



Casa abierta al tiempo

UNIVERSIDAD AUTÓNOMA METROPOLITANA

Unidad Iztapalapa

División de Ciencias Básicas e Ingeniería

Monitorización del espectro multibanda en radios cognoscitivos

Idónea comunicación de resultados que para obtener el grado de

Maestro en Ciencias

(Ciencias y Tecnologías de la Información)

Presenta:

Yanqueleth Antonio de Jesús Molina Tenorio

Asesores:

Dr. Alfonso Prieto Guerrero

Dr. Rafael Aguilar González

Sinodales:

Dr. Marco Aurelio Cárdenas Juárez

Dr. Miguel López Guerrero

Dr. Rafael Aguilar González

CDMX, 27 de septiembre 2019

Agradecimientos

Agradezco y dedico este trabajo de investigación principalmente a Pilar Tenorio. La persona que creyó y ha dado todo por mí, a quien le debo mi persona y todo lo malo que no soy. Con cariño y admiración te dedico mi éxito madre mía.

Quiero agradecer con todo mi corazón a Lay mi alma gemela (mi hermana) y a Viry el amor de mi vida (mi novia). Gracias por el apoyo y la confianza depositada en cada una de mis decisiones.

A mis abues Felipe Tenorio y Mary González, quienes a base de sus consejos, platicas y experiencia me han inculcado la perseverancia, el trabajo y humildad.

A mi padre Felipe Molina, a mi madrina Delia Tenorio, a mis primos-hermanos y a la familia Tenorio González infinitas gracias por el apoyo brindado.

Expreso mi profundo agradecimiento y admiración a mis asesores Dr. Alfonso Prieto Guerrero y el Dr. Rafael Aguilar González que me apoyaron, guiaron y compartieron sus conocimientos durante la elaboración del presente trabajo de investigación.

Quiero agradecer a mis sinodales el Dr. Marco Aurelio Cárdenas Juárez, el Dr. Miguel López Guerrero y el Dr. Rafael Aguilar González, por su orientación, sus tan acertadas correcciones y por acceder a ser parte del jurado.

A mis profesores que me han compartido sus conocimientos durante cada clase y aún fuera de ellas. Y por supuesto, a mis compañeros y amigos con quienes compartí momentos de estudio y de diversión.

Agradezco a mi casa de estudios la Universidad Autónoma Metropolitana unidad Iztapalapa, por las facilidades prestadas para el desarrollo de este trabajo.

Al Consejo Nacional de Ciencia y Tecnología, por el financiamiento otorgado durante los años de estudio de mi posgrado.

Contenido

Agradecimientos	II
Lista de figuras	V
Lista de tablas.....	IX
Abreviaturas	X
Resumen.....	XI
Capítulo 1 Introducción	1
1.1 Planteamiento del problema.....	2
1.2 Objetivos del proyecto.....	4
1.2.1 Objetivo general	4
1.2.2 Objetivos específicos.....	4
1.3 Metodología de investigación.....	4
1.4 Productos de investigación.....	5
1.5 Estructura del documento	5
Capítulo 2 Antecedentes.....	7
2.1 Monitorización del espectro en una banda.....	7
2.1.1 Detector de energía.....	7
2.1.2 Basada en forma de onda.....	8
2.1.3 Basada en proceso cicloestacionario.....	8
2.1.4 Basada en radio identificación	8
2.1.5 Por filtro acoplado.....	9
2.2 Redes cooperativas de radios cognoscitivos.....	9
2.3 Monitorización del espectro multibanda.....	10
2.3.1 En serie.....	13
2.3.2 En paralelo	14
2.3.3 Por banda ancha.....	14
2.4 Redes cooperativas de RC multibanda.....	16
Capítulo 3 Marco teórico.....	17
3.1 Transformada continua de <i>wavelet</i>	17
3.2 Análisis multiresolución	18
3.3 Dimensión fractal de Higuchi.....	20
3.4 <i>Machine learning</i>	22
3.4.1 Redes neuronales.....	22
3.4.2 <i>Expectation maximization</i>	23
3.4.3 <i>K-means</i>	24
3.4.4 <i>Dirichlet process Gaussian mixture model</i>	24
Capítulo 4 Campaña de medición	25

Capítulo 5	Desarrollo metodológico.....	30
5.1	Técnicas relacionadas.....	30
5.2	Técnica de monitorización del espectro multibanda basada en la TCW y la DFH.....	32
5.3	Técnica de monitorización del espectro multibanda basada en los coeficientes de aproximación y la DFH.....	37
5.4	<i>Machine Learning</i> aplicado a la Técnica de monitorización del espectro multibanda basada en los coeficientes de aproximación y la DFH.....	39
5.4.1	Utilización de una red neuronal con un umbral de decisión manual.....	41
5.4.2	Utilización de una NN con un umbral de decisión basado en el algoritmo <i>expectation maximization</i>	44
5.4.3	Clasificación basada en el algoritmo <i>K-means</i>	48
5.4.4	Clasificación basada en el <i>Dirichlet process Gaussian mixture model</i>	51
Capítulo 6	Resultados.....	55
6.1	La regla de decisión: la dimensión fractal de Higuchi.....	55
6.2	Aplicación de las metodologías propuestas en señales simuladas.....	58
6.2.1	Resultados de la primera metodología.....	59
6.2.2	Resultados de la segunda metodología	62
6.2.3	Resultados de aplicar las técnicas de ML a la segunda metodología.....	64
6.3	Aplicación de las metodologías en señales reales	69
6.3.1	Resultados de la primera y segunda metodología a señales reales.....	69
6.3.2	Resultados de la 2da metodología con técnicas de ML a señales reales.....	74
Capítulo 7	Conclusiones y perspectivas de investigación	77
	Referencias.....	80

Lista de figuras

Figura 1. a) Espectro multibanda [0.6-2.6] GHz. b) El mismo espectro multibanda 10 segundos después.	3
Figura 2. El concepto de monitorización multibanda en RC presentado en [6].	3
Figura 3. Clasificación de las técnicas de monitorización.	7
Figura 4. La cooperación entre US para mejorar la detección del UP, obtenida de [6].	10
Figura 5. a) Señal sintetizada. b) Módulo máximo de la TCW.	18
Figura 6. Implementación del AMR basado en un banco de filtros.	19
Figura 7. a) Señal original y señal reconstruida a partir únicamente de los coeficientes de aproximación. b) Coeficientes de aproximación en el nivel 3.	20
Figura 8. a) Ruido blanco con valor de 1.96 para la DFH. b) Símbolo NRZ-CDMA con valor 1.5 para la DFH.	21
Figura 9. Red neuronal.	22
Figura 10. Porcentaje de ocupación de una semana en el intervalo de frecuencia [0.6 - 2.6] GHz.	25
Figura 11. CT de un día de la banda [698 – 806] MHz.	26
Figura 12. CT de un día de la banda [806-902] MHz.	27
Figura 13. CT de un día de la banda [902-928] MHz.	27
Figura 14. CT de un día de la banda [1.7-2] GHz.	28
Figura 15. CT de un día de la banda [2.3-2.5] GHz.	28
Figura 16. CT de un día de la banda [2.6-2.8] GHz.	29
Figura 17. Esquema completo de la primera metodología propuesta.	33
Figura 18. El resultado de aplicar AMR a $X(f)$	34
Figura 19. TCW con escala en el intervalo [1, 150] de la señal $X_{app}(f)$	35
Figura 20. a) $X_{app}(f)$, señal reconstruida con los coeficientes de aproximación obtenidos de $X(f)$. b) El resultado de aplicar el módulo máximo de la TCW a la señal $X_{app}(f)$ en la escala 120 y sus correspondientes bordes detectados.	35
Figura 21. a) Las señales original y aproximada con un nivel de descomposición $L=3$ del AMR. b) Los CNI que marcan los bordes de frecuencia y al mismo tiempo determinan los límites de las ventanas dinámicas y el umbral de 0.7.	36
Figura 22. El espectro resultante que será utilizado en los Pasos 5 y 6 junto con la regla de decisión para detectar a un posible UP.	37
Figura 23. Segunda metodología considerando los CNI en la detección de bordes de frecuencia.	38
Figura 24. Inclusión de técnicas de ML a la segunda metodología.	40

Figura 25. Diagrama de funcionamiento de la NN.....	41
Figura 26. a) Espectro multibanda aleatorio, b) Coeficientes normalizados y reescalados que se utilizarán para entrenar la NN.	42
Figura 27. El resultado del entrenamiento de la NN con un umbral manual establecido en 0.6 sobre una trama completa. Los coeficientes de aproximación normalizados y reescalados han sido clasificados. También se determinan los bordes de ventanas dinámicas.	42
Figura 28. a) Espectro multibanda aleatorio. b) Clasificación de los coeficientes de aproximación, resultado del uso de la NN (Figura 27). c) Resultado de aplicar toda la metodología.	44
Figura 29. Diagrama de bloques que describe la integración del algoritmo EM en el entrenamiento de la red.	45
Figura 30. a) Espectro multibanda aleatorio. b) Coeficientes que se utilizan para entrenar la NN.....	45
Figura 31. Se muestra la potencia de los coeficientes en el eje X y el resultado de clasificarlos en dos clases con distribución gaussiana.	46
Figura 32. La tendencia de la NN entrenada con una clasificación de los coeficientes de aproximación normalizados y reescalados, utilizando el algoritmo EM donde el umbral es colocado en 0.654.	47
Figura 33. a) Espectro multibanda generado aleatoriamente. b) Clasificación de los coeficientes, resultado de utilizar la NN entrenada que se menciona en Figura 32 . c) Ocupación a lo largo del espectro multibanda.	48
Figura 34. Diagrama de bloques que describe el funcionamiento de la técnica de monitorización usando el algoritmo <i>K-means</i>	48
Figura 35. a) Coeficientes clasificados y los respectivos bordes de frecuencia. b) El resultado de aplicar <i>K-means</i>	50
Figura 36. a) Espectro multibanda aleatorio que corresponde a los coeficientes de aproximación presentados en la Figura 35 . b) Ocupación a lo largo del espectro multibanda.	51
Figura 37. Diagrama de bloques que describe el funcionamiento de la técnica de monitorización usando DPGMM.....	52
Figura 38. a) Coeficientes clasificados. b) Clasificación de los coeficientes de aproximación normalizados y reescalados en función de su potencia.	52
Figura 39. a) Espectro multibanda aleatorio. b) Ocupación a lo largo del espectro multibanda.	53
Figura 40. a) Promedio de 300 tramas de espectro que corresponden a la banda [806 - 902] MHz. b) Promedio de la DFH calculada sobre estas tramas en ventanas de frecuencia de tamaño uniforme.	55
Figura 41. Espectro de múltiples símbolos a) OFDM. b) NRZ-CDMA.	57

Figura 42. DFH de espectros para diferentes SNR. a) Símbolos OFDM. b) Símbolos NRZ-CDMA.....	57
Figura 43. Espectro real (en rojo) y las señales aproximadas del AMR utilizando una familia de <i>wavelets</i> de Daubechies.	58
Figura 44. Esquema de la simulación global.	59
Figura 45. Media y DE para ruido y símbolos simulados (OFDM y NRZ-CDMA) aplicando la primera metodología.....	60
Figura 46. Estudio de detección de bordes de frecuencia aplicando la primera metodología.	61
Figura 47. PE de la primera metodología en señales simuladas.....	61
Figura 48. Media y desviación estándar para ruido y símbolos simulados (OFDM y NRZ-CDMA) aplicando la segunda metodología.....	62
Figura 49. Estudio de detección de bordes de frecuencia aplicando la segunda metodología.	63
Figura 50. PE de la segunda metodología en señales simuladas.....	63
Figura 51. Esquema de la simulación global para ML aplicado a la segunda metodología.	65
Figura 52. Media y DE de la detección de los bordes de frecuencia considerando los umbrales L1, L2 como los valores máximo y mínimo posibles, respectivamente.....	66
Figura 53. Media y DE para localizar los bordes de frecuencia con base en las diferentes técnicas de ML propuestas.....	67
Figura 54. PE de cada técnica de ML para los diferentes valores de SNR.	68
Figura 55. a) Espectro multibanda generado aleatoriamente. b) Segunda metodología y las cuatro técnicas de ML aplicadas para determinar la ocupación del UP.....	68
Figura 56. a) Señal real obtenida de la banda de frecuencia [698 - 806] MHz. b) El resultado de aplicar ambas metodologías a la señal real en términos de ocupación del espectro.	70
Figura 57. a) Señal real obtenida de la banda de frecuencia [806 - 902] MHz. b) El resultado de aplicar ambas metodologías a la señal real en términos de ocupación del espectro.	70
Figura 58. a) Una señal real obtenida de la banda de frecuencia [902 - 928] MHz. b) El resultado de aplicar ambas metodologías a la señal real en términos de ocupación del espectro.	71
Figura 59. a) Señal real obtenida de la banda de frecuencia [1.7 - 2] GHz. b) El resultado de aplicar ambas metodologías a la señal real en términos de ocupación del espectro.....	71

Figura 60. a) Señal real obtenida de la banda de frecuencia [2.3 - 2.5] GHz. b) El resultado de aplicar ambas metodologías a la señal real en términos de ocupación del espectro.	72
Figura 61. a) Una señal real obtenida de la banda de frecuencia [2.6 - 2.8] GHz. b) El resultado de aplicar ambas metodologías a la señal real en términos de ocupación del espectro. En este caso, la segunda metodología da una mejor detección de bordes de frecuencia.	72
Figura 62. a) Una señal real obtenida de la banda ancha completa de [0.6 - 2.6] GHz. b) El resultado de aplicar ambas metodologías a la señal real en términos de ocupación del espectro.	73
Figura 63. a) Señal real obtenida de la banda de frecuencia [698 - 806] MHz. b) El resultado de aplicar las cuatro técnicas de ML a la 2da metodología a la señal real en términos de ocupación del espectro.	74
Figura 64. a) Señal real obtenida de la banda de frecuencia [806-902] MHz. b) El resultado de aplicar las cuatro técnicas de ML a la 2da metodología a la señal real en términos de ocupación del espectro.	75
Figura 65. a) Señal real obtenida de la banda de frecuencia [1.7-2] GHz. b) El resultado de aplicar las cuatro técnicas de ML a la 2da metodología a la señal real en términos de ocupación del espectro.	75
Figura 66. a) Señal real obtenida de la banda de frecuencia [2.3-2.5] GHz. b) El resultado de aplicar las cuatro técnicas de ML a la 2da metodología a la señal real en términos de ocupación del espectro.	76
Figura 67. a) Señal real obtenida de la banda de frecuencia [2.6-2.8] GHz. b) El resultado de aplicar las cuatro técnicas de ML a la 2da metodología a la señal real en términos de ocupación del espectro.	76

Lista de tablas

Tabla 1. Técnicas de monitorización del espectro multibanda más comunes [6].	12
Tabla 2. Bandas de frecuencia monitorizadas.....	26
Tabla 3. La media y la varianza de la DFH aplicada a múltiples símbolos OFDM y NRZ- CDMA simulados sin ruido.....	57
Tabla 4. Parámetros de la simulación.	59
Tabla 5. Parámetros de Simulación considerando las técnicas de ML.	64
Tabla 6. Media de la detección de bordes para cada SNR simuladas.....	66

Abreviaturas

RC	Radio cognoscitivo
US	Usuario secundario
UP	Usuario primario
ML	Sigla del inglés <i>Machine Learning</i> 'aprendizaje maquinal'
DFH	Dimensión fractal de Higuchi
SNR	Sigla del inglés <i>Signal to Noise Ratio</i> 'relación señal a ruido'
OFDM	Sigla del inglés <i>orthogonal frequency division multiplexing</i> 'acceso múltiple por división de frecuencias ortogonales'
IoT	Sigla del inglés <i>Internet of Things</i> 'internet de las cosas'
DFS	Dimensión fractal Sevcick
RRC-MB	Redes de radios cognoscitivos multibanda
TCW	Transformada continua de <i>wavelet</i>
AMR	Análisis multiresolución
NRZ	Sigla del inglés <i>non return to zero</i> 'sin retorno a cero'
CDMA	Sigla del inglés <i>Code Division Multiple Access</i> 'acceso múltiple por división de código'
NN	Sigla del inglés <i>Neural Network</i> 'red neuronal'
EM	<i>Expectation Maximization</i>
DPGMM	Sigla del inglés <i>Dirichlet Process Gaussian Mixture Model</i>
CT	Ciclo de trabajo
CNI	Coefficientes de aproximación normalizados e interpolados
VP	Ventana de prueba
DE	Desviación estándar
BP	Baja potencia
AP	Alta potencia
PE	Porcentaje de éxito

Resumen

En este trabajo de investigación se plantean tres propuestas novedosas para la monitorización del espectro multibanda en un contexto de radios cognoscitivos. Estas metodologías hacen uso de herramientas específicas para la detección de los bordes de huecos disponibles en el espectro de banda ancha como: el modulo máximo de la transformada continua de *wavelet*, análisis multiresolución y algunos algoritmos de machine learning (red neuronal, *expectation maximization*, *k-means* y *Dirichlet process gaussian mixture model*). Además el análisis multiresolución se combina con la dimensión fractal de Higuchi (una medida no lineal) para establecer la regla de decisión que permite determinar la presencia o ausencia de un usuario primario en el espectro de banda ancha analizado.

Cada una de estas propuestas se probó en un entorno controlado (simulación) teniendo buenos resultados para una relación señal a ruido mayor a 0 dB de 95 %, 98 % y 99 % para la 1ª 2ª y 3ª metodología, respectivamente. Además estas propuestas se probaron en señales recuperadas del entorno (señales reales). Con base en lo anterior estos métodos propuestos son opciones efectivas para detectar la actividad del usuario primario en el espectro multibanda.

Capítulo 1

Introducción

Actualmente la administración del espectro radioeléctrico está fundamentada en licencias de uso exclusivo para operar en frecuencias fijas, otorgadas por los organismos reguladores de cada país. Esta asignación fija de frecuencias ha provocado la escasez de bandas de frecuencia libres para operar nuevos servicios. Sin embargo, es bien sabido que existe una sobreutilización de estas bandas (e.g. el sistema de telefonía celular 3G o 4G actuales) [1]. La optimización de la distribución del espectro ha llevado al desarrollo de un nuevo paradigma denominado radio cognoscitivo (RC), el cual es un modelo de las comunicaciones inalámbricas planteado por Mitola [2]. El concepto de RC consiste en un radio con la capacidad de aprovechar oportunamente las brechas espectrales para continuar transmitiendo [2]. El RC ha sido considerado en nuestros días como una de las soluciones sobresalientes para la escasez de espectro; y ha sido considerado en los estándares de la IEEE, por ejemplo, en el estándar 802.22 que propone el aprovechamiento de espacios libres en las frecuencias del espectro dedicadas a la televisión digital terrestre.

Las técnicas de RC proporcionan la capacidad de usar o compartir el espectro de manera oportuna y operar en el mejor canal disponible. De esta manera, la tecnología de los RC permitirá a los usuarios secundarios (US), también llamados usuarios sin licencia, determinar qué partes del espectro están disponibles y detectar la presencia de usuarios con licencia o usuarios primarios (UP). Cuando un US opera en una banda no autorizada, el RC selecciona el mejor canal disponible, coordina su acceso a este canal y, en el momento correcto, abandona el canal cuando se detecta un UP [3]. El paradigma de los RC involucra las funciones de monitorización, decisión, compartición y movilidad del espectro [4]. La monitorización es la capacidad de detectar oportunamente el inicio de transmisiones de un UP en el espacio del espectro ocupado por el US. La decisión se refiere a la capacidad del US de seleccionar la mejor banda de espectro disponible. La compartición se refiere al acceso coordinado al canal seleccionado por los US y la movilidad del espectro es la capacidad de un RC para desocupar el canal cuando se detecta un UP [4]. La primera etapa del RC, es decir la monitorización de espectro, es fundamental para determinar la presencia de un UP. El presente trabajo de investigación se enfoca en esta primera función de los RC.

La monitorización del espectro en un RC es un término que implica la obtención de las características del espectro a través de 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 [5]. Aunado a esto y considerando que los futuros servicios de comunicaciones inalámbricas requieren anchos de banda de mayor tamaño, es necesario considerar escenarios donde los espacios de espectro disponibles están en frecuencias no contiguas. Debido a esto, es necesario tener un panorama amplio de la actividad de los UP. Una solución es considerar la detección de espectro multibanda, i.e. realizar la detección de los espacios espectrales disponibles considerando un ancho de banda amplio [5]. Con base en esto, los RC multibanda representan una gran promesa para implementar redes de radios cognoscitivos eficientes, en comparación con las redes de una sola banda. La monitorización del espectro es 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 [6]. La motivación principal de este trabajo radica en la búsqueda de técnicas que mejoren la detección espectral de los sistemas de comunicación digital inalámbrica, con un enfoque de RC multibanda.

1.1 Planteamiento del problema

Este nuevo paradigma en la monitorización del espectro basado en considerar simultáneamente múltiples bandas de frecuencia, es denominado monitorización del espectro multibanda, y tiene como fin mejorar la detección oportuna del UP desde el punto de vista de los RC. En la *Figura 1* se muestra la variabilidad de uso de una determinada banda en dos instantes de tiempo diferentes. En ella se aprecia que las bandas licenciadas (ocupadas por UP) no siempre están ocupadas, lo que representa un nicho de oportunidad ante la escasez del espectro. La idea de la monitorización multibanda es mostrada en la *Figura 2*, donde un US está continuamente “barriendo” el espectro amplio con la perspectiva de colocarse en los “huecos”¹ liberados por los UP.

Bajo esta perspectiva, esta medición incluye la determinación de qué tipos de señales están ocupando el espectro, a saber, tipo de modulación, forma de onda, anchos de banda, frecuencias de portadora, etc.; lo cual requiere de algoritmos o técnicas de análisis de señales poderosos. Con base en lo anterior, la búsqueda de esquemas eficientes de

¹ Intervalos de tiempo que no son utilizados por los UP.

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 es la búsqueda de técnicas que mejoren la detección espectral de los sistemas de comunicación digital con un enfoque de radios cognoscitivos multibanda o de banda ancha.

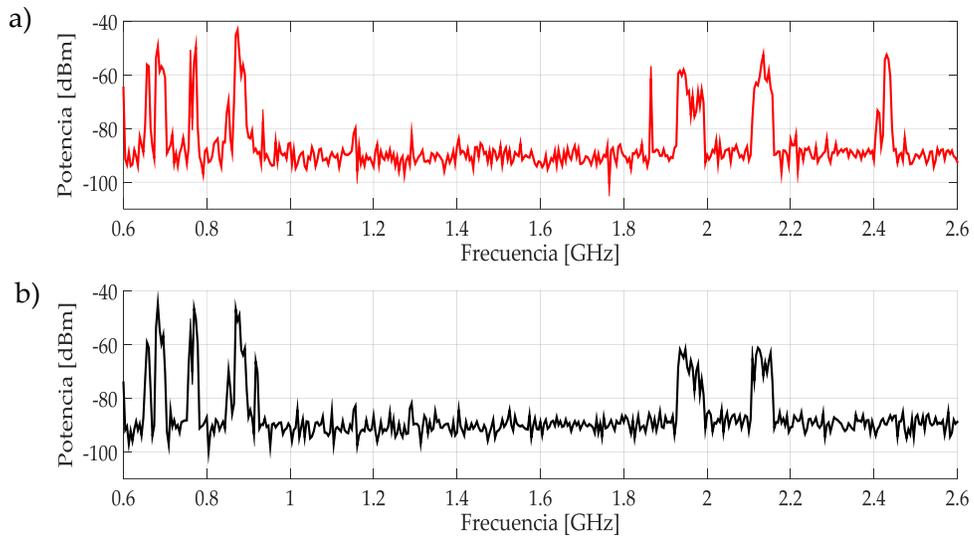


Figura 1. a) Espectro multibanda [0.6-2.6] GHz. b) El mismo espectro multibanda 10 segundos después.

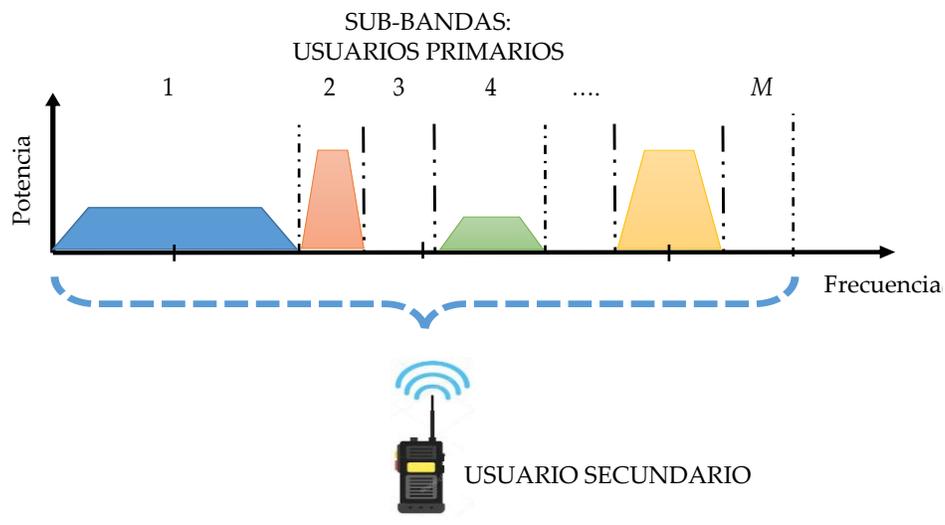


Figura 2. El concepto de monitorización multibanda en RC presentado en [6].

1.2 Objetivos del proyecto

1.2.1 Objetivo general

- Diseñar una metodología que permita mejorar la monitorización del espectro multibanda de radios cognoscitivos mediante técnicas avanzadas de procesamiento digital de señales y aprendizaje maquina (ML, sigla del inglés *Machine Learning*).

1.2.2 Objetivos específicos

- Comprender los principios de la monitorización del espectro multibanda y su aplicación en los radios cognoscitivos.
- Comprender los principios de la dimensión fractal de Higuchi (DFH) y *wavelets*.
- Comprender los principios de diferentes técnicas de ML.
- Desarrollar un algoritmo para monitorización multibanda.
- Evaluar el desempeño del algoritmo seleccionado en la plataforma de desarrollo MATLAB.

1.3 Metodología de investigación

Los desafíos actuales en las comunicaciones inalámbricas nos incitan a indagar en soluciones no lineales, las cuales rompen con los enfoques tradicionales. Asimismo, se busca alcanzar la autonomía de los sistemas mediante la integración de inteligencia artificial como son los algoritmos de ML. Con fundamento en lo anterior, la metodología planteada para cumplir los objetivos y metas de este proyecto puede dividirse en dos partes.

La primera parte, corresponde a un estudio del estado del arte correspondiente a los esquemas de monitorización multibanda en RC. De este estudio se desprenden algunas técnicas no lineales tales como *compressed sensing* y dimensión fractal en la detección de UP (especialmente la de Sevcik) sin embargo quedan abiertas otras posibles técnicas no lineales como *sample entropy* u otro tipo de dimensión fractal. Por ello, se propone estudiar la DFH para la etapa de percepción en RC multibanda. Esta primera etapa concluye con el análisis, comparación e integración de una técnica de monitorización de espectro multibanda con base en la DFH. La segunda parte consiste en adaptar los resultados a un

modelo basado en ML, haciendo el correspondiente estudio de las diferentes técnicas de ML, lo cual también es novedoso.

