberá cumplir las siguientes condiciones: (i) que sea adecuada para detectar correctamente a los UP. También, (ii) que tenga una complejidad computacional que permita una implementación en tiempo real en un entorno de comunicaciones inalámbricas, (iii) que sea viable para utilizarse con dispositivos de bajo costo fáciles de instalar y programar.

En el capítulo anterior se menciona de forma breve y concisa la técnica de monitorización de base, dicha técnica de MEMB será implementada en *hardware* genérico de comunicaciones donde la gestión de los dispositivos se hará a través de una aplicación desarrollada en Python.

Uno de los retos más desafiantes de este capítulo es monitorizar el espectro del entorno en tiempo real y que además se conserve la eficiencia de la técnica que fue desarrollada originalmente en un entorno simulado.

6.1. Metodología propuesta

La **Figura 6.1** muestra el escenario general para la MEMB utilizando dispositivos SDR de bajo costo para conocer la ocupación de un intervalo amplio del espectro.

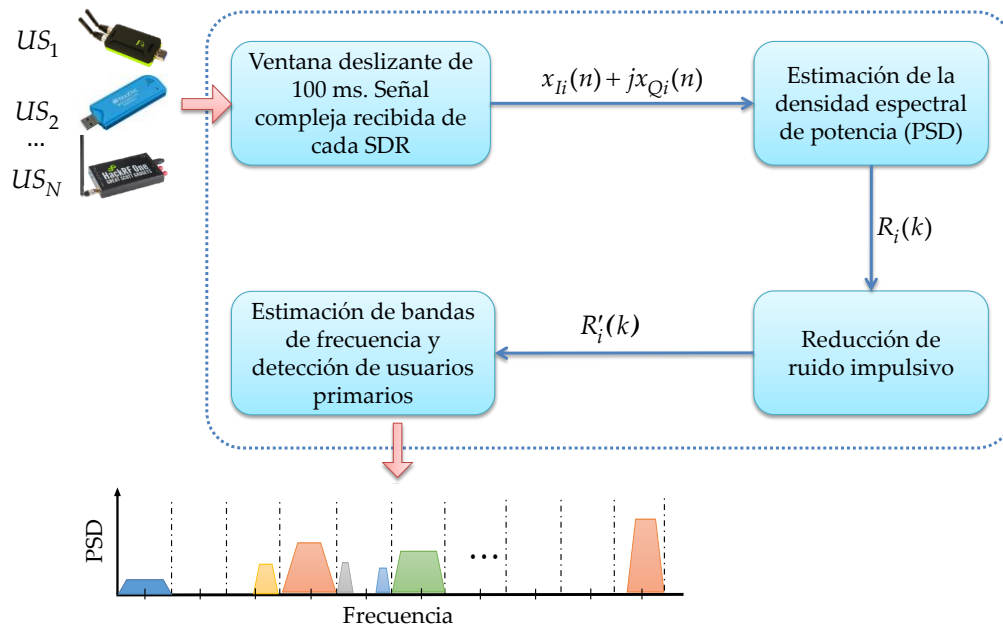


Figura 6.1. Escenario general implementado para la MEMB

En general, el escenario implementado consta de cuatro grandes bloques: una ventana de tiempo deslizante, un estimador de PSD, un bloque para reducción del ruido impulsivo y finalmente un bloque para determinar bordes de frecuencia y detección de UP. Básicamente, cada dispositivo recopila información del entorno (es decir, cada uno funciona como un US), esta información es procesada por el estimador de PSD para obtener el espectro en diferentes bandas. Posteriormente, esta PSD se modifica para eliminar el ruido, especialmente el impulsivo a través de un AMR. Finalmente, el último bloque permite decidir si un UP está presente o no usando *wavelets* discretas, aprendizaje automático y la DFH. A continuación, se describe en detalle cada uno de los bloques esquematizados en la **Figura 6.1**.

Ventana de tiempo deslizante

El bloque correspondiente a la ventana de tiempo deslizante se detalla en la **Figura 6.2**. En este bloque se acondicionan las señales recibidas por los dispositivos SDR, actualizando su percepción cada 100 ms. Cada dispositivo SDR entrega una señal compleja $r_i(n) = x_{Ii}(n) + jx_{Qi}(n)$ para $i = 1, 2, \dots, N$ para los N dispositivos conectados secuencialmente. Básicamente, para cada

dispositivo SDR considerado, se establecen tres parámetros: la frecuencia de muestreo, la frecuencia central (de recepción) y la ganancia. Para los dispositivos utilizados en el escenario propuesto, tenemos una frecuencia de muestreo de 20 MHz para el HackRF One, 3.2 MHz para el RTL-SDR y 30.72 MHz para el LimeSDR (ver **Tabla 5.1**). La ganancia inicial de cada dispositivo es de 0 dB, lo que significa que no se aumenta la potencia de la señal percibida por cada dispositivo. No obstante, este parámetro puede modificarse si la potencia de transmisión de la UP es imperceptible para el dispositivo SDR (este valor lo elige el usuario).

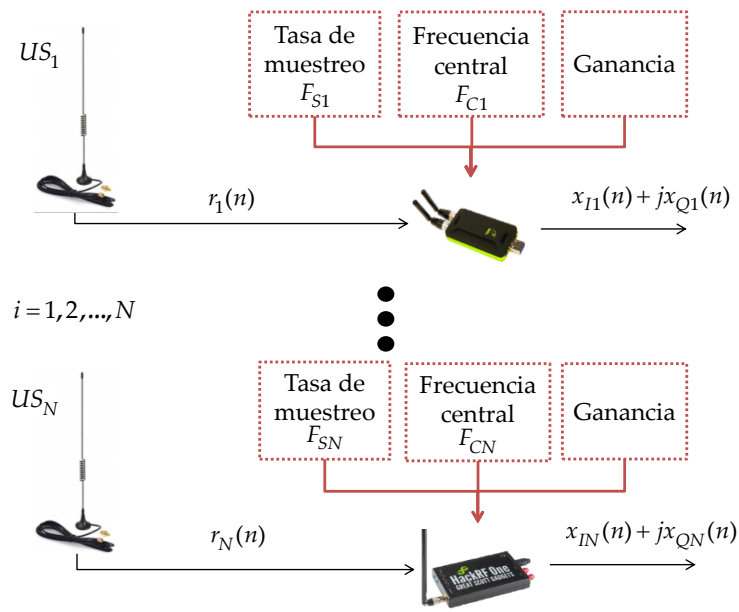


Figura 6.2. Etapa de percepción: Señales recibidas por los dispositivos SDR, actualizadas cada 100 ms.

La frecuencia central F_{CT} del espectro deseado (ancho de banda del espectro multibanda) la elige el usuario siguiendo los siguientes pasos (ver la **Figura 6.3**):

- El ancho de banda de cada dispositivo SDR conectado se suma para conformar el ancho de banda completo Bw_T a observar.
- El ancho de banda total está centrado en F_{CT} .
- Finalmente, se asigna la frecuencia central F_{Ci} de cada dispositivo conectado.

- Los pasos se repiten cada vez que se cambia el valor de F_{CT} .

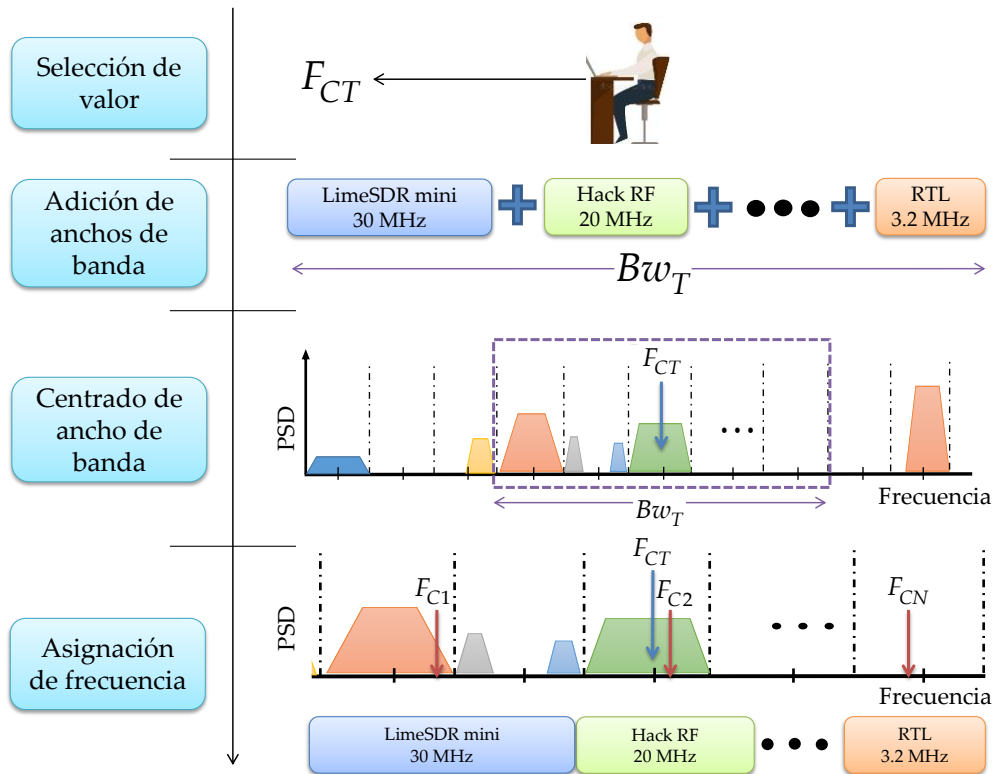


Figura 6.3. Asignación de frecuencias portadoras de cada dispositivo conectado para conformar el espectro multibanda observado

Estimador de densidad espectral de potencia

A partir de la señal recibida $r_i(n) = x_{Ii}(n) + jx_{Qi}(n)$ la cual es una señal compleja en el tiempo, se obtiene la PSD en una escala lineal discreta de la frecuencia $R_i(k)$ a través del estimador de Welch [116] para cada dispositivo conectado cada 100 ms (trama de tiempo).

La estructura y funcionamiento de este bloque se muestran en la **Figura 6.4**.

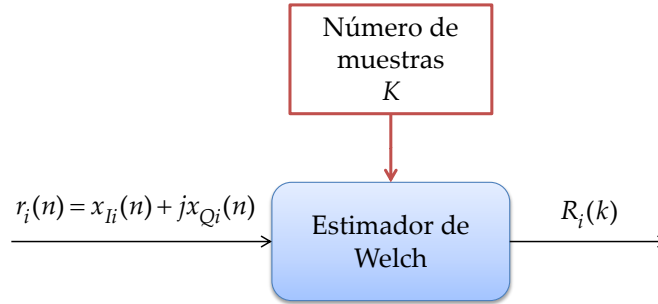


Figura 6.4. Estimador de la PSD a través del método de Welch

Inhibición de ruido impulsivo

El ruido impulsivo y el ruido de alta frecuencia se reducen considerablemente en este módulo. Este procesamiento se realiza a través de los coeficientes de detalle y los coeficientes de aproximación resultantes de haber aplicado el AMR a la estimación de PSD [117]. Esta propuesta de reducción de ruido es una técnica novedosa lo cual es un aporte de esta tesis, dando excelentes resultados. El resultado de este bloque es el PSD modificado R'_i como se menciona en la Sección 5.4.

Detección de usuarios primarios

En esta sección se presenta el último bloque de esta implementación: la detección de UPs en el espectro. Este procedimiento recibe la PSD en escala lineal $R'_i(k)$ como parámetro de entrada y entrega dos salidas: (i) la señal $R'_{i-dBm}(k)$, que es la PSD en escala logarítmica, y su ocupación (es decir, inicios y finales de los bordes de frecuencia de las bandas detectadas); (ii) la decisión binaria: si cada una de estas bandas detectadas corresponde a ruido o a una posible transmisión del UP. Esta estructura se muestra en la **Figura 6.5**.




Figura 6.5. Módulo de detección los UP

Este bloque consta de diferentes submódulos como se muestra en la **Figura 6.6**: (i) Detección de bandas de frecuencia vía AMR y ML, en este submódulo se utiliza el AMR para obtener los coeficientes de aproximación, estos coeficientes se clasificarán con el algoritmo K-means y se obtendrán las posibles ventanas espectrales. Y (ii) Detección de los UPs vía la DFH, en este submódulo se calcula la autocorrelación de cada ventana a través de la DFH. Al final de este bloque se obtiene cada ventana espectral en escala logarítmica y la ocupación de cada ventana. Esta técnica de MEMB es un aporte de esta tesis que fue publicada en [11]. En la propuesta mencionada en este capítulo, la novedad es la plataforma desarrollada para implementar esta técnica utilizando dispositivos de comunicación de propósito general.

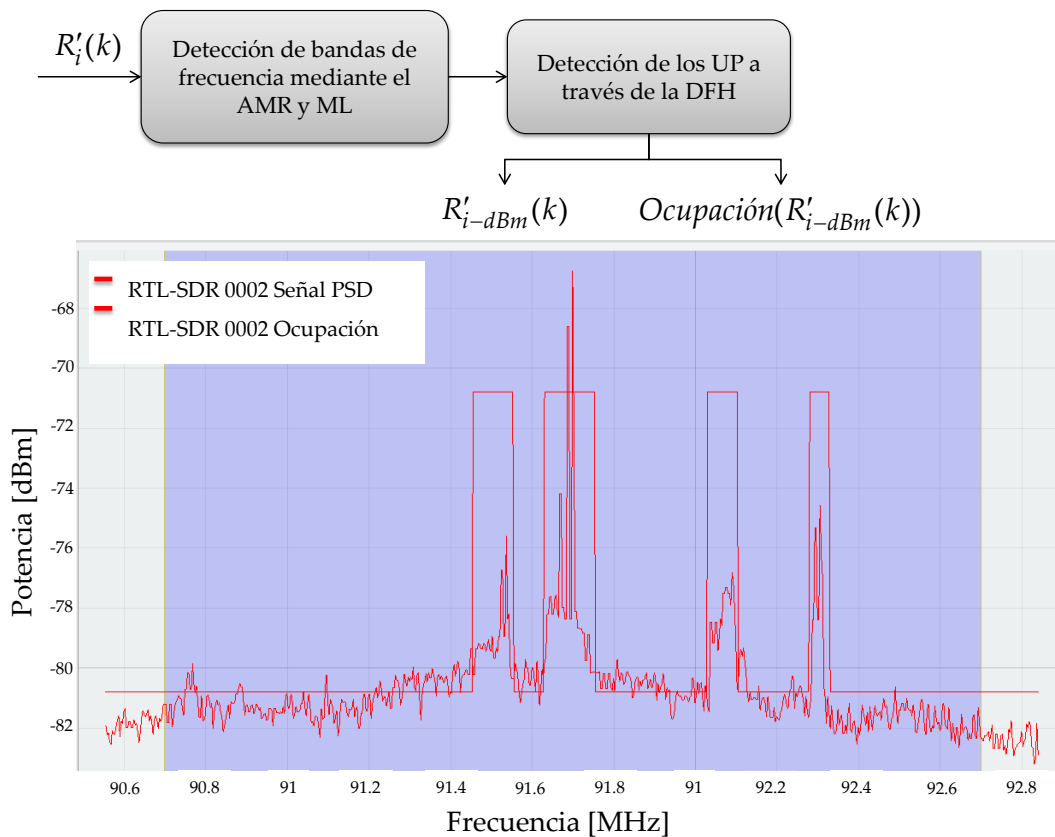


Figura 6.6. Señales entregadas desde el bloque "Detección de UP".

En la **Figura 6.6** podemos observar el resultado de aplicar este bloque de detección. Aquí, la señal de ocupación, que indica una transmisión del UP o ruido, se muestra como una representación binaria actualizada cada 100 ms.

6.2. Experimentos y resultados de la implementación en tiempo real

Esta sección presenta el entorno de desarrollo, los parámetros considerados y los resultados para validar el algoritmo de la MEMB en tiempo real utilizando dispositivos SDR a través de un escenario en el que se han tomado medidas para mantener ciertas variables constantes o dentro de rangos definidos lo que permitirá realizar las pruebas bajo condiciones predefinidas, para obtener lecturas confiables y replicables.

Escenario implementado

El entorno implementado se presenta en la **Figura 6.7**. Para ello se emplearon cuatro dispositivos SDR. Tres de los cuales se establecieron como US y uno como UP. Además, se utilizó un celular como UP. Las características de cada dispositivo utilizado y los parámetros asociados a la experimentación se describen en la **Tabla 6.1**. En esta implementación en tiempo real, todos estos dispositivos son controlados por una aplicación desarrollada por los autores que se explicará brevemente más adelante.

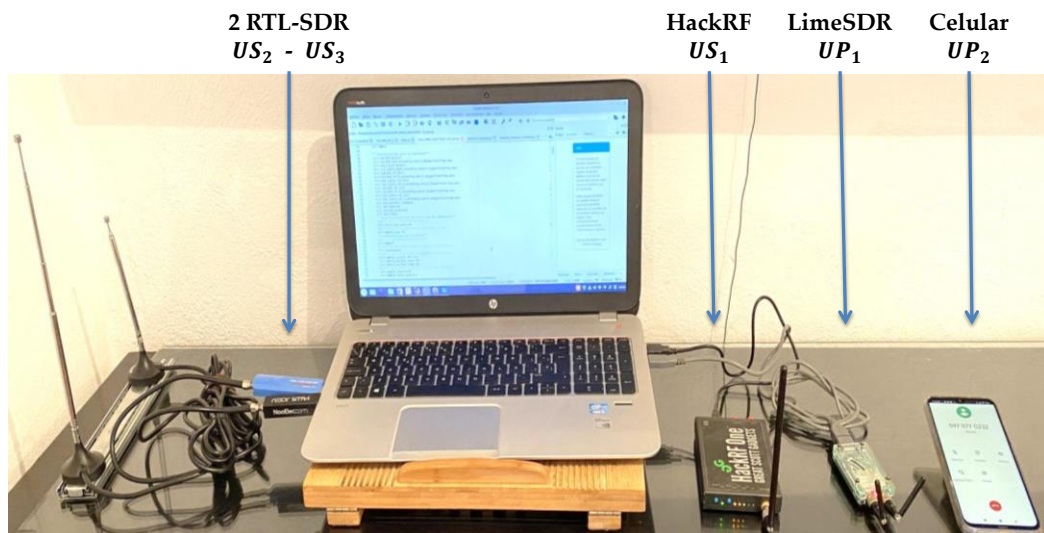


Figura 6.7. Escenario implementado

Tabla 6.1. Parámetros de los dispositivos considerados.

Tx/Rx	US_1	US_2	US_3	UP_1	UP_2
Dispositivo	HackRF One	RTL-SDR 0005	RTL-SDR 0002	LimeSDR Mini	Llamada por celular
Frecuencia de Tx [MHz]	-	-	-	847.8	842.5
Tipo de transmisión	-	-	-	OFDM	CDMA [10]
Ancho de banda de Tx [MHz]	-	-	-	1	5
Frecuencia de Rx [MHz]	835	846.2	848.6	-	-
Ancho de banda de Rx [MHz]	20	2.4	2.4	-	-

El orden en que se ubican los dispositivos SDR está dictado por la siguiente prioridad. El primero será el LimeSDR mini, el segundo el HackRF One y finalmente el RTL-SDR. Esta prioridad viene dada por el ancho de banda que cada dispositivo puede manejar. Con base en lo anterior, se realiza la visualización y alineación de las señales en la aplicación. Y con fines únicamente de una mejor visualización de los espectros captados por estos dispositivos, se realiza un ajuste en la potencia para "alinear" los espectros monitorizados. Es decir, todas las señales estarán al mismo nivel de potencia que el dispositivo con mayor ancho de banda, sin que este procesamiento modifique en modo alguno la forma de la PSD ni la ocupación de la señal. Esta alineación solo permite una mejor estética en la aplicación como se muestra en la **Figura 6.8**.

Algunos puntos importantes asociados a cada uno de los módulos que integran el sistema se describen a continuación:

- El módulo *ventana de tiempo deslizante* presenta un retardo (promedio) de 0.0065 s entre los dispositivos SDR y la PC (este valor no depende del número de muestras que contenga la PSD).
- El módulo *estimación de la PSD* muestra un tiempo de ejecución (en promedio) de 0.017 s con una trama de 512 muestras, 0.018 s con una

trama de 1,024 muestras, 0.02 s con una trama de 2,048 muestras y 0.026 s con una trama de 4,096 muestras.

- El módulo *eliminación de ruido impulsivo* presenta un tiempo de ejecución (en promedio) de 0.00047 s con una trama de 512 muestras, 0.00051 s con una trama de 1,024 muestras, 0.00071 s con una trama de 2,048 muestras y 0.0011 s con una trama de 4096 muestras.
- El módulo *estimación de bandas de frecuencia y detección de usuarios primarios* muestra un tiempo de ejecución (en promedio) de 0.0339 s con una trama de 512 muestras, 0.0468 s con una trama de, 0.0775 s con una trama de 2,048 muestras y 0.1264 s con una trama de 4096 muestras.
- Esto significa que en promedio esta implementación toma 0.0621 s con una trama de 512 muestras, 0.07181 s con una trama de 1,024 muestras, 0.10471 s con una trama de 2,048 muestras y 0.156 s con una trama de 4,096 muestras.

Estos valores se midieron en una laptop con 12 GB de RAM y un procesador Intel i5 y se analizaron 10,000 tramas para cada valor.

De acuerdo con los parámetros y configuraciones mencionados en la **Tabla 6.1**, los US estarían observando bandas contiguas como se muestra en la **Figura 6.8**, lo que significa que se percibe un total de 24.8 MHz de ancho de banda. En esta figura se muestra que el HackRF One observa la transmisión que hace el UP_2 y los RTL-SDR, US_2 y US_3 , ven la transmisión del UP_1 .