1.4 Productos de investigación

Estancia de investigación, en la Universidad Politécnica de Cataluña – EETAC, con la Dra. Silvia Ruiz Boqué. Del 11 de febrero de 2019 al 17 de mayo 2019.

Artículo en revista indexada [7] con los siguientes metadatos. **Molina-Tenorio, Y.;** Prieto-Guerrero, A.; Aguilar-Gonzalez, R. A Novel Multiband Spectrum Sensing Method Based on Wavelets and the Higuchi Fractal Dimension. *Sensors* **2019**, *19*, 1322.

Artículo sometido el 06 de septiembre de 2019, próximo a ser aceptado. Machine learning techniques applied to multiband spectrum sensing in cognitive radios.

1.5 Estructura del documento

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. A lo largo de este trabajo de investigación se realizó un estudio del comportamiento del espectro radioeléctrico en nuestro entorno, los resultados de esta campaña de mediciones se muestran en el *Capítulo 4*. Las propuestas para las diferentes metodologías planteadas en este trabajo aparecen en el *Capítulo 5*, donde se describe el funcionamiento a detalle de cada una de ellas en sus diferentes etapas, mientras que los resultados obtenidos de cada metodología se encuentran en el *Capítulo 6*. Aquí se analiza, discute y compara el desempeño de cada una de ellas. Finalmente, en el *Capítulo 7* aparecen las conclusiones y se describe las perspectivas de investigación.

Capítulo 2

Antecedentes

El concepto de monitorización del espectro en RC puede ser dividido en dos casos: cuando la detección se hace en una banda y cuando es multibanda. Esta categorización se muestra en la *Figura 3*. En este capítulo se mencionan las técnicas más comunes para la percepción en una banda y para la detección multibanda se hace una pequeña descripción de su funcionamiento, así como algunas técnicas que destacan. En las siguientes secciones se hace una pequeña descripción del funcionamiento, ventajas y desventajas de las técnicas de monitorización encontradas en la literatura.

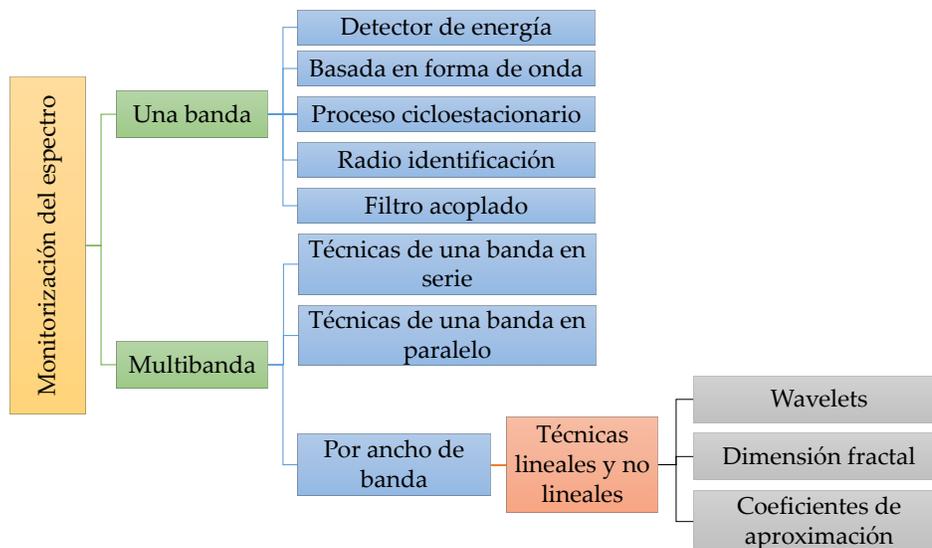


Figura 3. Clasificación de las técnicas de monitorización.

2.1 Monitorización del espectro en una banda

A continuación se mencionan las principales técnicas para la detección de UP en el espacio radioeléctrico en una determinada banda.

2.1.1 Detector de energía

Es la forma más común de monitorización de espectro debido a su baja complejidad computacional e implementación. Además, los receptores no necesitan ningún conocimiento sobre la señal de los UP [8]. La señal se detecta comparando la salida del

detector de energía con un umbral que depende del ruido de piso, i.e. la razón señal a ruido (SNR, sigla del inglés *Signal to Noise Ratio*) presente. Algunos de los desafíos con la monitorización basada en este detector incluyen la selección del umbral para detectar a un UP y la capacidad para diferenciar la transmisión de UP y el ruido (ruido impulsivo).

2.1.2 Basada en forma de onda

Algunos patrones conocidos se utilizan generalmente en sistemas inalámbricos para ayudar a la sincronización, tales como portadoras piloto transmitidos con regularidad, secuencias de expansión, etc. Con base en esto la monitorización puede realizarse correlacionando la señal recibida con una copia conocida de estos patrones, y se denomina monitorización basada en formas de onda o monitorización coherente. En [9] se menciona que este tipo de monitorización supera la basada en el detector de energía en confiabilidad. Además, se muestra que el rendimiento del algoritmo de monitorización aumenta a medida que aumenta la longitud del patrón de señal conocido.

2.1.3 Basada en proceso cicloestacionario

La extracción de características de un proceso cicloestacionario es un método para detectar transmisiones de los UP explotando las características de un proceso cicloestacionario (señales recibidas) causadas por la periodicidad en la señal o en sus estadísticas como media y autocorrelación [8]. Estas pueden ser inducidas intencionalmente como el prefijo cíclico en señales OFDM (sigla del inglés *orthogonal frequency division multiplexing* 'acceso múltiple por división de frecuencias ortogonales'). En lugar de la densidad espectral de potencia, la función de correlación (o correlación espectral) se utiliza para detectar periodicidades, presentes en un espectro determinado, además, se puede utilizar para distinguir entre diferentes tipos de transmisiones y UP.

2.1.4 Basada en radio identificación

Se puede obtener un conocimiento completo sobre las características del espectro identificando las tecnologías de transmisión utilizadas por los UP. Tal identificación permite que el RC tenga un conocimiento dimensional más elevado y proporcione una mayor precisión [10]. El RC puede querer comunicarse con los sistemas de comunicación identificados en algunas aplicaciones. En [11] mencionan que el objetivo es identificar la presencia de algunas tecnologías de transmisión conocidas y lograr la comunicación a través de ellas. Las dos tareas principales son la identificación de modo inicial donde el RC busca un posible modo de transmisión, luego del encendido y la supervisión de modo

alternativo, es la tarea de monitorizar otros modos mientras el dispositivo cognoscitivo se está comunicando.

2.1.5 Por filtro acoplado

En [12] se menciona que esta técnica es el método ideal para monitorización cuando se conoce la señal transmitida por el UP. Esta técnica según [13] utiliza un corto tiempo para lograr una cierta probabilidad de falsa alarma o probabilidad de detección. Es por ello que se requiere un conocimiento perfecto de las características de la transmisión de los UP, como ancho de banda, tipo y orden de modulación, etc. Además, dado que el RC necesita receptores para todos los tipos de señal, la complejidad de implementación de la unidad de monitorización es imprácticamente grande. Otra desventaja es el gran consumo de energía ya que varios algoritmos de receptor deben ejecutarse al mismo tiempo.

2.2 Redes cooperativas de radios cognoscitivos

En [14] se propone la monitorización cooperativa del espectro a través de una red de RC centralizada que consta de un punto de acceso o estación base y un número de usuarios de RC. En esta red, cada usuario de RC envía sus datos de monitorización a la estación base periódicamente a través de los canales de control, mientras la estación base combina los datos de monitorización de diferentes usuarios de RC y toma una decisión sobre la presencia o ausencia del UP.

En [6] muestran que uno de los desafíos comunes en los sistemas de comunicación inalámbrica es el problema de terminal oculta. Este fenómeno surge debido a la ubicación aleatoria de las terminales donde el US puede ser cubierto por un objeto. Por ejemplo, en la *Figura 4*, el US1 es oculto por un edificio, entonces, decidiría que hay una oportunidad de espectro a pesar de que el UP está presente. Por el contrario, el US2 colabora con el US3, y se da cuenta de la presencia del UP a través de la información compartida del US3. Por lo tanto, puede notificar al US1 que no acceda al espectro para evitar la interferencia con el UP. Este es el principio básico de la monitorización cooperativa donde los US en una determinada región geográfica cooperarían entre sí para mejorar efectivamente la fiabilidad de la monitorización. Sin embargo, uno de los problemas clave en las comunicaciones cooperativas es cómo combinar la información recopilada de los US participantes, como se muestra en la *Figura 4*. En [6] se mencionan tres técnicas principales para las redes cooperativas de RC: combinación dura, combinación suave y combinación híbrida.

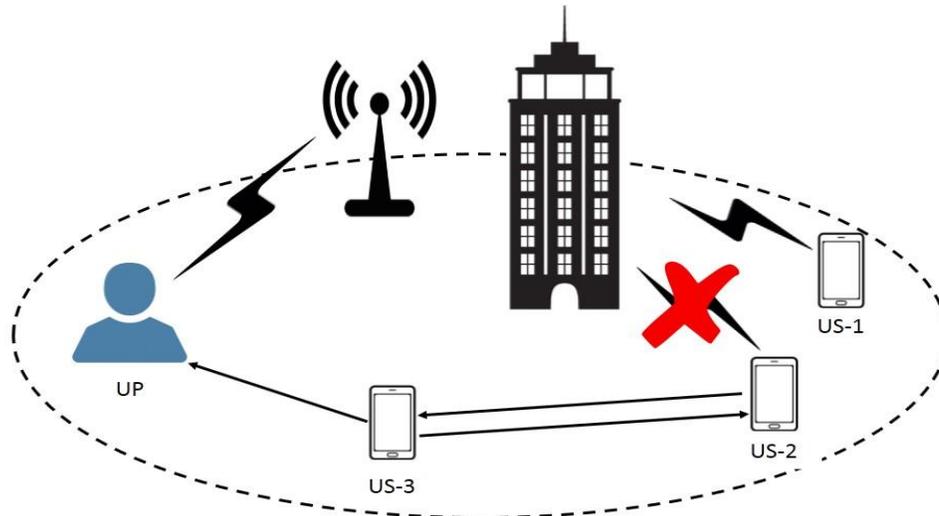


Figura 4. La cooperación entre US para mejorar la detección del UP, obtenida de [6].

Combinación dura: En esta técnica, el US simplemente envía su decisión final de un bit a los otros US, $\langle\langle 0 \rangle\rangle$ y $\langle\langle 1 \rangle\rangle$ indican la ausencia y la presencia de UP, respectivamente.

Combinación suave: En esta técnica, el US comparte su información de monitorización original (o las estadísticas originales) con los otros US sin procesarlas localmente. Se muestra que la combinación óptima se basa realmente en la suma ponderada de las estadísticas observadas del US colaborativas.

Combinación híbrida: Esta técnica surge a partir de las dos técnicas anteriores. En ella, el US envía sobrecarga de dos bits en lugar de uno. Esto proporciona un buen equilibrio entre los esquemas de combinación dura y suave. En general, aumentar la cantidad de bits mejorará el rendimiento a expensas de una sobrecarga mayor. En [14] mencionan tres umbrales en el esquema de dos bits, λ_1 , λ_2 y λ_3 , dividen el rango completo de la energía observada en 4 regiones. Por lo tanto los bits indican en qué región cae su energía.

2.3 Monitorización del espectro multibanda

Una primera introducción al concepto de detección de espectro multibanda aparece en [15]. 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 [16] 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 [17] 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 [6] se presenta un punto de vista moderno 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*, los autores mencionaron que este método proporciona un buen análisis de las singularidades del espectro. En [18] 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 [19], aquí se considera la correlación de canales para adaptar la propuesta a escenarios prácticos como la televisión abierta. En [20], se presenta un método de acceso probabilístico en la detección de espectro multibanda. Los autores clasifican la ocupación del espectro como probable. Sus resultados muestran cómo esta clasificación mejora las tasas de datos en comparación con los métodos de detección de espectro clásicos.

En el caso de la Internet de las cosas (IoT, sigla 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 [21] 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 contribuciones de detección de espectro similares.

Las técnicas de monitorización del espectro multibanda se pueden clasificar y generalizar en tres grandes grupos, a saber: en serie, en paralelo y por ancho de banda [22]. En la **Tabla 1**, se muestran las técnicas más comunes incluidas en estos tres grandes grupos.

Tabla 1. Técnicas de monitorización del espectro multibanda más comunes [6].

Categoría	Técnica de monitorización	Ventajas	Inconvenientes
Monitorización del espectro en serie	Filtro pasa banda reconfigurable [23]	Sencillo	Alta tasa de muestreo, procesamiento lento
	Oscilador sintonizable	Reduce la tasa de muestreo	Procesamiento lento debido al barrido
	Monitorización en dos etapas [24]	Monitorización rápida y detección mejorada	Complejo y costoso
	Detector ágil [25]	Monitorización rápida y detección mejorada	Complejo y costoso
Monitorización del espectro en paralelo	Banco de filtros [26]	Relativamente sencillo	Costoso
	Basada en frecuencia	Detección mejorada	Complejo y costoso
Monitorización del espectro por ancho de banda	Basada en <i>Wavelets</i> [27]	Usada cuando las fronteras son desconocidas	Podría detectar falsos bordes ²
	<i>Compressed sensing</i> [28]	Reduce notoriamente la tasa de muestreo	Requiere conocimiento de la señal
	Basada en ángulo [29]	Explora nuevas dimensiones para el acceso al espectro	Requiere un sistema multi-antena
	Técnicas ciegas [14]	Buena en la ausencia de conocimiento previo	Requiere buenas técnicas de estimación
	Estrategias aleatorias, persistentes y adaptativas [18]	Limitación en <i>hardware</i>	Detecta una pequeña porción del espectro multibanda
	Cooperativa basada en DFS [30]	Detección estable en el caso de incertidumbre de ruido	Complejidad computacional
	Basada en transformada continua de <i>wavelet</i> y DFH [7]	Sin conocimiento previo, precisión para colocar al US, usada para fronteras desconocidas	Complejidad computacional y alto tiempo de ejecución.
	Basada en coeficientes de aproximación y DFH [7]	Sin conocimiento previo, precisión para colocar al US, usada para fronteras desconocidas	Complejidad computacional

² Se explica en la sección 2.3.3

2.3.1 En serie

Es esencialmente un detector de banda única que monitoriza secuencialmente múltiples bandas, una a la vez. Esta técnica es relativamente lenta y requiere filtros y osciladores sintonizables. Cualquiera de los detectores de una banda mencionados en la *Sección 2.1* se pueden usar para detectar múltiples bandas, una por una, junto con alguna de las técnicas descritas a continuación [6].

Filtro paso banda reconfigurable

Se basa en implementación de un filtro paso banda reconfigurable en el *front-end* del receptor para seleccionar una banda a la vez, y luego se usa un detector de una banda para determinar si ésta en particular está ocupada. Claramente, esto requiere un *front-end* de receptor de banda ancha, que implica varios desafíos en la implementación del *hardware*: altas frecuencias de muestreo, control de las frecuencias de corte y el ancho de banda de los filtros.

Oscilador sintonizable

Está basado en un oscilador local sintonizable que convierte la frecuencia central de una banda a una frecuencia intermedia fija. Esto reduce significativamente el requisito de una tasa de muestreo. La principal limitación de los filtros paso banda reconfigurables y los osciladores sintonizables es que requieren afinación y barrido a medida que la monitorización se mueve de un canal al siguiente. Esto dificulta el procesamiento rápido, y por lo tanto estas técnicas pueden ser imprácticas.

Monitorización de dos etapas

Otra propuesta para la monitorización del espectro consiste en realizarla en dos etapas. Primero se realiza una monitorización aproximada y si es necesario una etapa de monitorización fina. Por ejemplo, un detector de energía en ambas etapas. En la etapa burda, se realiza una búsqueda rápida en un amplio ancho de banda, y en la etapa fina, la monitorización se realiza una a la vez sobre las subbandas individuales candidatas en ese ancho de banda. La monitorización del espectro en dos etapas proporciona un tiempo de búsqueda más rápido en comparación con los algoritmos de búsqueda basados en una etapa cuando la actividad del UP es alta. La etapa burda se basa en la monitorización de energía debido a su procesamiento rápido. Si las estadísticas de prueba son más grandes que un umbral predefinido, entonces la banda se considera ocupada. De lo contrario, se

realiza una etapa fina en la que se implementa un detector cicloestacionario u otro, debido a su robustez en el régimen de baja SNR.

2.3.2 En paralelo

Se habilita al equipar el receptor del US con múltiples detectores de banda única. Los detectores funcionan en paralelo de modo que cada uno de ellos detecta una sola banda. El procesamiento de múltiples canales en paralelo proporciona una monitorización más rápida, en comparación con la detección en serie. Sin embargo, la estructura del receptor es más grande, más compleja y más costosa debido a que se deben implementar múltiples detectores en el mismo dispositivo, aún más si los detectores no son del mismo tipo.

2.3.3 Por banda ancha

En esta categoría se incluyen detectores específicos de banda ancha como la técnica basada en *wavelets*, la técnica *compressed sensing*, etc. En este caso el US debe explorar un amplio espectro para explotar más oportunidades espectrales. Por lo tanto, el problema de monitorización multibanda es esencialmente detectar múltiples subcanales.

Basada en wavelets

Una de las suposiciones que se han hecho en las técnicas antes mencionadas es que el US conoce el número de subbandas M y sus ubicaciones correspondientes en la frecuencia. Sin embargo, en la práctica, esta suposición no es adecuada debido a que el RC debe ser capaz de soportar tecnologías heterogéneas que tienen diferentes requisitos (por ejemplo, esquemas de transmisión, ancho de banda, etc.). Para superar este problema, los detectores basados en *wavelets* se han convertido en un buen candidato debido a su capacidad para detectar y analizar las singularidades en el espectro. Estas singularidades, tienen interpretaciones importantes ya que ocurren en los bordes de las subbandas (es decir, cuando pasamos de una banda a las bandas vecinas).

Basada en la técnica compressed sensing

Convencionalmente, para reconstruir con éxito la señal recibida, la frecuencia de muestreo debe ser al menos dos veces la componente de frecuencia máxima en la señal (también conocida como tasa de Nyquist). *Compressed sensing* se ha convertido en un área activa de investigación debido a su capacidad de reducir tangiblemente la velocidad de muestreo cuando la señal es escasa en un dominio determinado. La dispersión de la señal

en el dominio de la frecuencia indica que tiene componentes de frecuencia relativamente menos importantes en comparación con su ancho de banda. En otras palabras, tiene una tasa de información menor en comparación con su tasa Nyquist, el número de muestras es proporcional a la velocidad de información de la señal, no a su tasa Nyquist. Dado que el espectro de banda ancha no se utiliza adecuadamente, o es escaso en el dominio de frecuencia, entonces *compressed sensing* parece ser un buen candidato para la monitorización del espectro multibanda.

Monitorización basada en ángulo

Las técnicas de monitorización de espectro más comunes se utilizan para explotar las oportunidades disponibles en tiempo, frecuencia o espacio. Es decir, no todos los subcanales están ocupados al mismo tiempo (oportunidad en el dominio de la frecuencia), no todos están ocupados permanentemente (oportunidad en el dominio del tiempo), y debido a las pérdidas de propagación en los canales inalámbricos, los mismos canales pueden reutilizarse en diferentes regiones geográficas (oportunidad en el espacio). Se perfila un acceso oportunista multidimensional donde podrían explotarse nuevas dimensiones, como el dominio de dirección de llegada. El principio básico es que, si el US tiene conocimiento del ángulo azimutal del UP, entonces cuando el UP transmite en una cierta dirección, el US puede transmitir simultáneamente en otra dirección, sobre la misma banda y área geográfica.

Estrategias aleatorias, persistentes y adaptativas para la monitorización

En [18] abordan la limitación de *hardware* en el US, lo que hace que la monitorización de espectro multibanda sea más desafiante bajo limitación de *hardware* del US dado que solo puede detectar una pequeña porción del espectro multibanda durante un período de tiempo dado, lo que introduce un problema de diseño de selección de subcanales para detectar en un momento determinado. Este artículo presenta una estrategia de monitorización de espectro aleatorio para seleccionar los subcanales para detectar de forma totalmente aleatoria, bajo el supuesto que el UP se comporta con la propiedad de Markov, se propone otra estrategia persistente de monitorización de espectro. Finalmente, proponen una monitorización de espectro adaptativo, que determina cuál de las anteriores utilizar para la monitorización de espectro en un momento dado en función de los parámetros de tráfico del UP.

2.4 Redes cooperativas de RC multibanda

Las redes de radios cognoscitivos multibanda (RRC-MB) pueden mejorar significativamente el rendimiento de los US. En [6], los autores proponen RRC-MB en comunicaciones cooperativas. Múltiples US pueden compartir sus resultados de monitorización entre sí. Sin embargo, si cada US monitoriza un subconjunto de subcanales y luego comparte sus resultados con otros, entonces se puede detectar todo el espectro y en consecuencia, se exploran más oportunidades para el acceso al espectro. Esto es, en general, una tarea desafiante ya que las bandas disponibles no son necesariamente contiguas, y la actividad de los UP podría correlacionarse a través de estas bandas.

Capítulo 3

Marco teórico

En esta sección, se presentan brevemente los antecedentes necesarios asociados con las técnicas utilizadas en las metodologías propuestas en este trabajo de investigación.

3.1 Transformada continua de *wavelet*

La transformada continua de *wavelet* (TCW) de una función $f(x)$ se define como [31]:

$$TCW_f(s, \tau) = \int_{-\infty}^{\infty} f(x) \psi_{s, \tau}^*(x) dx \quad (1)$$

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 *wavelet* inicial $\psi(x)$, a veces llamada *wavelet* madre, definida por:

$$\psi_{s, \tau}(x) = \frac{1}{\sqrt{s}} \psi\left(\frac{x - \tau}{s}\right) \quad (2)$$

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 $s < 1$. De esta manera, se ofrece una alternativa a las representaciones de tiempo-frecuencia: el plano tiempo (o traslación) - escala. Esta representación es efectiva detectando singularidades o discontinuidades en la señal $f(x)$. Estas transiciones pueden ubicarse determinando el módulo máximo de la TCW, definido por:

$$\max\left[|TCW_f(s, \tau)|\right] \quad (3)$$

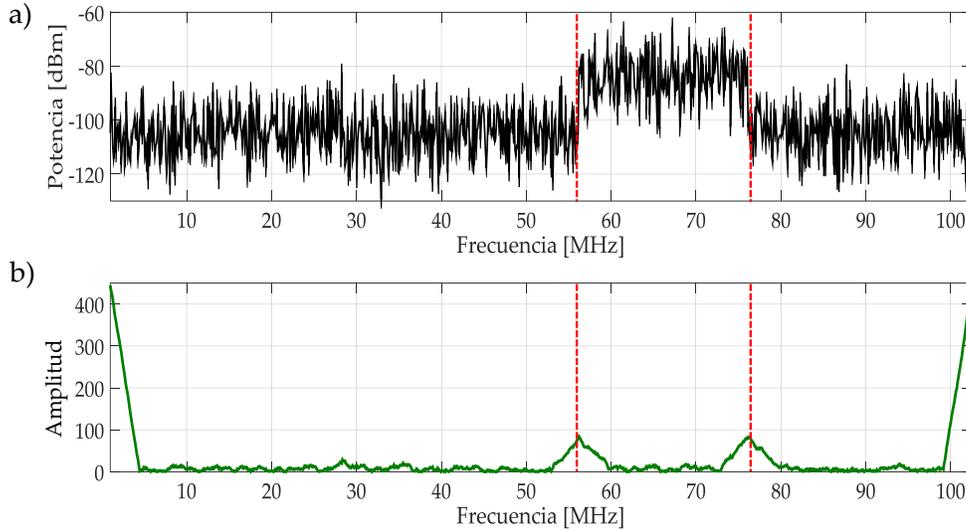


Figura 5. a) Señal sintetizada. b) Módulo máximo de la TCW.

Un claro ejemplo de la eficiencia del módulo máximo de la TCW en la detección de discontinuidades, se muestra en la *Figura 5 b)* que se ha aplicado a un espectro generado aleatoriamente (*Figura 5 a)*), con la *wavelet Haar* y una escala de 70. En esta figura se resaltan las singularidades de la señal con líneas discontinuas en color rojo, localizadas justamente donde ocurre una transición (transmisión del UP). Esta herramienta matemática es muy utilizada en muchos dominios diferentes como el procesamiento de imágenes, control, la ingeniería biomédica. En el caso específico de la detección del espectro en RC, esta técnica se considera efectiva para detectar los bordes del espectro multibanda [27], [32]–[35].

3.2 Análisis multiresolución

El análisis multiresolución (AMR) fue introducido por Mallat en 1989 [36]. Esta idea, que involucra espacios vectoriales incrustados o embebidos, permite descomponer (y reconstruir) una señal $f(x)$ utilizando una base ortonormal (o biortogonal). Esta idea compleja tiene una interpretación fácil a través de un banco de esquemas de filtros digitales, como se muestra en la *Figura 6*. La ecuación de descomposición viene dada por:

$$\begin{aligned}
 f(x) &= \text{aprox}_L(x) + \sum_{j=1}^L \text{detalle}_j(x) \\
 &= a_L(x) + \sum_{j=1}^L d_j(x)
 \end{aligned}
 \tag{4}$$

Donde $a_L(x)$ son los coeficientes de aproximación en el nivel L de descomposición y $d_j(x)$ son los coeficientes de los detalles que van desde los niveles 1 a L. De esta manera, la señal se filtra en octavas (es decir, cada banda se divide en dos iterativamente). Los coeficientes de aproximación permiten, en el proceso de reconstrucción, tener una versión uniforme de la señal original $f(x)$. Los coeficientes de detalle dan a la señal reconstruida las características finas. Basándose en estas propiedades, el AMR se puede utilizar en la etapa de monitorización para obtener la tendencia del espectro multibanda de los coeficientes de aproximación, eliminando, en el proceso de reconstrucción, la contribución de los coeficientes de detalle (que contienen el ruido agregado a la señal transmitida o simplemente el ruido de piso).

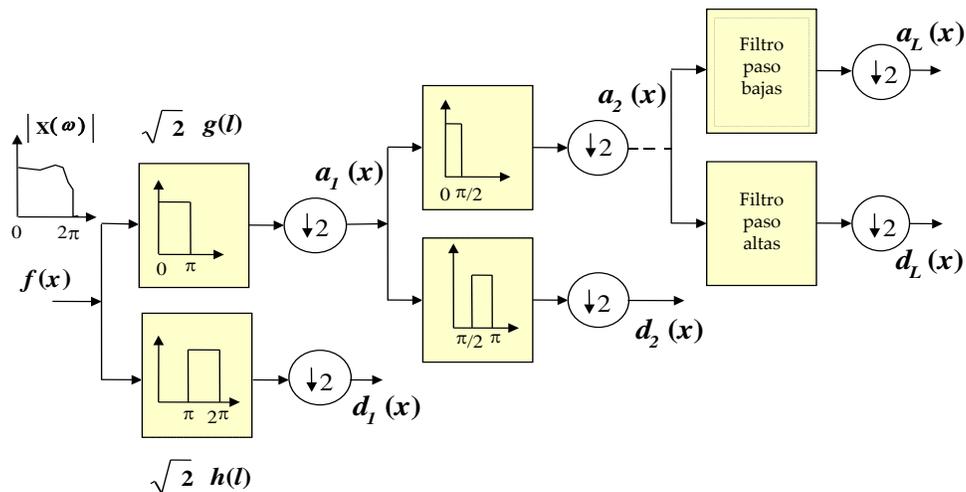


Figura 6. Implementación del AMR basado en un banco de filtros.