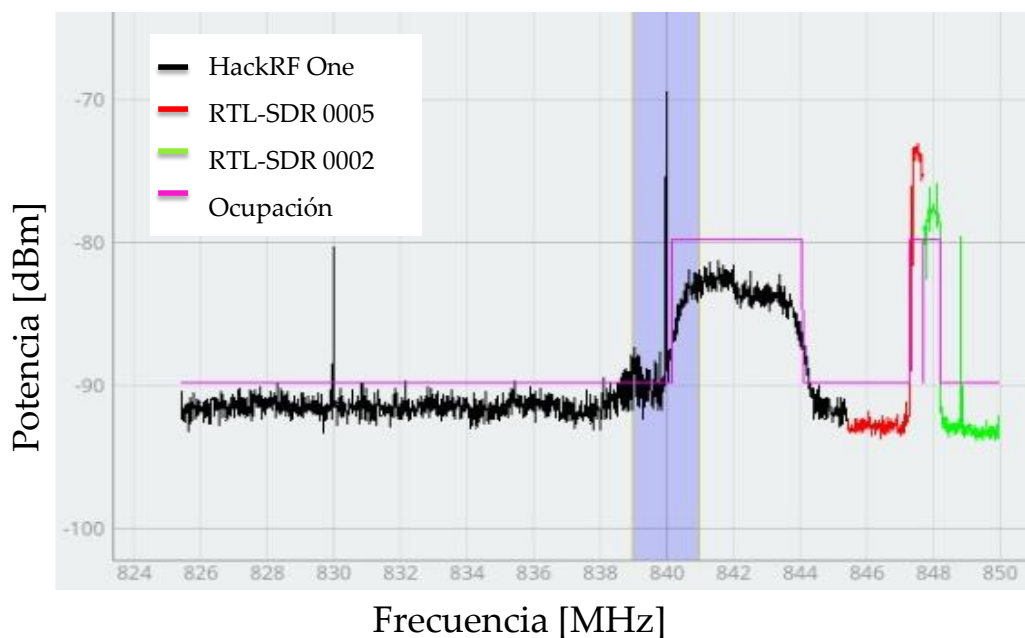


Figura 6.8. Rango de frecuencia percibido por los US

Procesamiento de señales en la implementación controlada

Esta sección describe en detalle el procesamiento de las señales y los parámetros utilizados en la implementación controlada. La **Figura 6.9** muestra los módulos agregados: (i) la adición de AWGN (del inglés *additive white Gaussian noise*) a las señales percibidas por los US en el dominio del tiempo. Con esto, es posible modificar la SNR en la implementación controlada para tener un entorno lo más cercano posible a la realidad. Se añade este ruido a la señal percibida por los US antes de procesar la señal. (ii) Estadísticas de cómputo y rendimiento que es el bloque que almacena los datos y obtiene las estadísticas para conocer la eficiencia de este trabajo en un entorno real de comunicación inalámbrica.

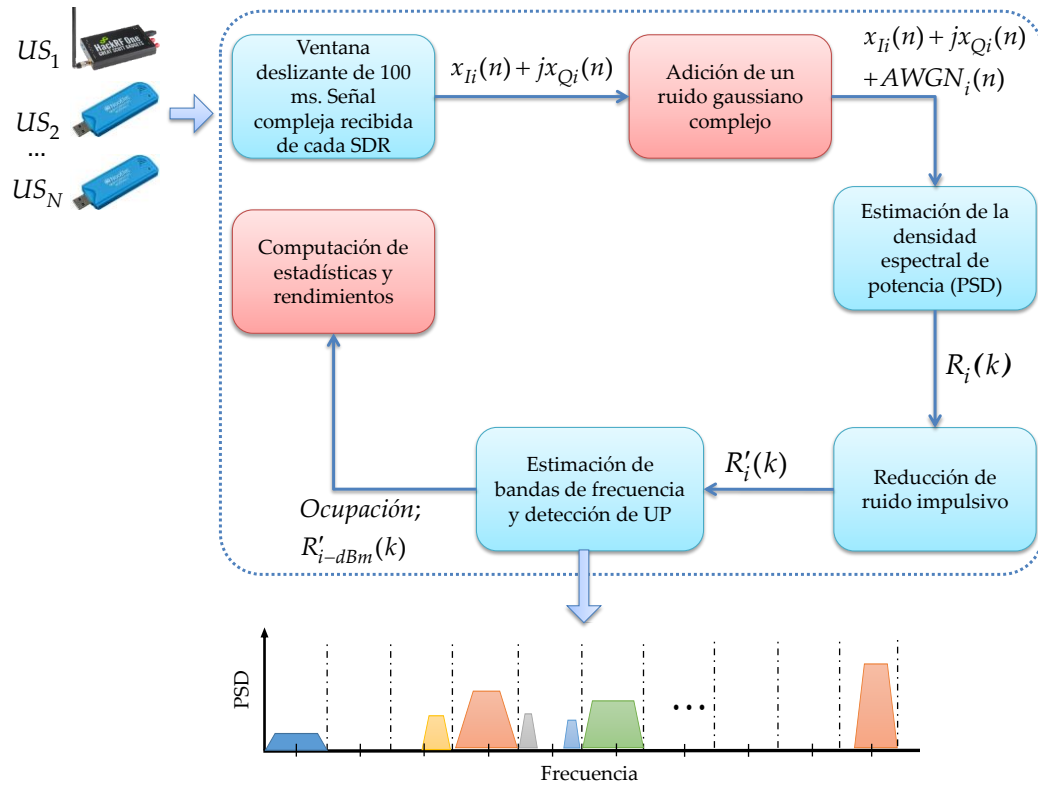


Figura 6.9. Pasos de la implementación controlada

La **Figura 6.10** muestra la estructura del bloque de adición de ruido artificial, que involucra tres parámetros de entrada: (i) la señal P_{SUI} , que es la potencia que transmite cada dispositivo i , (ii) el valor de SNR que tendrá el experimento controlado (este valor es lo mismo para cada dispositivo SDR,

ver Tabla 3) y (iii) la señal compleja $r_i(n) = x_{I_i}(n) + jx_{Q_i}(n)$ percibida por cada US i . Los valores de experimentación utilizados se muestran en la **Tabla 6.2**. Cabe mencionar que cada US percibió 16.66 horas para cada valor de SNR. Esto para una trama de 2048 muestras para el HackRF One y 1024 muestras por trama para RTL-SDR.

Tabla 6.2. Parámetros de la implementación controlada.

	US_1	US_2	US_3
Dispositivo	HackRF One	RTL-SDR 0005	RTL-SDR 0002
Valores de la SNR	[-5 -4 -2 -1 0 1 2 3 4 5 6 8 10 12 14 16 18 20] dB		
Tramas del Rx por valor de SNR	10,000	10,000	10,000
Muestras por trama	2048	1024	1024

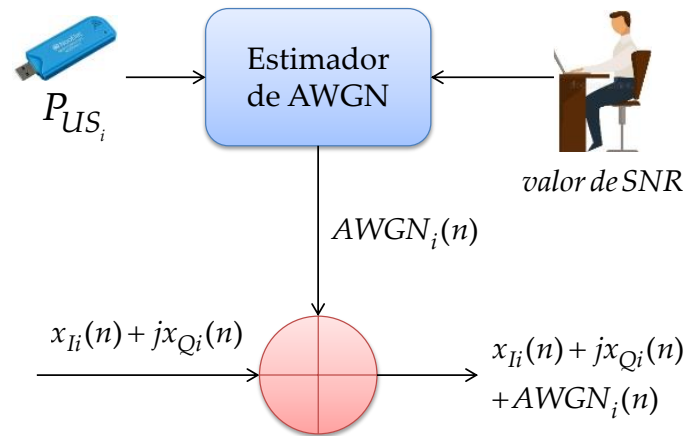


Figura 6.10. Bloque conteniendo la adición de ruido gaussiano complejo

En el bloque de suma de ruido artificial se utiliza el **Algoritmo 6.1** para calcular el ruido que se sumará a la señal $r_i(n) = x_{I_i}(n) + jx_{Q_i}(n)$.

Algoritmo 6.1. Adición de ruido artificial.

1. Función Artificial_Noise_Addition($r_i(n)$, P_{SUi} , SNR_value)
 2. Sigma=float ($P_{SUi}/(10^{**}(SNR_value /10))$)
 3. mu=0
 4. real=np.random.randn ((len($r_i(n)$)))*(sigma**0.5)+mu
 5. imag=np.random.randn ((len($r_i(n)$)))*(sigma**0.5)+mu
 6. $AWGN_i(n) = \text{real} + j*\text{imag}$
 7. $r_i(n) = r_i(n) + AWGN_i(n)$
 8. return($r_i(n)$)
-

Finalmente, en el bloque de estadísticas de cómputo y rendimiento se almacena: la señal $Ocupación(R'_{i-dBm}(k))$ que indirectamente contiene los bordes de inicio y final de una transmisión que forman las ventanas de frecuencia y si estas ventanas corresponden a ruido o una transmisión del UP. Posteriormente, la señal transmitida por cada UP_i se compara con la señal recibida por cada US_i .

Resultados

En esta sección se presentan los resultados obtenidos con la técnica MEMB. Los dos parámetros a evaluar en esta implementación son la probabilidad de éxito (PE) y las muestras en error.

La PE es el resultado de contar el total de ventanas de frecuencia correctamente ubicadas con respecto al número total de ventanas de frecuencia en un total de 10,000 tramas por valor de SNR. Para determinar el valor de PE se consideran cuatro posibles casos (ver la **Figura 6.11**):

1. La ventana que corresponde a una transmisión del UP y el US la clasifica como transmisión del UP incrementara el valor asociado a un verdadero positivo (VP).
2. La ventana de frecuencia que corresponde a una transmisión del UP y el US la clasifica como ruido incrementara un valor asociado a un falso negativo (FN).
3. La ventana que corresponde a ruido y el US lo clasifica como transmisión primaria incrementara un valor asociado a un falso positivo (FP).

- La ventana de frecuencia que corresponde a ruido y el US lo clasifica como tal, incrementara un valor asociado a un verdadero negativo (VN).

Con base en lo anterior, VP, VN, FP y FN son valores numéricos que indican cuantas veces ocurrio cada suceso en un total de 10,000 tramas analizadas por valor de SNR.

Con estos valores la PE está dada por:

$$PE = \frac{VP + VN}{VP + FP + FN + VN} \quad (6.1)$$

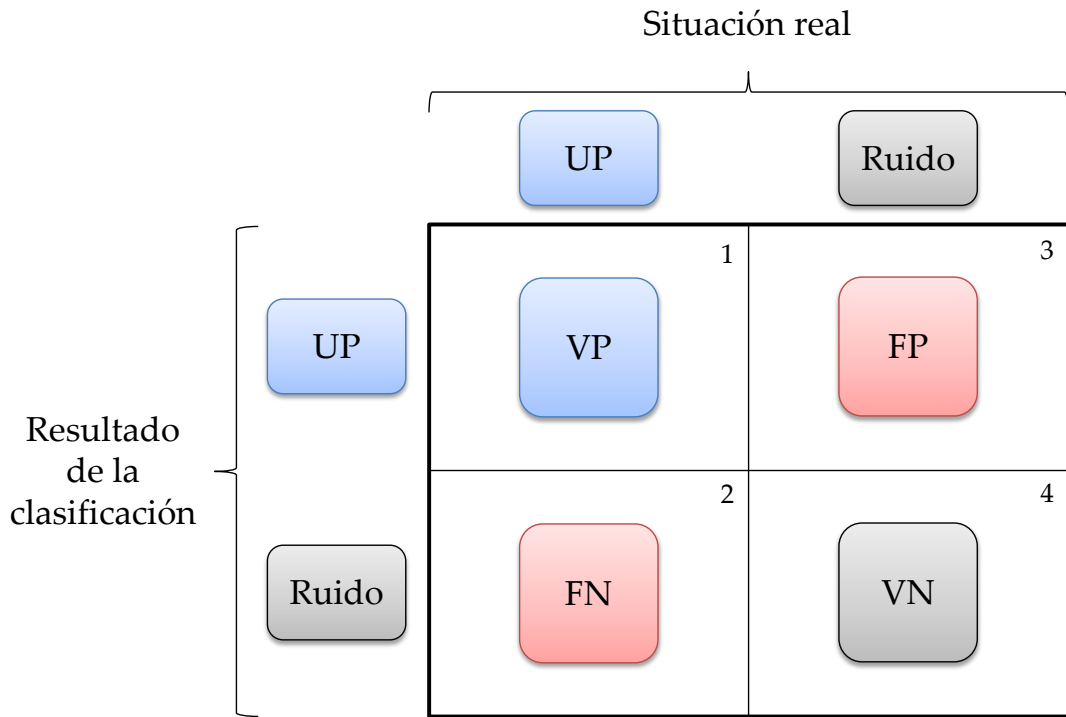


Figura 6.11. Clasificación de ventanas detectadas con la técnica MEMB

Para comparar el desempeño individual de cada uno de los dispositivos empleados, se obtuvo la PE considerando diversos valores de SNR y graficados en la **Figura 6.12**. Con base en estos resultados, se puede concluir que los RTL-SDR presentan un mejor resultado para detectar las ventanas de frecuencia, que pueden ser transmisión del UP o ruido, en comparación con los HackRF One. La PE para los RTL-SDR es superior a 0.98 para valores de $SNR \geq 0$ dB y la PE del HackRF One es superior a 0.94 para valores de $SNR \geq 0$ dB. Estos valores son muy similares a los presentados en [11] (la PE es superior a 0.98 para valores de $SNR \geq 0$ dB).




Figura 6.12. Probabilidad de éxito de cada US en la implementación controlada

Además de la técnica de MEMB descrita, se realizó una implementación con un detector de energía (DE) con un solo dispositivo RTL-SDR (US_4) $f_{C4} = 846.2$ MHz con un ancho de banda de 2.4 MHz lo que significa que US_4 monitoriza el mismo espacio de radiofrecuencia que el US_2 . En la **Figura 6.13** se muestra el resultado de aplicar el DE convencional. En este caso la PE es 0.64 para valores de $SNR \geq 5$ dB. Para esta técnica se seleccionó el umbral de -80 dBm, que es el mismo valor que se eligió para la etapa de selección de *clusters* en el algoritmo para clasificar los coeficientes de aproximación. Por la naturaleza de esta metodología se generan más ventanas, lo que ocurre al pasar de un estado a otro (de ocupado a vacío y viceversa). Este fenómeno reduce mucho la PE aunque localiza correctamente la transmisión del UP.




Figura 6.13. Probabilidad de éxito del DE

Las muestras en error corresponden al número de muestras entre el borde de la transmisión UP y el borde detectado con la técnica MEMB (ver la **Figura 6.14**). Otra forma de definir las muestras en error es como aquellas que hay para detectar el borde inicial o final de una transmisión del UP. En la **Figura 6.14** se muestra que para valores de $\text{SNR} \geq 0$ dB las muestras en error tienen un comportamiento estadísticamente estable para cada US, además los RTL-SDR presentan un mejor resultado para detectar UP con mayor precisión, entre 3 y 5 muestras en promedio para las muestras en error, y HackRF One tiene entre 8 y 9 muestras, lo que es un buen rendimiento. Además las muestras con error presentadas en [11] son entre 2 y 3 muestras en promedio.




Figura 6.14. Muestras en error para cada US en la implementación (media y desviación estándar, STD del inglés standard deviation)

Las muestras en error para el US_4 (DE convencional) son 36 muestras en promedio (ver la **Figura 6.15**). Esto se debe a las múltiples ventanas que existen para pasar de un estado a otro. El DE destaca por ser una técnica sencilla de implementar y por sus bajos recursos de procesamiento. Sin embargo, es una técnica que tiende a fallar muy rápidamente, especialmente cuando el ambiente tiene mucho ruido de alta frecuencia o ruido impulsivo.




Figura 6.15. Muestras en error del DE (media y STD)

Aplicación SDR-MEMB-UAMI

Finalmente, la metodología propuesta para la implementación de la técnica de MEMB utilizando dispositivos de comunicación de bajo costo se consolida en el desarrollo de una aplicación que denominamos SDR-UAMI-MEMB. Esta interfaz muestra la PSD y la ocupación de un intervalo espectral (ver la **Figura 6.16**), precisamente el espacio radioeléctrico que los US (dispositivos SDR conectados) pueden *visualizar* en su conjunto y consta de técnicas avanzadas de procesamiento digital de señales y fue desarrollado en lenguaje Python. Esta aplicación es fácil de usar, intuitiva y bastante descriptiva. Esto permite que el usuario tenga una fácil interacción. Además, al ser una aplicación de código abierto, permite saber con precisión qué hace cada módulo y si es posible mejorarlo. La interfaz SDR-UAMI-MEMB es una rama de la aplicación SDR-UAMI [74].




Figura 6.16. Aplicación SDR-MEMB-UAMI

Capítulo 7. Monitorización del espectro multibanda basada en entropía muestral

La idea principal de este capítulo es mostrar que SampEn es una técnica viable para ser utilizada como regla de decisión para distinguir ruido o una posible transmisión de UP en un escenario multibanda en tiempo real. El cálculo de SampEn requiere la determinación a priori de dos parámetros desconocidos, m y r (la longitud K de los datos, como se mencionó en la Sección 3.4. depende del tamaño de la ventana dinámica que corresponde a una sección de la PSD de cada dispositivo conectado). Los valores sugeridos de r están en el intervalo de $[0.1, 0.2]$ de la desviación estándar de la señal procesada X . La elección de una r correcta no es una tarea fácil. En efecto, en [118] se estudió cómo ajustar a los datos el mejor valor de r para el caso específico de la ApEn (una entropía similar a la de la SampEn) variando los valores de r en el intervalo de 0 a 1 y buscando el máximo de la ApEn (considerándolo como la interpretación correcta de la complejidad de una señal). Se concluyó que el máximo de la ApEn no siempre ocurre dentro del intervalo prescrito de valores r . Por lo tanto, calcular todos los valores r posibles no es práctico debido a la carga computacional que esto representa. Para esto, las recomendaciones prácticas que tienen buenos resultados para otras aplicaciones están en el intervalo $[0.1, 0.2]$. Con base en este hecho (y dejando como tema abierto de investigación la búsqueda del valor óptimo de r para nuestros datos analizados), en nuestras simulaciones planteamos $r=0.1$. El valor de m se puede calcular estimando el falso vecino más cercano [119]. En esta técnica de MEMB, el valor encontrado entre los falsos vecinos más cercanos para nuestras señales fue la mayor parte del tiempo igual a 2. Por lo tanto, se estableció en todas las simulaciones y pruebas experimentales. SampEn es, teóricamente hablando, una fracción en el intervalo $(-\infty < SampEn < \infty)$. Sin embargo, las siguientes dos fórmulas se pueden usar para encontrar los límites inferior y superior de SampEn para valores fijos de m y K [90].

El límite inferior se puede estimar como:

$$2[(K-m-1)(K-m)]^{-1} \quad (7.1)$$

y el límite superior como:

$$\ln(K-m) + \ln(K-m-1) - \ln(2) \quad (7.2)$$

El escenario original desarrollado en la Sección 6.2. utilizando dispositivos SDR como SDR-LTR, HackRF One y LimeSDR mini, configurados para funcionar como US y UP, es la base de este capítulo.

7.1. Metodología propuesta

En este capítulo se retoman algunos pasos básicos de la metodología original. La contribución actual aparece en el bloque de detección del UP (el último bloque en la **Figura 6.1**). La **Figura 7.1** muestra en detalle este módulo modificado, en el que se incluye la SampEn como regla de decisión. Este módulo se describe en el **Algoritmo 7.1**.

Algoritmo 7.1. Técnica de MEMB basada en SampEn.

1. La PSD percibida por cada dispositivo SDR conectado, se evalúa en dBm, para obtener la señal $R'_{i-dBm}(K)$. Se aplica el AMR a esta señal, lo que da como resultado los coeficientes de aproximación y de detalle en diferentes niveles de descomposición.
 2. El análisis de la señal reconstruida de los coeficientes de aproximación permitirá conocer el número de *clusters* en los que se clasificarán los coeficientes de aproximación normalizados y reescalados por el algoritmo K-means, para construir la señal *Test*.
 3. Procesando los cambios de estado de esta señal, es posible detectar los bordes de inicio y fin de la(s) transmisión(es) en la trama analizada. Con esta información, es posible construir ventanas de tamaño dinámico.
 4. Cada ventana dinámica (*Test Window*) representa una sección del espectro que corresponde directamente a una sección de la señal *Test*, es decir; a una sección de la señal reconstruida a partir de los coeficientes. Cada *Test Window* se compara con un umbral igual a 1. Si la comparación de la *Test Window* coincide con el umbral, SampEn se aplicará directamente a la ventana de espectro original. De lo contrario, SampEn se aplicará a la ventana de espectro reconstruido.
 5. Si el valor de SampEn es superior a 0.38, significa que solo hay ruido presente en la ventana analizada. Si el valor de SampEn es menor, es
-

Algoritmo 7.1. Técnica de MEMB basada en SampEn.

muy probable que haya un UP en la ventana analizada. Finalmente, procesando cada trama de cada dispositivo SDR conectado, se obtiene la Ocupación, es decir; la ubicación espectral del UP y los posibles huecos espectrales en los que se podría colocar el US. En la Sección 7.3. , se justifica la elección del umbral de decisión.