AMR se implementa utilizando un algoritmo rápido llamado *à trous*. 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 7** 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 como utilizando únicamente los coeficientes de aproximación, la reconstrucción

de la señal a partir de estos, permite obtener la tendencia de la misma. Esta propiedad será de gran utilidad en la propuesta metodológica de este proyecto de investigación.

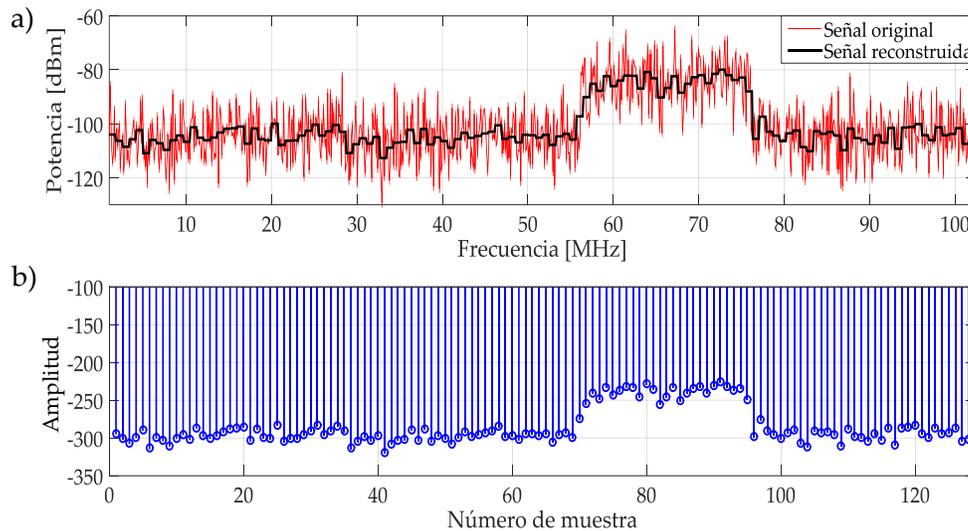


Figura 7. a) Señal original y señal reconstruida a partir únicamente de los coeficientes de aproximación. b) Coeficientes de aproximación en el nivel 3.

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 conjunto [37]. La dimensión fractal es un índice que describe la regularidad de una serie de tiempo (en general, un vector de N puntos ordenados secuencialmente). Higuchi [38] modifica el método propuesto en [39] para calcular la dimensión fractal y aplicarlo no sólo a los datos simulados, sino también a series temporales derivadas de fenómenos naturales con comportamiento turbulento, obteniendo un valor estable de la dimensión fractal.

La DFH devuelve un valor en el intervalo $[1, 2]$, donde el valor máximo significa que la serie evaluada no tiene una similitud consigo misma (completamente irregular). Sin embargo, para el valor mínimo, la auto-similitud en la serie evaluada es grande (por ejemplo, una señal periódica). A partir de simulaciones, la DFH para una señal similar a un ruido blanco (*Figura 8 a*) será un valor que tiende a 2. Esta característica importante es la base de la regla de decisión propuesta en este trabajo para diferenciar la transmisión del UP del ruido en sí. De hecho, al ignorar el efecto de un ruido gaussiano aditivo en una transmisión del UP, las transmisiones inalámbricas clásicas tienen formas que pueden considerarse regulares: un pulso NRZ (sigla del inglés *non return to zero* 'sin retorno a cero') asociado a CDMA (sigla del inglés *Code Division Multiple Access* 'acceso múltiple por

división de código') tiene un espectro que asemeja a un seno cardinal y un símbolo OFDM, en la recepción tiene una forma de un pulso con pequeños cambios a lo largo de su ancho de banda. De esta manera, la aplicación de la DFH a estas transmisiones regulares (**Figura 8 b**)), en general, tendrá un valor cercano a 1, lo que permitirá al US diferenciar claramente el ruido de una transmisión de un UP. Esta premisa se verifica con simulaciones detalladas presentadas en el **Capítulo 6**.

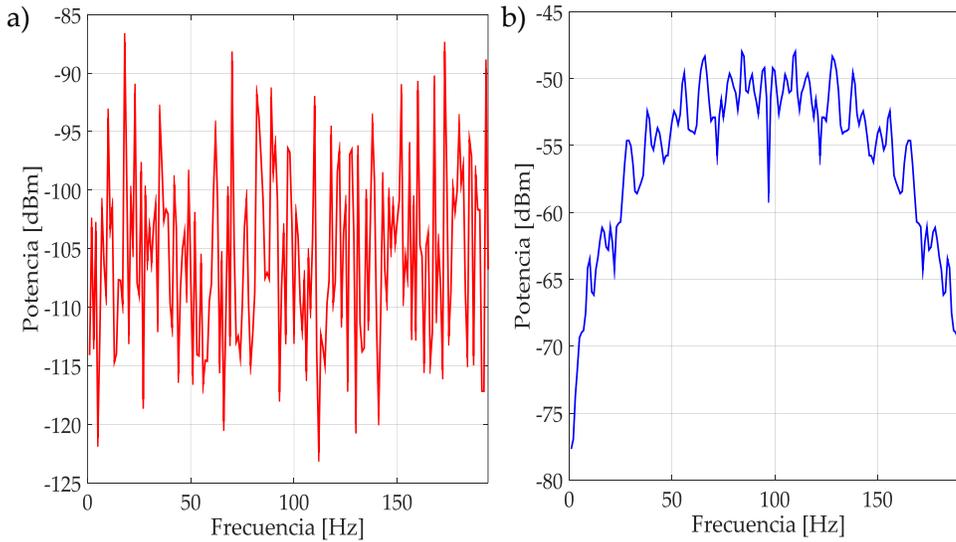


Figura 8. a) Ruido blanco con valor de 1.96 para la DFH. b) Símbolo NRZ-CDMA con valor 1.5 para la DFH.

El método propuesto por Higuchi [38] considera una serie temporal de N puntos (o 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 definida por:

$$x_k^m = \left\{ x(m), x(m+k), x(m+2k), \dots, x\left(m + \left\lceil \frac{N-m}{k} \right\rceil k\right) \right\} \quad m = 1, 2, \dots, k \quad (5)$$

Donde el símbolo $\lceil \cdot \rceil$ denota la parte entera, y tanto k como m son enteros que indican el tiempo inicial y el intervalo de tiempo, respectivamente. La pendiente de la curva en la ec. (5), en una escala logarítmica, corresponde a la DFH:

$$L_m(k) = \left\{ \frac{N-1}{\left\lceil \frac{N-m}{k} \right\rceil k} \left(\sum_{i=1}^{\left\lceil \frac{N-m}{k} \right\rceil} |x(m+ik) - x(m+(i-1)k)| \right) \right\} / k \quad (6)$$

3.4 Machine learning

ML se puede definir como un campo de estudio que le da a los dispositivos la capacidad de aprender sin ser programados explícitamente. Los métodos de ML proporcionan un análisis profundo y predictivo de los datos cuando el conjunto es grande, diverso y cambia rápidamente [40]. En esta sección se mencionan diferentes técnicas de clasificación de ML que han sido adaptadas a la monitorización del espectro multibanda. La mayoría de estos clasificadores destacan por su baja complejidad computacional (bajo tiempo de ejecución) y su fácil implementación.

3.4.1 Redes neuronales

Las redes neuronales (NN, sigla del inglés *neural network*) artificiales son modelos computacionales inspirados por el sistema nervioso central específicamente en el cerebro, tienen la capacidad de realizar el reconocimiento de patrones. Las NN generalmente se presentan como sistemas de "neuronas" interconectadas que pueden calcular valores de las entradas al suministrar información a través de la red [41]. Las NN son algoritmos supervisados que requieren entrenamiento con datos etiquetados. Estas redes se basan en la minimización de riesgos empíricos y requieren un conocimiento previo de la distribución del proceso observado. La **Figura 9** muestra una NN, consiste en una capa de entrada, una capa oculta y una capa de salida. Se utiliza una NN tanto para la clasificación como para la predicción considerando el algoritmo de propagación hacia atrás por el ajuste de peso de cada borde de las capas. En la actualidad, las NN suelen ser una tendencia en los sistemas de software, por ello, en la **Sección 5.4.1** y **5.4.2** son utilizadas para catalogar los coeficientes de aproximación.

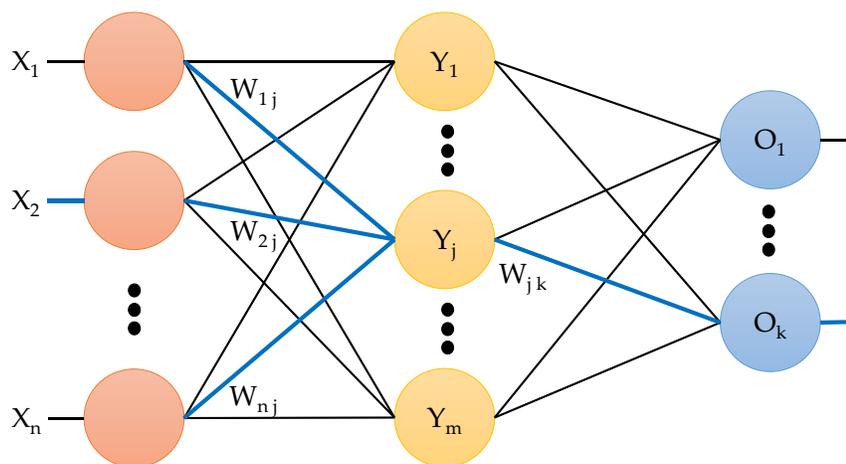


Figura 9. Red neuronal.

3.4.2 Expectation maximization

El algoritmo expectation maximization (EM) consta de dos pasos principales: un paso de expectativa, seguido de un paso de maximización. La esperanza se da respecto a las variables subyacentes desconocidas, utilizando la estimación actual de los parámetros y condicionada a las observaciones. El paso de maximización proporciona una nueva estimación de los parámetros. Estos dos pasos son iterados hasta la convergencia. El algoritmo EM fue desarrollado y empleado de forma independiente por varios investigadores diferentes. Sin embargo, los autores de [42] reunieron las ideas, demostraron la convergencia y acuñaron el término "algoritmo EM". En este documento, el algoritmo de EM se utiliza para separar dos posibles eventos. En la *Sección 5.4.2* se utiliza este algoritmo para clasificar los n coeficientes de aproximación (x_1, \dots, x_n) en 2 grupos, es por ello que se crean 2 Gaussianas con media y varianza aleatoria $G_A(\mu_A, \sigma_A^2)$; $G_B(\mu_B, \sigma_B^2)$ (A para describir las posibles transmisiones de un UP y B para describir el ruido gaussiano). Para cada punto x_i (coeficientes de aproximación), se calcula $P(b|x_i)$ además $P(b)$ es la probabilidad de ocurra una transmisión del UP y $P(a)$ que no exista transmisión de UP (es decir, solo sea ruido).

$$P(\mathbf{b}|x_i) = \frac{P(x_i | \mathbf{b}) P(\mathbf{b})}{P(x_i | \mathbf{b}) P(\mathbf{b}) + P(x_i | \mathbf{a}) P(\mathbf{a})} \quad (7)$$

$$P(x_i | \mathbf{b}) = \frac{1}{\sqrt{2\pi\sigma_B^2}} \exp\left(-\frac{(x_i - \mu_B)^2}{2\sigma_B^2}\right) \quad (8)$$

Recalculando (μ_B, σ_B^2) para G_B .

$$\mu_B = \frac{P(b_1)x_1 + \dots + P(b_n)x_n}{P(b_1) + \dots + P(b_n)} \quad (9)$$

$$\sigma_B^2 = \frac{P(b_1)(x_1 - \mu_B)^2 + \dots + P(b_n)(x_n - \mu_B)^2}{P(b_1) + \dots + P(b_n)} \quad (10)$$

Análogamente con (μ_A, σ_A^2) para G_A . Este algoritmo fue utilizado por su simplicidad para ser implementado. Más adelante se explicará cómo este método permite seleccionar un umbral para la etapa de entrenamiento de una NN.

3.4.3 *K-means*

El algoritmo *K-means* permite la clasificación de un conjunto de datos. Este algoritmo requiere un conocimiento previo del número de grupos (K) a clasificar. *K-means* define K número de centroides, encuentra una partición que minimiza el error cuadrado entre la media empírica del centroide de un grupo y los puntos en el grupo. Esto para cada clase o grupo. Iterativamente, recalcula el centroide de cada grupo hasta encontrar una partición que permita alcanzar la convergencia [43]. En [44] mencionan que podría converger al óptimo global cuando los grupos están bien separados, ya que por lo general siempre converge a un óptimo local. *K-means* pudiera parecer el clasificador más “débil” por la necesidad de conocer explícitamente el número de grupos a clasificar. Sin embargo este algoritmo se complementa con un análisis de ancho de banda, con ello no será necesario indicar el número de clases (ver *Sección 5.4.3*).

3.4.4 *Dirichlet process Gaussian mixture model*

Dirichlet process Gaussian mixture model (DPGMM) es un clasificador no paramétrico, no supervisado que además no requiere un conocimiento previo del número de clases / grupos y puede estimar esta cantidad a partir de los datos observados en sí mismos. El algoritmo DPGMM se puede aplicar para problemas de clasificación si se desconoce el número de grupos [45]. Esta técnica destaca sobre las anteriores por su generalidad para clasificar sin conocimiento previo del número de clases. El desempeño de esta técnica fue adaptado a la detección multibanda y se muestra en la *Sección 5.4.4*.

Capítulo 4

Campaña de medición

Al inicio de este trabajo de investigación, se hizo un estudio para analizar el comportamiento del espacio radioeléctrico de nuestro entorno, con la finalidad de obtener señales reales y caracterizar el espectro multibanda. Esta campaña consto de dos etapas y se realizó en la Universidad Autónoma Metropolitana unidad Iztapalapa. El grado de ocupación de cada intervalo en frecuencia se determina mediante el ciclo de trabajo (CT) siendo el porcentaje de ocupación por minuto para cierta frecuencia (es decir, para un ancho de banda, qué porcentaje de un minuto ha sido utilizado por un UP) [46]. Esto se determinó considerando un umbral en -80 dBm. Los datos se recabaron con un analizador de espectro N9343C, obteniendo 461 muestras por trama cada 100 ms con una antena hiperLOG direccional con ganancia de 5 dBi.

La primera etapa de esta campaña de medición tuvo lugar en el edificio T- 3er piso y se estudió el intervalo de frecuencia de [0.6 - 2.6] GHz durante una semana completa. En la *Figura 10* se muestra el CT de esta primera etapa, donde destaca la variabilidad de uso de las múltiples bandas observadas en función del tiempo. Esto motivó a implementar una segunda etapa, basada en un estudio de bandas específicas indicadas en la *Tabla 2* y su respectiva asignación [1].

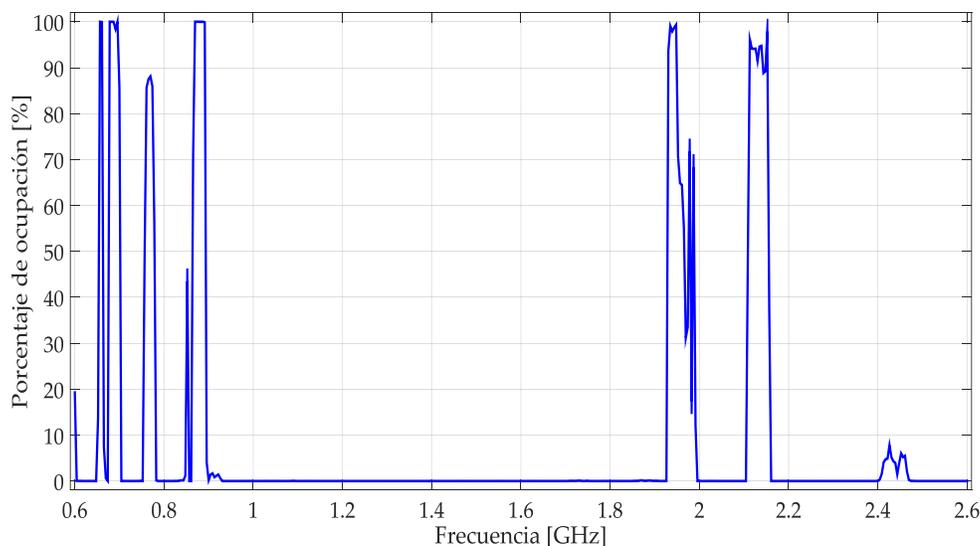


Figura 10. Porcentaje de ocupación de una semana en el intervalo de frecuencia [0.6 - 2.6] GHz.

Tabla 2. Bandas de frecuencia monitorizadas.

Banda de frecuencia	Tipo de comunicación
[698 – 806] MHz	Móvil y fijo.
[806 – 902] MHz	Móvil y móvil aeronáutico.
[902 – 928] MHz	Radiolocalización aficionado, móvil y fijo.
[1.7 – 2] GHz	Móvil y fijo.
[2.3 – 2.5] GHz	Radiolocalización aficionado móvil y fijo.
[2.6 – 2.8] GHz	Vehículos aéreos, radiolocalización, y radionavegación.

La segunda etapa se realizó en el edificio anexo de posgrado. Estas bandas específicas se estudiaron durante un día completo (ver *Figura 11-Figura 16*), y fueron elegidas por la oportunidad que tiene un US para colocarse en los posibles “huecos” espectrales, siendo buenas candidatas para implementar las técnicas de monitorización de espectro multibanda propuestas en el *Capítulo 5*.

En la *Figura 11* se muestra el comportamiento de una banda de uso exclusivo para móvil y fijo. En esta banda se puede observar que el CT no llega a 50 % durante todo el tiempo que fue monitorizada.

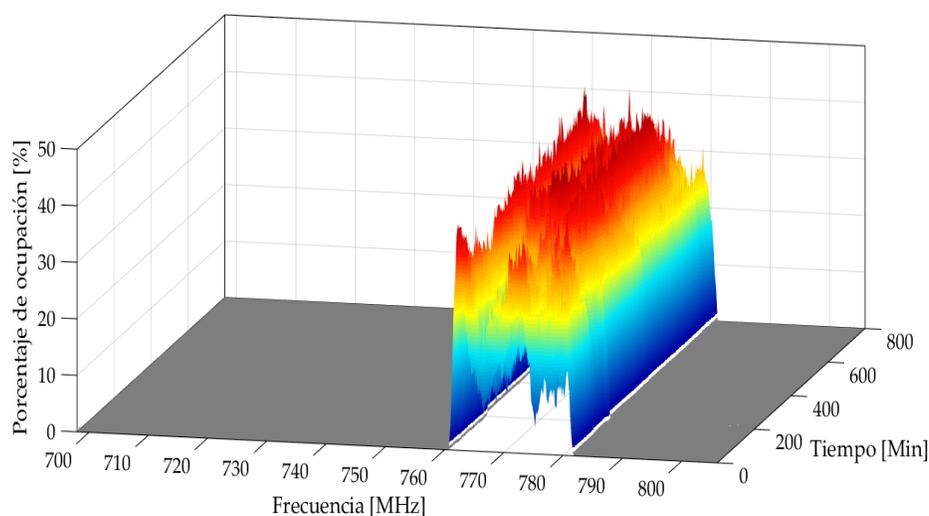


Figura 11. CT de un día de la banda [698 – 806] MHz.

El comportamiento de la banda de [806-902] MHz, mostrado en la *Figura 12*, es un claro ejemplo de un entorno multibanda ya que en diferentes lapsos de tiempo logran coexistir hasta 5 UP y a pesar que el intervalo [868-892] MHz suele estar ocupado por diferentes UP, existe la oportunidad para que un US pueda colocarse en los pequeños momentos que no transmiten los UP.

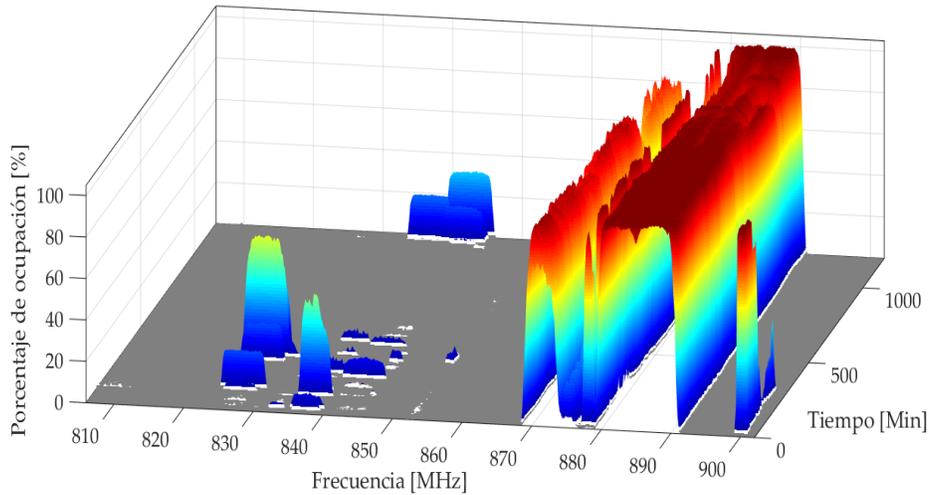


Figura 12. CT de un día de la banda [806-902] MHz.

En la *Figura 13* se muestra el comportamiento de una banda de uso exclusivo para radiolocalización, aficionado, móvil y fijo. Prácticamente solo existe ruido a lo largo de la señal ya que a lo largo del tiempo no se utiliza ni el 2 % de la misma. Se puede concluir que en el tiempo que se monitorizó solo se detectó ruido en sus diferentes formas.

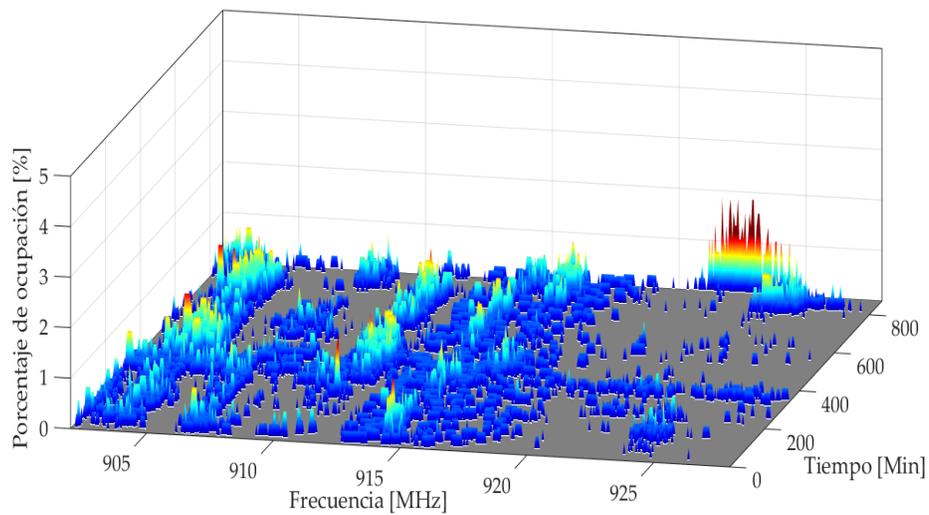


Figura 13. CT de un día de la banda [902-928] MHz.

En la **Figura 14** se muestra el comportamiento de una banda de uso exclusivo para móvil y fijo. Se muestra la coexistencia de múltiples UP y también la variabilidad de uso en el tiempo (oportunidad para los US) por parte de los UP.

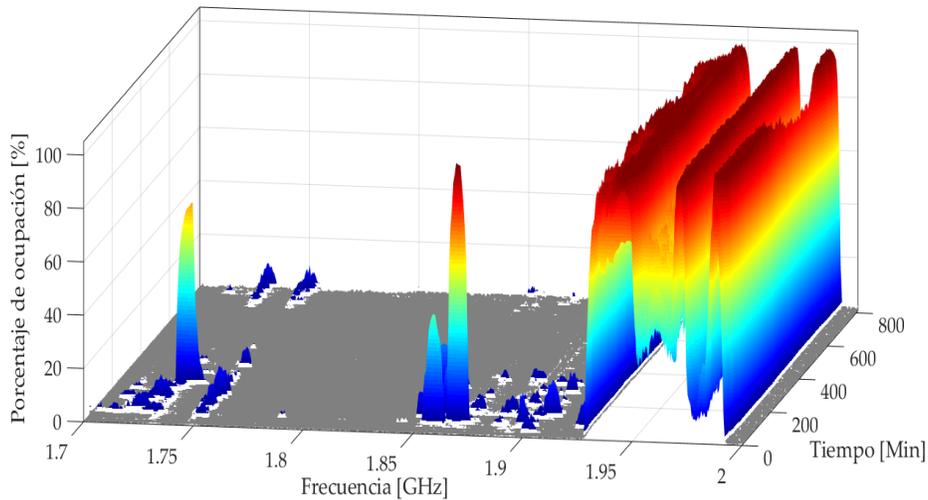


Figura 14. CT de un día de la banda [1.7-2] GHz.

El CT de la banda de [2.3-2.5] GHz que corresponde a uso exclusivo de radiolocalización, aficionado, móvil y fijo se muestra en la **Figura 15**. En esta figura se observa que alrededor de los 2.44 GHz el porcentaje de ocupación es bajo en la mayoría del tiempo, sin embargo en lapsos de tiempo a lo largo del día esta banda es más utilizada.

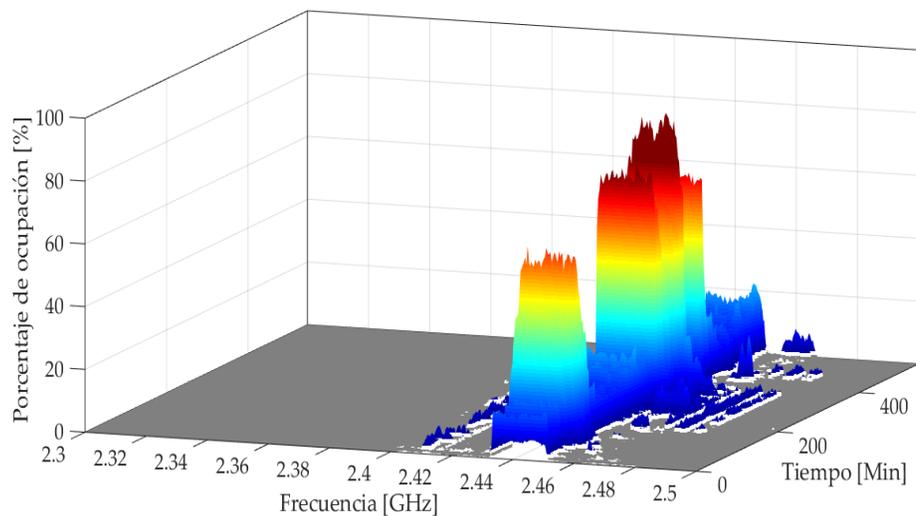


Figura 15. CT de un día de la banda [2.3-2.5] GHz.

En la *Figura 16* se muestra el comportamiento de una banda de uso exclusivo para vehículos aéreos, radiolocalización y radionavegación. Esta banda no alcanza el 80 % de uso durante un minuto durante todo el tiempo que fue monitorizada.

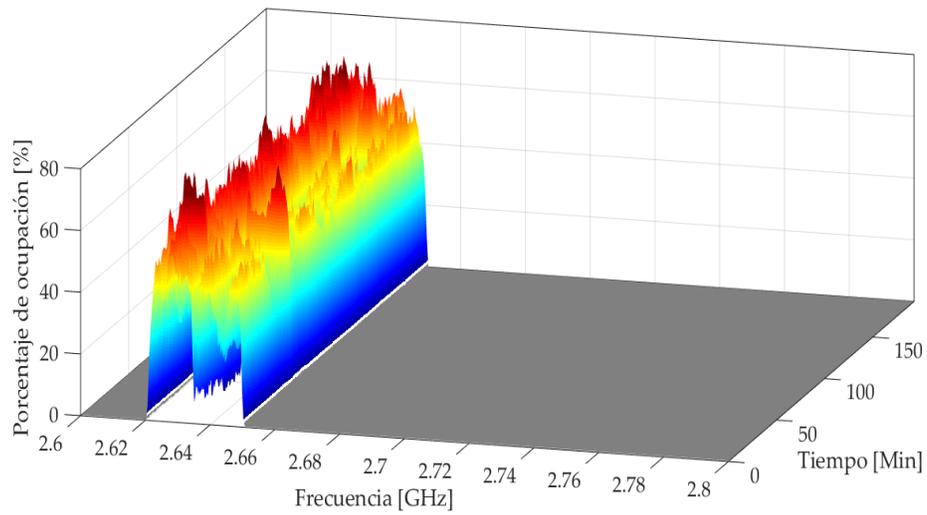


Figura 16. CT de un día de la banda [2.6-2.8] GHz.

Capítulo 5

Desarrollo metodológico

En este capítulo se presentan las técnicas implementadas para la monitorización multibanda de UP. Las metodologías propuestas en este trabajo permiten detectar la ocupación de múltiples bandas (o canales) e indicar perfectamente las frecuencias en las que se podría colocar un US, tal como se muestra en la *Figura 2*. Para ello, se considera un espectro de banda amplia que contiene M subbandas con posibles transmisiones de los UP. En esta propuesta de investigación se explora una combinación de la TCW [31], el AMR [36] y la DFH [38] para tal propósito. En la primera metodología, detallada en la *Sección 5.2*, se considera el módulo máximo de la TCW del espectro analizado. Este espectro, es reconstruido a partir de los coeficientes de aproximación obtenidos del AMR en un cierto nivel de descomposición. Esta señal reconstruida se usa para detectar las frecuencias (bordes) donde están ubicados los UP, generando así ventanas dinámicas donde se aplicará posteriormente una regla de decisión.

En la segunda metodología, descrita en la *Sección 5.3*, sólo se utilizan los coeficientes de aproximación del AMR para la detección de bordes de frecuencia. La regla de decisión, para ambas metodologías, se construye a partir de la aplicación del DFH sobre la misma señal reconstruida del AMR. La DFH permite detectar, como se mencionó anteriormente, perfectamente la presencia de un UP o su ausencia (solo detección de ruido) incluso en SNR bajas, como se muestra en los resultados derivados de señales reales y simuladas. El comportamiento de la DFH es bien conocido cuando se calcula en una señal similar a un ruido cuyo valor tiende a 2. Cuando la señal es más regular, como el caso de una senoide o un pulso rectangular, el valor de la DFH tiende a 1. De esta manera, es posible diferenciar el ruido de una señal de transmisión estableciendo un umbral correcto en la regla de decisión. Cabe mencionar que estas dos técnicas fueron propuestas e implementadas y los resultados fueron publicados en [7].

5.1 Técnicas relacionadas

Existen algunas propuestas relacionadas con las metodologías implementadas en este trabajo, especialmente utilizando la TCW a través de su módulo máximo para obtener los bordes que delimitan las diferentes subbandas [27] [33] [34]. Sin embargo, todos estos

trabajos basan su regla de decisión en la energía de los coeficientes lo cual presenta rendimientos bajos en SNR bajas (una característica bien conocida de los detectores de energía). Además, la detección de bordes también se ve afectada por el ruido de banda ancha en la señal de transmisión y por la aparición de ruido impulsivo (que genera detección de falsos bordes). En [32], se incluye el módulo máximo de la TCW para la detección de bordes, pero también el AMR para la regla de decisión. Esta regla se fundamenta en un detector de energía de los coeficientes de aproximación y de detalle del AMR, donde también se realiza el seguimiento de los máximos en el dominio discreto.

En [30], se propone un algoritmo de detección de espectro cooperativo de doble umbral basado en la Dimensión Fractal de Sevcik (DFS). En este trabajo, la idea principal es detectar la presencia de usuarios primarios analizando el espectro en función de las diferentes características de la DFS entre señales y ruido. Los resultados de las simulaciones muestran que el algoritmo puede lograr un alto rendimiento de detección con una SNR baja. Sin embargo, esta técnica sólo considera una banda, es decir, no es necesaria la detección de bordes de frecuencia. Además, el método se aplicó únicamente sobre señales simuladas.

En la *Sección 5.4*, se describe la metodología mencionada en la *Sección 5.3* utilizando técnicas de ML, específicamente (NN, EM, *K-means* y DPGMM), las cuatro son utilizadas como clasificadores de los coeficientes de aproximación obtenidos con el AMR para detectar la presencia de uno o varios UP. Algunos trabajos relacionados con esta propuesta, especialmente utilizando ML, son mencionados a continuación. En [47], los autores proponen un esquema cooperativo de detección de espectro basado en técnicas de ML. En el contexto de este esquema cooperativo, consideran un vector de energía como un vector de características donde cada componente es un nivel de energía estimado en cada dispositivo RC. Con base en esto, el clasificador ubica el vector de energía en una de dos clases: la clase de canal disponible (correspondiente al caso de que ningún UP está activo) y la clase de canal no disponible.

En [48], se ha propuesto una política de detección de espectro multibanda basada en un método codicioso para rastrear las estadísticas de ocupación del UP y para estimar el rendimiento de detección del US. Al emplear este método codicioso, la regla es capaz de seleccionar las subbandas que se detectarán y posiblemente se accederá a ellas, que brindan constantemente oportunidades de espectro con un alto rendimiento para la red secundaria. Este tipo de política también podría usarse para escanear simultáneamente más subbandas empleando US no asignados para detectar otras partes del espectro. En [49] el autor presenta una técnica para detectar la señal de un UP en un entorno

cognoscitivo utilizando un algoritmo de aprendizaje basado en una NN. En [50], se implementa un predictor de estado de canal para multi-US en un RC usando una NN.

El proceso de Dirichlet se ha utilizado como marco para el aprendizaje bayesiano no paramétrico en RC en [51]. En [52], se utilizó para identificar y clasificar los sistemas inalámbricos, según el proceso de restaurante chino (PRC). El método consiste en extraer dos características de las señales observadas y clasificarlos en un espacio de características mediante la adopción de una técnica de agrupación sin supervisión, basada en el PRC. El objetivo es identificar el número y los tipos de sistemas inalámbricos que existen en una determinada banda de frecuencia en un momento determinado. Una aplicación de esto se da cuando varios sistemas inalámbricos coexisten en la misma banda de frecuencia y tratan de comunicarse sin interferir entre sí.

5.2 Técnica de monitorización del espectro multibanda basada en la TCW y la DFH

La metodología de base propuesta en este trabajo de investigación se describe en los siguientes pasos:

- Paso 1. El espectro multibanda recibido por un US, $X(f)$, se descompone a través del AMR en el nivel L , lo que proporciona los coeficientes de aproximación y de detalle respectivos (ver *ec. (4)*).
- Paso 2. A partir de 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. El módulo máximo de la TCW se aplica a la señal $X_{app}(f)$ para obtener los bordes de frecuencia y crear las ventanas dinámicas (segmentos del espectro original) que serán utilizados en un análisis posterior.
- Paso 4. Cada ventana es procesada para detectar ruido o una posible transmisión de un UP. Por ello, los mismos coeficientes de aproximación obtenidos en el Paso 1 son normalizados e interpolados (para tener el mismo número de muestras que las ventanas dinámicas). Si los coeficientes de aproximación, normalizados

e interpolados (CNI) están en promedio, por debajo de un umbral predefinido de 0.7, entonces los valores de las ventanas analizadas corresponden a una transmisión de un UP. Si el valor promedio de los CNI es superior a 0.7, es altamente probable que la transmisión corresponda a ruido.

Paso 5. Si el valor de los CNI es superior a 0.7, la DFH se aplica directamente en la sección analizada del espectro multibanda $X(f)$. En otro caso, la DFH se aplica a la señal reconstruida del Paso 2, es decir a $X_{app}(f)$.

Paso 6. Para cada ventana, 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).

En la **Figura 17** se muestra el funcionamiento de esta primera metodología con un diagrama de bloques. Algunos detalles importantes, sobre la metodología propuesta, se discuten a continuación.

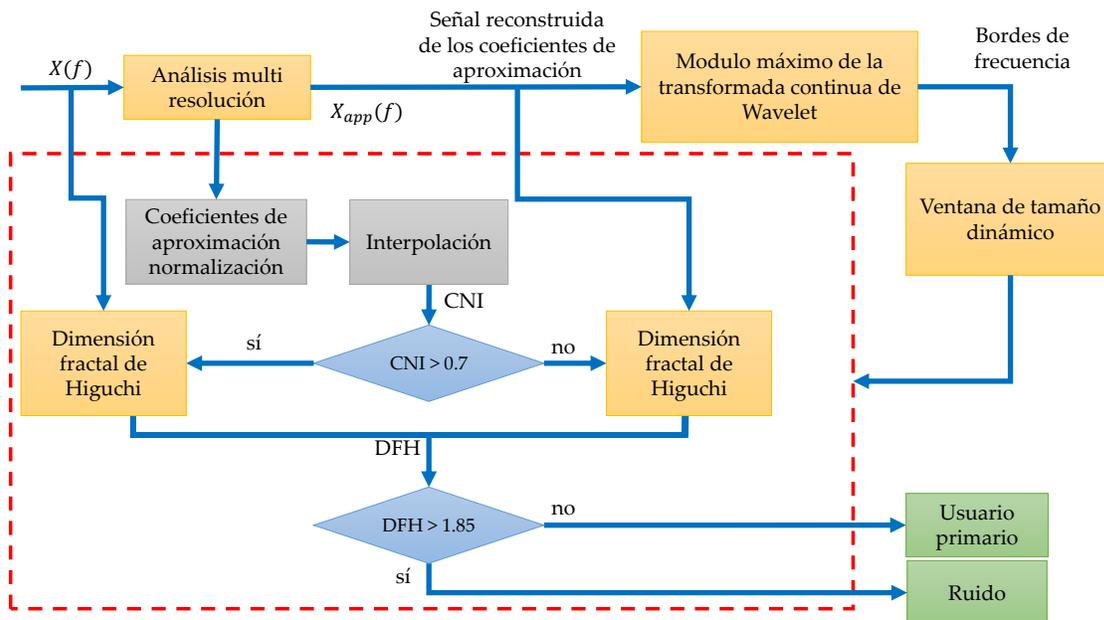


Figura 17. Esquema completo de la primera metodología propuesta.

En la **Figura 18**, se muestra una señal $X(f)$ que representa una densidad espectral de potencia en un amplio intervalo de frecuencias. Esta señal se descompone a través del AMR utilizando una *wavelet* "Haar" a un nivel de descomposición $L = 4$. La señal suave

resultante (indicada en la **Figura 18** como $X_{app}(f)$) es la señal reconstruida utilizando solo los coeficientes de aproximación (como se indica en el Paso 1). En esta figura se pueden apreciar cambios notables en la presencia de transmisión de los UP y la eliminación del ruido (Paso 2). De esta manera, mantener únicamente los coeficientes de aproximación, después de la reconstrucción, permite obtener la tendencia de la señal.

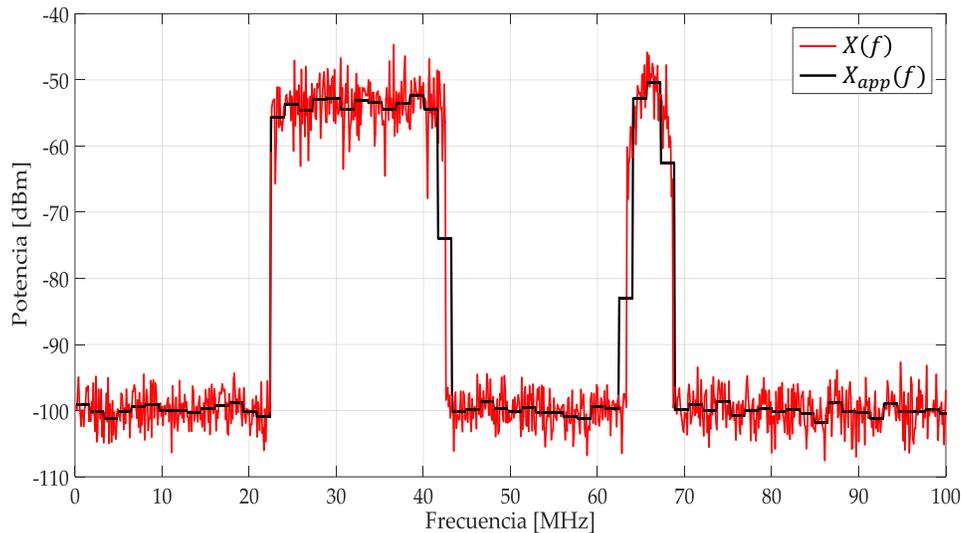


Figura 18. El resultado de aplicar AMR a $X(f)$.

En la **Figura 19** se muestra el resultado de aplicar el módulo máximo de la TCW a la señal $X_{app}(f)$ considerando una escala que va de 1 hasta 150. El propósito de usar el módulo máximo de la TCW es resaltar las discontinuidades de $X_{app}(f)$ en las que un posible UP esté transmitiendo. En este ejemplo se aprecia que para las escalas en el intervalo [1, 89] la TCW es muy sensible, es decir, resalta muchas más singularidades de las que son necesarias (la mayoría de las discontinuidades son por los pequeños cambios en la señal reconstruida, donde hay ausencia de transmisión, solo ruido). Con base en lo anterior se elige una escala única en 120 para localizar de manera oportuna los cambios en la señal que sean posibles transmisiones. Además, de las diferentes simulaciones realizadas, escoger una escala cercana al valor elegido (120) da una mejor precisión para localizar los bordes de frecuencia (ver **Figura 20**).

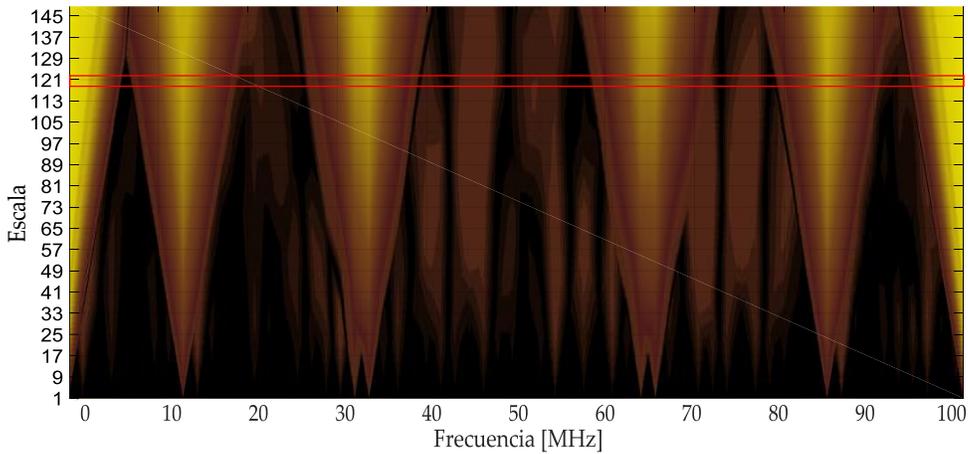


Figura 19. TCW con escala en el intervalo $[1, 150]$ de la señal $X_{app}(f)$.

El resultado de aplicar el módulo máximo de TCW al ejemplo de la señal anterior se muestra en la **Figura 20**. En la parte inferior de esta figura (**Figura 20 b**) aparece únicamente la escala seleccionada (120) del módulo máximo de TCW. Posteriormente se toman los máximos de esta escala que corresponden a cambios repentinos en las frecuencias del espectro suave $X_{app}(f)$. Estos valores máximos de frecuencia se utilizan para construir las ventanas dinámicas indicadas en el Paso 3 de la metodología general. En este caso se construyen 5 ventanas (marcadas como V_1, V_2, \dots, V_5) con los bordes de frecuencia obtenidos, delimitados por las flechas verdes en la **Figura 20 b**). Estos segmentos alimentan el bloque más grande en el algoritmo propuesto en la **Figura 17**.

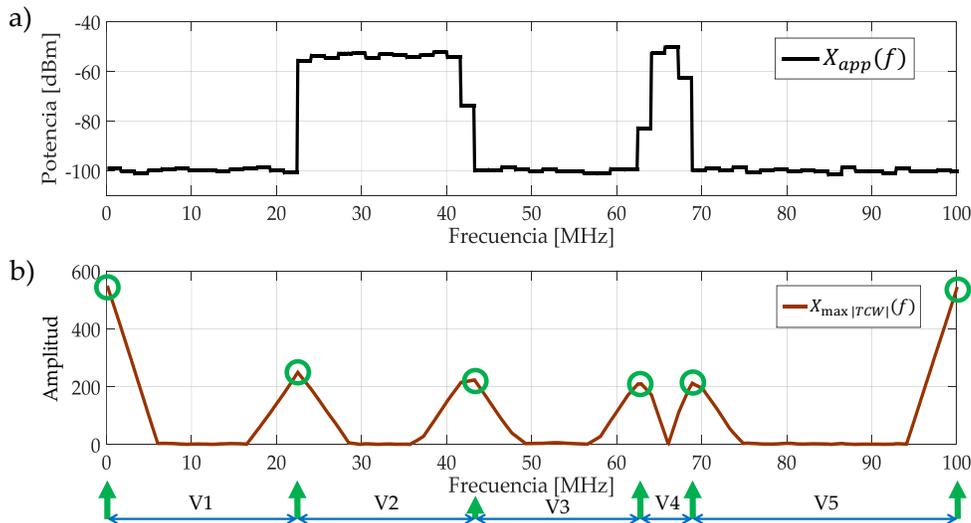


Figura 20. a) $X_{app}(f)$, señal reconstruida con los coeficientes de aproximación obtenidos de $X(f)$. b) El resultado de aplicar el módulo máximo de la TCW a la señal $X_{app}(f)$ en la escala 120 y sus correspondientes bordes detectados.

Una vez detectados los bordes de frecuencia, los coeficientes de aproximación originales obtenidos con el AMR se normalizan e interpolan para tener el mismo número de puntos alineados con la señal original (es decir, alineados con las ventanas obtenidas en la *Figura 20 b*), como se muestra en la *Figura 21*. La construcción de un nuevo espectro, mostrado en la *Figura 22* y utilizado en los Pasos 5 y 6, se realizará de la siguiente forma. Si el promedio de los CNI alineados con cada ventana dinámica es mayor que 0.7, significa que el intervalo de frecuencia (ventana) que se procesará es directamente la señal original $X(f)$, de lo contrario, será el espectro $X_{app}(f)$ en el mismo intervalo. El valor de 0.7 fue ajustado haciendo un estudio pertinente con señales simuladas y es presentado en el *Capítulo 6*. El resultado de aplicar este umbral, para este ejemplo específico, se muestra en la *Figura 22*, en esta figura se puede apreciar la idea fundamental de la metodología propuesta para determinar la presencia o no de UP: identificar con la DFH el ruido en el espectro de una señal más regular (totalmente diferente de un ruido) que corresponderá a una posible transmisión de un UP.

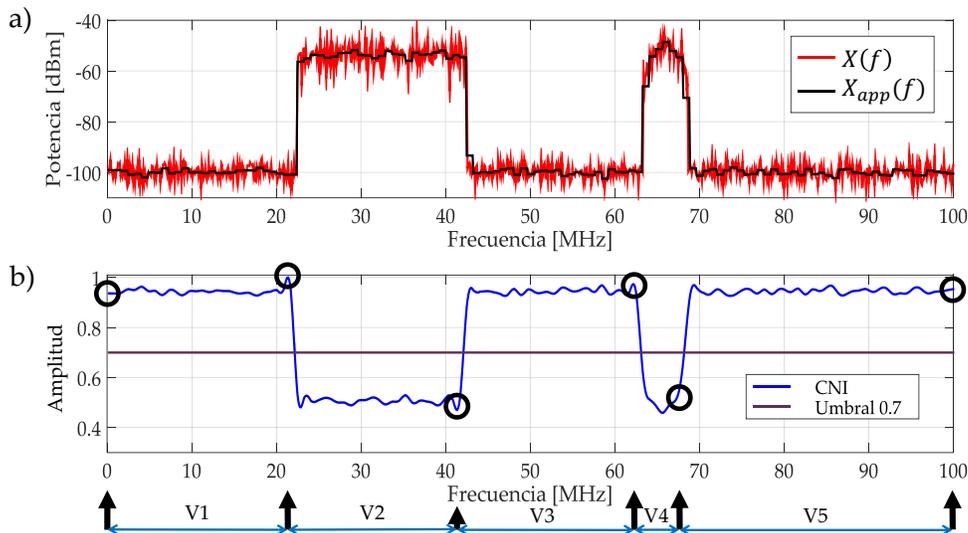


Figura 21. a) Las señales original y aproximada con un nivel de descomposición $L=3$ del AMR. b) Los CNI que marcan los bordes de frecuencia y al mismo tiempo determinan los límites de las ventanas dinámicas y el umbral de 0.7.

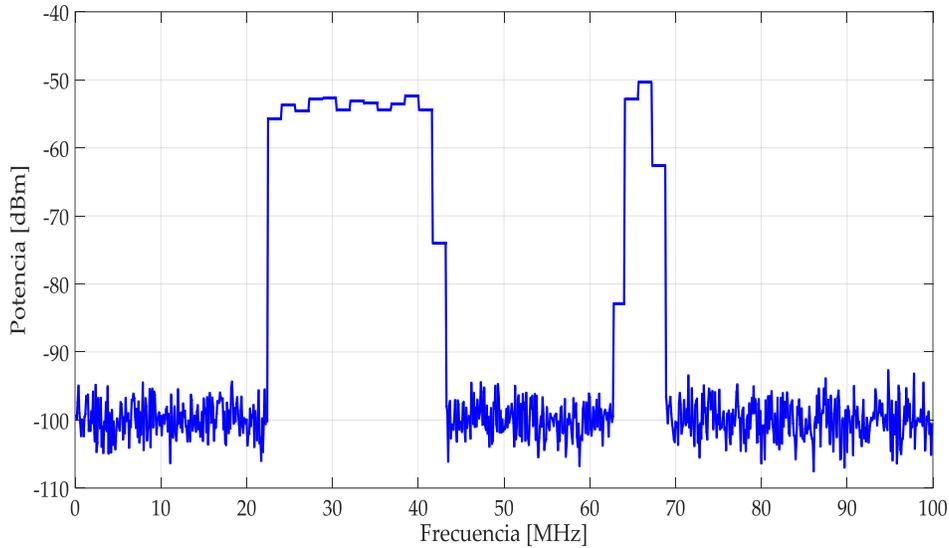


Figura 22. El espectro resultante que será utilizado en los Pasos 5 y 6 junto con la regla de decisión para detectar a un posible UP.

Como paso final, la señal resultante (espectro mostrado en la *Figura 22*) se utiliza para determinar una posible transmisión de los UP. Donde, la DFH se aplica sobre cada segmento (ventana) del espectro ($X_{app}(f)$ o la señal original). El umbral de decisión, para determinar si existe transmisión del UP o no, se establece en 1.85. Si la DFH es mayor que 1.85, eso significa que en este intervalo de frecuencia podría colocarse un US o, de lo contrario, un UP estaría transmitiendo.

El umbral de 1.85 para la DFH también se estableció probando la metodología con señales simuladas. Es importante señalar que la elección de tomar directamente o no la señal original, está basada en el comportamiento de la DFH. De hecho, es más fácil decidir sobre una transmisión del UP o ruido, al suavizar el espectro de un UP (es decir, hacer que la señal del espectro sea más regular) y mantener la característica de no regularidad del ruido cuando se calcula la DFH.

5.3 Técnica de monitorización del espectro multibanda basada en los coeficientes de aproximación y la DFH

En la *Figura 21* se puede observar el comportamiento de los coeficientes de aproximación, normalizados e interpolados, obtenidos con el AMR con un nivel de descomposición igual a 3, el comportamiento de los CNI sigue perfectamente los cambios directos de la señal original $X(f)$. De aquí surge una idea sencilla: utilizar los cambios

presentados a lo largo de la frecuencia de estos CNI para obtener directamente los bordes de frecuencia en el espectro multibanda. De esta manera, la primera metodología, explicada anteriormente, puede modificarse produciendo un segundo algoritmo. Esta segunda propuesta está descrita por el diagrama de bloques presentado en la *Figura 23*, donde se modificó la forma de detectar los bordes de frecuencia (que a su vez formarán las ventanas dinámicas), eliminando la aplicación de la TCW.

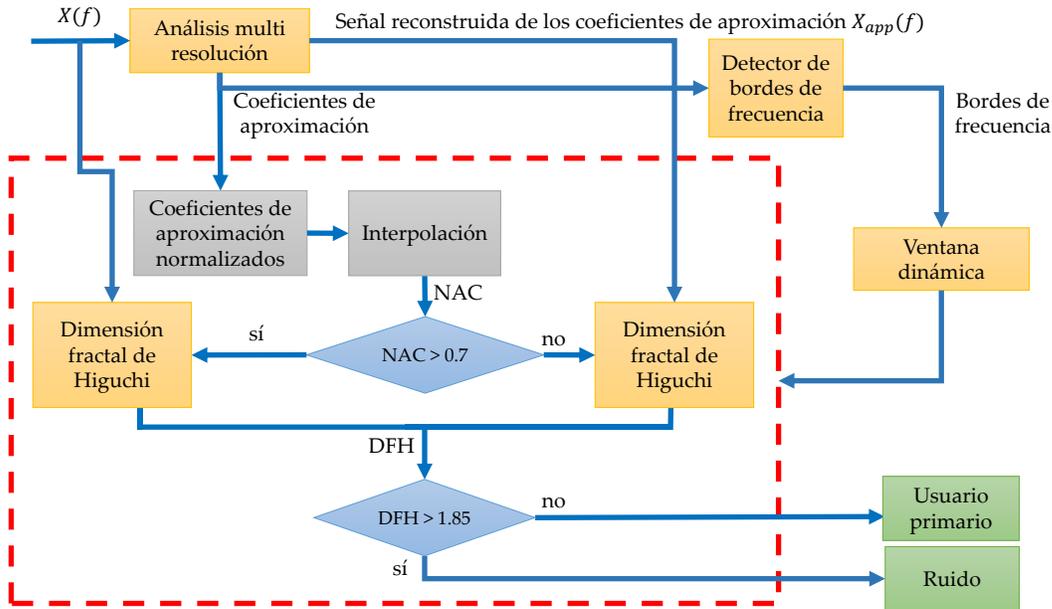


Figura 23. Segunda metodología considerando los CNI en la detección de bordes de frecuencia.