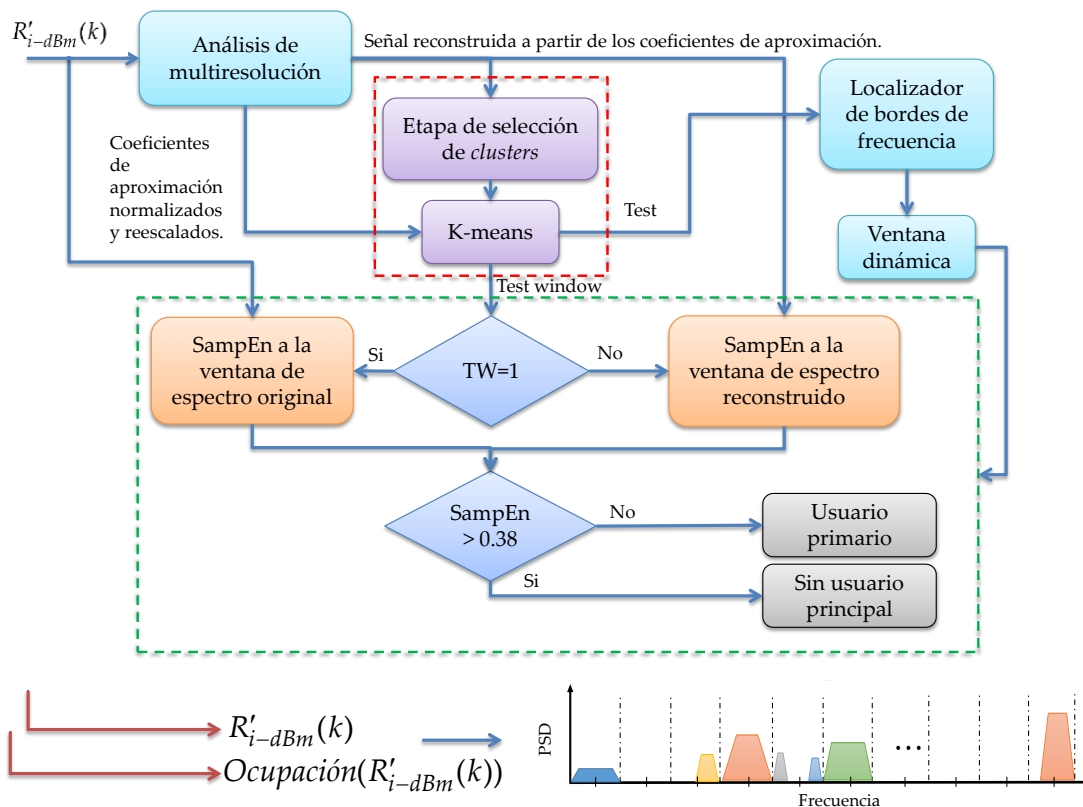


Figura 7.1. Módulo modificado (línea verde punteada) para la detección de los UP utilizando SampEn

7.2. Simulaciones y escenario controlado en tiempo real

En esta sección se presentan las simulaciones y pruebas experimentales de la metodología propuesta, para evaluar el desempeño de este método se proponen dos esquemas diferentes: una simulación considerando señales sintéticas (explicado en la Sección *Simulación*) y un entorno controlado en tiempo real utilizando dispositivos SDR como transmisores y/o receptores (explicado en la Sección *Implementación del escenario controlado*).

Antes de detallar los escenarios implementados, es necesario indicar la inclusión controlada de ruido tanto en la simulación como en la implementación en tiempo real, con el fin de evaluar el desempeño del método en función de una SNR.

Para ello, añadimos un proceso AWGN a cada señal recibida en el tiempo, modificando su potencia para conseguir una SNR específica. Esta adición se muestra en la **Figura 7.2**.

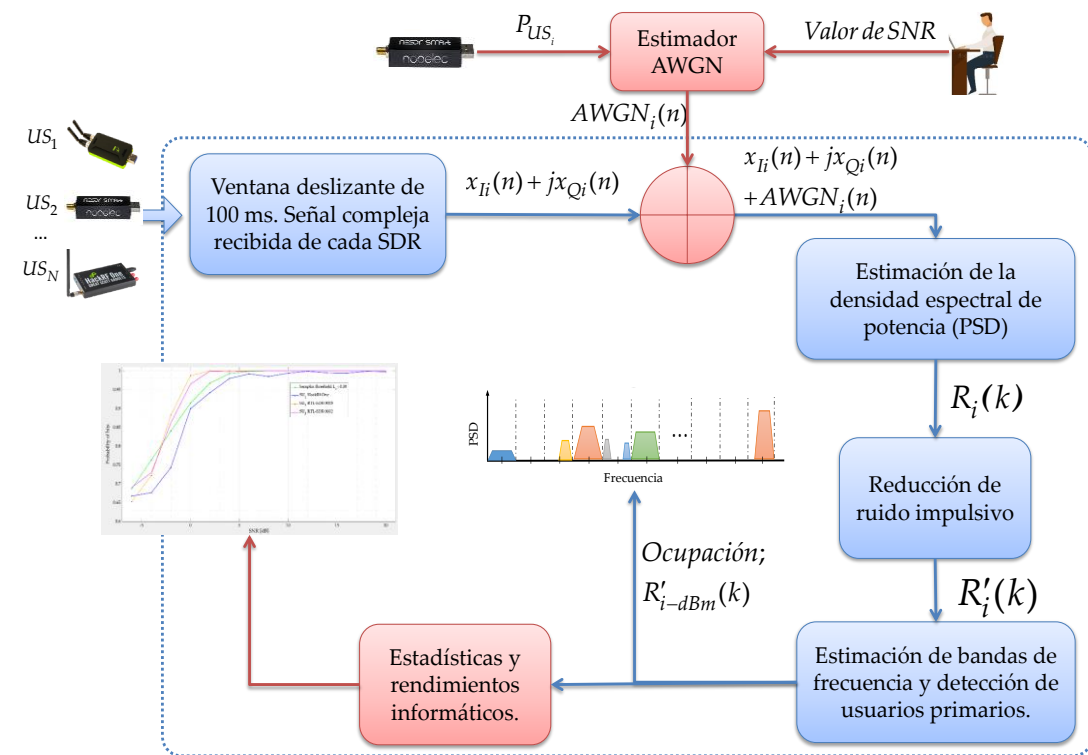


Figura 7.2. Pasos para la simulación e implementación controlada

Simulación

La simulación se realizó considerando un UP, apareciendo aleatoriamente en una banda ancha. Para ello se implementó el escenario con el software MATLAB con los parámetros definidos en la **Tabla 7.1**. Se estudió el desempeño de la SampEn aplicándolo a secuencias de puntos que corresponden a transmisiones con AWGN, específicamente símbolos OFDM. Esta simulación es necesaria para comparar el desempeño de la entropía con el de la DFH, antes de profundizar en su aplicación real. Los resultados de esta simulación se presentan en la Sección 7.3.

Tabla 7.1. Parámetros de simulación.

Software	MATLAB 2019a
Valores de SNR	-6 a 20 dB espaciado en 2 dB
Número de tramas por valor de SNR	10,000
Muestras por trama	743
Número de símbolos por trama	1 símbolo, OFDM

Implementación del escenario controlado

Esta sección detalla la implementación de la metodología en un entorno controlado de comunicación inalámbrica. Para ello se utilizaron los dispositivos SDR descritos en la **Tabla 5.1**.

Con base en las ventajas que ofrecen los dispositivos SDR mencionados anteriormente, se propone utilizarlos en el escenario en tiempo real de comunicaciones inalámbricas de corta distancia, mostrado en la **Figura 6.1**. El objetivo de este escenario es tener un punto de comparación entre la DFH y la SampEn, previamente probada para la MEMB. El escenario incluye tres US y dos UP, cubriendo una banda ancha. Estos usuarios están posicionados en las frecuencias centrales indicadas en la **Tabla 6.2**.

Este escenario controlado se implementó para que la comparación entre ambas técnicas fuera lo más realista posible. Sin embargo, dado que tenemos un entorno de comunicación real, hay un punto importante a considerar: es casi imposible aislar las transmisiones externas que pueden influir en el resultado, incluido un ruido aditivo externo clásico que afecta las comunicaciones (esto es diferente) del ruido controlado agregado en las señales recibidas para obtener una SNR deseable, con fines de evaluación del rendimiento).

7.3. Resultados

En esta sección se presentan los resultados obtenidos en función de la probabilidad de éxito y el número de muestras en error tanto para ensayos

simulados como experimentales. Sin embargo, para realizar ambas pruebas, primero es necesario establecer un valor crítico: el umbral para la entropía de muestra en la regla de decisión. En los párrafos siguientes se discute esta elección.

Selección de umbral en la regla de decisión

Antes de establecer el umbral en la regla de decisión y entender cómo funciona la metodología propuesta, presentamos un ejemplo donde la SampEn se aplicó básicamente a dos secuencias de puntos diferentes: una transmisión primaria (símbolo OFDM) y una secuencia de AWGN. Para ello se aplicó la SampEn a una trama dividida en 3 secciones (ventanas), dos de estas secciones corresponden a AWGN y una a una transmisión OFDM. La trama completa, que se muestra en la **Figura 7.3a**, está integrado por las muestras (número) 1 a 225 y 500 a 743 correspondientes al AWGN y las muestras 226 a 499 que contienen la transmisión OFDM. Este proceso se repitió a 1000 tramas (o realizaciones aleatorias) con un valor SNR específico de 10 dB. El resultado (promedio y STD) de aplicar la SampEn a estas tramas se muestra en la **Figura 7.3c**. Paralelamente, se aplicó la DFH (utilizado como regla de decisión en trabajos anteriores y solo con fines comparativos) a estas mismas tramas y sus resultados se muestran en la **Figura 7.3b**. Claramente, SampEn (como también lo hace DFH) diferencia qué es ruido y qué es una transmisión. Podemos observar que SampEn es cercano a 0 cuando las secuencias analizadas tienen gran similitud consigo misma (en este caso una posible transmisión del UP). Por el contrario, la SampEn tiende a un valor igual o superior a 2, cuando la serie discreta es más compleja (en este caso al AWGN).




Figura 7.3. a) Ejemplo de trama correspondiente a una transmisión OFDM con AWGN (SNR=10 dB). b) Resultado de aplicar la DFH sobre 1,000 tramas. c) Resultado de aplicar la SampEn sobre 1,000 tramas.

Ahora, sabiendo que SampEn permite clasificar estos dos estados, se debe responder una pregunta: ¿Cuál es el umbral óptimo para clasificar ambos estados considerando el nivel de ruido (variación de la SNR)? Para ello, se implementó el algoritmo de clasificación ciega ExMa. Según el tipo de señales procesadas, es factible pensar que justo donde se cruzan las dos gaussianas se encuentra el umbral SampEn óptimo. De esta forma, 2,084,015 valores de SampEn fueron analizados por ExMa con valores de SNR que oscilan entre -6 y 20 dB. La **Figura 7.4** muestra el resultado de aplicar ExMa a los valores obtenidos de este proceso. Los valores $L_1 = \mu_1 + n\sigma_1$ y $L_2 = \mu_2 + n\sigma_2$ con $n=0.5$ se utilizan para delimitar la región en la que se puede elegir un umbral. Esta región está relativamente cerca de la intersección de ambas gaussianas ($L_0 = 0.38$). Además, estos límites (L_1 y L_2) se proponen como límites inferior y superior, respectivamente, para comparar el resultado de tomar valores específicos para SampEn.




Figura 7.4. Algoritmo ExMa aplicado a los valores de la SampEn para determinar el umbral de decisión óptimo

Resultados de la simulación

La evaluación del rendimiento de las pruebas tanto experimentales como simuladas se basa en la PE, que es el resultado de contar el total de ventanas de frecuencia correctamente ubicadas con respecto al número total de ventanas de frecuencia detectadas. Para determinar este parámetro (ec. (6.1)) se consideran los cuatro casos posibles de la Sección Resultados de la Sección 6.2.

Los resultados de la prueba simulada usando los umbrales propuestos, mencionados en la Sección 7.2. , se muestran en la **Figura 7.5**. Claramente, no hay diferencia en elegir entre el umbral óptimo $L_0 = 0.38$ y el límite superior $L_2 = 0.48$, ambos dan los mismos resultados. Los valores de umbral superiores a 0.48 tienen menor eficiencia en el sistema propuesto. La **Figura 7.5** muestra los resultados obtenidos por la SampEn y la DFH considerando solo un UP simulado por trama, como se mencionó en la Sección 7.2. Ambas técnicas muestran claramente un excelente desempeño para valores de SNR mayores o iguales a 0 dB. Para valores más bajos de SNR, ambas técnicas muestran un rendimiento similar y bueno.




Figura 7.5. Probabilidad de éxito para diferentes umbrales propuestos para la SampEn. Los resultados se comparan con la DFH.

La **Figura 7.6** muestra la clasificación de las ventanas detectadas según la **Figura 6.11**. La **Figura 7.6a** muestra esta clasificación cuando los datos son analizados con la DFH, y la **Figura 7.6b** aquellos con el SampEn. Aquí se muestra una clara diferencia entre estas dos reglas de decisión cuando la SNR tiende a valores negativos. De hecho, a medida que la SNR disminuye, el valor de la SampEn y la DFH comienzan a aumentar debido a la complejidad de la señal y el algoritmo comienza a clasificar erróneamente las diferentes ventanas de tamaño dinámico.

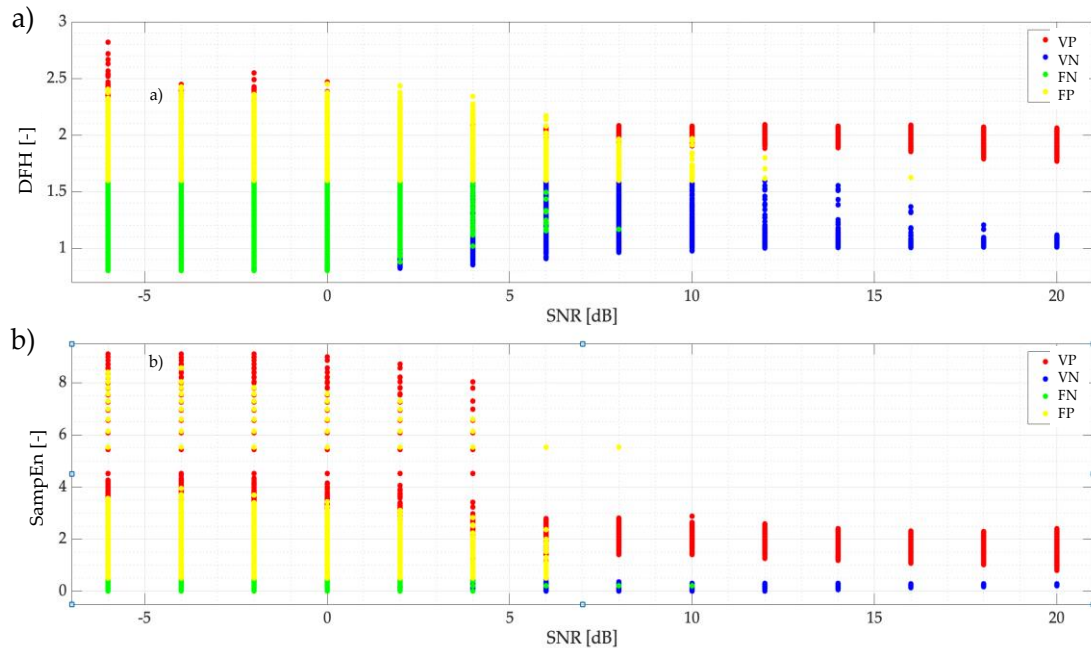


Figura 7.6. a) Clasificación de ventanas detectadas usando a) la DFH y b) la SampEn (umbral fijado en 0.38) como regla de decisión.

El parámetro, para evaluar la metodología propuesta, son las muestras en error, es decir; el número de muestras que existen entre el valor ideal del borde de frecuencia de la transmisión controlada y el punto detectado en el que el método propuesto ubica la transmisión del UP. En la **Figura 7.7** pueden apreciar las muestras en error para las pruebas simuladas (media y STD). Aquí el comportamiento tanto de la DFH como de la SampEn, con umbral $L_0 = 0.38$, es prácticamente el mismo: una excelente detección para valores de SNR superiores a 5 dB (menos de 10 muestras en error de media) y una muy buena detección para valores de SNR inferiores (de media, solo 20 muestras en error).




Figura 7.7. Muestras en error para el umbral propuesto para la SampEn. Los resultados se comparan con la DFH.

Resultados del escenario controlado

Los resultados, en términos de la PE y la SNR, de la implementación del entorno de comunicación inalámbrica controlada, se presentan en la **Figura 7.8**. Aquí se muestran los resultados promedio de la eficiencia del método para detectar los tres UP conectados, utilizando la DFH y la SampEn. El comportamiento que presentan ambas técnicas, para determinar correctamente la presencia de los UP en el intervalo espectral percibido, es prácticamente el mismo. Ambas técnicas tienen un excelente rendimiento para valores de SNR superiores a 0 dB, situándose en torno a 0.98 para la DFH y 0.99 para la SampEn. Para valores de la SNR inferiores a 0 dB, la DFH muestra un decaimiento abrupto. Por otro lado, SampEn mantiene muy buenos resultados, incluso en casos muy ruidosos.




Figura 7.8. Probabilidad de éxito en función de la SNR del entorno real controlado

En la **Figura 7.9**, se presentan también los resultados (media y STD) de las muestras en error para este escenario real considerando tres UP diferentes. Podemos observar que, en este caso, DFH supera ligeramente a SampEn. Sin embargo, el número de muestras en error es, en general, relativamente pequeño para ambas técnicas, mostrando un excelente rendimiento para localizar con precisión a los UP en un amplio espectro.




Figura 7.9. Muestras en error contra SNR para la implementación en tiempo real propuesta

Finalmente, se muestra un caso desafiante específico (es decir, una trama específica) para ambas técnicas, la DFH y la SampEn. En esta trama, hay un UP con una transmisión OFDM con un ancho de banda de 1 MHz (ver la **Figura 7.10a**). Esta trama analizada tiene un valor de $SNR = 0$ dB, lo que significa que la potencia de la señal es la misma que la del ruido. Como resultado de aplicar el algoritmo propuesto a este marco, la Ocupación se muestra en la **Figura 7.10a** como una señal continua que contiene los cambios de estado: ocupado y no ocupado. La **Figura 7.10b** muestra el número ordenado de ventanas en las que se segmenta el espectro y sus respectivos valores calculados con la metodología propuesta para ambas técnicas, SampEn y la DFH. El número de ventanas es el mismo para ambas técnicas porque utilizan el mismo detector de bordes para formar las diferentes ventanas de tamaño dinámico. En este ejemplo, ambas metodologías detectan al UP, sin embargo, también se detectan otros huecos de espectro por error. Por lo tanto, identificamos un problema importante: cuando la SNR desciende, se formará un número creciente de ventanas dinámicas. Esto significa que el algoritmo necesita procesar cada vez más ventanas haciendo ineficiente la metodología desde el punto de vista de recursos computacionales.




Figura 7.10. a) Ocupación de una trama espectral utilizando la DFH y la SampEn con una $SNR = 0$ dB. b) Valor calculado de la DFH y la SampEn para cada ventana detectada en el intervalo de espectro.

Capítulo 8. Monitorización cooperativa del espectro multibanda basada en mapas de entorno de radio y redes neuronales

En el capítulo anterior, la idea original planteada fue considerar una computadora integrando diferentes dispositivos SDR detectando cada UP en una sola banda, para monitorizar un amplio rango de frecuencias como se muestra en la **Figura 8.1a**. Esto puede verse como una única entidad que contiene diferentes US. Ahora, en este capítulo, se propone replicar esta entidad, que contiene diferentes dispositivos SDR conectados, para crear una red de CR cooperativa que detecte un amplio rango de frecuencias en una región geográfica más amplia. Cada entidad será considerada como un US que contiene diferentes tecnologías para percibir un amplio espectro, como se muestra en la **Figura 8.1b**. Además de monitorizar el espectro radioeléctrico y conocer el comportamiento de los UP en una determinada región geográfica, esta red cooperativa de CR tiene la tarea de evitar el problema de terminal oculta. Una de las principales fortalezas de esta nueva propuesta planteada en este Capítulo (ver la **Figura 8.1**) es la cooperación de los diferentes US para ubicar geográficamente los UP a través de los REM. Además se desea que todo el procesamiento en la red pueda realizarse en tiempo real.

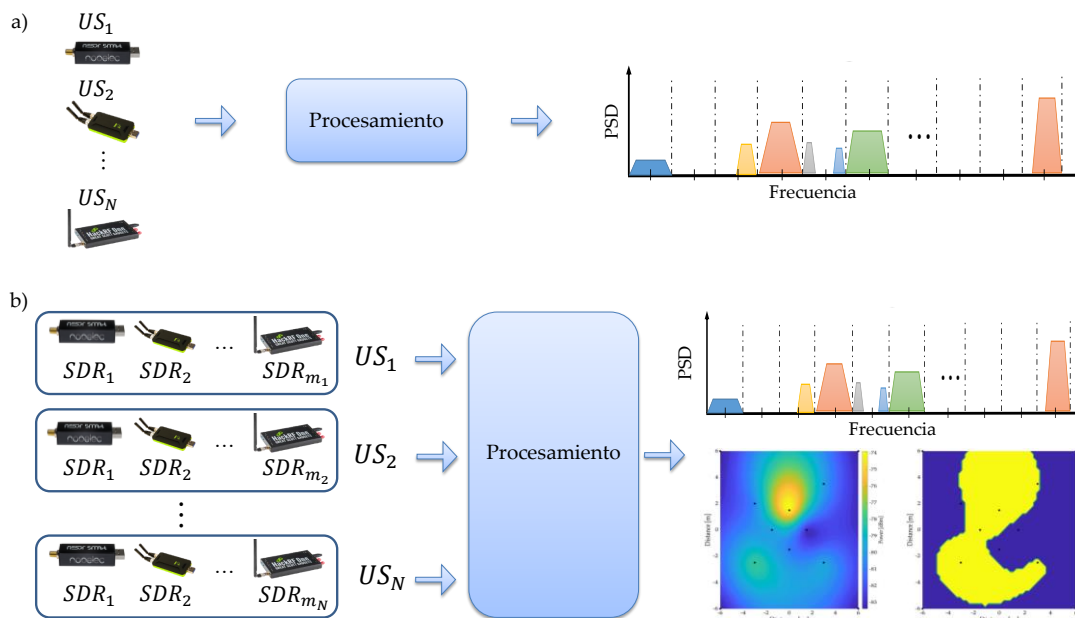


Figura 8.1. a) Propuesta del Capítulo 7. b) Nueva propuesta.

8.1. Metodología

En general, la metodología propuesta se puede agrupar en tres grandes bloques (como se esquematiza en la **Figura 8.2**):

- **La recopilación de información obtenida por cada US.** Para ello, cada US procesa localmente los datos percibidos para enviar a una entidad central, la ocupación del espectro observado en su ubicación geográfica incluyendo bordes de bandas de frecuencia y vectores de potencias estimadas.
- **La base de datos,** que almacena la información obtenida por cada US en un tiempo determinado.
- **La entidad central,** que supervisa y realiza el procesamiento para determinar el área geográfica que ocupan los UP detectados en el espectro radioeléctrico.

Cada bloque se describe en detalle a continuación.

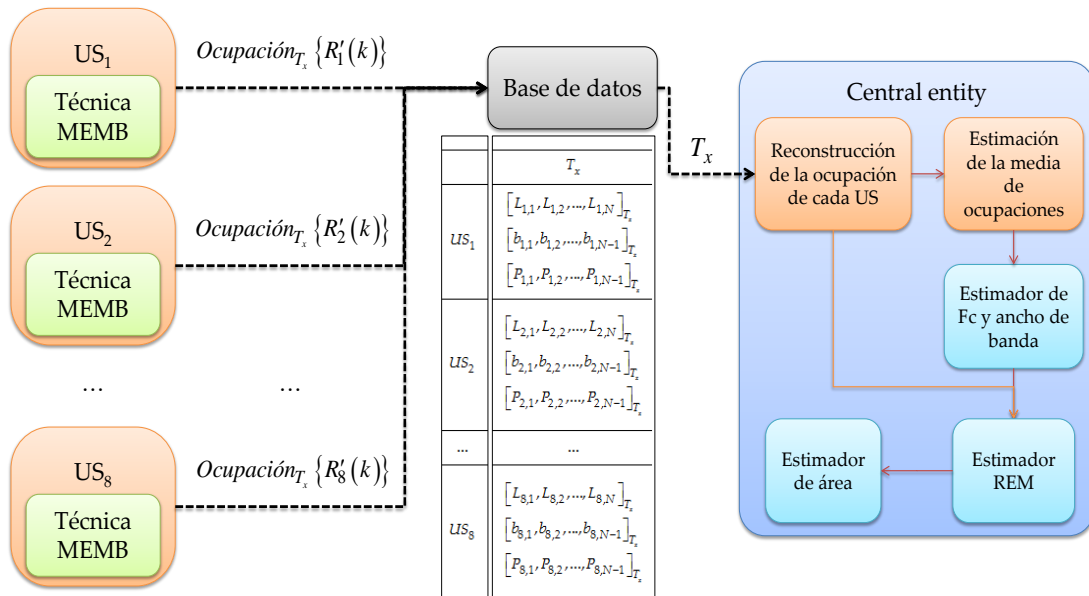


Figura 8.2. Esquema general de la metodología

Recopilación de información a nivel local por parte de los US

La recolección de información se realiza cada 100 ms por cada US, dando como resultado la $Ocupation_{T_x} \{R'_{i,l}(k)\}$ de cada señal espectral analizada,

como se mencionó anteriormente en la Sección 6.1. y se muestra en la **Figura 6.1**. Esta información está contenida en tres vectores:

- El vector detector de bordes $[L_{i,1}, L_{i,2}, \dots, L_{i,N}]_{T_i}$, que almacena los bordes de frecuencia donde es posible encontrar la presencia de los UP.
- El vector de decisión binaria $[b_{i,1}, b_{i,2}, \dots, b_{i,N-1}]_{T_i}$, que almacena una decisión binaria para las bandas delimitadas correspondientes donde se detecta ruido o una posible transmisión del UP
- El vector de potencia $[P_{i,1}, P_{i,2}, \dots, P_{i,N-1}]_{T_i}$, que almacena la potencia promedio recibida correspondiente a cada ventana clasificada, esto es, cada decisión binaria.

De esta forma, los vectores de decisión binaria y potencia tienen el mismo tamaño.

Base de datos

El detector de bordes, la decisión binaria y los vectores de potencia se almacenan en la base de datos. Es importante mencionar que la información almacenada en la base de datos proviene de cada US, no necesariamente es similar, es decir, la longitud de los vectores será diferente para cada US. De hecho, cada US observa un comportamiento diferente del espectro radioeléctrico debido a que se ubican aleatoriamente en diferentes coordenadas geográficas. Para contrarrestar esta situación, todos los vectores están etiquetados con el instante de detección exacto T_x (ver **Tabla 8.1**), es decir, están sincronizados. Toda esta información es subida a un servidor, permitiendo guardar en la base de datos solo la información relevante suficiente (tres vectores diferentes para cada US), haciendo que el almacenamiento y extracción de información sea lo más rápido posible y aprovechando que el *hardware* de cada US implementa localmente la técnica de MEMB. De hecho, los tres vectores cargados para cada US ocupan muy poco espacio de memoria. En el mejor de los casos (cuando ni siquiera hay un UP en el espectro detectado) el vector de detección de bordes tendrá una longitud de dos, mientras que el vector de decisión binario y el vector de potencia tendrán una longitud de uno. En el peor de los casos, cuando la SNR tiene un valor bajo (cercano a 0 dB) aparecerán múltiples ventanas debido al

ruido, aumentando así las longitudes de los vectores. Sin embargo, con estos 3 vectores, por muy grandes que sean, la información será compacta, facilitando la reconstrucción de la señal de ocupación del espectro que incluye la potencia media para cada ventana reconstruida.

Tabla 8.1. Información que cada US comparte en la base de datos en cada tiempo de detección T_x .

	T_1	T_2	...	T_x
US_1	$[L_{1,1}, L_{1,2}, \dots, L_{1,N}]_{T_1}$	$[L_{1,1}, L_{1,2}, \dots, L_{1,N}]_{T_2}$		$[L_{1,1}, L_{1,2}, \dots, L_{1,N}]_{T_x}$
	$[b_{1,1}, b_{1,2}, \dots, b_{1,N-1}]_{T_1}$	$[b_{1,1}, b_{1,2}, \dots, b_{1,N-1}]_{T_2}$...	$[b_{1,1}, b_{1,2}, \dots, b_{1,N-1}]_{T_x}$
	$[P_{1,1}, P_{1,2}, \dots, P_{1,N-1}]_{T_1}$	$[P_{1,1}, P_{1,2}, \dots, P_{1,N-1}]_{T_2}$		$[P_{1,1}, P_{1,2}, \dots, P_{1,N-1}]_{T_x}$
US_2	$[L_{2,1}, L_{2,2}, \dots, L_{2,N}]_{T_1}$	$[L_{2,1}, L_{2,2}, \dots, L_{2,N}]_{T_2}$		$[L_{2,1}, L_{2,2}, \dots, L_{2,N}]_{T_x}$
	$[b_{2,1}, b_{2,2}, \dots, b_{2,N-1}]_{T_1}$	$[b_{2,1}, b_{2,2}, \dots, b_{2,N-1}]_{T_2}$...	$[b_{2,1}, b_{2,2}, \dots, b_{2,N-1}]_{T_x}$
	$[P_{2,1}, P_{2,2}, \dots, P_{2,N-1}]_{T_1}$	$[P_{2,1}, P_{2,2}, \dots, P_{2,N-1}]_{T_2}$		$[P_{2,1}, P_{2,2}, \dots, P_{2,N-1}]_{T_x}$
...
US_8	$[L_{8,1}, L_{8,2}, \dots, L_{8,N}]_{T_1}$	$[L_{8,1}, L_{8,2}, \dots, L_{8,N}]_{T_2}$		$[L_{8,1}, L_{8,2}, \dots, L_{8,N}]_{T_x}$
	$[b_{8,1}, b_{8,2}, \dots, b_{8,N-1}]_{T_1}$	$[b_{8,1}, b_{8,2}, \dots, b_{8,N-1}]_{T_2}$...	$[b_{8,1}, b_{8,2}, \dots, b_{8,N-1}]_{T_x}$
	$[P_{8,1}, P_{8,2}, \dots, P_{8,N-1}]_{T_1}$	$[P_{8,1}, P_{8,2}, \dots, P_{8,N-1}]_{T_2}$		$[P_{8,1}, P_{8,2}, \dots, P_{8,N-1}]_{T_x}$

Entidad central

Las tareas principales de la entidad central son:

- Indicar cuántos UP aparecen en el espectro que están percibiendo los US.
- Construir un REM para cada UP detectado tomando como parámetros la ubicación de cada US, la potencia percibida en cada US y el tiempo en que se monitoreó el espacio radio eléctrico.
- Finalmente mostrar el área cubierta por lo UP.

Estas tareas se implementaron en dos formas diferentes. La primera, mediante procesamiento digital clásico y la segunda, utilizando técnicas de ML, en concreto NN). Ambas formas se detallan a continuación.

Entidad central basada en procesamiento clásico de señales

El procesamiento de señales digitales, que utiliza algoritmos programados para procesar y analizar datos, es una herramienta muy madura y estable que se ha utilizado durante décadas en una amplia variedad de aplicaciones. Es relativamente fácil de implementar y puede ser muy rápido y eficiente en situaciones donde el conjunto de datos y las tareas son específicos. En este caso, la entidad central se implementa considerando técnicas clásicas para la reconstrucción de la ocupación del espectro a partir de la información compartida (detector de bordes, decisión binaria y vectores de potencia) por cada US con la base de datos. La entidad central procesará la información como se muestra en la **Figura 8.2** y cuyos pasos se describen en el **Algoritmo 8.1**.

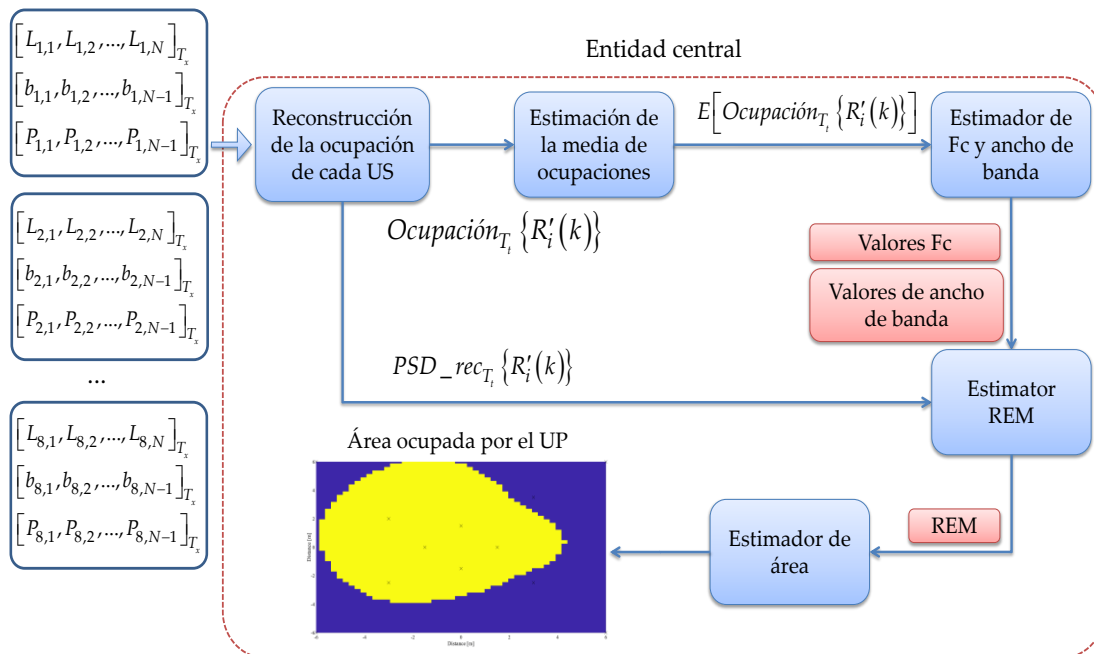


Figura 8.3 Implementación de la entidad central utilizando procesamiento de señal digital clásico

Algoritmo 8.1. Entidad central funcionando con procesamiento de señales tradicional

- Paso 1. La entidad central recopila de la base de datos la información asociada a los bordes detectados, la decisión binaria y los vectores de potencia de cada UP en un instante de tiempo determinado T_x . Con esta información, la entidad central reconstruye la señal de ocupación $Occupation_{T_i} \{R'_i(k)\}$ y construye simultáneamente, una aproximación de la PSD $PSD_rec_{T_i} \{R'_i(k)\}$ utilizando únicamente las potencias medias (vector de potencia) asociadas a cada US. La longitud de las tramas se establece en 1024 muestras.
- Paso 2. Una vez realizada la reconstrucción de la ocupación de cada US, se calcula el valor medio $E[Occupation_{T_i} \{R'_i(k)\}]$.
- Paso 3. Luego de procesar el valor medio de la Ocupación, es posible inferir la presencia de uno o varios UP, dando dos posibles vectores. Primero, el vector $F_{C_vector} = [F_{C1}, F_{C2}, \dots]$ que contiene los valores de las frecuencias centrales de las UP detectadas. La longitud de este vector será el número de UP detectadas por el algoritmo. También se obtiene un segundo vector $B_{vector} = [B_{PU_1}, B_{PU_2}, \dots]$ que contiene los anchos de banda ocupados por cada UP detectado. A través del número de singularidades y sus correspondientes anchos detectados en $E[Occupation_{T_i} \{R'_i(k)\}]$, es posible estimar cuántos UP hay en el espectro y sus respectivos anchos de banda ($B_{vector} = [B_{PU_1}, B_{PU_2}, \dots]$).
- Paso 4. Conociendo la frecuencia central y el ancho de banda correspondiente de cada UP detectado, es posible ubicarlos en cada PSD reconstruida $PSD_rec_{T_i} \{R'_i(k)\}$. La media del intervalo B_{PU_N} centrado en F_{C_N} de la $PSD_rec_{T_i} \{R'_i(k)\}$ retorna el escalar $aux_psd_{i,N}$. En sentido estricto, este escalar representa la potencia promedio en la portadora, monitorizada por cada US, donde el PU_N está o debería estar.
- Paso 5. Con el escalar $aux_psd_{i,N}$ de cada US ubicado en una coordenada específica, se construirá el REM mediante una doble interpolación. La primera interpolación se realiza a través del método IDW y para
-

Algoritmo 8.1. Entidad central funcionando con procesamiento de señales tradicional

la segunda se aplica el método Kriging. Debido a que en nuestro caso solo se consideran ocho puntos geográficos (es decir, solo se implementan ocho US), esta doble interpolación se realiza con el fin de tener una mayor precisión para describir el comportamiento del espacio radioeléctrico en el entorno (descrito más adelante). En este caso, cada REM se construye con los valores $aux_psd_{i,N}$ que corresponden específicamente a la potencia media del ancho de banda B_{PU_N} .

Paso 6. Finalmente, se determinará el *área activa* de cada UP de acuerdo a la información recopilada por cada entidad secundaria. Para ello se utiliza un umbral de -80 dBm para clasificar el área estimada por los REM que se eligió en [11] para un entorno inalámbrico. Es decir, las regiones del REM que están por encima de este umbral corresponden al *área activa* de los UP detectados.

Entidad central basada en redes neuronales

En este apartado se implementa la entidad central considerando técnicas de ML, en concreto NN. Las NN tienen la capacidad de aprender de los datos y mejorar su desempeño a medida que se les presenta más información. Esto las hace particularmente útiles en aplicaciones donde los datos son complejos o difíciles de entender y procesar usando métodos tradicionales. Además, las NN pueden realizar tareas que los métodos tradicionales no pueden, como reconocer patrones en datos no estructurados o procesar señales de entrada que cambian con el tiempo. En este caso, algunos módulos en la entidad central son reemplazados por NN como se muestra en la **Figura 8.4**. Los pasos de su operación (**Algoritmo 8.2**) se describen a continuación.

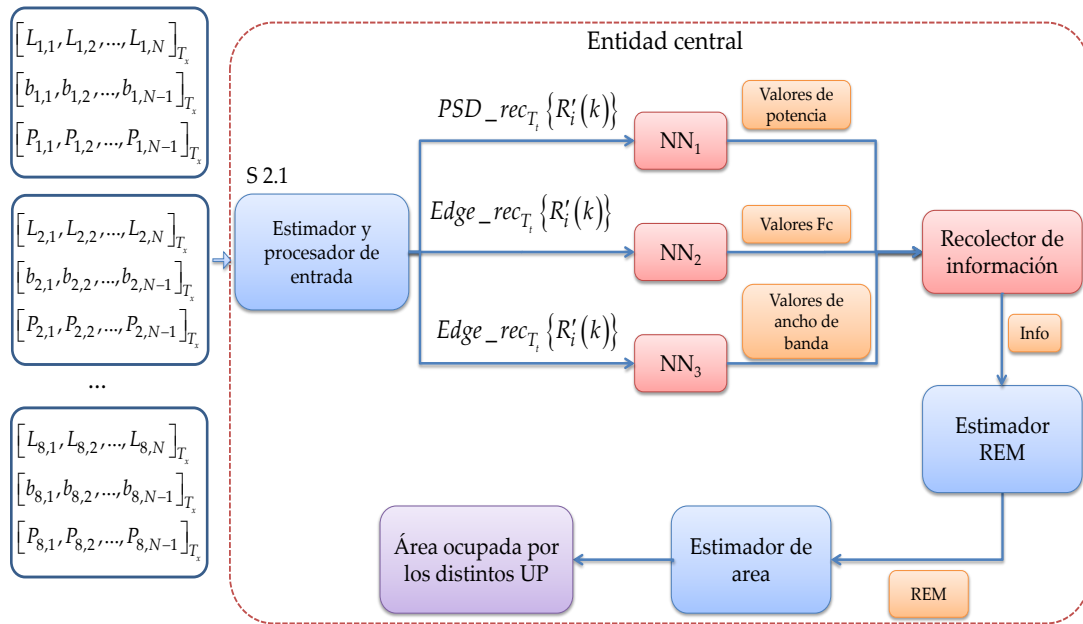


Figura 8.4. Entidad central que determina los parámetros para la construcción de REM y mapas de área a través de NN

Algoritmo 8.2. Entidad central funcionando con redes neuronales.

Paso 1. La entidad central recolecta los datos de cada uno de los US de la base de datos en un momento específico T_x . En el módulo *estimador y procesador de entradas* se realiza un procesamiento para estimar las entradas que impulsan al conjunto de NN. Como se mencionó anteriormente, los tres vectores que provienen de cada US para el tiempo T_x no tienen la misma longitud que los vectores para el tiempo T_{x+t_1} o T_{x-t_2} . Incluso, el tamaño de los vectores difiere de un US a otro US aunque sean al mismo tiempo T_x . Basado en este hecho, este módulo supervisa la construcción de los vectores de entrada $PSD_rec_{T_i} \{R'_i(k)\}$ y $Edge_rec_{T_i} \{R'_i(k)\}$ para las NN. Para ello, estos vectores deben tener siempre la misma longitud (en nuestro caso esta longitud se establece en 13 muestras). Este bloque se detalla a continuación.

Paso 2. El vector $PSD_rec_{T_i} \{R'_i(k)\}$ es evaluado por NN_1 , al mismo tiempo el vector $Edge_rec_{T_i} \{R'_i(k)\}$ es evaluado por NN_2 y por NN_3 . Esta evaluación se realiza secuencialmente, es decir, cada vector de cada US será evaluado por su correspondiente NN uno tras otro hasta

Algoritmo 8.2. Entidad central funcionando con redes neuronales.

obtener el resultado del i -ésimo US conectado. Como resultado de este paso, NN_1 proporciona un número aproximado de UP detectados y sus potencias. NN_2 da un número aproximado de UP detectados y sus frecuencias centrales. Finalmente, NN_3 devuelve un número aproximado de UP detectadas y sus anchos de banda. Al final de esta sección, se discute qué sucedería si el número de UP detectadas por cada NN no es el mismo.

Paso 3. La información obtenida del Paso 2 se evalúa para determinar el número de UP en el espectro y su correspondiente potencia, ancho de banda y frecuencia portadora. Esta evaluación se detalla a continuación.

Paso 4. La información obtenida del Paso 3 será compartida con el módulo estimador REM. Este bloque recibe (i) las coordenadas geográficas de los US en la red, (ii) los datos de los posibles UP en el espectro (potencia, portadora y ancho de banda) y (iii) un identificador que corresponde al tiempo T_x en que el espectro fue monitoreado.

El resto de pasos de este algoritmo que incluye NN corresponden a los Pasos 5 y 6 de la metodología mencionada en el **Algoritmo 8.1**. Más adelante, se describen en detalle los módulos *estimador y procesador de entrada* (Paso 1 del **Algoritmo 8.2**) y *recolector de información* (Paso 3 del **Algoritmo 8.2**).

La **Figura 8.5** muestra el proceso para generar $PSD_rec_T \{R'_i(k)\}$, el vector de entrada de NN_1 . Para ello, en primer lugar se utilizan los vectores de potencia, detector de borde y de decisión binaria. Estos vectores oscilan en los intervalos de [1-20], [1-20] y [2-21] muestras respectivamente, según los estudios realizados en el trabajo [13]. A través de estos vectores, como se mencionó al inicio de esta sección, se conoce (i) el rango de frecuencias que fue percibido por cada US, (ii) el número de muestras de la PSD estimada y (iii) el número de ventanas en las que se dividió el espectro detectado. Para cada ventana detectada se asigna un valor de ocupación, siendo 1 para una posible transmisión del UP o 0 para el ruido. Acompañando a cada valor de ocupación hay un valor de potencia promedio (elemento de vector de potencia) que es la estimación de potencia en cada ventana detectada. De esta forma se reconstruye la señal de ocupación y potencia con estos valores medios de cada ventana detectada, fijando ambos vectores a una longitud de 1024 muestras cada uno.

Después de eso, los vectores reconstruidos de potencia y ocupación se multiplican columna por columna, lo que da como resultado el vector *Power_Occupation* de 1024 muestras también. En este último vector, los lugares donde se estime ruido tendrán valor 0 y, donde exista una posible transmisión de uno o varios UP, tendrán un valor correspondiente a la potencia media de las ventanas detectadas. Se realiza una reducción del muestreo del vector *Power_Occupation* para mantener solo 10 muestras de este. Este vector submuestreado es finalmente concatenado con las coordenadas de los US (a las que corresponden los vectores analizados) y el tiempo T_x en que se monitorizó la señal $Ocupación_{T_i} \{R'_{i,l}(k)\}$, integrando de esta forma el vector de entrada para NN_1 . Es importante mencionar que el parámetro de tiempo es sumamente importante ya que el espectro se comporta de manera diferente en el tiempo.