Con base en lo anterior, los Pasos 3, 4 y 5 de la primera metodología se sustituyen por los siguientes:

Paso 3. El localizador de bordes de frecuencia se construye detectando los cambios de valores de los mismos coeficientes de aproximación a través del umbral de 0.7, es decir, los coeficientes de aproximación que van de un valor superior a uno inferior de 0.7 o viceversa. Estos cambios serán los bordes de frecuencia necesarios para construir las ventanas dinámicas.

Paso 4. Los mismos coeficientes de aproximación obtenidos en el Paso 1 se normalizan y se interpolan (para tener el mismo número de muestras que la señal original $X(f)$ y la señal reconstruida $X_{app}(f)$). Con los CNI, cada ventana conformada se procesa para detectar ruido o una posible transmisión

de UP. Si los CNI están, en promedio, por debajo de un umbral definido de 0.7, los valores de las ventanas analizadas probablemente sean una transmisión del UP. Si es mayor que 0.7, es prácticamente seguro de que la transmisión corresponde a ruido.

Paso 5. Si los CNI en promedio son mayores que 0.7, la dimensión fractal de Higuchi se aplica directamente en la sección analizada del espectro multibanda. En otro caso, la DFH se aplica a la señal reconstruida del Paso 2 (es decir, a $X_{app}(f)$).

Considerando las frecuencias en las que los CNI cambian según el umbral de 0.7, éstas serán los bordes necesarios para construir las ventanas dinámicas. En el caso del ejemplo, estos puntos críticos detectados están marcados en la *Figura 21* con círculos negros sobre los CNI. La eliminación del módulo máximo de la TCW para detectar los bordes de frecuencia proporciona una disminución considerable en la complejidad computacional del algoritmo.

5.4 *Machine Learning* aplicado a la Técnica de monitorización del espectro multibanda basada en los coeficientes de aproximación y la DFH

La inclusión de las técnicas de ML en la segunda metodología presentada anteriormente tiene como objetivos principales lograr mejoras en el proceso de detección de los UP y tener un sistema automatizado. Básicamente, los dos primeros pasos y el último de la metodología anterior se mantienen, sin embargo en este nuevo enfoque, los coeficientes de aproximación se procesan mediante técnicas de ML que mejoran el proceso de detección antes de aplicar la regla de decisión basada en la DFH.

La metodología anterior en los Pasos 3 y 4 (marcados por una línea azul discontinua) se modifica de forma siguiente: el umbral de 0.7 con estas técnicas de ML se adapta a lo largo del tiempo y se mejora la detección de los bordes de frecuencia. En la *Figura 24* se muestra la inclusión de este nuevo bloque con las técnicas de ML (la línea roja discontinua señala el lugar). Todas las técnicas descritas en la *Sección 3.4*, se implementan en este bloque. Como resultado, los bordes de frecuencia se mejoran y se utiliza una 'ventana de prueba' para determinar la presencia o ausencia de un UP en lugar de los CNI directamente (Paso 5 de la sección anterior, también marcado por una línea azul discontinua).

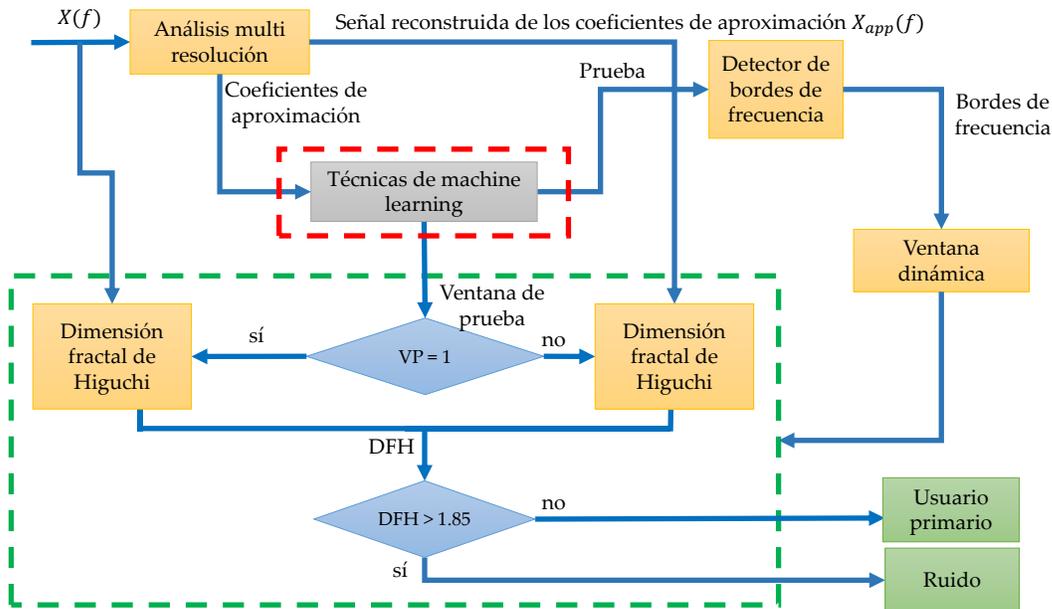


Figura 24. Inclusión de técnicas de ML a la segunda metodología.

Los cambios importantes a este nuevo algoritmo son:

- Escalamiento de los coeficientes de aproximación en las señales donde aparecen transmisiones de UP en el intervalo $[0, 1]$ (donde el 0 representa el coeficiente con mayor potencia y el 1 representa el de menor potencia), con la finalidad de hacer una mejor localización. En señales que sólo contienen ruido no se realiza tal escalamiento.
- Los coeficientes de aproximación no se interpolan, es decir, los coeficientes representan un punto en la señal original obtenido al aplicar el AMR. El número de coeficientes está directamente relacionado con el factor 2^L donde L es el nivel de descomposición que en este caso es 3.

A continuación, se describe la implementación de cada una de las técnicas de ML y cómo se incorporan en la metodología original. A lo largo de este trabajo de investigación se muestran las gráficas resultado de aplicar las diferentes técnicas de monitorización propuestas, donde la ocupación de la señal evaluada está descrita por una decisión binaria $\langle\langle 0 \rangle\rangle$ y $\langle\langle 1 \rangle\rangle$ para solo ruido y ocupado por un UP, respectivamente (i.e. *Figura 28 c*), la *Figura 33 c*), la *Figura 36 c*), etc.).

5.4.1 Utilización de una red neuronal con un umbral de decisión manual

En esta sección se utiliza una NN para hacer la clasificación de los coeficientes de aproximación. En la *Figura 25* se muestra el diagrama de funcionamiento general propuesto para esta técnica de ML. Este clasificador usa los coeficientes de aproximación, normalizados y reescalados, para determinar el tamaño de las ventanas dinámicas, tal que sea posible delimitar los espacios donde exista la aparición de un UP a lo largo de la banda estudiada.

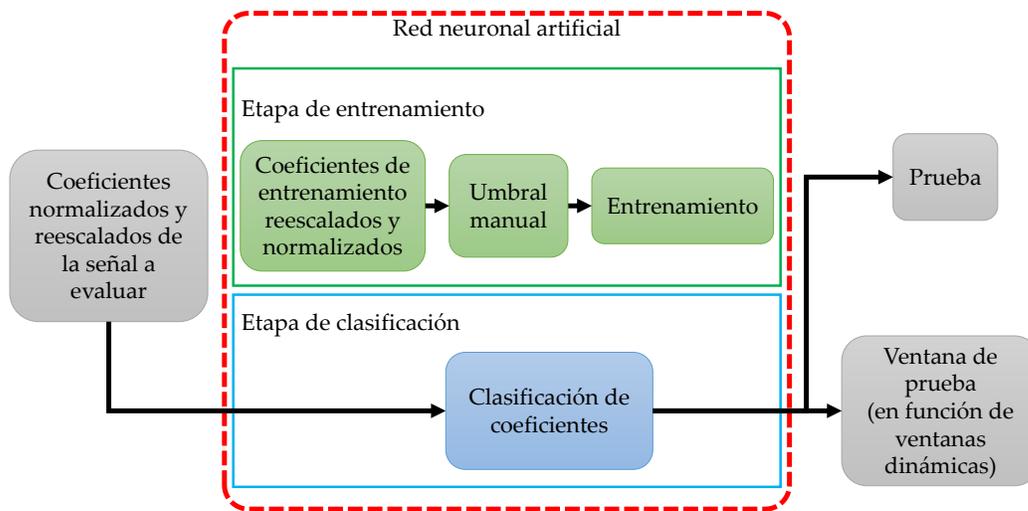


Figura 25. Diagrama de funcionamiento de la NN.

La naturaleza de esta técnica, presenta dos etapas: entrenamiento y clasificación. La primera se hace con ayuda de un tercero y debe cumplirse lo siguiente: que los coeficientes de aproximación normalizados y reescalados con los que será entrenada la NN contengan al menos una transmisión de un UP y un tercero debe elegir un umbral (umbral manual) que los separe en dos clases. El umbral manual se refiere a que el usuario debe elegir visualmente el umbral para determinar qué coeficientes representan la transmisión de UP. Esto significa que depende del criterio que tenga el usuario, lo que hace extremadamente impredecible al método. Al final los resultados dependerán de la percepción del usuario. En la *Figura 26*, por ejemplo, se muestra el espectro y los coeficientes de aproximación que han sido utilizados para entrenar la NN. En la *Figura 27*, el usuario ha seleccionado el umbral en 0.6 y se muestra el resultado de entrenar la NN con este umbral. Acorde al umbral manual, los coeficientes de aproximación se representan con 1 para ruido y 0 para transmisión de UP.

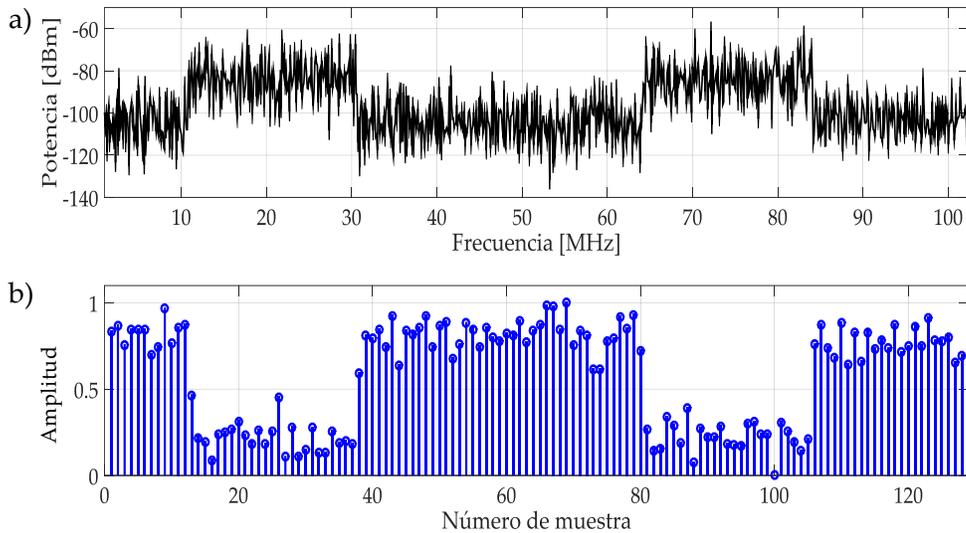


Figura 26. a) Espectro multibanda aleatorio, b) Coeficientes normalizados y reescalados que se utilizarán para entrenar la NN.

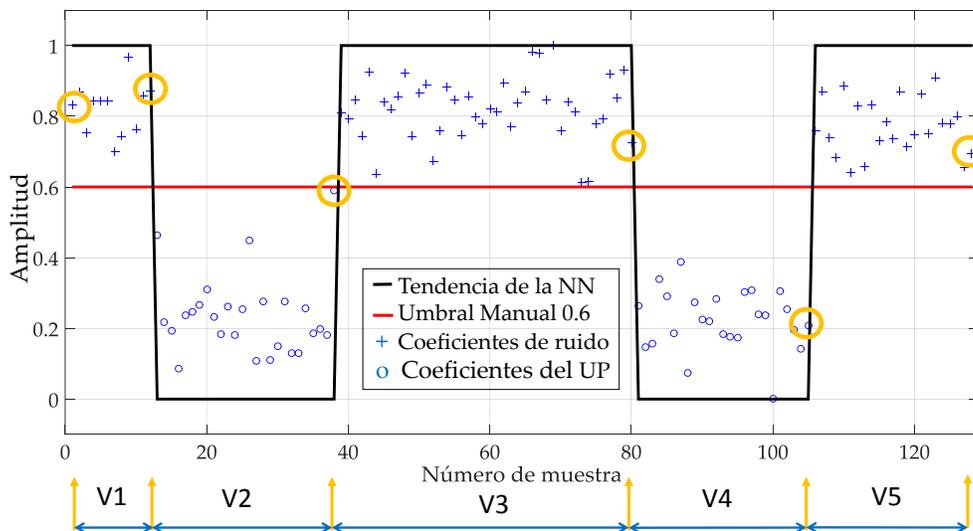


Figura 27. El resultado del entrenamiento de la NN con un umbral manual establecido en 0.6 sobre una trama completa. Los coeficientes de aproximación normalizados y reescalados han sido clasificados. También se determinan los bordes de ventanas dinámicas.

En la **Figura 27** se puede observar la tendencia de los coeficientes de aproximación, que permite determinar los bordes de frecuencia de una transmisión de un UP, además de separar ambas clases. Esto ocurre cuando un cambio está presente en un coeficiente asociado al ruido y el siguiente es un coeficiente asociado a un UP (o viceversa), como lo

muestran los círculos amarillos en la *Figura 27*. Estos valores (círculos amarillos) permiten construir las ventanas dinámicas (marcadas como V_1, \dots, V_5 en este caso) que se procesarán de forma individual para determinar si el segmento de señal corresponde o no, a un UP.

Con la NN entrenada, ahora es posible aplicar esta red a otras tramas y obtener los bordes de frecuencia, a partir de los coeficientes de aproximación normalizados y reescalados, que dan como resultado la señal "Prueba" (que es la clasificación de los coeficientes, hecha por la NN entrenada) y la señal "Ventana de prueba" (segmentos de la señal "Prueba" correspondientes a las ventanas dinámicas construidas). Con base en esto, los Pasos 3 a 5 de la metodología original se modifican de la siguiente forma:

Paso 3. Se selecciona una trama aleatoria para el entrenamiento: los coeficientes de aproximación se normalizan y se escalan. Estos coeficientes se utilizan para entrenar a la NN con un umbral inicial establecido por el usuario. Después de entrenar la NN, se obtienen y evalúan los coeficientes de aproximación normalizados y reescalados de alguna otra trama a analizar, lo que da como resultado la señal 'Prueba' que contiene la clasificación de los coeficientes (0 para una posible transmisión del UP y 1 para el ruido).

Paso 4. Los bordes de frecuencia y las ventanas dinámicas se determinan a partir de la salida de la NN. Los bordes son el resultado del cambio de un estado a otro (de uno a cero y viceversa) de los coeficientes clasificados.

Paso 5. Si la señal 'Prueba' 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 $X_{app}(f)$.

El resultado de todo este proceso se muestra en la *Figura 28*. Primero, en la *Figura 28 a)* se presenta una señal aleatoria multibanda real, esta señal es un ejemplo para demostrar la funcionalidad de la metodología. Después, en la *Figura 28 b)* se muestra la clasificación de los coeficientes de aproximación mediante una NN. Aquí, es posible apreciar la diferencia entre los coeficientes asociados al UP y el ruido. Finalmente, en la *Figura 28 c)* se muestra el resultado de la determinación de la disponibilidad de espacio en un espectro de banda ancha. En esta figura, está claro cómo la NN entrenada clasifica la señal de espectro en ocupada o vacía.

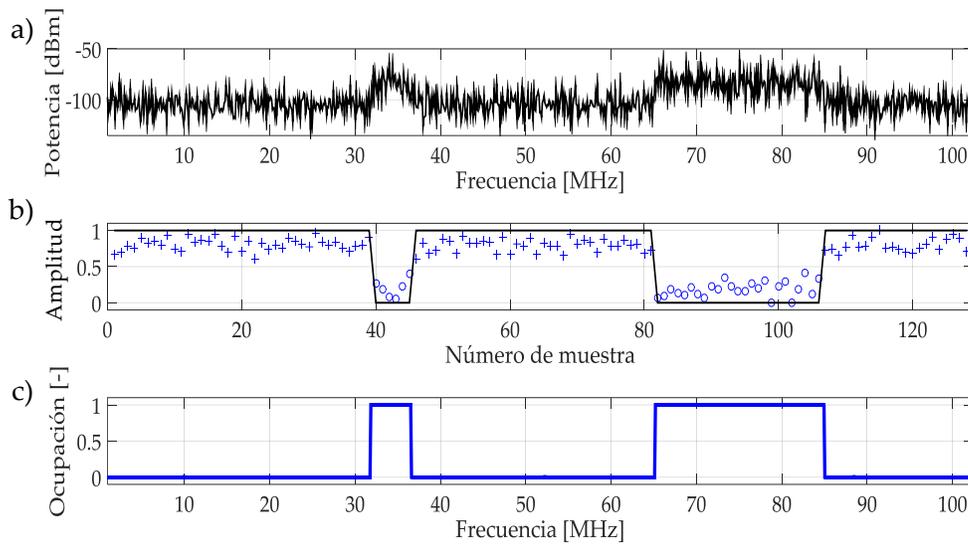


Figura 28. a) Espectro multibanda aleatorio. b) Clasificación de los coeficientes de aproximación, resultado del uso de la NN (**Figura 27**). c) Resultado de aplicar toda la metodología.

5.4.2 Utilización de una NN con un umbral de decisión basado en el algoritmo *expectation maximization*

El umbral de entrenamiento de la NN y los resultados en la *Sección 5.4.1* dependen del criterio del usuario. Para quitar esta dependencia, se propone el algoritmo EM para seleccionar este umbral, necesario para el entrenamiento correcto de la NN. Para ello, es necesario agregar un bloque que simplifique esta tarea. En la *Figura 29*, se muestra el diagrama de bloques correspondiente, que es el resultado de modificar la *Figura 25*.

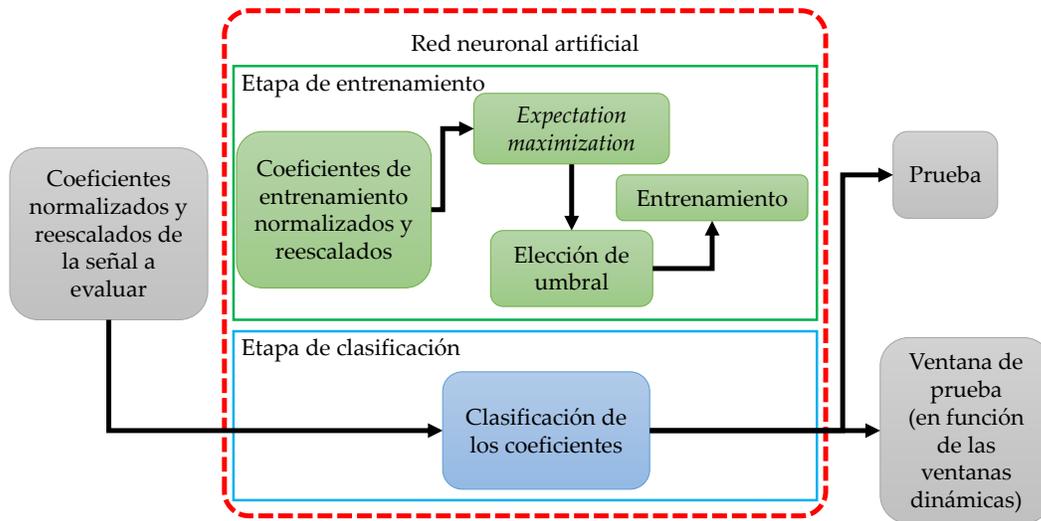


Figura 29. Diagrama de bloques que describe la integración del algoritmo EM en el entrenamiento de la red.

Para comprender el funcionamiento del método propuesto, utilizamos un espectro multibanda generado aleatoriamente. Esta señal es graficada en la *Figura 30 a)*. De igual manera en esta misma figura (*Figura 30 b)*) aparecen los coeficientes de aproximación normalizados y reescalados de este espectro multibanda utilizado para entrenar la NN. Al aplicar el algoritmo EM a estos coeficientes, se obtienen dos límites específicos. El umbral se elige al azar entre estos límites. El argumento de esta decisión se plantea en los párrafos siguientes.

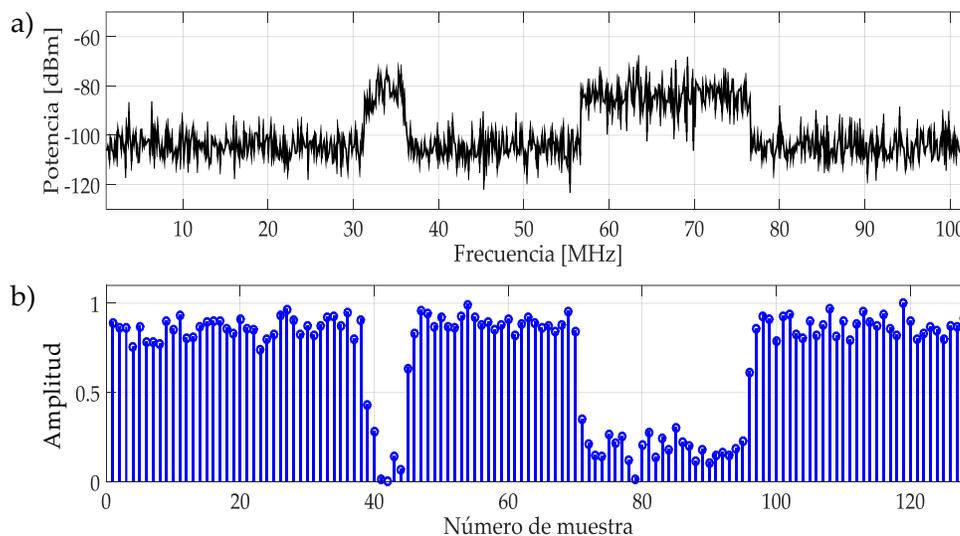


Figura 30. a) Espectro multibanda aleatorio. b) Coeficientes que se utilizan para entrenar la NN.

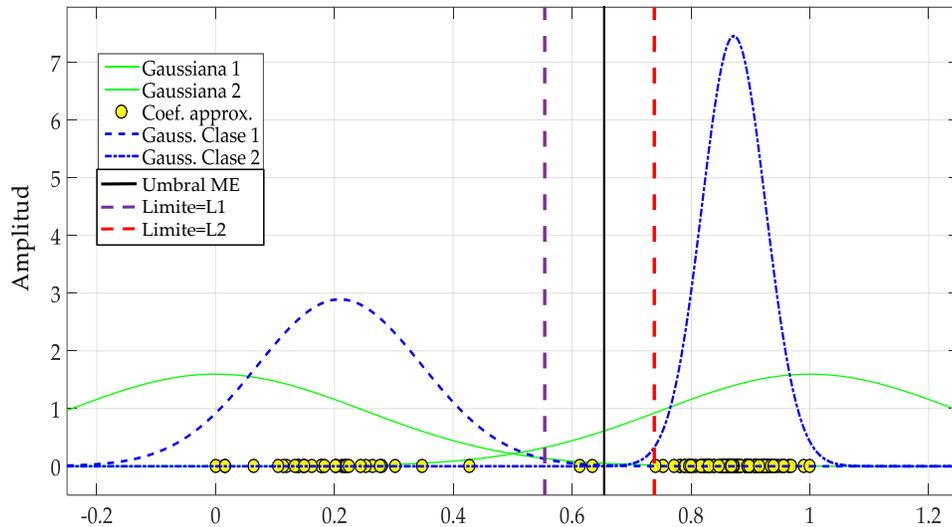


Figura 31. Se muestra la potencia de los coeficientes en el eje X y el resultado de clasificarlos en dos clases con distribución gaussiana.

En la **Figura 31** se describe el algoritmo *expectation maximization*, que consiste en escoger aleatoriamente dos clases con distribución gaussiana (marcadas en color verde). En el caso del ejemplo escogido, los coeficientes de aproximación normalizados y reescalados son graficados en el eje de las abscisas, donde se grafica únicamente la amplitud de cada coeficiente (marcado con puntos amarillos en esta figura). El resultado de aplicar el algoritmo EM a los coeficientes son las dos gaussianas en color azul (Las parejas (0.211, 0.1143) y (0.872, 0.0446) corresponden a la media y desviación estándar (DE) de las funciones Gaussianas 1 y 2, respectivamente, donde claramente se ve que corresponden a dos grupos que pueden ser separados en coeficientes de aproximación que corresponden a ruido y posibles transmisiones de UP. En base a lo anterior serán elegidos los límites $L1$ y $L2$ como $L1 = \mu_1 + 3\sigma_1$ y $L2 = \mu_2 - 3\sigma_2$ cuando $L1 < L2$; esto porque la probabilidad de que ocurra un evento después de $L1$ es de 0.001, análogamente para $L2$. Finalmente el umbral es elegido aleatoriamente entre $L1$ y $L2$ (el argumento de esta decisión se plantea en la **Sección 6.2.3**). Para el caso $L1 > L2$, significa que hay una SNR negativa o positiva cercana a 0 dB. En este caso hacemos $L1 = \mu_1 + n\sigma_1$ y $L2 = \mu_2 - n\sigma_2$ probando con distintos $n = 2, 1, 0$ hasta que $L1 < L2$. Donde la probabilidad de que ocurra un evento mayor a $L1$ sería de 0.022, 0.158, 0.499 para cada n , respectivamente (análogamente esto se aplica a $L2$). En el caso del ejemplo analizado (ver **Figura 30**) el umbral elegido es de 0.654 (**Figura 31**). Es importante resaltar que el umbral permite catalogar los coeficientes de aproximación. Es decir lo que haya por encima del umbral muy probablemente será ruido, lo que esté por debajo seguramente serán transmisiones de UP con los que se va a entrenar la NN. En la **Figura 32** se muestra el resultado de entrenar la NN con los coeficientes una vez catalogados.

La metodología sólo se modifica en el Paso 3, con respecto a los pasos propuestos en la subsección anterior, específicamente en el proceso de entrenamiento:

Paso 3. Se selecciona una trama aleatoria para el entrenamiento: los coeficientes de aproximación se normalizan y son reescalados. Estos coeficientes se utilizan para entrenar a la NN. El algoritmo EM clasificará los coeficientes y elegirá dos límites ($L1$ y $L2$). A continuación, un número aleatorio entre $L1$ y $L2$ será seleccionado como umbral, necesario para la clasificación.

Después del entrenamiento con la NN, los coeficientes de aproximación normalizados y reescalados de alguna otra señal aleatoria serán evaluados, lo que da como resultado la señal "Prueba" que contiene la clasificación de los coeficientes de aproximación (0 para una transmisión del UP y 1 para el ruido).

El resultado de utilizar esta técnica de ML en la metodología se muestra en la *Figura 33*. En esta figura, se utiliza un espectro multibanda generado aleatoriamente para determinar sus estados de ocupación según la NN entrenada de la *Figura 32*.