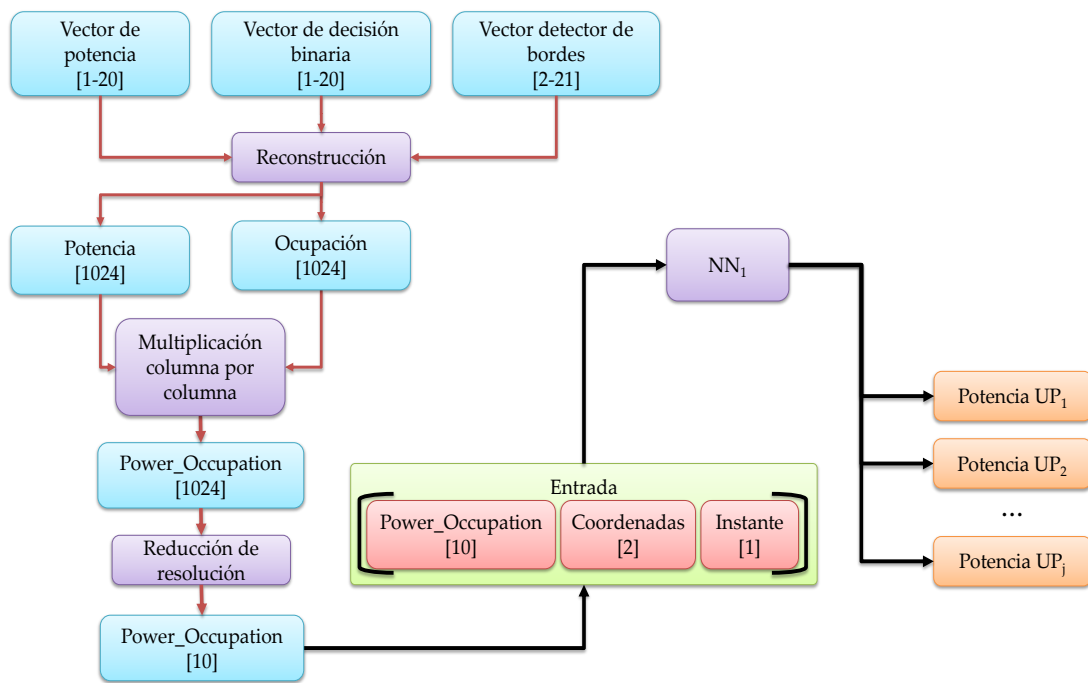


Figura 8.5. Construcción del vector $PSD_rec_{T_i} \{R'_i(k)\}$

La **Figura 8.6** muestra el proceso de construcción del vector $Edge_rec_{T_i} \{R'_i(k)\}$. Aquí se reconstruye el vector de ocupación y el vector de bandas de frecuencia correspondientes al intervalo de frecuencia que es percibido por el US correspondiente. Este vector también se multiplica columna a columna con el vector de ocupación, resultando en el vector

$Freq_Occupation$ de 1024 muestras de longitud. De esta forma, este último vector contiene ceros donde corresponde a ruido y tiene valores distintos de cero en las muestras que corresponden a una o varias transmisiones de los UP. Nuevamente, también se aplica un sub muestreo para reducir este vector a solo 10 muestras y se concatena con las coordenadas de los US y el tiempo T_x correspondiente al período de detección. Esta concatenación impulsa la entrada de las redes neuronales NN_2 y NN_3 .

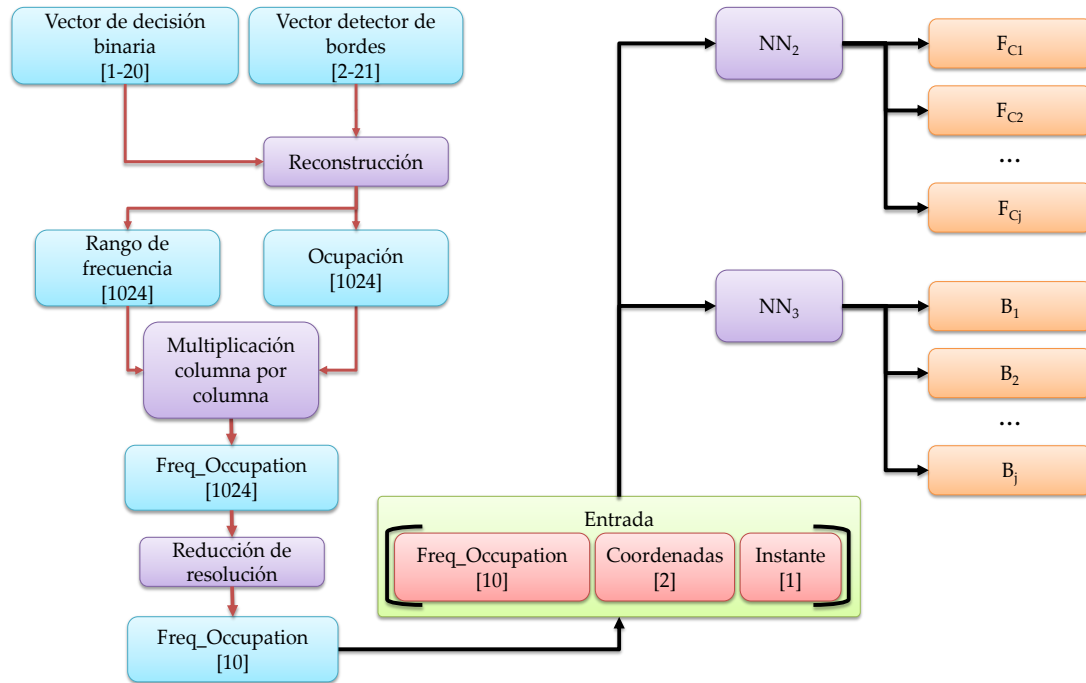


Figura 8.6. Construcción del vector $Edge_rec_T \{R'_i(k)\}$

La salida de NN_1 corresponde a la potencia de cada UP detectado por cada US. En este caso, si el valor de la potencia de la UP es inferior a -80 dBm, entonces se interpreta que no hay transmisión y corresponde a ruido. La salida de NN_2 resulta en la portadora en el que se ha localizado una posible transmisión de UP. Finalmente, la salida de NN_3 entrega los anchos de banda de transmisión correspondientes a cada UP detectada en el espectro analizado.

Las salidas resultantes de las NN, para cada US, se muestran en la **Figura 8.7**. Estas salidas se pueden clasificar en tres grandes grupos: potencias, frecuencias portadoras y anchos de banda de transmisión de cada UP

detectado por el US correspondiente. El bloque *recolector de información* se encarga de analizar la salida de cada US que integra la red y enviarla al módulo que permite estimar el REM. Por ejemplo, en la **Figura 8.7a** se muestra que la potencia de PU_1 es menor a -80 dBm, en este caso el *recolector de información* interpreta que PU_1 no corresponde a una transmisión y al compartir la información entregada por SU_1 con el estimador de REM, asume que SU_1 observa $(j-1)$ UP (donde j representa el número de posibles transmisiones de los UP). La **Figura 8.7b** muestra que la frecuencia portadora de PU_1 y PU_j están fuera del espacio que se está monitoreando. Entonces, el *recolector de información* comparte con el estimador REM que SU_2 solo observa $(j-2)$ UP. En la **Figura 8.7c** se muestra que B de PU_1 es un valor muy pequeño (esto podría corresponder a un ruido impulsivo). Luego, el *recolector de información* comparte con el módulo *estimador REM* que SU_n observa a los $(j-1)$ UP. Es importante mencionar que cualquiera de estas combinaciones mostradas en la **Figura 8.7**, cambiará el número de UP observados, es decir, si la potencia de un primer UP no supera el umbral de -80 dBm y la portadora de un segundo UP no está en un rango de frecuencia correcta y el B de un tercer UP tiende a cero, entonces estos 3 UP serán considerados como ruido.

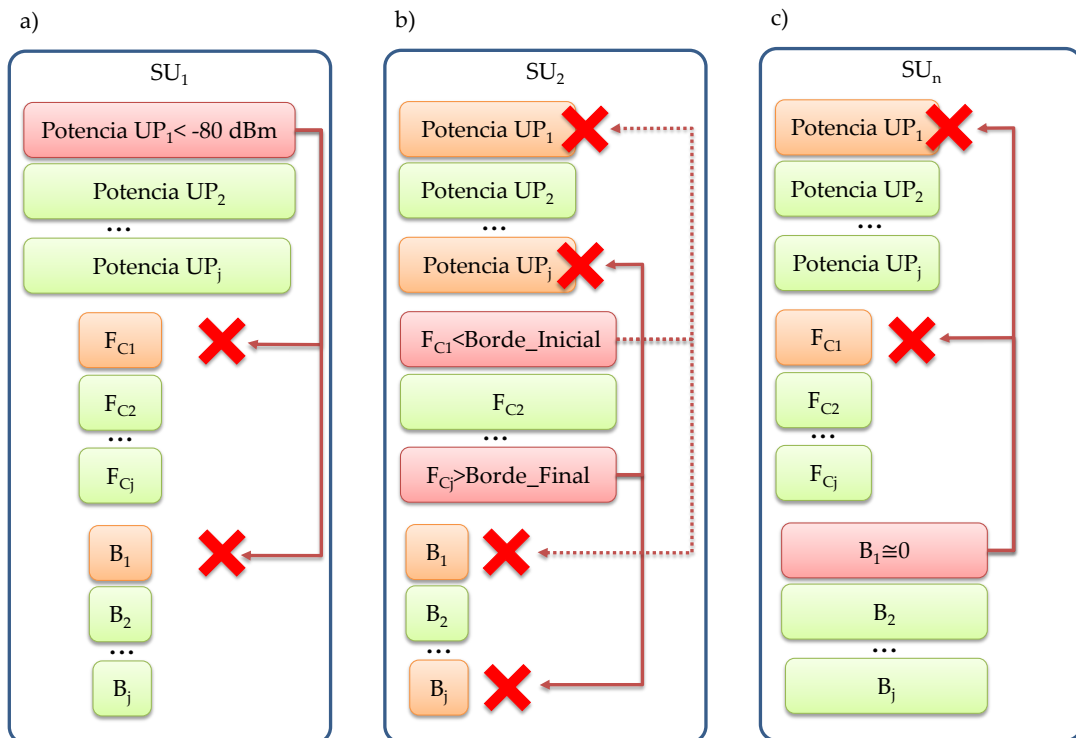


Figura 8.7. a) US_1 observa j UP, pero UP_1 se descarta porque no alcanza el umbral. b) US_2 observa j UP, sin embargo, UP_1 y UP_j se descartan porque no están en el rango de frecuencia correcto. c) US_n observa j US, UP_1 se descartan por no tener un ancho de banda lo suficientemente grande para ser considerada como transmisión.

La propuesta de metodología ha sido implementada en un entorno real de comunicaciones inalámbricas. Este entorno controlado se explica en la siguiente sección.

8.2. Entorno real de comunicación inalámbrica

La **Figura 8.8** muestra el ambiente controlado real implementado en este trabajo de investigación. En este escenario propuesto, consideramos dos UP ubicadas en el centro del área de estudio y, al mismo tiempo, ocho US están detectando el comportamiento de estos UP en su zona geográfica de influencia. Es importante mencionar que los US y los UP no están compartiendo información sobre coordenadas geográficas entre ellas. Sin embargo la entidad central conoce las coordenadas geográficas de las entidades secundarias. Los UP están ubicados en el centro buscando que la mayoría de los US puedan recibir parte de su señal. Los US se establecieron aleatoriamente en el área de estudio.

La **Tabla 8.2** especifica los parámetros involucrados tanto para los US como para los UP. Estos US comparten la ocupación del canal con la base de datos y la entidad central para determinar: (i) cuántos UP en promedio se observan en este entorno, (ii) el B y la F_C en los que se ubican los UP detectados, y (iii) finalmente el área que está ocupada por estos UP detectados. Los UP y los US están desplegadas en un área de 12×12 m². En esta zona existen estructuras como muros, puertas, ventanas, columnas, etc., como se indica en la **Figura 8.8**.

Tabla 8.2. Principales parámetros de los UP y US.

Etiqueta	Dispositivo	F_C del Tx [MHz]	F_C del Rx [MHz]	Ancho de banda [MHz]	Coordenada (X,Y) [m]
UP ₁	Mini LimeSDR	699.5	-	0.5	(0, 0)
UP ₂	HackRF ONE	700.5	-	1	(0, 0)
US ₁	RTL-SDR	-	700	2.4	(-1.5, 0)
US ₂	RTL-SDR	-	700	2.4	(0, 1.5)
US ₃	RTL-SDR	-	700	2.4	(1.5, 0)
US ₄	RTL-SDR	-	700	2.4	(0, -1.5)
US ₅	RTL-SDR	-	700	2.4	(-3, 2)
US ₆	RTL-SDR	-	700	2.4	(3, 3.5)
US ₇	RTL-SDR	-	700	2.4	(3, -2.5)
US ₈	RTL-SDR	-	700	2.4	(-3, -2.5)




Figura 8.8. El escenario real implementado

8.3. Resultados

En esta sección se muestran los resultados de implementar la metodología propuesta bajo un entorno real de comunicación inalámbrica. Se dividieron en dos subsecciones, la primera corresponde a la entidad central basada en procesamiento digital de señales y la segunda es a la entidad central basada en NNs.

Resultados con una entidad central basada en procesamiento digital de señales

En esta sección se muestran los resultados obtenidos por el escenario implementado presentado en la **Figura 8.8**. La **Figura 8.9** muestra la reconstrucción de la ocupación de cada US por parte de la entidad central. En este caso, podemos destacar los siguientes puntos importantes:

- Hay US que no logran percibir ambos UP.
- El tamaño del ancho de banda B para cada UP varía para cada US.
- Dado el punto anterior, la frecuencia central F_C de cada UP es percibida a diferente frecuencia por cada US.
- Los US que están más alejadas de los UP no detectan ambas UP.




Figura 8.9. Ocupación de espectro para cada US

La **Figura 8.10** muestra el resultado de construir una aproximación de la PSD para cada US considerando únicamente valores medios de potencia para cada tramo del espectro. Estas aproximaciones se utilizarán para la estimación del REM.




Figura 8.10. PSD aproximada para cada US

La **Figura 8.11** muestra el resultado de aplicar el módulo que estima la ocupación promedio de cada US. Además, en esta figura aparece el resultado de la estimación de la F_C y B de cada UP. En este caso, el primer valor obtenido fue $F_{C1} = 699.48$ MHz con un ancho de banda de $B_1 = 0.4$ MHz. Asimismo, se obtuvo $F_{C2} = 700.49$ MHz con ancho de banda de $B_2 = 0.825$ MHz. Dado que el valor exacto para $F_{C1} = 699.5$ MHz, $B_1 = 0.5$ MHz, $F_{C2} = 700.5$ MHz y $B_2 = 1$ MHz. Los valores obtenidos muestran una buena estimación de la ocupación por el método de MEMB en conjunto con la entidad central para una determinada zona geográfica cubierta por los UP.




Figura 8.11. Media de la ocupación obtenida por la entidad central

La **Figura 8.12a** y la **Figura 8.13a** muestran el REM de UP_1 y UP_2 respectivamente. Este mapa se elabora a partir de la información recopilada por los US en sus distintas localidades. La **Figura 8.12b** y la **Figura 8.13b** muestran las respectivas áreas ocupadas por UP_1 y UP_2 . Los valores del área ocupada para cada UP son $\text{área}_{UP_1} = 60.76 \text{ m}^2$ y $\text{área}_{UP_2} = 56.39 \text{ m}^2$. Este resultado se obtiene colocando un umbral $L = -80 \text{ dBm}$ en el REM obtenido. De esta forma, la zona que tiene una potencia superior a este umbral es considerada como espacio ocupado por el UP.

La **Figura 8.12b** muestra que US_6 y US_8 no observan la transmisión del UP_1 (es decir, ambos US_6 y US_8 no aparecen en esta área de influencia). Este efecto se produce debido a la distribución estructural en la que se realizó la implementación del escenario real. No obstante, una esperada colaboración entre US podría mejorar este resultado.

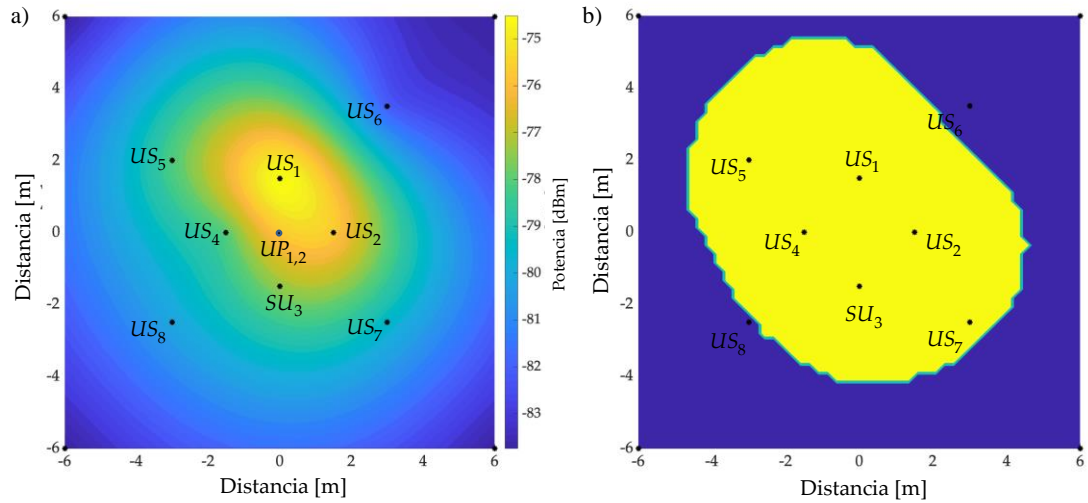


Figura 8.12. Transmisión primaria en la banda de 699.48 MHz con un B de 0.4 MHz. a) REM, b) Superficie ocupada.

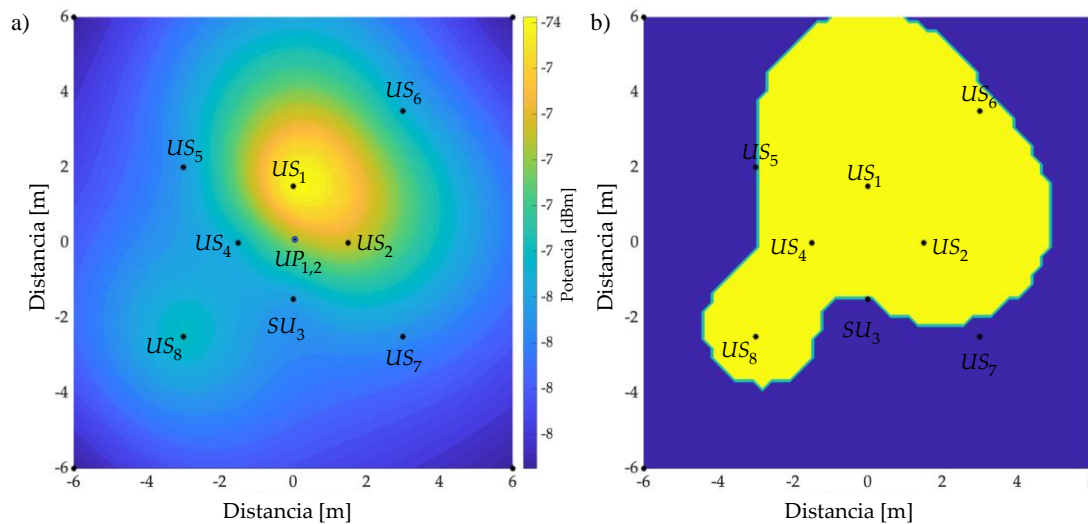


Figura 8.13. Transmisión primaria en la banda de 700.49 MHz con un B de 0.825 MHz. a) REM, b) Superficie ocupada.

Resultados con una entidad central basada en NN

Esta sección presenta en detalle los resultados del uso de una entidad central que está constituida por tres NN. Primero se presentarán los detalles del entrenamiento de las NN y luego se mostrarán los resultados obtenidos al aplicar los algoritmos de ML a esta etapa.

Entrenamiento

Para la etapa de entrenamiento de NN_1 , NN_2 y NN_3 , se utilizó el algoritmo *backpropagation*, la función de activación de Levenberg-Marquardt [120], 1000 épocas, el error cuadrático medio como función de pérdida y, una tasa baja de aprendizaje. Además, se utilizaron 9000 vectores de entradas y sus correspondientes salidas. Es común preguntarse, ¿cuál es la mejor NN?, ¿cuántas capas se deben usar?, ¿o cuántas neuronas? Para responder a estas preguntas se estudiaron 12 NN para realizar el trabajo de NN_1 , 12 NN para realizar el trabajo de NN_2 y 12 NN para realizar el trabajo de NN_3 . Para ello, cada NN se considera con el número de capas $ca = 1, 2, 3, 4$ y con el número de neuronas $ne = 16, 32, 64$. Habrá para cada NN 12 combinaciones posibles entre neuronas y capas. Este procedimiento se realizó para saber cuál es la configuración de NN más conveniente para este trabajo.

Debido a estas configuraciones, se presentan los resultados obtenidos tanto para la entidad que utiliza procesamiento digital de señales como para la que utiliza las tres NN. Como primer parámetro se mencionará el tiempo de entrenamiento utilizado por cada NN. La **Tabla 8.3** muestra el tiempo empleado por cada NN para la etapa de formación. Además, en la **Figura 8.14** se puede observar que cuantas más neuronas y/o capas tenga una NN, el tiempo de entrenamiento será mayor. Todo el procesamiento se realizó con la misma computadora (MacBook Pro con 8 GB de RAM y procesador M1 de 1ra generación), el tiempo de entrenamiento para cada NN en sus diferentes versiones tiende a tener un comportamiento muy similar.

Tabla 8.3. Tiempo de entrenamiento de a) NN_1 ; b) NN_2 ; c) NN_3 .

Tiempo de entrenamiento de NN_1 [min]				Tiempo de entrenamiento de NN_2 [min]				Tiempo de entrenamiento de NN_3 [min]						
a)		Neuronas			b)		Neuronas			c)		Neuronas		
		16	32	64			16	32	64			16	32	64
Capas	1	2	10	60	Capas	1	2	6	16	Capas	1	2	5	16
	2	10	25	180		2	8	33	290		2	5	19	280
	3	120	192	1500		3	15	80	850		3	11	75	875
	4	162	600	3984		4	20	129	7610		4	21	145	3628




Figura 8.14. Tiempo de entrenamiento para las diferentes versiones de la NN_3

Los resultados estadísticos de ambas propuestas se mencionan a continuación.

Estadísticas

En esta sección se analizan los resultados estadísticos de las tres NN utilizadas en esta propuesta. Para obtener estos resultados se consideraron 27000 entradas por cada NN. La **Figura 8.15a** muestra los resultados de NN_1 , que supervisa otorgar el valor de potencia de los UP detectados. Esta figura muestra la diferencia de potencia entre los valores reales y los obtenidos con la NN_1 en sus diferentes versiones. La diferencia entre el valor real esperado y el obtenido por la NN_1 , en promedio, es de -0.01 dBm, esto para cada versión de NN_1 , lo que resalta la precisión de la potencia pronosticada con el enfoque basado en NN. En la **Figura 8.15b** solo se muestra el valor medio, indicando que el margen de error entre el valor esperado y el dado por las distintas NN es muy cercano, prácticamente el mismo.

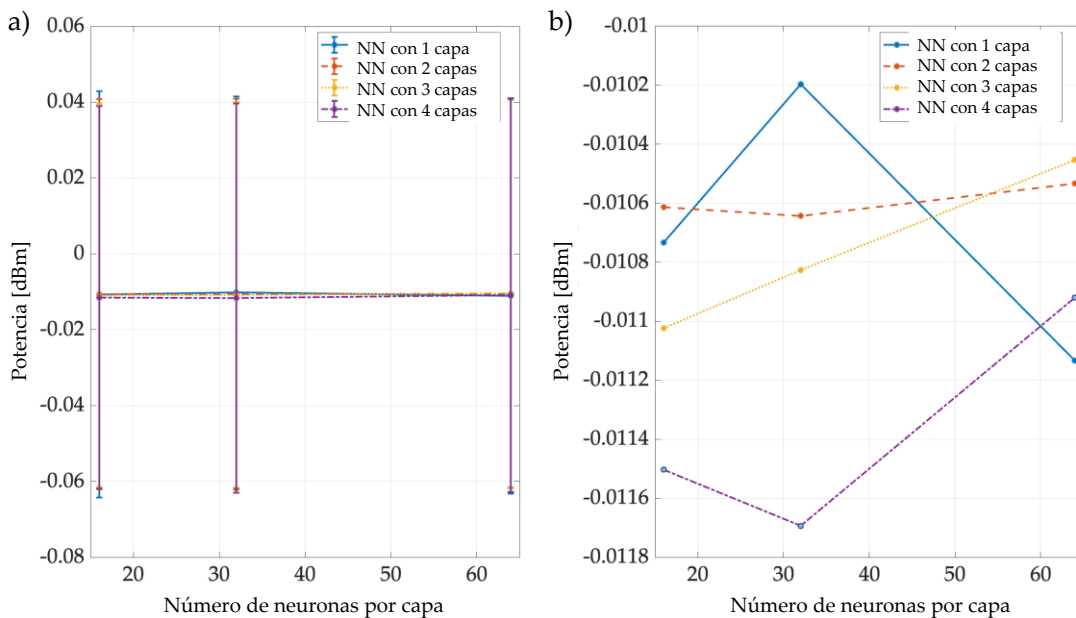


Figura 8.15. Diferencia entre los valores reales y los obtenidos por la NN_1 a) media y STD, b) media.

La **Figura 8.16** muestra el resultado de NN_2 , que es la red que da el valor de portadora de cada UP detectado. Debido al entorno propuesto, la NN_2 detectó dos UP. La precisión para detectar la portadora de cada uno de ellos se muestra en dicha imagen, donde en promedio F_{C1} es de 699.4 MHz, independientemente de la configuración de la NN_2 (ver la **Figura 8.16a**). La **Figura 8.16b** muestra la precisión de la NN_2 para detectar la portadora del

UP_2 . Aquí se observa que en promedio la portadora es de 700.494 MHz y aunque la red con 2 capas y 64 neuronas por capa se desvía levemente del valor ideal (700.5 MHz) en comparación con las demás configuraciones de la NN, sigue brindando un resultado razonablemente preciso. En ambas imágenes, el valor de aplicar procesamiento de señal digital se puede ver en azul, que está bastante cerca del valor ideal, 699.4934 MHz y 700.4935 MHz para el UP_1 y el UP_2 respectivamente, lo que da como resultado un nivel de precisión comparable al del sistema basado en NN.

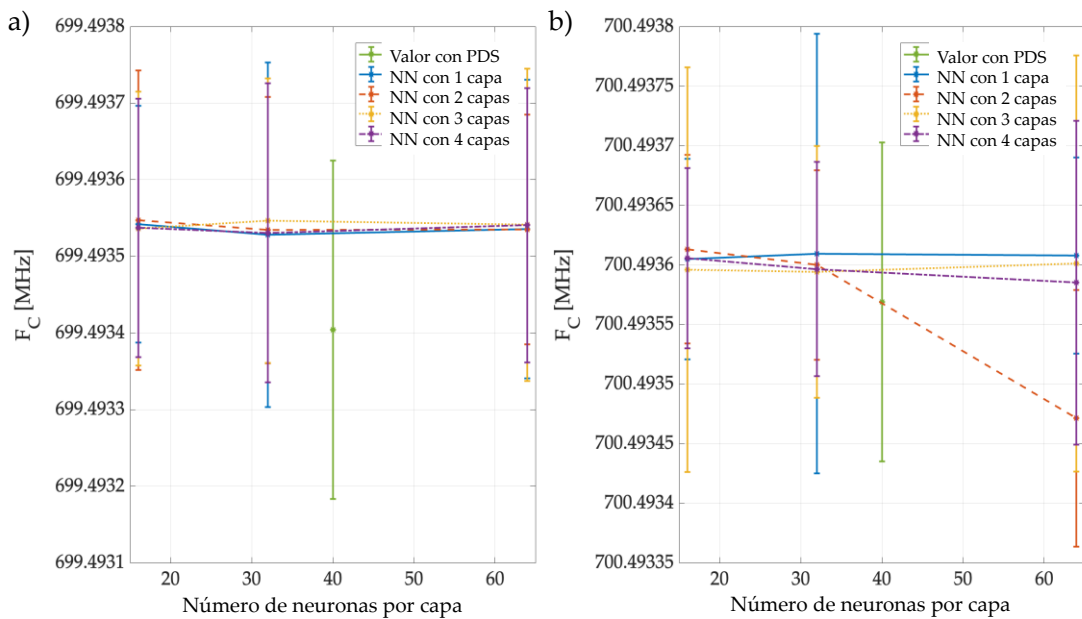


Figura 8.16. Media y STD de la precisión para detectar a) la portadora del UP_1 de las distintas variantes de la NN_2 . b) la portadora del UP_2 de las diferentes redes.

La **Figura 8.17** muestra los resultados de la NN_3 , que es la red encargada de mostrar los B de cada UP detectado en las tramas del espectro percibido. En esta figura, el promedio de B es de 0.48 MHz, independientemente de la configuración de la red (ver la **Figura 8.17a**). Además, la **Figura 8.17b** muestra que a pesar de la estructura de la NN, el valor de B para el UP_2 es prácticamente de 1 MHz, lo que coincide perfectamente con el valor ideal (ver **Tabla 8.2**). Esta imagen también muestra mediante un punto azul el resultado del uso del procesamiento de señales digitales. Dando un resultado de $B_1 = 0.425$ MHz y $B_2 = 0.824$ MHz. Para B_1 el nivel de error/precisión de DSP y NN es bastante similar (solo que DSP sobreestima mientras que NN

subestima) mientras que para B_2 parece que la NN es mucho más precisa, por lo que podría indicarse que el método basado en la NN tiende a mejorar DSP o, en el peor de los casos, proporciona un error absoluto comparable.

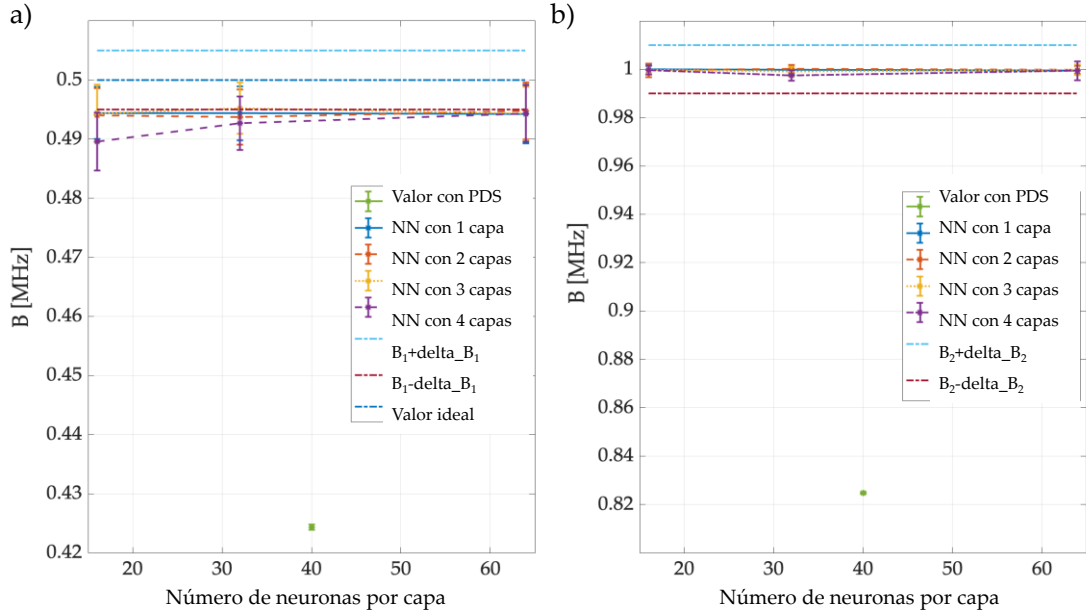


Figura 8.17. Media y STD de la precisión para detectar a) el B_1 de las distintas variantes. b) el B_2 de las diferentes redes.

En este caso, para medir la precisión de esta metodología se utilizará el F1-score ($F1$) [121], el cual es una métrica de evaluación comúnmente utilizada en el campo del ML para evaluar la precisión de un modelo de clasificación binaria. Esta métrica combina la precisión y la recuperación del modelo en una sola medida (*recall*).

La precisión se refiere a la proporción de VP sobre la suma de los VP con los FP,

$$precisión = \frac{VP}{VP + FP} \quad (8.1)$$

mientras que la *recall*, por otro lado, se refiere a la proporción de VP sobre la suma de los VP con los FN.).

$$recall = \frac{VP}{VP + FN} \quad (8.2)$$

El valor de $F1$ es la media armónica de precisión y completitud, lo que significa que da más peso a los valores bajos. La fórmula es la siguiente:

$$F1 = 2 \frac{(\text{precisión} * \text{recall})}{(\text{precisión} + \text{recall})} \quad (8.3)$$

Un valor de $F1$ igual a 1 indica que la precisión y la sensibilidad son perfectas, mientras que un valor de $F1$ de 0 indica que el modelo no puede clasificar correctamente ninguna de las muestras. $F1$ es una métrica valiosa para comparar diferentes modelos de clasificación binaria y seleccionar el mejor modelo para una tarea de clasificación determinada. Para determinar este parámetro (es decir, $F1$), se consideran los siguientes cuatro casos posibles (ver la **Figura 8.18**):

1. Una ventana que corresponde a una transmisión del UP y que el US clasifica como transmisión del UP es un valor VP.
2. Una ventana de frecuencia que corresponde a una transmisión del UP y que el US clasifica como ruido es un valor FN.
3. Una ventana que corresponde a ruido y que el US clasifica como transmisión del UP es un valor FP.
4. Una ventana de frecuencia que corresponde al ruido y que el US clasifica como ruido es un valor VN.

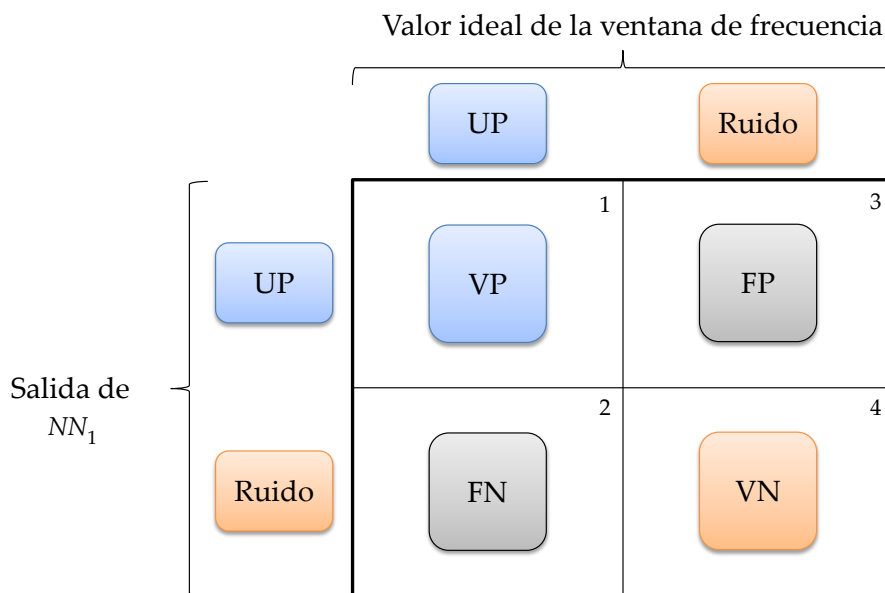


Figura 8.18. Salidas de evaluación de ventanas detectadas

En la **Figura 8.19** se muestra el $F1$ de la NN_1 , que indica si los UP se ubicaron correctamente. En esta imagen, todos las NN tienen un rendimiento casi perfecto en torno a 0.98.




Figura 8.19. F1 score de la NN_1

En el caso de B , se estimó $F1$ a partir de los siguientes casos (ver la **Figura 8.20**):

- El resultado de NN_3 tal que B coincida con el ancho de banda ideal que corresponde a una transmisión será un caso verdadero positivo (VP).
- El resultado de NN_3 tal que B corresponda a un ancho de banda ideal cercano a cero será un caso verdadero negativo (VN).
- El resultado de NN_3 tal que B es mucho mayor que un ancho de banda ideal cercano a cero será un caso de falso positivo (FP).
- El resultado de NN_3 tal que B sea un valor cercano a cero pero que debería corresponder a una transmisión ideal será un caso de falso negativo (FN).

La **Figura 8.20** muestra un valor, que es la diferencia entre el ancho de banda real y el estimado, cuando existe un UP. Cuando este parámetro tiende a crecer, proporciona flexibilidad para que el resultado coincida con un ideal que corresponde a una transmisión. Sin embargo, cuando el valor de es muy pequeño, el sistema se vuelve más inexacto ya que solo detecta como VP aquellos valores que se acercan al valor ideal.

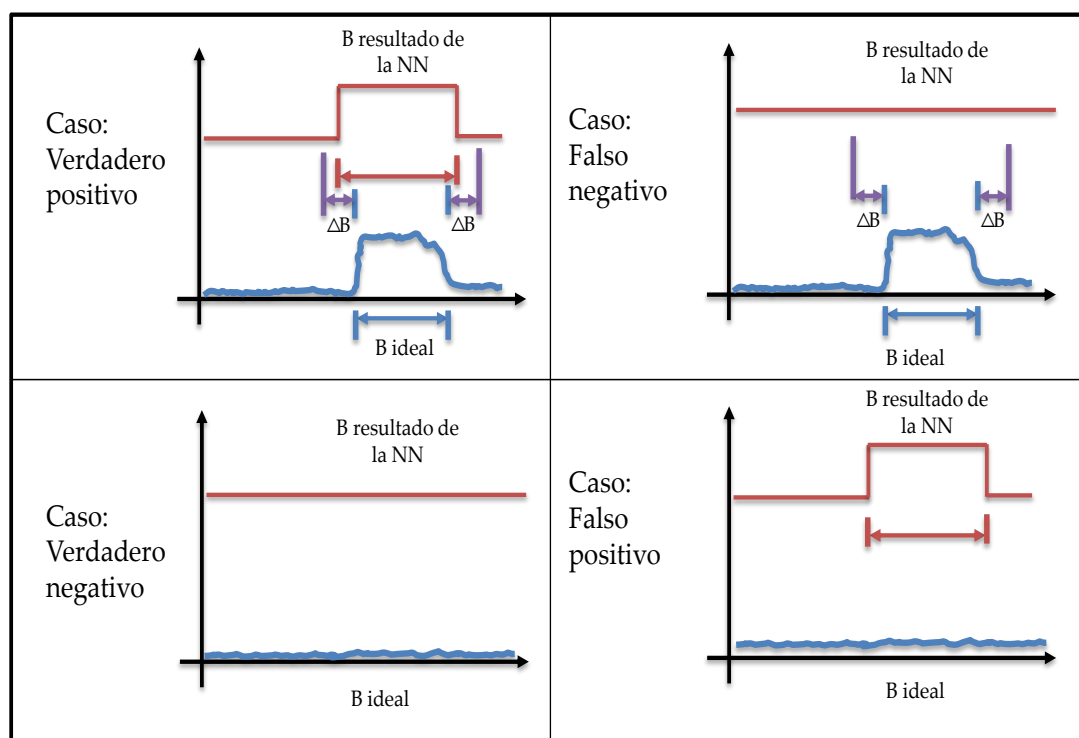


Figura 8.20. Resultados de la evaluación de B

La **Figura 8.21** muestra el $F1$ de NN_3 . En esta imagen, la NN con cuatro capas y la NN con 2 capas tienen un desempeño no deseado. La razón de este bajo desempeño se puede explicar observando la **Figura 8.17**, en la cual el resultado de B_1 está muy cerca del valor mínimo ($valor_ideal - \Delta B$). Sin embargo, este desempeño indeseable se observa solo cuando se emplea un bajo número de neuronas por capa (es decir, 16). Al configurar correctamente el número de neuronas por capa a un valor suficientemente alto (por ejemplo, 32 o más), se obtiene un rendimiento preciso con valores alrededor de $[0.95 - 0.96]$ también con 2 y 4 capas en la NN. De esta figura también se puede concluir que en las NN de 2 y 4 capas existe un sobreajuste. Esto se debe a que el modelo para la NN de 2 capas y la NN de 4 capas, ambos con 16 neuronas por capa, se ajusta demasiado bien a los datos de entrenamiento y, como resultado, no se generaliza bien a los nuevos datos. A pesar de ello, tienen un $F1$ de 0.9 y 0.79 respectivamente.




Figura 8.21. $F1$ de NN_3

La **Figura 8.22** muestra la relación de $F1$ score entre el tiempo de entrenamiento para las NN_1 y la NN_3 (ver la **Figura 8.22a** y **b**, respectivamente). El valor obtenido de esta relación indica que la NN proporciona la mejor compensación según el resultado de precisión del $F1$ obtenido y el tiempo invertido en entrenar la red para alcanzar dicho nivel de precisión. Como se puede notar, el uso de la NN con una sola capa proporciona el mejor rendimiento del $F1$ por el tiempo de entrenamiento requerido para obtenerlo. Aumentar aún más el número de capas aumentará el rendimiento de la puntuación de $F1$, pero requerirá proporcionalmente un tiempo de entrenamiento mucho más largo, lo que conducirá a una peor compensación o relación entre el beneficio (representado por el rendimiento de $F1$) y el costo (representado por el tiempo de entrenamiento requerido).

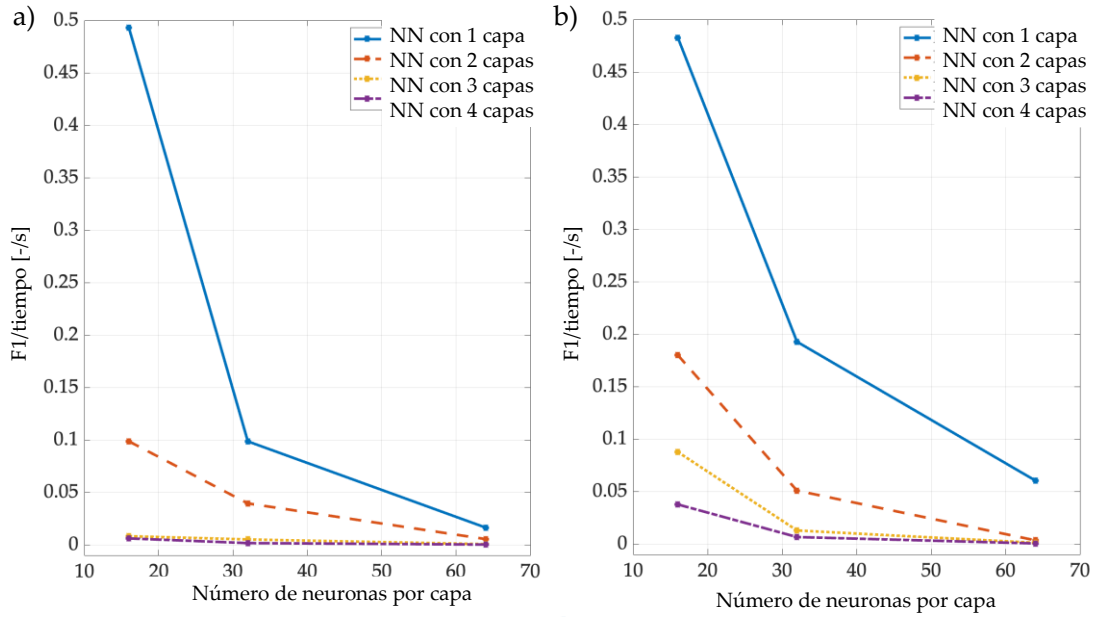


Figura 8.22. F1 y relación del tiempo de entrenamiento de a) NN_1 y b) NN_3

Finalmente, la **Figura 8.23** muestra el comportamiento de la metodología propuesta a lo largo del tiempo, en la que se analiza el espectro percibido en un área geográfica específica, donde los US colaboran para obtener el REM de los diferentes UP detectados. Como se puede apreciar, la metodología propuesta puede caracterizar la evolución temporal dinámica de los REM en el área geográfica de interés, proporcionando así una valiosa herramienta para el estudio de las CRN.