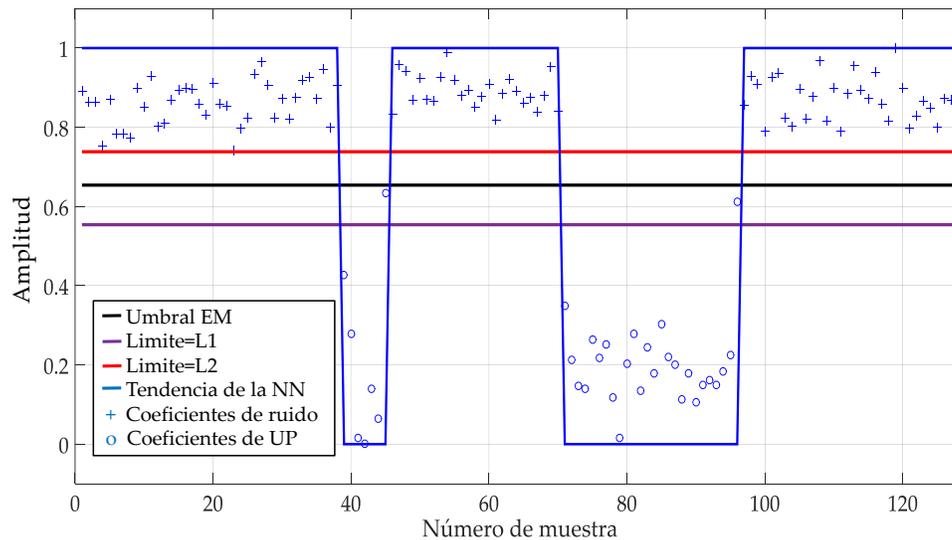


Figura 32. La tendencia de la NN entrenada con una clasificación de los coeficientes de aproximación normalizados y reescalados, utilizando el algoritmo EM donde el umbral es colocado en 0.654.

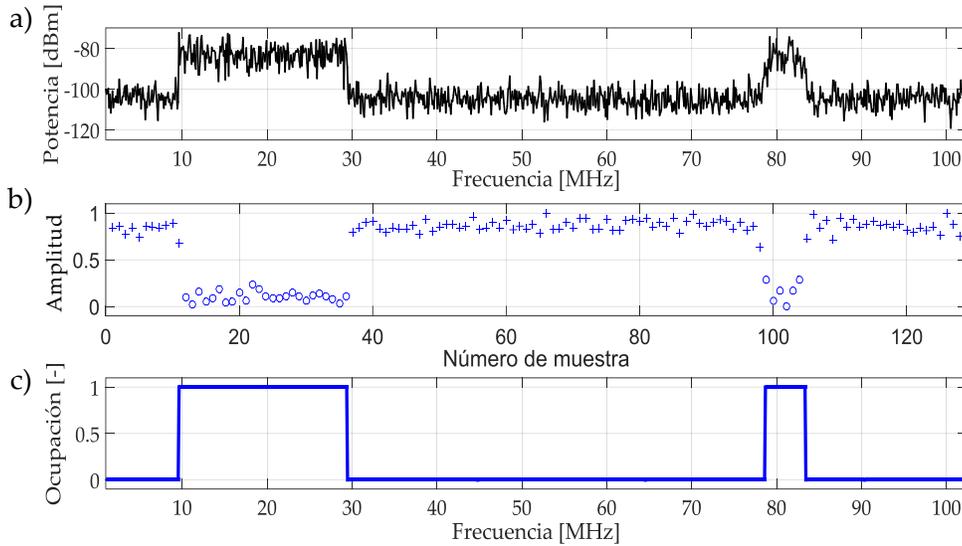


Figura 33. a) Espectro multibanda generado aleatoriamente. b) Clasificación de los coeficientes, resultado de utilizar la NN entrenada que se menciona en **Figura 32**. c) Ocupación a lo largo del espectro multibanda.

5.4.3 Clasificación basada en el algoritmo *K-means*

Otro método no supervisado utilizado en este trabajo como un clasificador de los coeficientes de aproximación de un espectro multibanda aleatorio, es la técnica de *K-means*. La disponibilidad multibanda del espectro se determina con los coeficientes de aproximación, normalizados y reescalados. El diagrama de bloques de este proceso está esquematizado en la **Figura 34**.

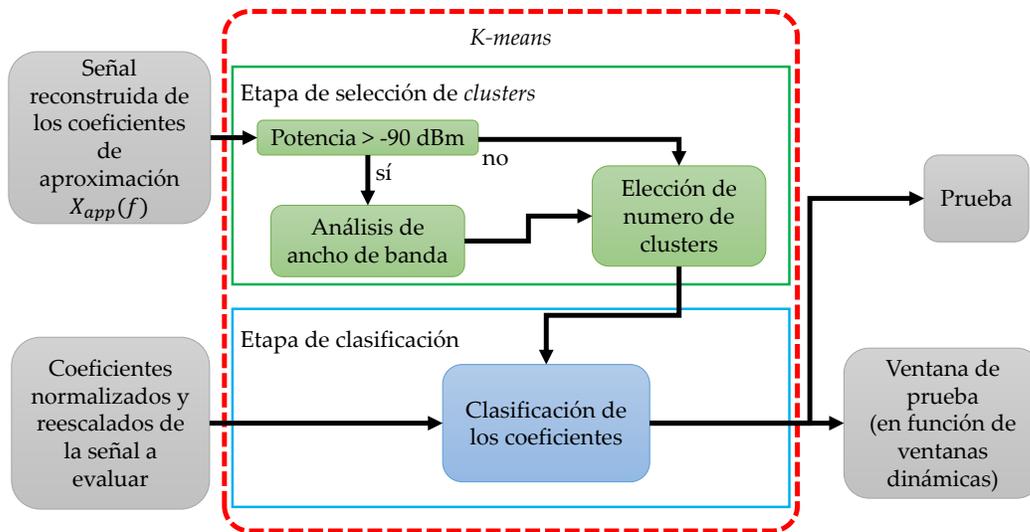


Figura 34. Diagrama de bloques que describe el funcionamiento de la técnica de monitorización usando el algoritmo *K-means*.

En esta técnica, el objetivo es clasificar los coeficientes de aproximación en dos grupos (o *clusters*), uno que infiere la transmisión del 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 clasificar. Lo cual es 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 34**, evaluar primero la posible presencia de un UP de forma simple a través de un algoritmo. Se coloca un detector de energía 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 casos que se resuelven con un pequeño análisis del ancho de banda.

Caso 1: Ruido impulsivo en la trama. Debido al pequeño ancho de banda de esta anomalía, es decir, un número menor a 7 muestras \times 0.1 [MHz], indicaría que el número de *clusters* seleccionado será 1.

Caso 2: Posible transmisión del UP en la señal. Con el entendimiento de que una transmisión tiene al menos 7 muestras \times 0.1 [MHz], entonces el número de *clusters* será de 2.

Caso 3: Ruido impulsivo y posible transmisión del UP coexistiendo en la señal. En este caso, cuando se localiza que existe una posible transmisión teniendo al menos 7 muestras \times 0.1 [MHz], el número de *clusters* será de 2.

Lo que conlleva a que los Pasos 3, 4 y 5 de la metodología original se modifiquen de la siguiente forma:

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 del umbral colocado en -90 dBm y los 3 casos mencionados anteriormente; con los coeficientes de aproximación normalizados y reescalados se realiza la clasificación. Lo que da como resultado la señal "Prueba".

Paso 4. Los bordes de frecuencia y las ventanas dinámicas se determinan a partir de la Señal "Prueba". Los bordes son el resultado del cambio de un estado a otro (de uno a cero y viceversa) de los coeficientes de aproximación.

Paso 5. Si la señal "Prueba" en cada ventana dinámica ("Ventana de prueba", 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 de un UP y la DFH será aplicada sobre $X_{app}(f)$.

El resultado de aplicar *K-means* a los coeficientes aparece en la **Figura 35**. Además, en la **Figura 35 a)** se muestra cómo se integran las ventanas dinámicas y los bordes de frecuencia (círculos y flechas en color verde). En la **Figura 35 b)**, 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.

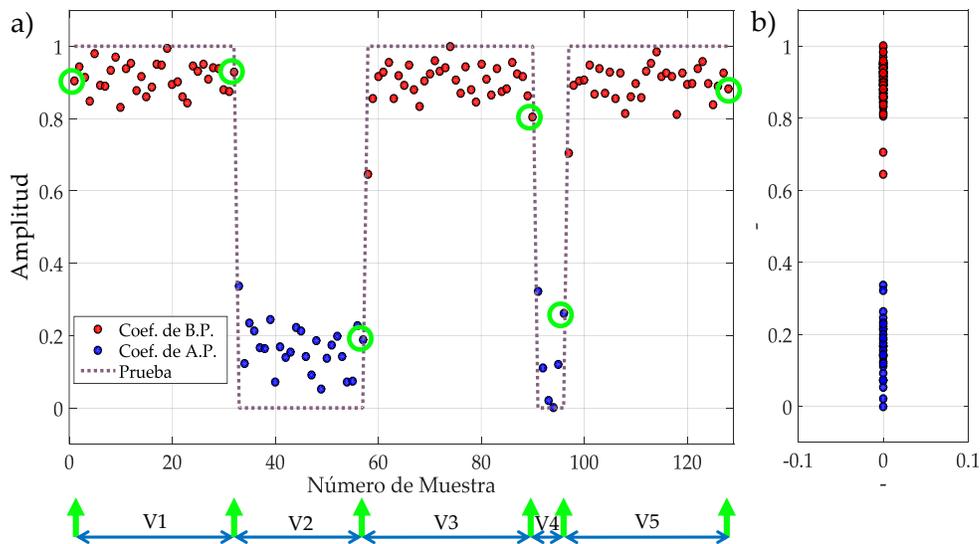


Figura 35. a) Coeficientes clasificados y los respectivos bordes de frecuencia. b) El resultado de aplicar *K-means*.

En la **Figura 36** se muestra el resultado de aplicar *K-means* a la técnica de monitorización del espectro multibanda utilizando la técnica como un clasificador. La

Figura 36 a) corresponde a un espectro multibanda generado aleatoriamente. La **Figura 36 b)** presenta la ocupación a lo largo de la frecuencia, resultado de la metodología. Esta figura representa el resultado final de todo el proceso para el espectro multibanda analizado.

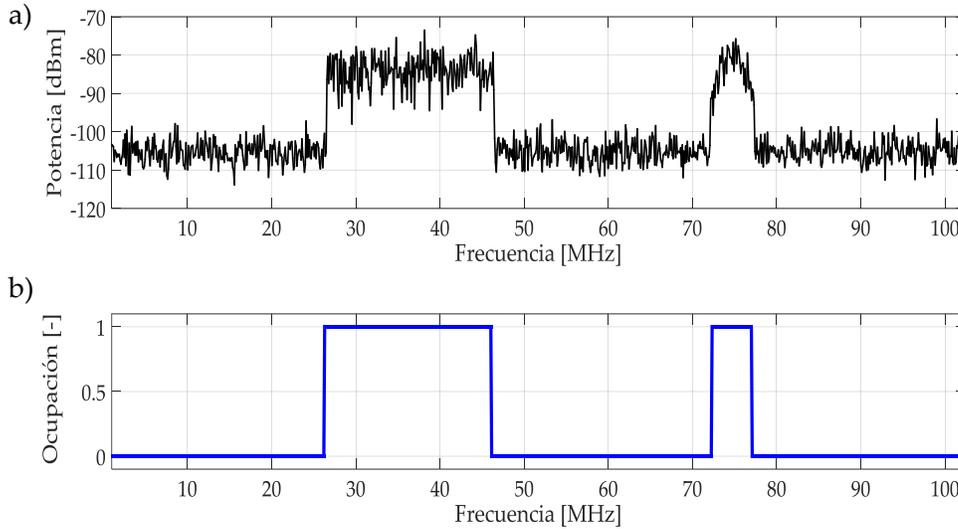


Figura 36. a) Espectro multibanda aleatorio que corresponde a los coeficientes de aproximación presentados en la **Figura 35**. b) Ocupación a lo largo del espectro multibanda.

5.4.4 Clasificación basada en el *Dirichlet process Gaussian mixture model*

Finalmente, en esta subsección se presenta la versión que utiliza DPGMM para determinar los bordes de frecuencia y las ventanas dinámicas. Es importante destacar que DPGMM es una técnica general para agrupación y no es necesario especificar el número de *clusters* para catalogar los coeficientes. En la **Figura 37** se muestra el funcionamiento de esta técnica.

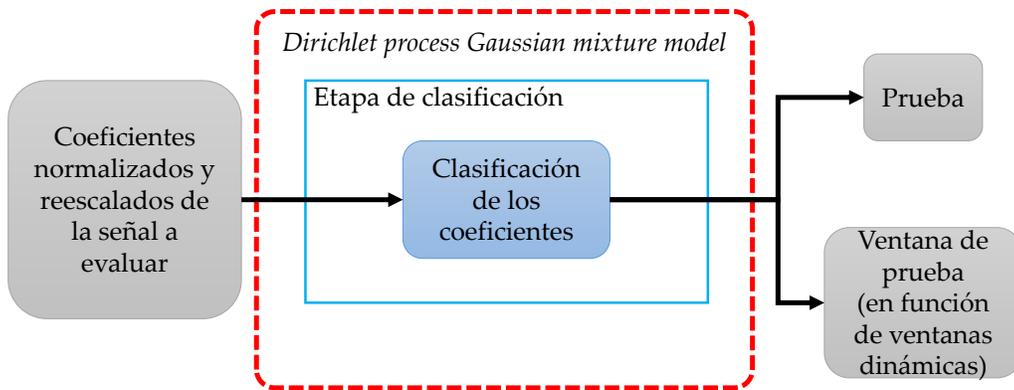


Figura 37. Diagrama de bloques que describe el funcionamiento de la técnica de monitorización usando DPGMM.

La metodología únicamente se modifica en el Paso 3, con respecto a los pasos propuestos en la subsección anterior.

Paso 3. Los coeficientes de aproximación normalizados y reescalados de la señal a evaluar son clasificados por la técnica DPGMM. Lo que da como resultado la señal "Prueba".

La clasificación hecha por DPGMM marcada por la señal "Prueba", permite identificar los bordes de frecuencia y las ventanas dinámicas en el espectro multibanda. Para este ejemplo en particular, los elementos detectados son señalados con círculos y flechas en color negro en la *Figura 38*.

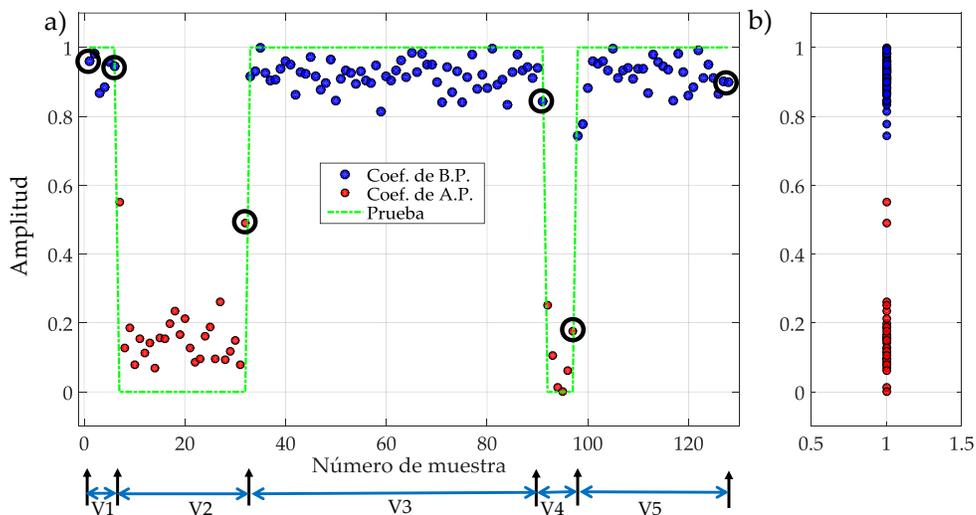


Figura 38. a) Coeficientes clasificados. b) Clasificación de los coeficientes de aproximación normalizados y reescalados en función de su potencia.

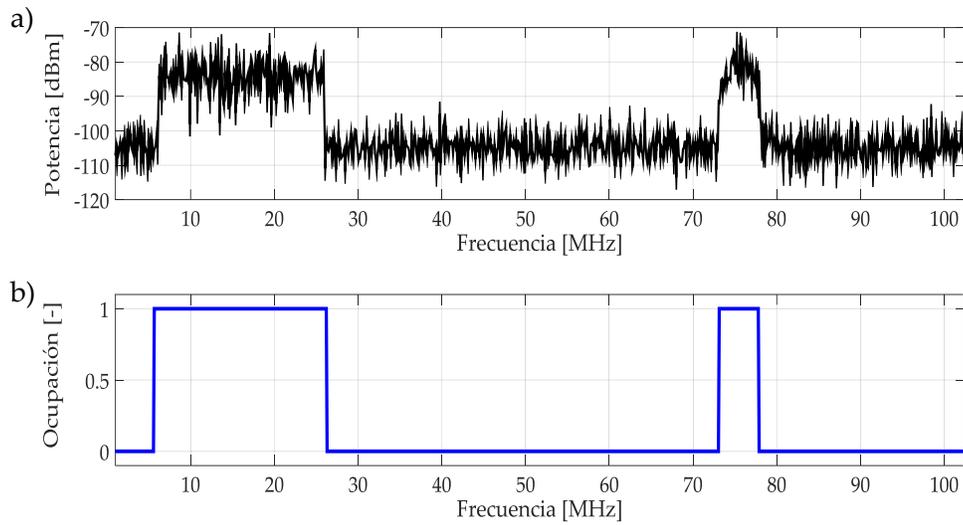


Figura 39. a) Espectro multibanda aleatorio. b) Ocupación a lo largo del espectro multibanda.

En la *Figura 39* se muestra el resultado de integrar DPGMM a la técnica de monitorización del espectro multibanda propuesta, basada en los coeficientes de aproximación.

Capítulo 6

Resultados

En esta sección, se presentan los resultados de las metodologías propuestas en el *Capítulo 5*. Primeramente se evalúa el desempeño de estos métodos a través de señales simuladas y posteriormente a través de señales reales. Antes de presentar estas implementaciones, se analiza la aplicación de la dimensión fractal de Higuchi en la regla de decisión. Para ello, se desarrolla un análisis de su aplicación a las transmisiones clásicas asociadas con las tecnologías inalámbricas más representativas de nuestros días.

6.1 La regla de decisión: la dimensión fractal de Higuchi

El punto de partida para este trabajo fue pensar en aplicar la DFH a una señal de espectro multibanda, en principio se consideró la posibilidad de utilizar ventanas de análisis de tamaño uniforme. Para ello se realizó una evaluación de esta técnica sobre señales reales, correspondientes a 300 tramas cada una de ellas conteniendo 461 puntos de espectro multibanda localizados en el intervalo [806-902] MHz. En la *Figura 40*, se muestra el resultado de aplicar la DFH sobre ventanas de frecuencia del mismo tamaño.

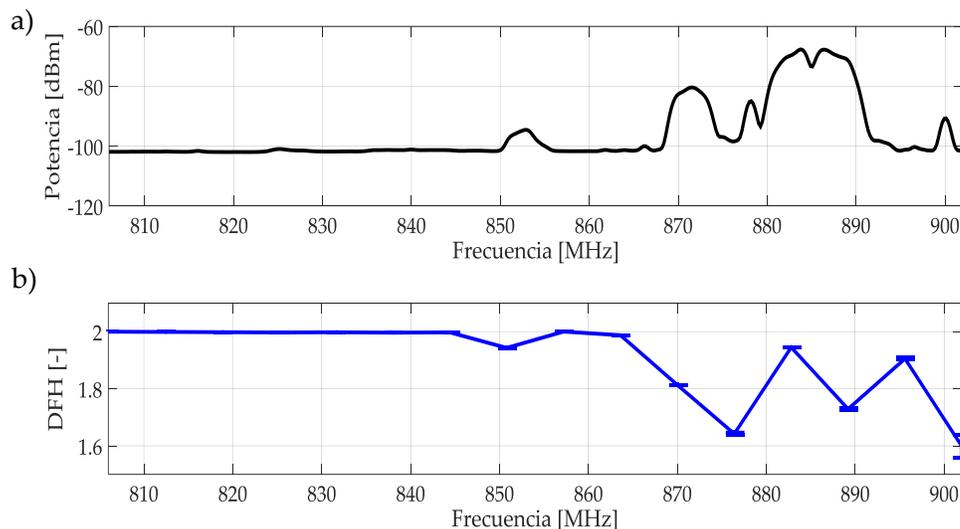


Figura 40. a) Promedio de 300 tramas de espectro que corresponden a la banda [806 - 902] MHz. b) Promedio de la DFH calculada sobre estas tramas en ventanas de frecuencia de tamaño uniforme.

De la *Figura 40* se destacan dos puntos importantes:

- En las múltiples tramas capturadas, la DFH de una señal sin la presencia de algún UP (es decir ruido) tiene un valor que tiende a 2.
- Debido a las ventanas de frecuencia de tamaño uniforme, la ubicación del comienzo y final de las transmisiones de UP no es precisa. Lo cual, introduce un valor de la DFH incorrecto, lo que indica una posible transmisión de un UP como ruido.

El segundo punto se corrige, con las técnicas propuestas, ya descritas anteriormente, detectando adecuadamente los bordes de frecuencia y considerando ventanas de tamaño no uniforme (ventanas dinámicas). Sin embargo, para establecer el umbral fundamental en la regla de decisión, es necesario poder diferenciar entre el ruido ($DFH \approx 2$) y una posible transmisión de un UP. Para esto se realizó un análisis donde se aplicó la DFH a señales simuladas que representan el acceso clásico en tecnologías inalámbricas (es decir, LTE, WIFI, 3G, etc.): OFDMA y CDMA, considerando diferentes SNR.

En la *Figura 41* se muestran múltiples realizaciones de los símbolos OFDM y NRZ-CDMA sintetizados sin ruido. En la *Tabla 3* se muestra la media y varianza de la DFH aplicada a estos símbolos. Aquí se puede observar que los valores de la DFH son muy lejanos a 2, lo cual hace factible su utilización en la distinción de ruido de un UP. La DFH promediada correspondiente para estos símbolos, considerando un amplio intervalo de SNR, se muestra en la *Figura 42*. Acorde a las *Figura 41*, la *Figura 42* y la *Tabla 3*, podemos concluir que el comportamiento de la DFH calculado es de alrededor de 2 cuando los símbolos son prácticamente ruido (comportamiento clásico de la DFH con el ruido blanco) esto es, con una SNR muy baja. Un factor importante a considerar con estas simulaciones, es la sensibilidad de la DFH en presencia de altos niveles de ruido, dando resultados erróneos (con valores que tienden a 2). Debido a esto, la aplicación directa de la DFH no es completamente viable (por ejemplo si la SNR es negativa o cercana a 0 dB) y es necesario implementar otro procesamiento. Por ello, en este trabajo de investigación se propone utilizar los coeficientes de aproximación del AMR para obtener un espectro sin ruido (suave), dando valores para la DFH lejos de 2 y fácilmente identificables del ruido real.

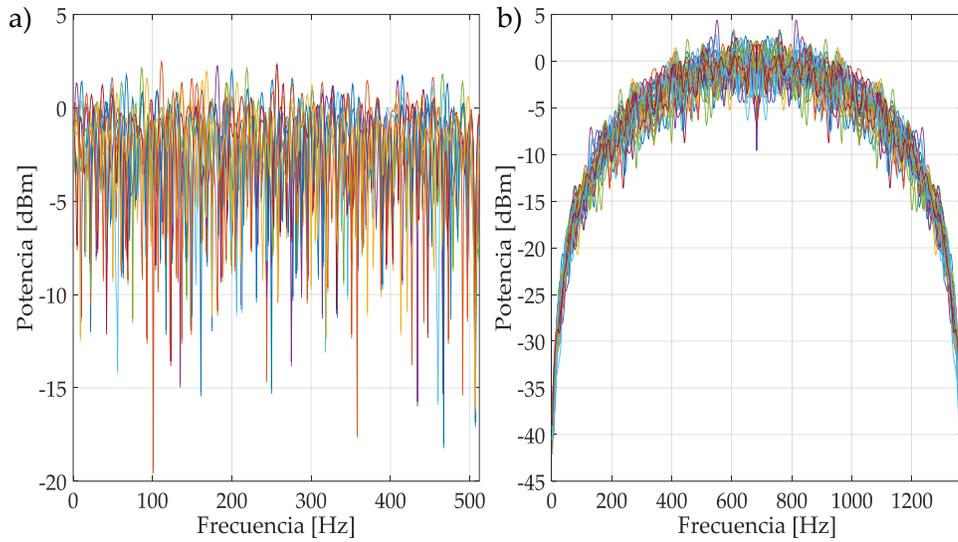


Figura 41. Espectro de múltiples símbolos a) OFDM. b) NRZ-CDMA.

Tabla 3. La media y la varianza de la DFH aplicada a múltiples símbolos OFDM y NRZ-CDMA simulados sin ruido.

Símbolo	Media DFH	Varianza DFH
OFDM	1.476	0.001
NRZ-CDMA	1.0383	0.0001

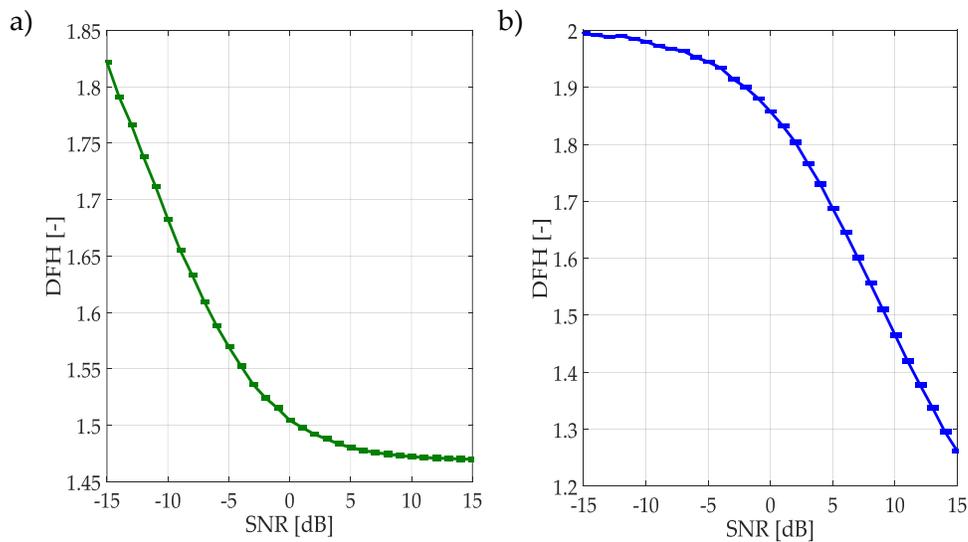


Figura 42. DFH de espectros para diferentes SNR. a) Símbolos OFDM. b) Símbolos NRZ-CDMA

La primera consideración, para resolver el problema mencionado anteriormente, es determinar qué tipo de *wavelet* debe usarse. La **Figura 43** muestra las diferentes señales aproximadas, resultado de aplicar el AMR con diferentes funciones *wavelet* (Daubechies) sobre una señal real. Aunque la tendencia del espectro se debe rastrear mediante el uso de cualquier *wavelet* de esta familia, los cambios ante la presencia de una transmisión de un UP son más claros con la *wavelet* db1 (o *Haar*). Esto mejora la precisión para ubicar los bordes de frecuencia en un espectro multibanda.