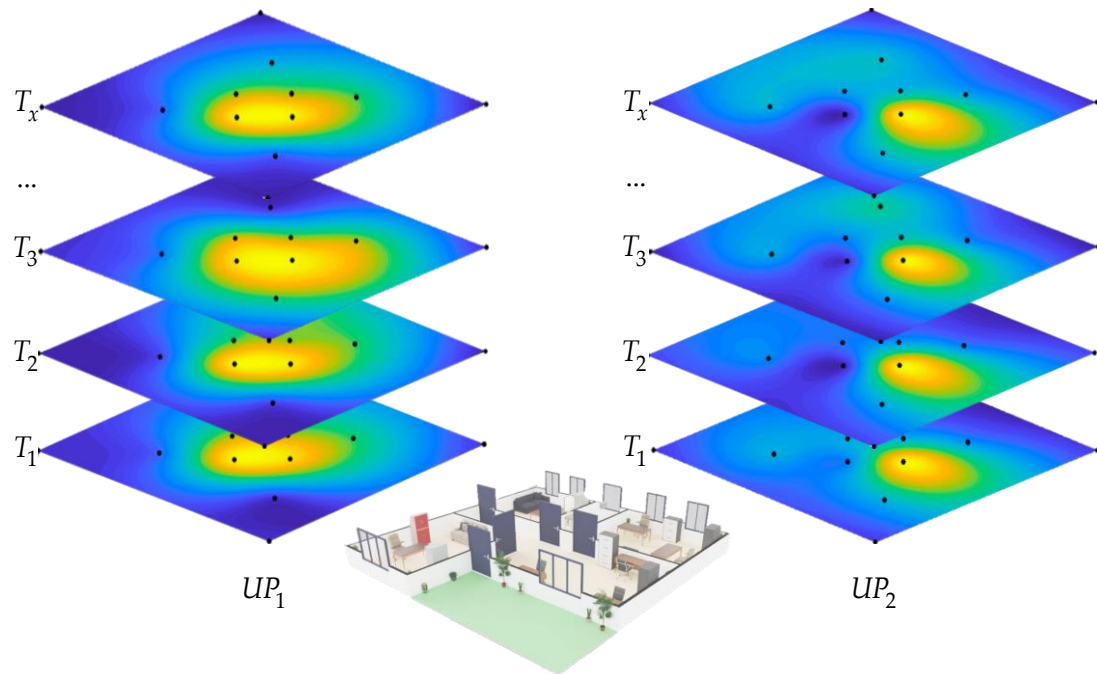


Figura 8.23. Resultado de la entidad central

Conclusiones y perspectivas de investigación

En esta investigación se han desarrollado e implementado dos técnicas de MEMB utilizando dispositivos de comunicación SDR. Estas técnicas se implementaron en lenguaje de programación Python, actualizando la información cada 100 ms.

Uno de los aportes de esta tesis radica en la implementación y validación de dos técnicas de MEMB, que demuestran un desempeño notable en la monitorización del espectro. Comparada con los métodos convencionales de detección del UP, estas técnicas de MEMB ofrecen mejoras significativas al determinar la ocupación del espectro en un entorno de comunicación inalámbrica real.

Este primer aporte proporciona algunas características importantes como: Si aumenta el número de US conectados a la plataforma, el tiempo de ejecución será mayor y habrá un retraso entre lo que perciben los SDR y lo que se muestra en la aplicación. Esto está en función del número de muestras que contiene cada cuadro. Además, el dispositivo HackRF One tiene un buen rendimiento para: (i) detectar correctamente el ruido o una posible transmisión de UP, y (ii) localizar el inicio y el final de una posible transmisión de UP. Las muestras con error de todas las US muestran un buen desempeño.

Otro aporte significativo de este trabajo de investigación es el módulo de eliminación de ruido impulsivo presentado en el Capítulo 6. Este módulo de eliminación de ruido tiene un buen desempeño para eliminar ruido impulsivo, ruido de alta frecuencia y cambios bruscos en la señal. Esto se logra a partir de los coeficientes de aproximación. La modificación de los coeficientes de aproximación afecta indirectamente la precisión para detectar la transmisión del UP. Prácticamente, con esta metodología se sacrifica la precisión de detección para mejorar la probabilidad de éxito.

Para la técnica basada en SampEn como regla de decisión destacan algunos puntos importantes:

- Los resultados experimentales para la detección de los usuarios primarios son consistentes con los resultados del cálculo simulado, lo que

indica que la técnica MEMB propuesta es correcta y factible de ser considerada para un entorno real de comunicación inalámbrica.

- Es difícil dar un intervalo en el que se ubica la SampEn, esto se debe a que en esta investigación los cuadros analizados por la técnica propuesta son variables y estos pueden cambiar dependiendo de la SNR o la cantidad de muestras que contenga la PSD. Sin embargo, es posible observar (ver la **Figura 7.6**) que el valor de SampEn está entre 0 y 9. Estos límites se pueden obtener con las ecuaciones (7.1) y (7.2). Sin embargo, el valor obtenido para estos bordes no es exacto en un entorno real ya que el número de muestras de cada ventana analizada es variable. Por otro lado, para un entorno ideal en el que la trama analizada tanto para el ruido como para la transmisión de UP es de 512 muestras, el límite inferior es 7.7×10^{-6} y el límite superior es 11.77. Además, es posible observar a partir de esta misma figura que la entropía siempre aumenta a medida que disminuye la SNR.

- Los resultados de aplicar L_2 o L_0 como umbral para el SampEn, son prácticamente los mismos. Surge entonces la pregunta, ¿cuál es el valor máximo que podría tomar el SampEn que permita tener un buen desempeño clasificando los dos estados posibles? Es posible considerar este tema como una perspectiva de investigación futura.

- Con una precisión promedio del 99% para detectar las UP y con 12 muestras (media) de error para ubicar los bordes de inicio y final de una transmisión, podemos concluir que SampEn es una técnica viable para la detección de los UP en un espectro amplio.

Se concluye que la técnica MEMB implementada tiene un buen desempeño muy similar al resultado esperado (0.98 de PE y 2 (media) muestras con error para localizar la transmisión UP) [11]. Esta técnica MEMB presenta un mejor rendimiento que un ED convencional, tanto para detectar la transmisión de un UP como para detectar con precisión su ubicación. Además, con este algoritmo es posible utilizar siete dispositivos SDR vistos como US.

Otra contribución de este trabajo se da en la implementación un escenario real de comunicación inalámbrica para detectar la ocupación de múltiples UP a través de varios US mediante una entidad central. Esta colaboración permite determinar el área que está siendo utilizada por los UP en base a

estimaciones de REM. Por otra parte, los US considerados estiman las características (potencia, ancho de banda, y frecuencia central) de los posibles UP detectados a partir de las tramas de espectro multibanda.

Para esta tarea se propone el uso de NN con el fin de sustituir el clásico procesamiento digital de señales utilizado en trabajos preliminares. Con esto, se espera que el tiempo de ejecución y procesamiento sea más rápido. Claramente, el estado de formación de las NN, tal y como se muestra en el apartado de resultados, es un factor a tener en cuenta. En el caso específico de este trabajo, se prefiere mayor precisión para ubicar la UP y menor tiempo de procesamiento para la entidad central al utilizar las NN. Sin embargo, hay que tener en cuenta que el tiempo de entrenamiento de las NN no es despreciable e incluso puede ser elevado dependiendo de las capas y neuronas que contenga cada NN. La diferencia entre los valores reales y el de las NNs es muy estrecha e incluso se podría decir que son prácticamente iguales e incluso en algunos casos la NN muestra mejores resultados que el procesamiento de señal digital, como es el caso al detectar la portadora de los UP.

Finalmente, la implementación del sistema en un escenario real de comunicación inalámbrica ha mostrado que las técnicas avanzadas utilizadas contribuyen significativamente a la mejora de la precisión en la detección y localización de usuarios primarios. Los resultados obtenidos validan la hipótesis de que estas técnicas avanzadas no solo optimizan el rendimiento en términos de detección, sino que también mejoran la asignación dinámica del espectro, permitiendo una adaptación más ágil y efectiva a las condiciones cambiantes del entorno espectral.

Referencias bibliográficas

- [1] S. Haykin, "Cognitive radio: brain-empowered wireless communications," *IEEE Journal on Selected Areas in Communications*, vol. 23, no. 2, Art. no. 2, Feb. 2005, doi: 10.1109/JSAC.2004.839380.
- [2] I. F. Akyildiz, W.-Y. Lee, M. C. Vuran, and S. Mohanty, "NeXt generation/dynamic spectrum access/cognitive radio wireless networks: A survey," *Computer Networks*, vol. 50, no. 13, pp. 2127–2159, Sep. 2006, doi: 10.1016/j.comnet.2006.05.001.
- [3] J. Mitola and G. Q. Maguire, "Cognitive radio: making software radios more personal," *IEEE Personal Communications*, vol. 6, no. 4, pp. 13–18, Aug. 1999, doi: 10.1109/98.788210.
- [4] "IEEE 802.22 WRAN WG Website." Accessed: Aug. 15, 2023. [Online]. Available: <https://www.ieee802.org/22/>
- [5] M. T. Masonta, M. Mzyece, and N. Ntlatlapa, "Spectrum Decision in Cognitive Radio Networks: A Survey," *IEEE Communications Surveys & Tutorials*, vol. 15, no. 3, pp. 1088–1107, 2013, doi: 10.1109/SURV.2012.111412.00160.
- [6] R. N. Yadav and R. Misra, "An Analysis of Different TCP Variants in Cognitive Radio Networks," in *2014 International Conference on Cyber-Enabled Distributed Computing and Knowledge Discovery*, Shanghai, China: IEEE, Oct. 2014, pp. 414–419. doi: 10.1109/CyberC.2014.78.
- [7] G. Hattab and M. Ibnkahla, "Multiband Spectrum Access: Great Promises for Future Cognitive Radio Networks," *Proceedings of the IEEE*, vol. 102, no. 3, pp. 282–306, Mar. 2014, doi: 10.1109/JPROC.2014.2303977.
- [8] Y. Arjoune and N. Kaabouch, "A Comprehensive Survey on Spectrum Sensing in Cognitive Radio Networks: Recent Advances, New Challenges, and Future Research Directions," *Sensors*, vol. 19, no. 1, p. 126, Jan. 2019, doi: 10.3390/s19010126.
- [9] M. S. Gupta and K. Kumar, "Progression on spectrum sensing for cognitive radio networks: A survey, classification, challenges and future research issues," *Journal of Network and Computer Applications*, vol. 143, pp. 47–76, Oct. 2019, doi: 10.1016/j.jnca.2019.06.005.
- [10] "Cuadro Nacional de Atribución de Frecuencias (CNAF) | Cuadro Nacional de Atribución de Frecuencias (CNAF) - IFT." Accessed: Mar. 25, 2019. [Online]. Available: <http://cnaf.ift.org.mx/>
- [11] Y. Molina-Tenorio, A. Prieto-Guerrero, R. Aguilar-Gonzalez, and S. Ruiz-Boqué, "Machine Learning Techniques Applied to Multiband Spectrum

- Sensing in Cognitive Radios,” *Sensors*, vol. 19, no. 21, Art. no. 21, Oct. 2019, doi: 10.3390/s19214715.
- [12] Y. Molina-Tenorio, A. Prieto-Guerrero, and R. Aguilar-Gonzalez, “Real-Time Implementation of Multiband Spectrum Sensing Using SDR Technology,” *Sensors*, vol. 21, no. 10, p. 3506, May 2021, doi: 10.3390/s21103506.
- [13] Y. Molina-Tenorio, A. Prieto-Guerrero, and R. Aguilar-Gonzalez, “Multiband Spectrum Sensing Based on the Sample Entropy,” *Entropy*, vol. 24, no. 3, p. 411, Mar. 2022, doi: 10.3390/e24030411.
- [14] Y. Molina-Tenorio, A. Prieto-Guerrero, R. Aguilar-Gonzalez, and M. Lopez-Benitez, “Cooperative Multiband Spectrum Sensing Using Radio Environment Maps and Neural Networks,” *Sensors*, vol. 23, no. 11, p. 5209, May 2023, doi: 10.3390/s23115209.
- [15] Ž. Tabakovi, “A Survey of Cognitive Radio Systems”.
- [16] V. Sharma and S. Joshi, “A Literature Review on Spectrum Sensing in Cognitive Radio Applications,” in *2018 Second International Conference on Intelligent Computing and Control Systems (ICICCS)*, Madurai, India: IEEE, Jun. 2018, pp. 883–893. doi: 10.1109/ICCONS.2018.8663089.
- [17] S. Shankar N., C. Cordeiro, and K. Challapali, “Spectrum agile radios: utilization and sensing architectures,” in *First IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks, 2005. DySPAN 2005.*, Baltimore, MD, USA: IEEE, 2005, pp. 160–169. doi: 10.1109/DYSPAN.2005.1542631.
- [18] T. Yucek and H. Arslan, “A survey of spectrum sensing algorithms for cognitive radio applications,” *IEEE Communications Surveys & Tutorials*, vol. 11, no. 1, Art. no. 1, 2009, doi: 10.1109/SURV.2009.090109.
- [19] T. Yucek and H. Arslan, “Spectrum Characterization for Opportunistic Cognitive Radio Systems,” in *MILCOM 2006*, Washington, DC, USA: IEEE, Oct. 2006, pp. 1–6. doi: 10.1109/MILCOM.2006.302124.
- [20] T. Farnham *et al.*, “IST-TRUST: a perspective on the reconfiguration of future mobile terminals using software download,” in *11th IEEE International Symposium on Personal Indoor and Mobile Radio Communications. PIMRC 2000. Proceedings (Cat. No.00TH8525)*, London, UK: IEEE, 2000, pp. 1054–1059. doi: 10.1109/PIMRC.2000.881582.
- [21] G. Hattab and M. Ibnkahla, “Multiband Spectrum Sensing: Challenges and Limitations,” *arXiv:1409.6394 [cs, math]*, Sep. 2014, Accessed: Feb. 27, 2019. [Online]. Available: <http://arxiv.org/abs/1409.6394>
- [22] Y. Liu *et al.*, “Adaptive double threshold energy detection based on Markov model for cognitive radio,” *PLOS ONE*, vol. 12, no. 5, Art. no. 5, May 2017, doi: 10.1371/journal.pone.0177625.

- [23] H. Li, Y. Hu, and S. Wang, "A Novel Blind Signal Detector Based on the Entropy of the Power Spectrum Subband Energy Ratio," *Entropy*, vol. 23, no. 4, p. 448, Apr. 2021, doi: 10.3390/e23040448.
- [24] Zhi Quan, Shuguang Cui, A. H. Sayed, and H. V. Poor, "Optimal Multiband Joint Detection for Spectrum Sensing in Cognitive Radio Networks," *IEEE Transactions on Signal Processing*, vol. 57, no. 3, pp. 1128–1140, Mar. 2009, doi: 10.1109/TSP.2008.2008540.
- [25] C. Jiang, C. Jiang, N. C. Beaulieu, Y. Li, Y. Zou, and Y. Ren, "DYWAMIT: Asynchronous Wideband Dynamic Spectrum Sensing and Access System," *IEEE Systems Journal*, vol. 11, no. 3, pp. 1777–1788, Sep. 2017, doi: 10.1109/JSYST.2014.2368692.
- [26] T. Xiong, Z. Li, Y.-D. Yao, and P. Qi, "Random, Persistent, and Adaptive Spectrum Sensing Strategies for Multiband Spectrum Sensing in Cognitive Radio Networks With Secondary User Hardware Limitation," *IEEE Access*, vol. 5, pp. 14854–14866, 2017, doi: 10.1109/ACCESS.2017.2734811.
- [27] T. Xiong, Y.-D. Yao, Y. Ren, and Z. Li, "Multiband Spectrum Sensing in Cognitive Radio Networks With Secondary User Hardware Limitation: Random and Adaptive Spectrum Sensing Strategies," *IEEE Transactions on Wireless Communications*, vol. 17, no. 5, pp. 3018–3029, May 2018, doi: 10.1109/TWC.2018.2805729.
- [28] M. Karimi and S. M. S. Sadough, "Improved spectrum sensing and achieved throughput of multiband cognitive radio systems under probabilistic spectrum access," *AEU - International Journal of Electronics and Communications*, vol. 86, pp. 8–16, Mar. 2018, doi: 10.1016/j.aeue.2018.01.012.
- [29] M. Alijani and A. Osman, "Calculate the Optimum Threshold for Double Energy Detection Technique in Cognitive Radio Networks (CRNs)," *Science and Technology*, p. 13, 2020.
- [30] Yue Wang, Zhi Tian, and Chunyan Feng, "Sparsity Order Estimation and its Application in Compressive Spectrum Sensing for Cognitive Radios," *IEEE Transactions on Wireless Communications*, vol. 11, no. 6, Art. no. 6, Jun. 2012, doi: 10.1109/TWC.2012.050112.110505.
- [31] W. Ejaz and M. Ibnkahla, "Multiband Spectrum Sensing and Resource Allocation for IoT in Cognitive 5G Networks," *IEEE Internet of Things Journal*, vol. 5, no. 1, pp. 150–163, Feb. 2018, doi: 10.1109/JIOT.2017.2775959.
- [32] W. Zhu, J. Ma, and O. Faust, "A Comparative Study of Different Entropies for Spectrum Sensing Techniques," *Wireless Pers Commun*, vol. 69, no. 4, pp. 1719–1733, Apr. 2013, doi: 10.1007/s11277-012-0659-6.
- [33] Xiaofei Chen and S. Nagaraj, "Entropy based spectrum sensing in cognitive radio," in *2008 Wireless Telecommunications Symposium*, Pomona, CA, USA: IEEE, Apr. 2008, pp. 57–61. doi: 10.1109/WTS.2008.4547544.

- [34] S. V. Nagaraj, "Entropy-based spectrum sensing in cognitive radio," *Signal Processing*, vol. 89, no. 2, Art. no. 2, Feb. 2009, doi: 10.1016/j.sigpro.2008.07.022.
- [35] E. Cadena Muñoz, L. F. Pedraza Martínez, and C. A. Hernandez, "Rényi Entropy-Based Spectrum Sensing in Mobile Cognitive Radio Networks Using Software Defined Radio," *Entropy*, vol. 22, no. 6, p. 626, Jun. 2020, doi: 10.3390/e22060626.
- [36] M. Sanna and M. Murrioni, "Nonconvex Optimization of Collaborative Multiband Spectrum Sensing for Cognitive Radios with Genetic Algorithms," *International Journal of Digital Multimedia Broadcasting*, vol. 2010, pp. 1–12, 2010, doi: 10.1155/2010/531857.
- [37] J. Kim and J. P. Choi, "Sensing Coverage-Based Cooperative Spectrum Detection in Cognitive Radio Networks," *IEEE Sensors Journal*, vol. 19, no. 13, Art. no. 13, Jul. 2019, doi: 10.1109/JSEN.2019.2903408.
- [38] W. Ejaz and M. Ibnkahla, "Multiband Spectrum Sensing and Resource Allocation for IoT in Cognitive 5G Networks," *IEEE Internet of Things Journal*, vol. 5, no. 1, Art. no. 1, Feb. 2018, doi: 10.1109/JIOT.2017.2775959.
- [39] M. Khayyeri and K. Mohammadi, "Cooperative wideband spectrum sensing in cognitive radio based on sparse real-valued fast Fourier transform," *IET Communications*, vol. 14, no. 8, Art. no. 8, May 2020, doi: 10.1049/iet-com.2018.5930.
- [40] Y. Ma, Y. Gao, Y.-C. Liang, and S. Cui, "Reliable and Efficient Sub-Nyquist Wideband Spectrum Sensing in Cooperative Cognitive Radio Networks," *IEEE Journal on Selected Areas in Communications*, vol. 34, no. 10, Art. no. 10, Oct. 2016, doi: 10.1109/JSAC.2016.2605998.
- [41] A. Kumar, S. Saha, and R. Bhattacharya, "Wavelet transform based novel edge detection algorithms for wideband spectrum sensing in CRNs," *AEU - International Journal of Electronics and Communications*, vol. 84, pp. 100–110, Feb. 2018, doi: 10.1016/j.aeue.2017.11.024.
- [42] S. E. El-Khamy, M. S. El-Mahallawy, and E. S. Youssef, "Improved wideband spectrum sensing techniques using wavelet-based edge detection for cognitive radio," in *2013 International Conference on Computing, Networking and Communications (ICNC)*, San Diego, CA: IEEE, Jan. 2013, pp. 418–423. doi: 10.1109/ICCNC.2013.6504120.
- [43] A. Kumar, S. Saha, and R. Bhattacharya, "Wavelet transform based novel edge detection algorithms for wideband spectrum sensing in CRNs," *AEU - International Journal of Electronics and Communications*, vol. 84, pp. 100–110, Feb. 2018, doi: 10.1016/j.aeue.2017.11.024.

- [44] X. Diao, Q. Dong, Z. Yang, and Y. Li, "Double-Threshold Cooperative Spectrum Sensing Algorithm Based on Sevcik Fractal Dimension," *Algorithms*, vol. 10, no. 3, Art. no. 3, Aug. 2017, doi: 10.3390/a10030096.
- [45] J. J. Popoola and R. van Olst, "Application of neural network for sensing primary radio signals in a cognitive radio environment," in *IEEE Africon '11*, Victoria Falls, Livingstone, Zambia: IEEE, Sep. 2011, pp. 1–6. doi: 10.1109/AFRCON.2011.6072009.
- [46] N. Shamsi, A. Mousavinia, and H. Amirpour, "A channel state prediction for multi-secondary users in a cognitive radio based on neural network," in *2013 International Conference on Electronics, Computer and Computation (ICECCO)*, Ankara, Turkey: IEEE, Nov. 2013, pp. 200–203. doi: 10.1109/ICECCO.2013.6718263.
- [47] Y. Molina-Tenorio, A. Prieto-Guerrero, and R. Aguilar-Gonzalez, "A Novel Multiband Spectrum Sensing Method Based on Wavelets and the Higuchi Fractal Dimension," *Sensors*, vol. 19, no. 6, Art. no. 6, Mar. 2019, doi: 10.3390/s19061322.
- [48] D. J. Zaidawi and S. B. Sadkhan, "Blind Spectrum Sensing Algorithms in CRNs: A Brief Overview," in *2021 7th International Engineering Conference "Research & Innovation amid Global Pandemic" (IEC)*, Erbil, Iraq: IEEE, Feb. 2021, pp. 78–83. doi: 10.1109/IEC52205.2021.9476142.
- [49] Y. Molina-Tenorio, A. Prieto-Guerrero, R. Aguilar-Gonzalez, and S. Ruiz-Boqué, "Machine Learning Techniques Applied to Multiband Spectrum Sensing in Cognitive Radios," *Sensors*, vol. 19, no. 21, Art. no. 21, Oct. 2019, doi: 10.3390/s19214715.
- [50] C. Politis, S. Maleki, J. M. Duncan, J. Krivochiza, S. Chatzinotas, and B. Ottesten, "SDR Implementation of a Testbed for Real-Time Interference Detection With Signal Cancellation," *IEEE Access*, vol. 6, pp. 20807–20821, 2018, doi: 10.1109/ACCESS.2018.2825885.
- [51] R. W. Stewart *et al.*, "A low-cost desktop software defined radio design environment using MATLAB, simulink, and the RTL-SDR," *IEEE Commun. Mag.*, vol. 53, no. 9, Art. no. 9, Sep. 2015, doi: 10.1109/MCOM.2015.7263347.
- [52] O. Hiari and R. Mesleh, "A Reconfigurable SDR Transmitter Platform Architecture for Space Modulation MIMO Techniques," *IEEE Access*, vol. 5, pp. 24214–24228, 2017, doi: 10.1109/ACCESS.2017.2761859.
- [53] E. Santos-Luna, A. Prieto-Guerrero, R. Aguilar-Gonzalez, V. Ramos, M. Lopez-Benitez, and M. Cardenas-Juarez, "A Spectrum Analyzer Based on a Low-Cost Hardware-Software Integration," in *2019 IEEE 10th Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON)*, Vancouver, BC, Canada: IEEE, Oct. 2019, pp. 0607–0612. doi: 10.1109/IEMCON.2019.8936239.