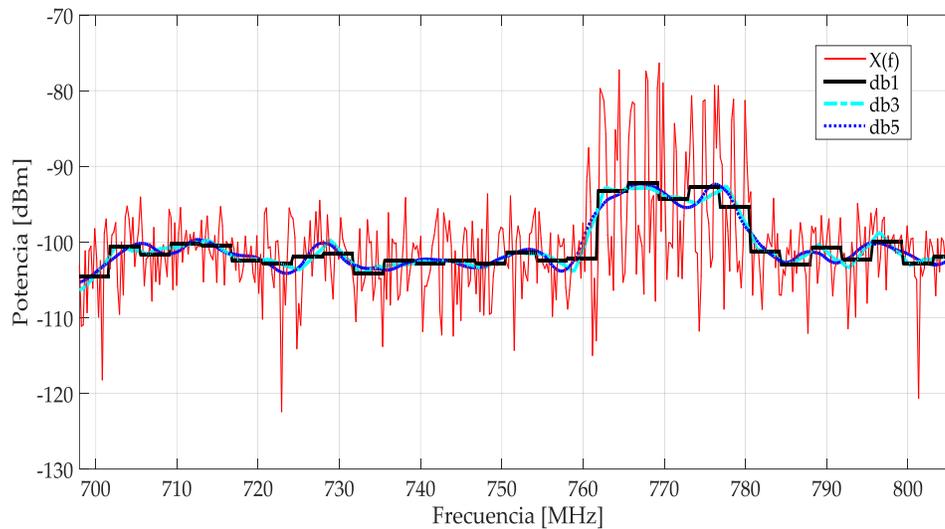


Figura 43. Espectro real (en rojo) y las señales aproximadas del AMR utilizando una familia de *wavelets* de Daubechies.

6.2 Aplicación de las metodologías propuestas en señales simuladas

Ambas metodologías (*Secciones 5.2 y 5.3*) propuestas en este trabajo se aplicaron a una primera simulación global de 750,000 tramas para valores de SNR variando en el intervalo $[-10, 20]$ dB y espaciados en 2 dB, como se indica en la **Figura 44**. En cada trama, el número, el tipo (OFDM o NRZ asociado a CDMA) y la posición (bordes de frecuencia) del espectro de los símbolos simulados se generaron de forma aleatoria. Cada trama consta de 1000 puntos, separados 0.1 MHz (es decir, una banda completa de 100 MHz) para la primera metodología (basada en la TCW) y se ajustaron para la segunda metodología (basada únicamente en los coeficientes de aproximación) en 1024. Los parámetros de simulación se resumen en la **Tabla 4**. En la **Figura 44** se agregaron tres bloques de análisis: estudios de ruido, símbolos y bordes de frecuencia. Estos estudios fueron realizados para establecer el umbral correcto en la regla de decisión basada en la DFH y la precisión de los bordes de frecuencia de detección, como se detalla en los siguientes párrafos. Además, los niveles de descomposición de la AMR fueron colocados en 4 y 3 para la primera y segunda metodología, respectivamente.

Tabla 4. Parámetros de la simulación.

	1a metodología	2a metodología
Software utilizado	MATLAB 2014b	
Valores de SNR	-10 a 20 dB en intervalo de 2	
Número de tramas para cada valor de SNR simulado	750,000	
Número de símbolos por trama	Aleatoriamente en el intervalo [0, 2]	
Ancho de banda de cada trama	100 MHz	102.4 MHz
Muestras por trama	1000	1024
Nivel de descomposición del AMR	4	3
<i>Wavelet</i> seleccionada	<i>Haar</i>	

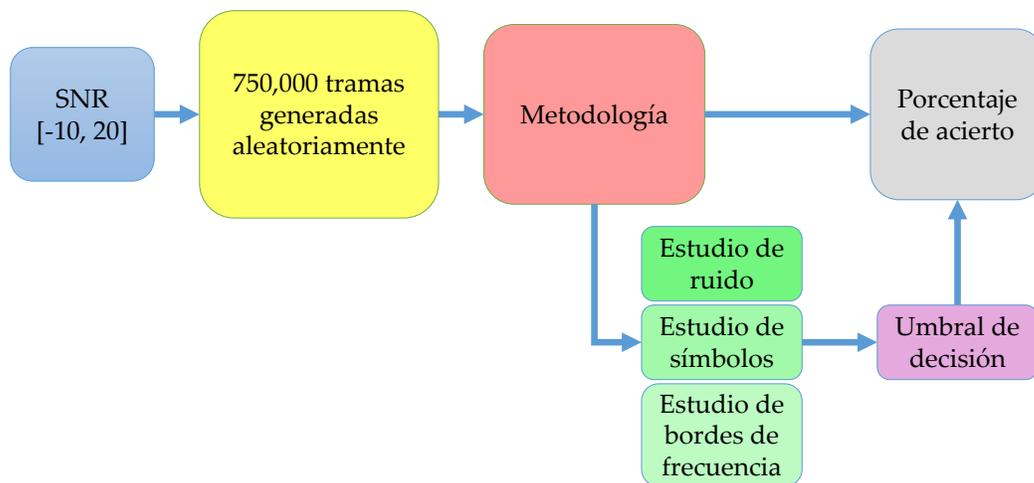


Figura 44. Esquema de la simulación global.

6.2.1 Resultados de la primera metodología

El resultado de estudiar los símbolos y el ruido al aplicar la primera metodología basada en la TCW para la detección de los bordes de frecuencia, se presenta en la **Figura 45**. En esta figura se muestra la media y DE de la DFH aplicada a las ventanas de tamaño dinámico que representan ruido, símbolos OFDM o símbolos NRZ-CDMA a lo largo de las diferentes SNR.

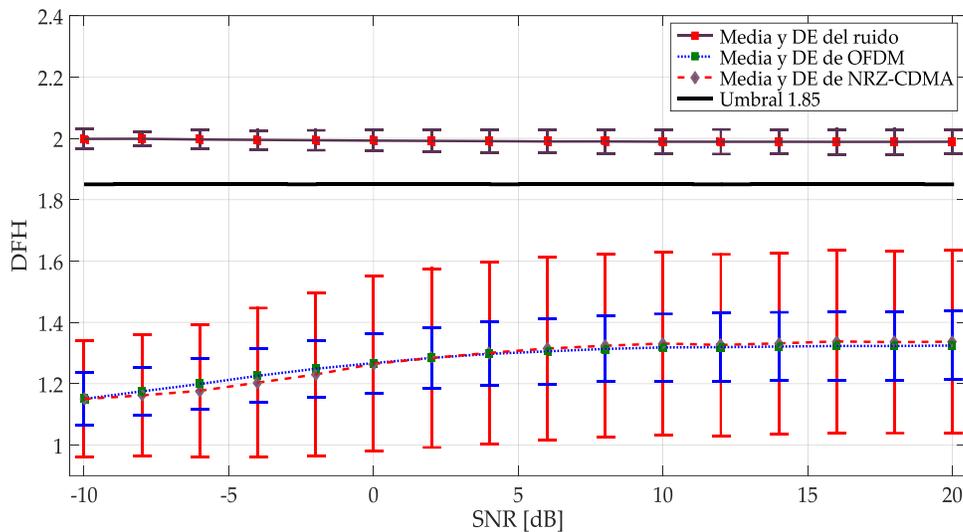


Figura 45. Media y DE para ruido y símbolos simulados (OFDM y NRZ-CDMA) aplicando la primera metodología.

A partir de estos resultados, se puede enfatizar que la aparición de una señal OFDM o NRZ-CDMA no se puede diferenciar directamente (es decir, la media de la DFH es prácticamente la misma para ambos tipos de símbolos con la misma SNR). Sin embargo, existe una clara división de lo qué es ruido y lo qué es una transmisión de un UP. Con base a estos estudios, para la primera metodología, se eligió un umbral para la DFH en la regla de decisión de 1.85.

También se estudió la precisión en la detección de los bordes de frecuencia (donde ocurre un cambio de la señal simulada). Estos bordes son los límites de las ventanas dinámicas, que para la primera metodología se obtienen con el módulo máximo de la TCW. Los resultados de este estudio se muestran en la **Figura 46**. En estas simulaciones, el desempeño del detector de bordes propuesto es excelente, considerando que la media para localizar el borde real simulado de todos los valores detectados es de 5 muestras. En SNR de menos de -4 dB (prácticamente ruido), la detección de bordes es extremadamente imprecisa y los resultados no se muestran en la figura.

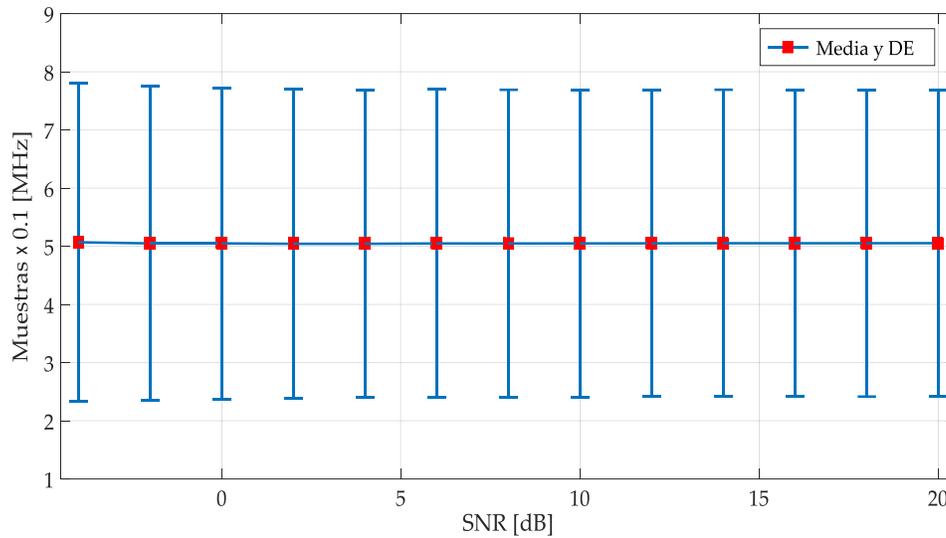


Figura 46. Estudio de detección de bordes de frecuencia aplicando la primera metodología.

El desempeño global para cada metodología se obtuvo considerando el porcentaje total de transmisiones correctamente localizadas con respecto al total de transmisiones de UP simuladas es decir, el porcentaje de éxito (PE). El resultado de esta simulación global con la primera metodología es mostrado en la *Figura 47*.

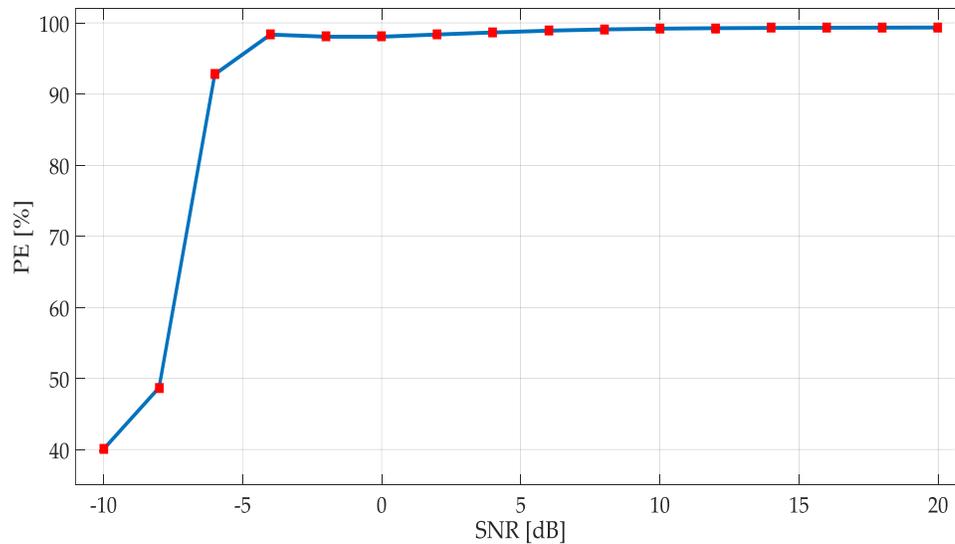


Figura 47. PE de la primera metodología en señales simuladas.

A partir de estos resultados algunos puntos importantes se pueden señalar:

- El desempeño de esta primera metodología propuesta, para SNR por encima de 0 dB es excelente. De hecho, el porcentaje de éxito obtenido es superior al 95 % de detección correcta cuando la SNR es mayor a 5 dB.
- Para los valores de SNR entre 0 y -4 dB, se mantiene el mismo buen desempeño. Si consideramos que en estos valores de SNR la señal está embebida en el ruido, los rendimientos de la técnica propuesta siguen siendo muy buenos.
- Con una SNR <-5 dB, la precisión del método para detectar transmisiones del UP se degrada rápidamente.

6.2.2 Resultados de la segunda metodología

Al igual que con la primera metodología, se realizó un estudio de los símbolos y el ruido implementando la segunda metodología. Sin embargo, en esta ocasión sólo considerando los coeficientes de aproximación obtenidos con el AMR para detectar los bordes de frecuencia y establecer la regla de decisión. Los resultados se muestran en la *Figura 48*. La primera diferencia con respecto a la metodología anterior es que ahora se pueden identificar claramente los tipos de símbolos transmitidos: una señal OFDM o una señal NRZ-CDMA. Los valores medios de la DFH de estas transmisiones están claramente separados e incluso los niveles de varianza no se traslapan realmente, sin embargo esta tarea no es el objetivo de este trabajo de investigación. En segundo lugar, ahora hay una separación más clara en la DFH entre una señal de ruido y una transmisión de un UP, lo que permite establecer un umbral inferior, con respecto a la primera metodología, para la DFH en la regla de decisión. Sin embargo, este umbral se mantiene en 1.85 como el caso de la primera metodología.

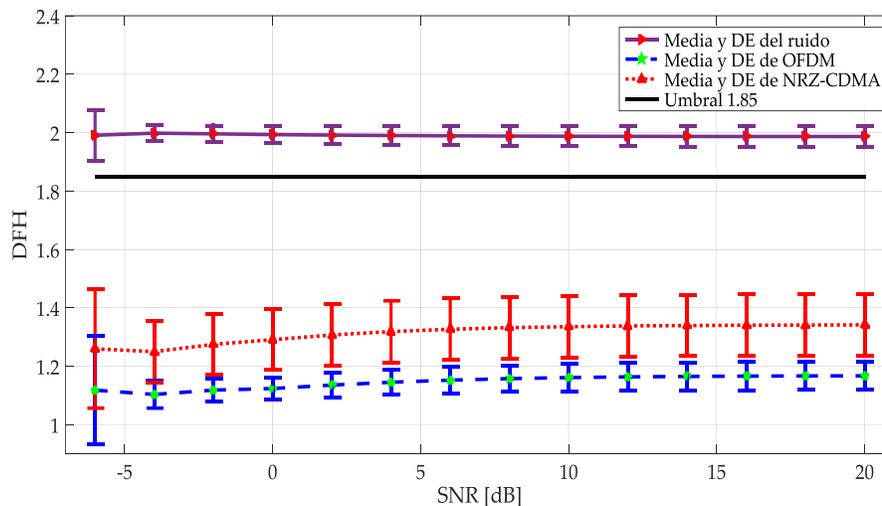


Figura 48. Media y desviación estándar para ruido y símbolos simulados (OFDM y NRZ-CDMA) aplicando la segunda metodología.

La **Figura 49** muestra los resultados del estudio de la precisión en la detección de los bordes de frecuencia. Estos resultados muestran un mejor desempeño con respecto a los obtenidos con la primera metodología. Principalmente se aumenta la precisión para detectar verdaderas transmisiones simuladas a 2.4 muestras (en lugar de 5 en el caso de la primera metodología). Sin embargo, este detector de bordes es más susceptible a los altos niveles de ruido (es decir, con una SNR muy baja), en comparación con el detector basado en el módulo máximo de la TCW.

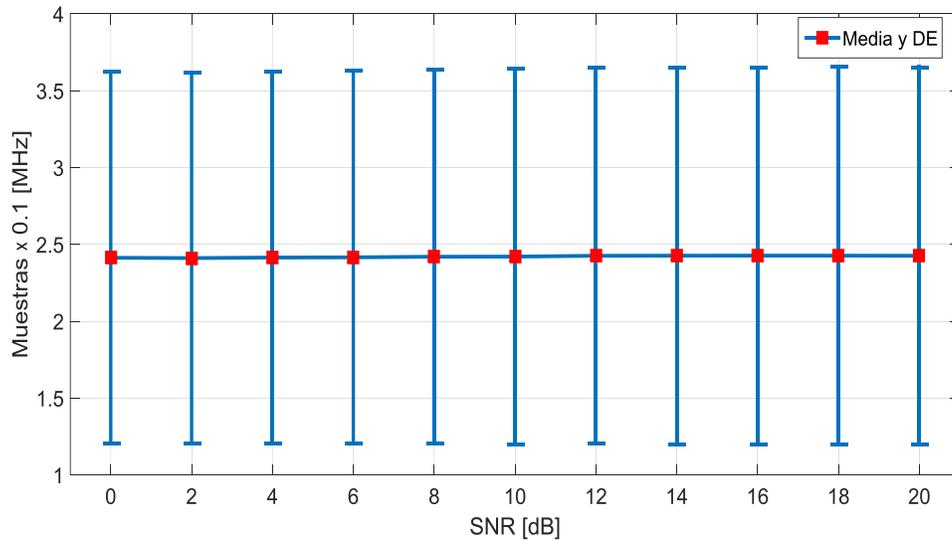


Figura 49. Estudio de detección de bordes de frecuencia aplicando la segunda metodología.

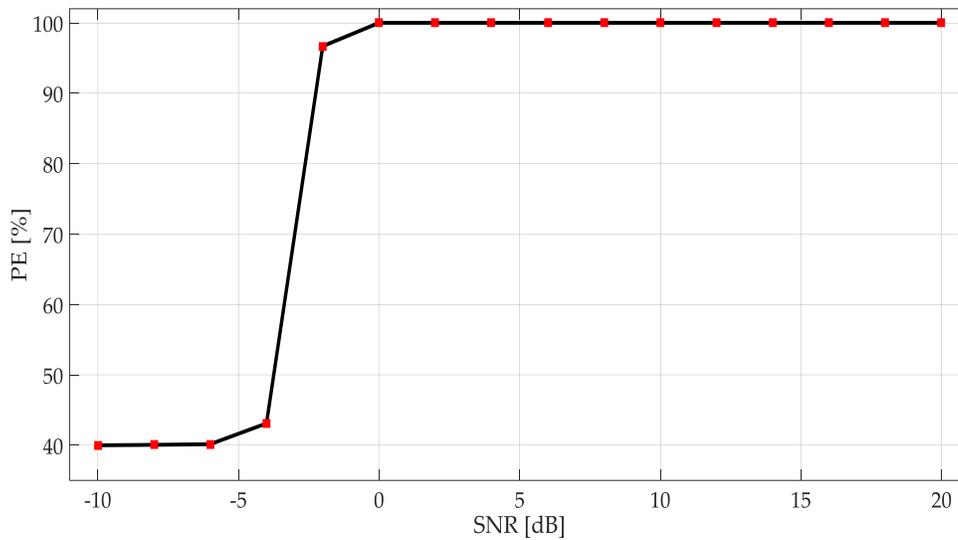


Figura 50. PE de la segunda metodología en señales simuladas.

El porcentaje de éxito de la aplicación de esta segunda metodología se representa en la *Figura 50*. En comparación con la primera metodología, se pueden destacar algunos puntos importantes:

- La segunda metodología para valores de la SNR por encima de 0 dB tiene un mejor desempeño con respecto a la primera metodología. De hecho, el porcentaje de éxito obtenido es prácticamente de alrededor del 98 % de detección correcta para estos valores de SNR.
- Con valores de SNR entre 0 y -4 dB, la primera metodología tiene un mejor desempeño.
- Para una SNR <-5 dB, la precisión de ambos métodos se degrada rápidamente.

6.2.3 Resultados de aplicar las técnicas de ML a la segunda metodología

En este apartado, se realizó una segunda simulación global para cada una de las técnicas de ML mencionadas en la *Sección 5.4*, de 500,000 tramas para cada valor de SNR, variando en el intervalo [-6, 20] dB y espaciados en 2 dB, como se muestra en la *Figura 51*. Al igual que en la simulación global anterior, cada trama, el número, el tipo (OFDM o NRZ asociado a CDMA) y la posición (bordes de frecuencia) del espectro de los símbolos simulados se generaron de forma aleatoria. Cada trama consta de 1024 puntos, separados por 0.1 MHz (es decir, una banda completa de 102.4 MHz). Los parámetros de simulación se resumen en la *Tabla 5*. En la *Figura 51* se agregan dos bloques: la técnica de monitorización multibanda, utilizando la segunda metodología y las diferentes técnicas de ML que funcionan como un clasificador para detectar los bordes de frecuencias que a su vez forman las ventanas dinámicas. Además, se hace el estudio de la precisión en la detección de los bordes de frecuencia y del comportamiento de los símbolos y ruido.

Tabla 5. Parámetros de Simulación considerando las técnicas de ML.

	Técnicas de ML			
	NN - Umbral manual	NN - Umbral por EM	<i>K-means</i>	DPGMM
Software utilizado	MATLAB 2014b			
Valores de SNR	-6 a 20 dB en intervalos de 2 dB			
Número de tramas para cada valor de SNR simulado	500,000			5,000
Número de símbolos para trama	Aleatoriamente en el intervalo [0, 2]			

Ancho de banda de cada trama	102.4 MHz
Muestras por trama	1024
Nivel de descomposición del AMR	3
Wavelet seleccionada	Haar

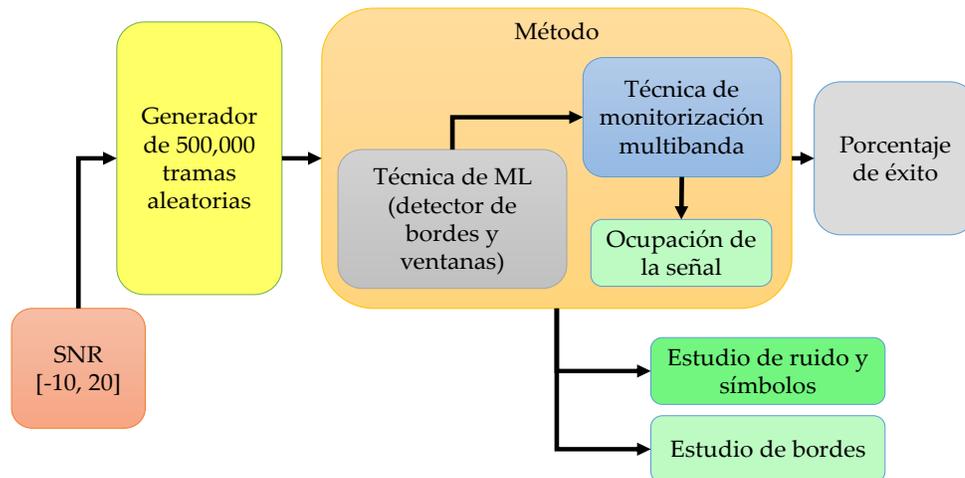


Figura 51. Esquema de la simulación global para ML aplicado a la segunda metodología.

En primera instancia se muestran los resultados de los estudios correspondientes a la detección de los bordes de frecuencia basados en las diferentes propuestas de ML. En el caso del algoritmo basado en EM, es necesario escoger un umbral aleatorio entre los valores de $L1$ y $L2$. Esta decisión es el resultado del estudio mostrado en la *Figura 52*. Para ello se realizó una simulación de 10,000 tramas generadas aleatoriamente para cada valor de SNR y se escogieron dos umbrales ($L1$, $L2$) basados en los valores máximo y mínimo obtenidos, respectivamente. En la *Figura 52* se muestra la media de la detección de bordes de frecuencia considerando cada uno de estos límites. En esta figura se puede observar que elegir entre cualquiera de los límites no representa un gran cambio en el resultado. Lo que supone que si escogemos un valor aleatorio entre uno de estos dos valores no hará una gran diferencia al detectar los bordes de frecuencia.

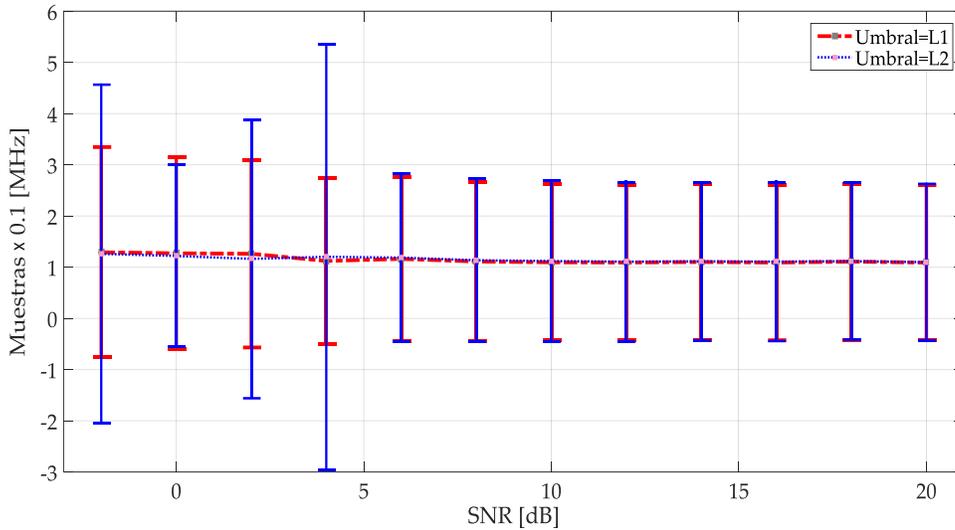


Figura 52. Media y DE de la detección de los bordes de frecuencia considerando los umbrales $L1$, $L2$ como los valores máximo y mínimo posibles, respectivamente.

En la **Figura 53** se muestra el estudio de detección de bordes para cada una de las técnicas de ML aplicadas a lo largo de las diferentes SNR. Donde aparentemente la media de cada uno de ellos tiende a tener el mismo comportamiento como se muestra en la **Tabla 6**. Sin embargo, podemos observar que la DE para cada técnica en sus diferentes valores de SNR difiere bastante en algunos casos. Con base en estos resultados, se puede concluir que la técnica más estable para localizar los bordes de frecuencia es *K-means*.

Tabla 6. Media de la detección de bordes para cada SNR simuladas.