- [54] S. Aghabeiki, C. Hallet, N. E.-R. Noutehou, N. Rassem, I. Adjali, and M. Ben Mabrouk, "Machine-learning-based spectrum sensing enhancement for software-defined radio applications," in *2021 IEEE Cognitive Communications for Aerospace Applications Workshop (CCAAW)*, Cleveland, OH, USA: IEEE, Jun. 2021, pp. 1–6. doi: 10.1109/CCA AW50069.2021.9527294.
- [55] A. F. B. Selva, A. L. G. Reis, K. G. Lenzi, L. G. P. Meloni, and S. E. Barbin, "Introduction to the Software-defined Radio Approach," *IEEE LATIN AMERICA TRANSACTIONS*, vol. 10, no. 1, Art. no. 1, 2012.
- [56] "About RTL-SDR," rtl-sdr.com. Accessed: Aug. 08, 2022. [Online]. Available: <https://www.rtl-sdr.com/about-rtl-sdr/>
- [57] E. R. Brand a National Instruments, "USRP Software Defined Radio (SDR) online catalog," Ettus Research. Accessed: Mar. 11, 2021. [Online]. Available: <https://www.ettus.com/products/>
- [58] "LimeSDR Mini is a \$135 Open Source Hardware, Full Duplex USB SDR Board (Crowdfunding)." Accessed: Aug. 21, 2020. [Online]. Available: <https://www.cnx-software.com/2017/09/18/limesdr-mini-is-a-135-open-source-hardware-full-duplex-usb-sdr-board-crowdfunding/>
- [59] F. Daneshgaran and M. Laddomada, "[No title found]," *Wireless Personal Communications*, vol. 24, no. 2, Art. no. 2, 2003, doi: 10.1023/A:1022584911505.
- [60] T. Ulversoy, "Software Defined Radio: Challenges and Opportunities," *IEEE Commun. Surv. Tutorials*, vol. 12, no. 4, Art. no. 4, 2010, doi: 10.1109/SURV.2010.032910.00019.
- [61] C.-V. Nastase, A. Martian, C. Vladeanu, and I. Marghescu, "Spectrum Sensing Based on Energy Detection Algorithms Using GNU Radio and USRP for Cognitive Radio," in *2018 International Conference on Communications (COMM)*, Bucharest: IEEE, Jun. 2018, pp. 381–384. doi: 10.1109/ICComm.2018.8484763.
- [62] M. K. Chamran, K.-L. A. Yau, R. M. D. Noor, and R. Wong, "A Distributed Testbed for 5G Scenarios: An Experimental Study," *Sensors*, vol. 20, no. 1, Art. no. 1, Dec. 2019, doi: 10.3390/s20010018.
- [63] H. Anandakumar and K. Umamaheswari, "An Efficient Optimized Handover in Cognitive Radio Networks using Cooperative Spectrum Sensing," *Intelligent Automation & Soft Computing*, pp. 1–8, Sep. 2017, doi: 10.1080/10798587.2017.1364931.
- [64] D. Corral-De-Witt *et al.*, "Sensing TV spectrum using Software Defined Radio hardware," in *2017 IEEE 30th Canadian Conference on Electrical and Computer Engineering (CCECE)*, Windsor, ON: IEEE, Apr. 2017, pp. 1–4. doi: 10.1109/CCECE.2017.7946840.

- [65] F. Awin, A. Younan, D. Corral-De-Witt, K. Tepe, and E. Abdel-Raheem, "Real-Time Multi-Channel TVWS Sensing Prototype Using Software Defined Radio," in *2018 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT)*, Louisville, KY, USA: IEEE, Dec. 2018, pp. 235–240. doi: 10.1109/ISSPIT.2018.8642660.
- [66] D. Corral-De-Witt, S. Ahmed, F. Awin, J. L. Rojo-Álvarez, and K. Tepe, "An Accurate Probabilistic Model for TVWS Identification," *Applied Sciences*, vol. 9, no. 20, p. 4232, Oct. 2019, doi: 10.3390/app9204232.
- [67] C. Politis, S. Maleki, J. M. Duncan, J. Krivochiza, S. Chatzinotas, and B. Ottesten, "SDR Implementation of a Testbed for Real-Time Interference Detection With Signal Cancellation," *IEEE Access*, vol. 6, pp. 20807–20821, 2018, doi: 10.1109/ACCESS.2018.2825885.
- [68] T. Djamal, M. S. Azzaz, and S. Sadoudi, "Analysis Study and SDR Implementation of GoF Based Spectrum Sensing for Cognitive Radio," *IET Communications*, Jan. 2020, doi: 10.1049/iet-com.2019.0711.
- [69] O. Hiari and R. Mesleh, "A Reconfigurable SDR Transmitter Platform Architecture for Space Modulation MIMO Techniques," *IEEE Access*, vol. 5, pp. 24214–24228, 2017, doi: 10.1109/ACCESS.2017.2761859.
- [70] S. Soltani, Y. Sagduyu, Yi Shi, J. Li, J. Feldman, and J. Matyjas, "Distributed cognitive radio network architecture, SDR implementation and emulation testbed," in *MILCOM 2015 - 2015 IEEE Military Communications Conference*, Tampa, FL, USA: IEEE, Oct. 2015, pp. 438–443. doi: 10.1109/MILCOM.2015.7357482.
- [71] C.-V. Nastase, A. Martian, C. Vladeanu, and I. Marghescu, "Spectrum Sensing Based on Energy Detection Algorithms Using GNU Radio and USRP for Cognitive Radio," in *2018 International Conference on Communications (COMM)*, Bucharest: IEEE, Jun. 2018, pp. 381–384. doi: 10.1109/ICComm.2018.8484763.
- [72] M. K. Chamran, K.-L. A. Yau, R. M. D. Noor, and R. Wong, "A Distributed Testbed for 5G Scenarios: An Experimental Study," *Sensors*, vol. 20, no. 1, Art. no. 1, Dec. 2019, doi: 10.3390/s20010018.
- [73] N. Sharma, D. B. Rawat, B. B. Bista, and S. Shetty, "A Testbed Using USRP(TM) and LabView(R) for Dynamic Spectrum Access in Cognitive Radio Networks," in *2015 IEEE 29th International Conference on Advanced Information Networking and Applications*, Gwangju, South Korea: IEEE, Mar. 2015, pp. 735–740. doi: 10.1109/AINA.2015.261.
- [74] E. Santos-Luna, A. Prieto-Guerrero, R. Aguilar-Gonzalez, V. Ramos, M. Lopez-Benitez, and M. Cardenas-Juarez, "A Spectrum Analyzer Based on a Low-Cost Hardware-Software Integration," in *2019 IEEE 10th Annual Information Technology, Electronics and Mobile Communication Conference*

- (IEMCON), Vancouver, BC, Canada: IEEE, Oct. 2019, pp. 0607–0612. doi: 10.1109/IEMCON.2019.8936239.
- [75] K. Koutlia, B. Bojović, S. Lagén, and L. Giupponi, “Novel radio environment map for the ns-3 NR simulator,” in *Proceedings of the Workshop on ns-3*, Virtual Event USA: ACM, Jun. 2021, pp. 41–48. doi: 10.1145/3460797.3460803.
- [76] J. Li, G. Ding, X. Zhang, and Q. Wu, “Recent Advances in Radio Environment Map: A Survey,” in *Machine Learning and Intelligent Communications*, vol. 226, X. Gu, G. Liu, and B. Li, Eds., in Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering, vol. 226. , Cham: Springer International Publishing, 2018, pp. 247–257. doi: 10.1007/978-3-319-73564-1_25.
- [77] C. M. Spooner and N. V. Khambekar, “Spectrum sensing for cognitive radio: A signal-processing perspective on signal-statistics exploitation,” in *2012 International Conference on Computing, Networking and Communications (ICNC)*, Maui, HI, USA: IEEE, Jan. 2012, pp. 563–568. doi: 10.1109/ICCNC.2012.6167485.
- [78] X. Zhang, Y. Zhao, and H. Chen, “Adaptive Compressed Wideband Spectrum Sensing Based on Radio Environment Map Dedicated for Space Information Networks,” in *Wireless and Satellite Systems*, vol. 280, M. Jia, Q. Guo, and W. Meng, Eds., in Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering, vol. 280. , Cham: Springer International Publishing, 2019, pp. 128–138. doi: 10.1007/978-3-030-19153-5_12.
- [79] Y. H. Santana, D. Plets, R. M. Alonso, G. G. Nieto, L. Martens, and W. Joseph, “Radio Environment Map of an LTE Deployment Based on Machine Learning Estimation of Signal Levels,” in *2022 IEEE International Symposium on Broadband Multimedia Systems and Broadcasting (BMSB)*, Bilbao, Spain: IEEE, Jun. 2022, pp. 01–06. doi: 10.1109/BMSB55706.2022.9828582.
- [80] V. Borisov, T. Leemann, K. Sessler, J. Haug, M. Pawelczyk, and G. Kasneci, “Deep Neural Networks and Tabular Data: A Survey,” *IEEE Trans. Neural Netw. Learning Syst.*, pp. 1–21, 2022, doi: 10.1109/TNNLS.2022.3229161.
- [81] M. Xu, Z. Yin, Y. Zhao, and Z. Wu, “Cooperative Spectrum Sensing Based on Multi-Features Combination Network in Cognitive Radio Network,” *Entropy*, vol. 24, no. 1, p. 129, Jan. 2022, doi: 10.3390/e24010129.
- [82] R. G. Nair and K. Narayanan, “Cooperative spectrum sensing in cognitive radio networks using machine learning techniques,” *Appl Nanosci*, vol. 13, no. 3, pp. 2353–2363, Mar. 2023, doi: 10.1007/s13204-021-02261-0.
- [83] T. Jiang, M. Jin, Q. Guo, Y. Tian, and J. Liu, “Graph Learning-Based Cooperative Spectrum Sensing in Cognitive Radio Networks,” *IEEE Wireless*

Commun. Lett., vol. 12, no. 1, pp. 138–142, Jan. 2023, doi: 10.1109/LWC.2022.3219413.

[84] Y. Bouzegag, D. Teguig, and A. Maali, “Experimental SDR implementation of cooperative spectrum sensing in cognitive radio networks,” *Phys. Scr.*, vol. 98, no. 1, p. 015213, Jan. 2023, doi: 10.1088/1402-4896/aca56d.

[85] I. Daubechies, *Ten lectures on wavelets*, 9. print. in CBMS-NSF regional conference series in applied mathematics, no. 61. Philadelphia, Pa: Soc. for Industrial and Applied Mathematics, 2006.

[86] S. G. Mallat, “A theory for multiresolution signal decomposition: the wavelet representation,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 11, no. 7, Art. no. 7, Jul. 1989, doi: 10.1109/34.192463.

[87] B. B. Mandelbrot, *Fractals: form, chance, and dimension*. San Francisco: W. H. Freeman, 1977.

[88] T. Higuchi, “Approach to an irregular time series on the basis of the fractal theory,” *Physica D: Nonlinear Phenomena*, vol. 31, no. 2, Art. no. 2, Jun. 1988, doi: 10.1016/0167-2789(88)90081-4.

[89] L. F. Burlaga and L. W. Klein, “Fractal structure of the interplanetary magnetic field,” *Journal of Geophysical Research*, vol. 91, no. A1, p. 347, 1986, doi: 10.1029/JA091iA01p00347.

[90] J. S. Richman and J. R. Moorman, “Physiological time-series analysis using approximate entropy and sample entropy,” *American Journal of Physiology-Heart and Circulatory Physiology*, vol. 278, no. 6, pp. H2039–H2049, Jun. 2000, doi: 10.1152/ajpheart.2000.278.6.H2039.

[91] J. Li, G. Ding, X. Zhang, and Q. Wu, “Recent Advances in Radio Environment Map: A Survey,” in *Machine Learning and Intelligent Communications*, vol. 226, X. Gu, G. Liu, and B. Li, Eds., in Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering, vol. 226. , Cham: Springer International Publishing, 2018, pp. 247–257. doi: 10.1007/978-3-319-73564-1_25.

[92] N. S.-N. Lam, “Spatial Interpolation Methods: A Review,” *The American Cartographer*, vol. 10, no. 2, pp. 129–150, Jan. 1983, doi: 10.1559/152304083783914958.

[93] P. A. Burrough, R. McDonnell, and P. A. Burrough, *Principles of geographical information systems*. in Spatial information systems. Oxford ; New York: Oxford University Press, 1998.

[94] B. I. Harman, H. Koseoglu, and C. O. Yigit, “Performance evaluation of IDW, Kriging and multiquadric interpolation methods in producing noise mapping: A case study at the city of Isparta, Turkey,” *Applied Acoustics*, vol. 112, pp. 147–157, Nov. 2016, doi: 10.1016/j.apacoust.2016.05.024.

- [95] Arseni, Voiculescu, Georgescu, Iticescu, and Rosu, "Testing Different Interpolation Methods Based on Single Beam Echosounder River Surveying. Case Study: Siret River," *IJGI*, vol. 8, no. 11, p. 507, Nov. 2019, doi: 10.3390/ijgi8110507.
- [96] G. Matheron, "Principles of geostatistics," *Economic Geology*, vol. 58, no. 8, pp. 1246–1266, Dec. 1963, doi: 10.2113/gsecongeo.58.8.1246.
- [97] M. A. Oliver and R. Webster, "Kriging: a method of interpolation for geographical information systems," *International journal of geographical information systems*, vol. 4, no. 3, pp. 313–332, Jul. 1990, doi: 10.1080/02693799008941549.
- [98] K. S. Gundogdu and I. Guney, "Spatial analyses of groundwater levels using universal kriging," *J Earth Syst Sci*, vol. 116, no. 1, pp. 49–55, Feb. 2007, doi: 10.1007/s12040-007-0006-6.
- [99] N. A. C. Cressie, *Statistics for spatial data*, Revised edition. Hoboken, NJ: John Wiley & Sons, Inc, 2015.
- [100] E. H. Isaaks and R. M. Srivastava, *Applied geostatistics*. New York: Oxford University Press, 1989.
- [101] J. Han and M. Kamber, *Data mining: concepts and techniques*, 3rd ed. Burlington, MA: Elsevier, 2012.
- [102] W. Wang and Y. Yang, "Development of convolutional neural network and its application in image classification: a survey," *Opt. Eng.*, vol. 58, no. 04, p. 1, Apr. 2019, doi: 10.1117/1.OE.58.4.040901.
- [103] S. S. Haykin and S. S. Haykin, *Neural networks and learning machines*, 3rd ed. New York: Prentice Hall, 2009.
- [104] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning representations by back-propagating errors," *Nature*, vol. 323, no. 6088, pp. 533–536, Oct. 1986, doi: 10.1038/323533a0.
- [105] J. Schmidhuber, "Deep learning in neural networks: An overview," *Neural Networks*, vol. 61, pp. 85–117, Jan. 2015, doi: 10.1016/j.neunet.2014.09.003.
- [106] A. F. B. Selva, A. L. G. Reis, K. G. Lenzi, L. G. P. Meloni, and S. E. Barbin, "Introduction to the Software-defined Radio Approach," *IEEE LATIN AMERICA TRANSACTIONS*, vol. 10, no. 1, p. 6, 2012.
- [107] F. Daneshgaran and M. Laddomada, "[No title found]," *Wireless Personal Communications*, vol. 24, no. 2, pp. 99–121, 2003, doi: 10.1023/A:1022584911505.
- [108] R. W. Stewart *et al.*, "A low-cost desktop software defined radio design environment using MATLAB, simulink, and the RTL-SDR," *IEEE Commun. Mag.*, vol. 53, no. 9, pp. 64–71, Sep. 2015, doi: 10.1109/MCOM.2015.7263347.

- [109] T. Ulversoy, "Software Defined Radio: Challenges and Opportunities," *IEEE Commun. Surv. Tutorials*, vol. 12, no. 4, pp. 531–550, 2010, doi: 10.1109/SURV.2010.032910.00019.
- [110] "Nooelec - Nooelec NESDR SMARt v4 SDR - Premium RTL-SDR w/ Aluminum Enclosure, 0.5PPM TCXO, SMA Input. RTL2832U & R820T2-Based - Software Defined Radio." Accessed: Mar. 08, 2021. [Online]. Available: <https://www.noelec.com/store/sdr/nesdr-smart-sdr.html>
- [111] "HackRF One - Great Scott Gadgets." Accessed: Mar. 08, 2021. [Online]. Available: <https://greatscottgadgets.com/hackrf/one/>
- [112] "LimeSDR Mini," Lime Microsystems. Accessed: Mar. 08, 2021. [Online]. Available: <https://limemicro.com/products/boards/limesdr-mini/>
- [113] P. Welch, "The use of fast Fourier transform for the estimation of power spectra: A method based on time averaging over short, modified periodograms," *IEEE Trans. Audio Electroacoust.*, vol. 15, no. 2, pp. 70–73, Jun. 1967, doi: 10.1109/TAU.1967.1161901.
- [114] S. Liu, F. Yang, W. Ding, J. Song, and Z. Han, "Impulsive Noise Cancellation for MIMO-OFDM PLC Systems: A Structured Compressed Sensing Perspective," in *2016 IEEE Global Communications Conference (GLOBECOM)*, Washington, DC, USA: IEEE, Dec. 2016, pp. 1–6. doi: 10.1109/GLOCOM.2016.7841891.
- [115] R. Ram, S. Panda, H. K. Palo, and M. N. Mohanty, "Impulsive noise cancellation for speech enhancement using state space adaptive algorithm," in *2016 International Conference on Signal Processing, Communication, Power and Embedded System (SCOPEs)*, Paralakhemundi, Odisha, India: IEEE, Oct. 2016, pp. 1393–1396. doi: 10.1109/SCOPEs.2016.7955669.
- [116] S. M. Kay, *Modern spectral estimation: theory and application*. in Prentice-Hall signal processing series. Englewood Cliffs, N.J: Prentice Hall, 1988.
- [117] S. G. Mallat, "A theory for multiresolution signal decomposition: the wavelet representation," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 11, no. 7, Art. no. 7, Jul. 1989, doi: 10.1109/34.192463.
- [118] K. H. Chon, C. G. Scully, and S. Lu, "Approximate entropy for all signals," *IEEE Eng. Med. Biol. Mag.*, vol. 28, no. 6, pp. 18–23, Nov. 2009, doi: 10.1109/MEMB.2009.934629.
- [119] M. B. Kennel, R. Brown, and H. D. I. Abarbanel, "Determining embedding dimension for phase-space reconstruction using a geometrical construction," *Phys. Rev. A*, vol. 45, no. 6, pp. 3403–3411, Mar. 1992, doi: 10.1103/PhysRevA.45.3403.
- [120] S. Sapna, "Backpropagation Learning Algorithm Based on Levenberg Marquardt Algorithm," in *Computer Science & Information Technology (CS & IT*

), Academy & Industry Research Collaboration Center (AIRCC), Oct. 2012, pp. 393–398. doi: 10.5121/csit.2012.2438.

[121] Y. Sasaki, “The truth of the f-measure,” Oct. 2007, Accessed: Apr. 07, 2007. [Online]. Available:

<https://www.cs.odu.edu/~mukka/cs795sum11dm/Lecturenotes/Day3/F-measure-YS-26Oct07.pdf>



Casa abierta al tiempo

UNIVERSIDAD AUTÓNOMA METROPOLITANA

ACTA DE DISERTACIÓN PÚBLICA

No. 00022

Matrícula: 2173802181

IMPLEMENTACIÓN DE TÉCNICAS AVANZADAS PARA LA MONITORIZACIÓN DEL ESPECTRO MULTIBANDA EN RADIOS COGNITIVOS.

En la Ciudad de México, se presentaron a las 10:00 horas del día 30 del mes de septiembre del año 2024 en la Unidad Iztapalapa de la Universidad Autónoma Metropolitana, los suscritos miembros del jurado:

DR. MARCO AURELIO CARDENAS JUAREZ
DR. ALFONSO PRIETO GUERRERO
DR. JORGE SIMON RODRIGUEZ
DRA. ANABEL MARTINEZ VARGAS
DR. MIGUEL LOPEZ GUERRERO

Bajo la Presidencia del primero y con carácter de Secretario el último, se reunieron a la presentación de la Disertación Pública cuya denominación aparece al margen, para la obtención del grado de:




DOCTOR EN CIENCIAS (CIENCIAS Y TECNOLOGÍAS DE LA INFORMACIÓN)

DE: YANQUELETH ANTONIO DE JESUS MOLINA TENORIO

y de acuerdo con el artículo 78 fracción IV del Reglamento de Estudios Superiores de la Universidad Autónoma Metropolitana, los miembros del jurado resolvieron:

Aprobar

Acto continuo, el presidente del jurado comunicó al interesado el resultado de la evaluación y, en caso aprobatorio, le fue tomada la protesta.

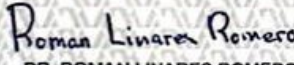
YANQUELETH ANTONIO DE JESUS MOLINA TENORIO
ALUMNO

REVISÓ



MTRA. ROSALIA SERRANO DE LA PAZ
DIRECTORA DE SISTEMAS ESCOLARES

DIRECTOR DE LA DIVISIÓN DE CBI



DR. ROMAN LINARES ROMERO

PRESIDENTE



DR. MARCO AURELIO CARDENAS JUAREZ

VOCAL




DR. ALFONSO PRIETO GUERRERO

VOCAL



DR. JORGE SIMON RODRIGUEZ

VOCAL



DRA. ANABEL MARTINEZ VARGAS

SECRETARIO



DR. MIGUEL LOPEZ GUERRERO