Técnica	SNR												
	-2	0	2	4	6	8	10	12	14	16	18	20	
NN - Umbral Manual	1.49	2	1.07	1.99	1.1	1.18	2.99	1.16	1.18	1.16	1.66	1.33	
<i>K-means</i>	1.22	1.18	1.15	1.12	1.11	1.1	1.1	1.1	1.09	1.09	1.09	1.09	
NN - Umbral con EM	2.14	1.3	1.29	1.26	1.17	1.25	1.48	1.35	1.32	1.27	1.13	1.36	
DPGMM	1.65	1.07	1.16	0.93	1.1	1.13	1.07	1.08	1.54	0.86	1.27	1.24	

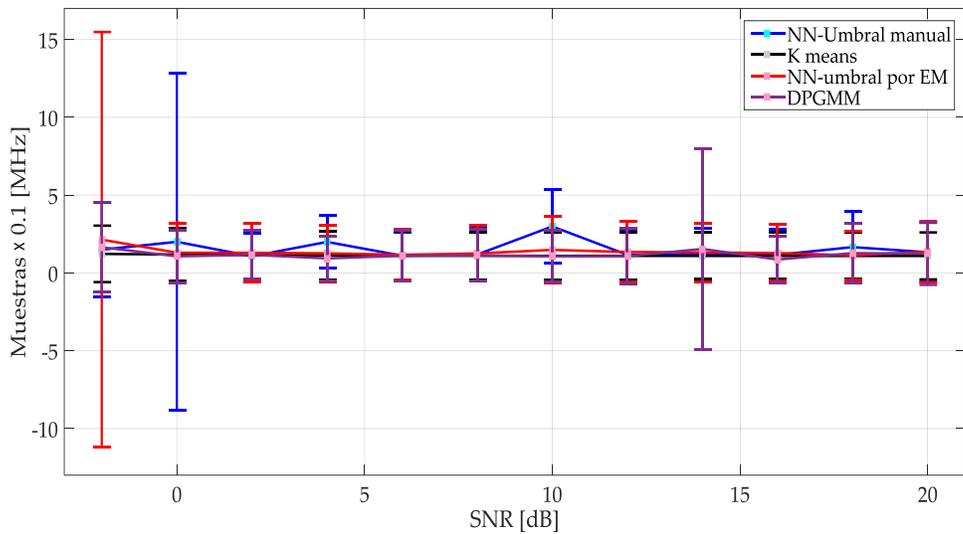


Figura 53. Media y DE para localizar los bordes de frecuencia con base en las diferentes técnicas de ML propuestas.

En la *Figura 54* es posible observar el porcentaje de acierto para cada una de las técnicas planteadas. Podemos destacar los siguientes puntos:

- La NN muestra una clara mejora en los -2 dB al utilizar el algoritmo EM para determinar el umbral con el cual se entrena la red.
- DPGMM muestra un comportamiento totalmente inestable e impredecible. Lo cual se atribuye a que, al ser una técnica general no supervisada para clasificación, separa los coeficientes en más de dos clases (en algunos casos tiende a catalogarlos en un grupo debido a que la separación entre los coeficientes es pequeña, a pesar de que exista transmisión de un UP).
- K- means, NN-umbral basado en el algoritmo EM y NN-Umbra manual presentan un porcentaje de éxito de prácticamente el 100 % para SNR>0 dB.
- Para todas las técnicas, el rendimiento decae abruptamente para SNR<= -4 dB. Este valor es básicamente una señal embebida en el ruido.
- La técnica que muestra el mejor porcentaje de acierto en general es *K-means*.

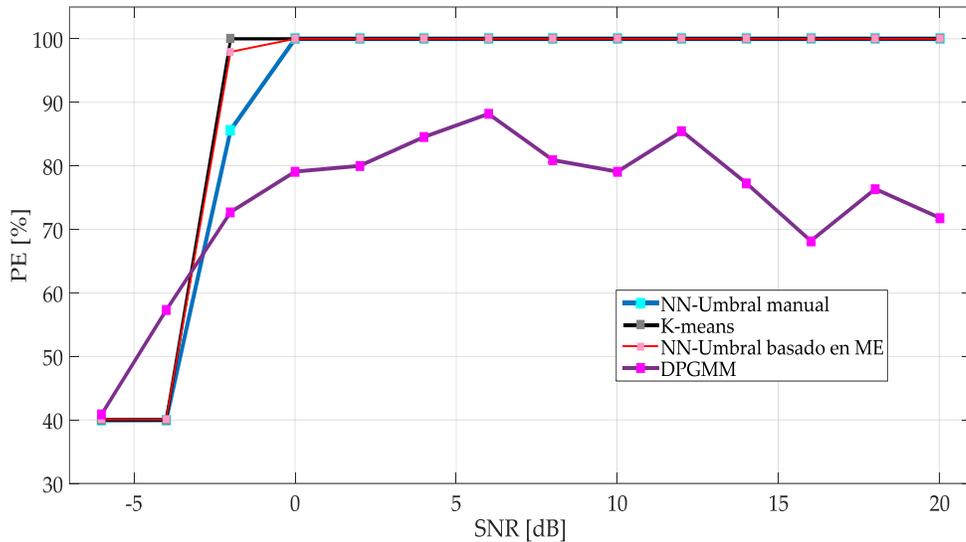


Figura 54. PE de cada técnica de ML para los diferentes valores de SNR.

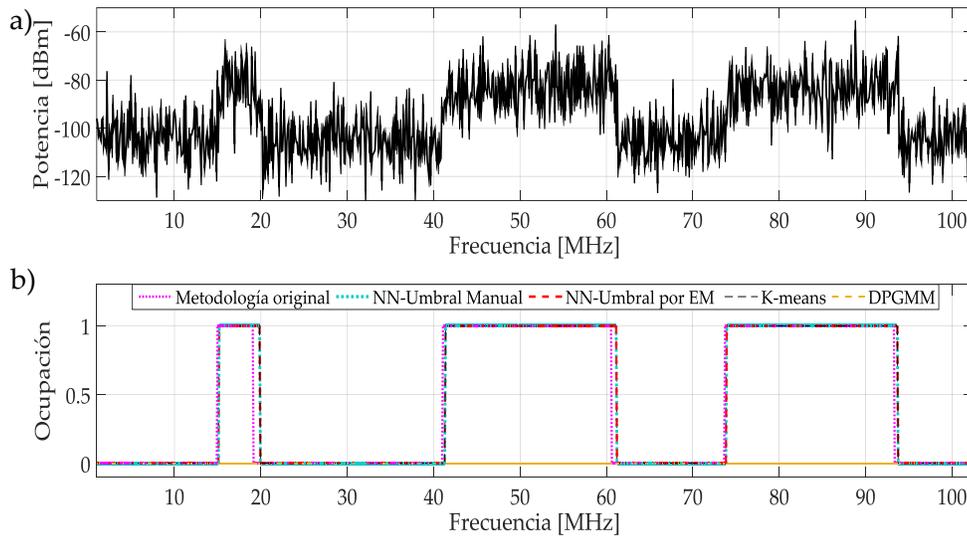


Figura 55. a) Espectro multibanda generado aleatoriamente. b) Segunda metodología y las cuatro técnicas de ML aplicadas para determinar la ocupación del UP.

Como ejemplo en la *Figura 55 a)* aparece el espectro multibanda aleatorio que representa un caso difícil debido a la potencia de ruido que contiene. En la *Figura 55 b)* se muestra que las técnicas que presentan un mejor rendimiento en un entorno bastante ruidoso son NN con umbral manual, NN con umbral por EM y *K-means*. Por otro lado, DPGMM como se había mencionado, tiene errores al detectar la presencia del UP (esto porque hace una clasificación incorrecta de los coeficientes, para este caso 3). Lo que la convierte en una técnica no viable de las cuatro utilizadas en este trabajo. Además, la

complejidad computacional de DPGMM lleva a un alto tiempo de ejecución que toma en promedio de 16.67 segundos (sólo para hacer la clasificación de los coeficientes) en comparación con *K-means* que es 0.0027 segundos. Lo que significa que DPGMM es al menos 6000 veces más lento³. También DPGMM tiene una alta deficiencia para detectar las transmisiones de los posibles UP comparada con las otras técnicas de ML propuestas. Esta técnica pues ser descartada en la implementación de la metodología propuesta.

6.3 Aplicación de las metodologías en señales reales

Las metodologías planteadas en este trabajo de investigación fueron utilizadas para determinar la ocupación de los diferentes espectros obtenidos del entorno (ver *Capítulo 4*), algunos de los resultados son mostrados a continuación. En primer término se implementaron las metodologías basadas en la TCW y en los coeficientes de aproximación obtenidos con el AMR. En los ejemplos mostrados se realiza una comparación del desempeño de ambos métodos para la detección de los UP y los bordes de frecuencia respectivos. Posteriormente se aplicaron las diferentes técnicas de ML propuestas únicamente para el caso de la metodología basada en los coeficientes de aproximación para la mejora en la detección de los bordes de frecuencia. Las señales analizadas, mostradas a continuación, fueron seleccionadas considerando las bandas de frecuencia mostradas anteriormente en la *Tabla 2*. Sólo se consideró, por cuestiones de espacio, un ejemplo para cada una de las bandas seleccionadas.

6.3.1 Resultados de la primera y segunda metodología a señales reales

En el caso mostrado en la *Figura 56* que ha sido obtenida de la banda de frecuencia [698-806] MHz se aplican las dos metodologías. En este caso, la metodología basada en los coeficientes de aproximación proporciona una mejor detección de bordes de frecuencia.

³ En este caso se utilizó una computadora portátil con sistema operativo *Windows 7 professional*, core i5 a 2.6 GHz y 12 GB en RAM

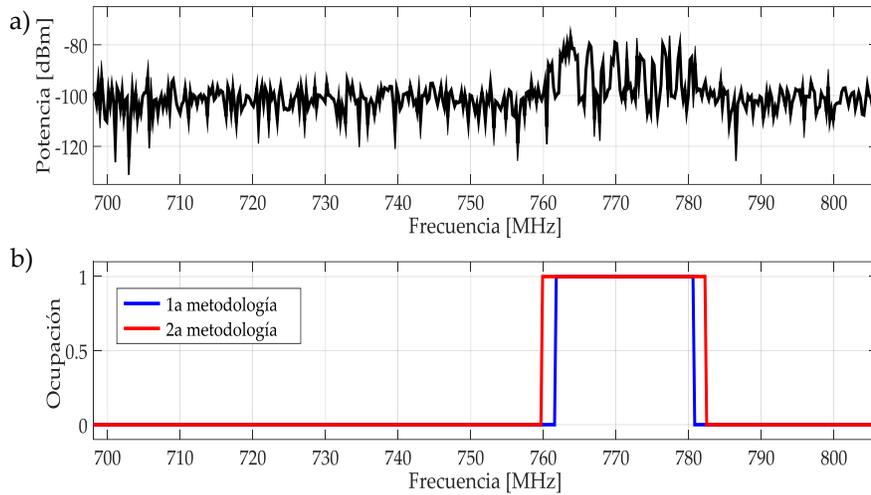


Figura 56. a) Señal real obtenida de la banda de frecuencia [698 - 806] MHz. b) El resultado de aplicar ambas metodologías a la señal real en términos de ocupación del espectro.

En la *Figura 57* se analiza la ocupación del espectro en la banda de frecuencia [806-902] MHz. En esta figura ambas metodologías hacen una correcta detección de las transmisiones de los UP, sin embargo la metodología basada en los coeficientes de aproximación del AMR hace una mejor detección de bordes de frecuencia.

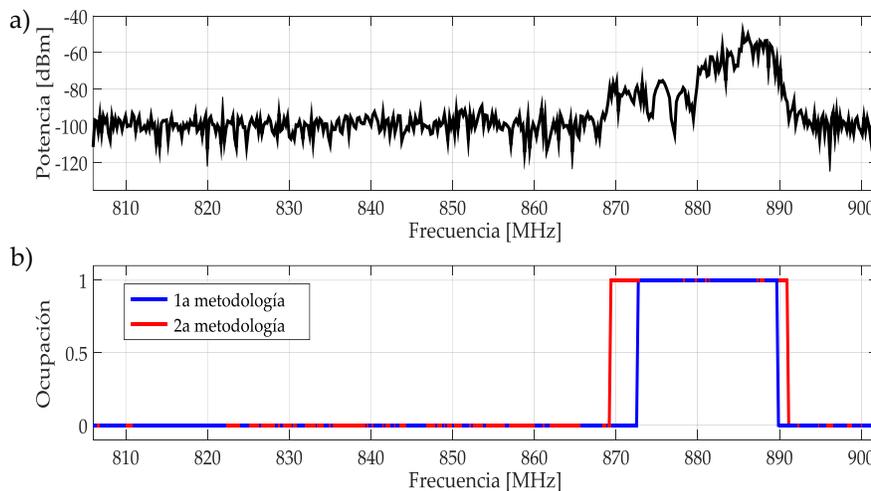


Figura 57. a) Señal real obtenida de la banda de frecuencia [806 - 902] MHz. b) El resultado de aplicar ambas metodologías a la señal real en términos de ocupación del espectro.

También, ambas metodologías hacen una correcta detección en un entorno que carece de transmisión de un UP como se muestra en la *Figura 58*. En esta figura se analiza la banda de frecuencia [902-928] MHz.

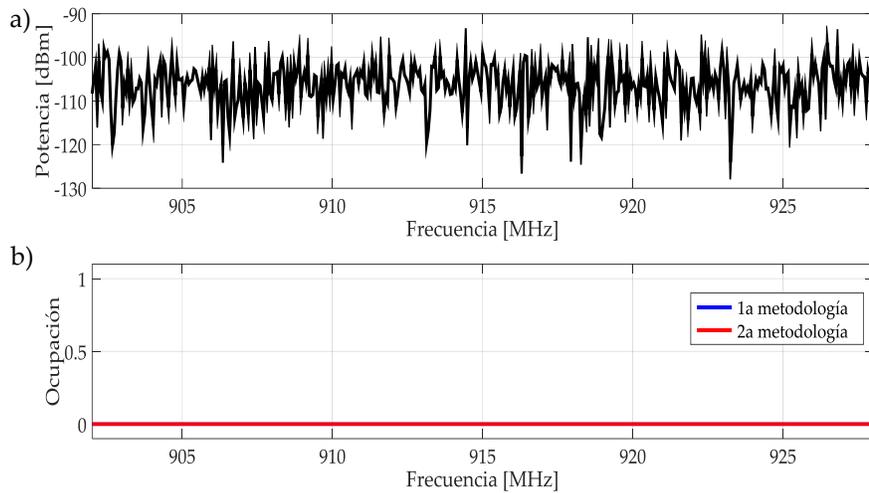


Figura 58. a) Una señal real obtenida de la banda de frecuencia [902 - 928] MHz. b) El resultado de aplicar ambas metodologías a la señal real en términos de ocupación del espectro.

En la *Figura 59* se observa la ocupación del espectro en la banda de frecuencia [1.7-2] GHz. En esta figura, se muestra que las dos metodologías detectan correctamente el espacio ocupado por los UP. Sin embargo la metodología basada en los coeficientes de aproximación hace una mejor detección de bordes de frecuencia.

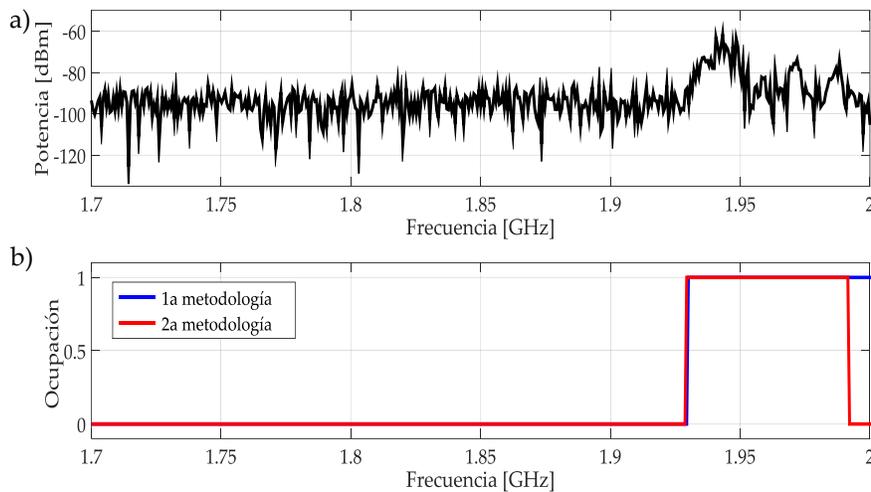


Figura 59. a) Señal real obtenida de la banda de frecuencia [1.7 - 2] GHz. b) El resultado de aplicar ambas metodologías a la señal real en términos de ocupación del espectro

En la *Figura 60* se analiza la banda de frecuencia [2.3-2.5] GHz. En esta figura se aprecia la ocupación del espectro donde la metodología basada en la TCW tiene un mejor desempeño en localizar los bordes de frecuencia.

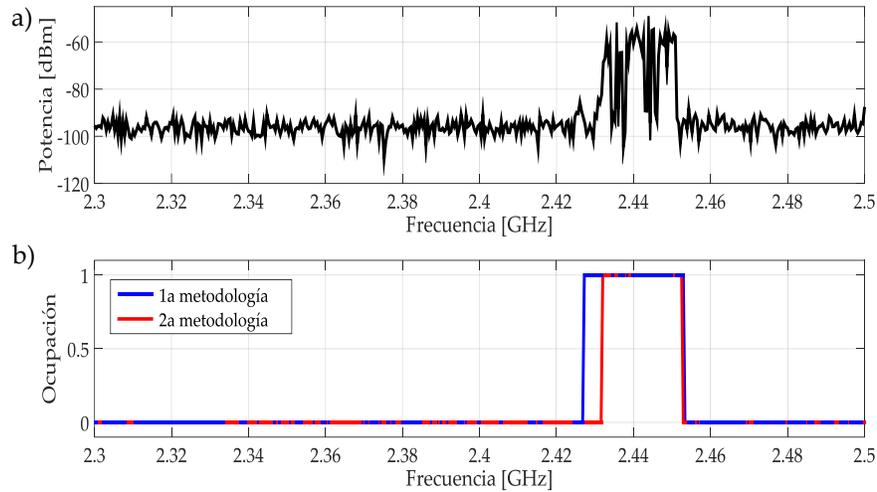


Figura 60. a) Señal real obtenida de la banda de frecuencia [2.3 - 2.5] GHz. b) El resultado de aplicar ambas metodologías a la señal real en términos de ocupación del espectro.

En la **Figura 61** se analiza la ocupación del espectro en la banda de frecuencia [2.6-2.8] GHz. En esta figura se muestra que ambas metodologías hacen una correcta detección ante la presencia de UP. Sin embargo la metodología basada en los coeficientes de aproximación tiene un mejor resultado en los bordes de frecuencia.

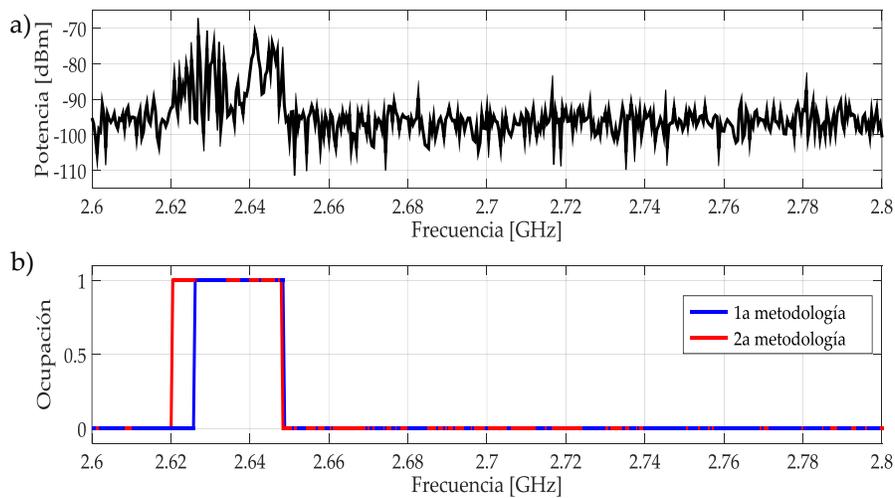


Figura 61. a) Una señal real obtenida de la banda de frecuencia [2.6 - 2.8] GHz. b) El resultado de aplicar ambas metodologías a la señal real en términos de ocupación del espectro. En este caso, la segunda metodología da una mejor detección de bordes de frecuencia.

Finalmente, ambas metodologías se aplicaron a una señal real que cubre el intervalo de frecuencia completo [0.6 - 2.6] GHz, como se muestra en la *Figura 62*. Aquí ambas metodologías muestran un buen desempeño en una detección correcta frente a la transmisión de los UP.

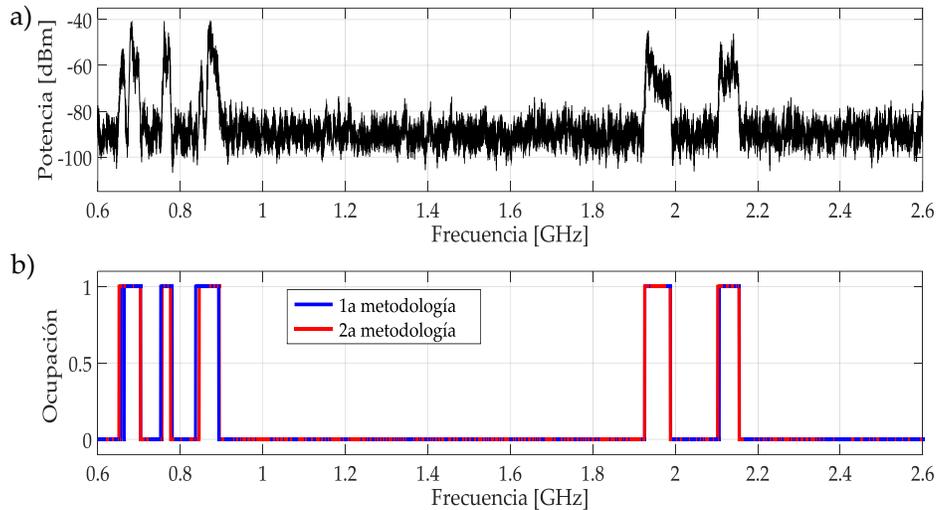


Figura 62. a) Una señal real obtenida de la banda ancha completa de [0.6 - 2.6] GHz. b) El resultado de aplicar ambas metodologías a la señal real en términos de ocupación del espectro.

El desempeño en general de ambas metodologías es notable. En algunas ocasiones, la detección de frecuencia de borde tiende a ser mejor para la primera metodología, como en el caso de las señales que se muestran en la *Figura 60*. No obstante, de forma general la segunda metodología supera ligeramente a la primera. Sin embargo, en todos los casos, la transmisión del UP es perfectamente detectada. En el caso de la señal de sólo ruido, ambas metodologías funcionan perfectamente (ver *Figura 58*). La gran ventaja de la segunda metodología es una menor complejidad computacional en comparación con la primera metodología (la inclusión del módulo máximo de la TCW involucra muchas operaciones computacionales). Esto brinda una oportunidad real para que la segunda metodología se considere en una implementación en tiempo real, teniendo en cuenta que el AMR utiliza un algoritmo rápido en su implementación.

6.3.2 Resultados de la 2da metodología con técnicas de ML a señales reales

En las señales reales tomadas directamente del entorno no es posible controlar la transmisión del UP; sin saber su potencia y los límites exactos de frecuencia donde se está transmitiendo. Sin embargo, por inspección, la mayor parte del tiempo es posible reconocer una o más transmisiones del UP en un espectro multibanda específico. Sobre la base de estos hechos, se aplicó la segunda metodología con las diferentes técnicas de ML a los datos obtenidos en las diferentes bandas mencionadas en la *Tabla 2*. En este trabajo, se elige un caso desafiante (señal) para cada banda y los resultados se representan en las siguientes figuras. Para la banda [902-928] MHz, las señales no contenían transmisión del UP (solo ruido). En la *Figura 63* se analiza la ocupación del espectro en la banda de frecuencia [698-906] MHz. En esta figura se observa que las técnicas NN con umbral manual, NN con umbral basado en el algoritmo EM y *K-means*, tienen un correcto desempeño. Sin embargo, DPGMM no localiza la transmisión de UP.

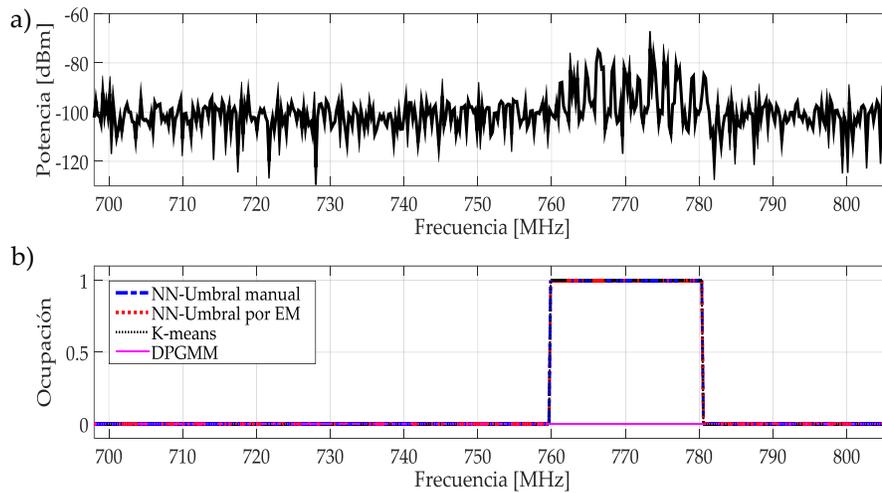


Figura 63. a) Señal real obtenida de la banda de frecuencia [698 - 806] MHz. b) El resultado de aplicar las cuatro técnicas de ML a la 2da metodología a la señal real en términos de ocupación del espectro.

En la *Figura 64* se muestra cómo *K-means*, NN con umbral basado en el algoritmo EM y en DPGMM proporcionan buenos resultados, siendo las dos últimas las de mejor desempeño, detectando las tres transmisiones del UP. Por otro lado, con NN - umbral manual localiza dos de las tres transmisiones.

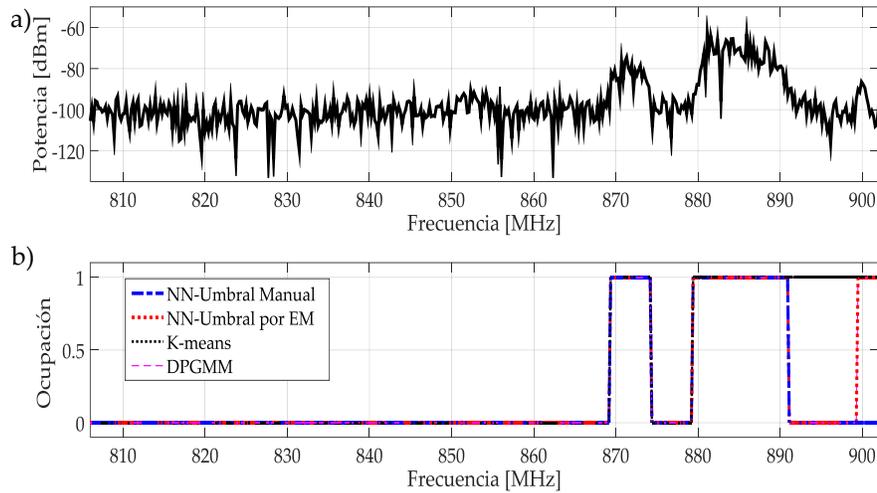


Figura 64. a) Señal real obtenida de la banda de frecuencia [806-902] MHz. b) El resultado de aplicar las cuatro técnicas de ML a la 2da metodología a la señal real en términos de ocupación del espectro.

Para el caso mostrado en la *Figura 65*, visualmente todas las metodologías brindan buenos resultados, detectando la aparición de UP (las transmisiones observadas están muy juntas). NN con umbral manual muestra un resultado favorable y tal vez el más preciso de las cuatro técnicas, detectando los bordes de frecuencia de las transmisiones de UP.

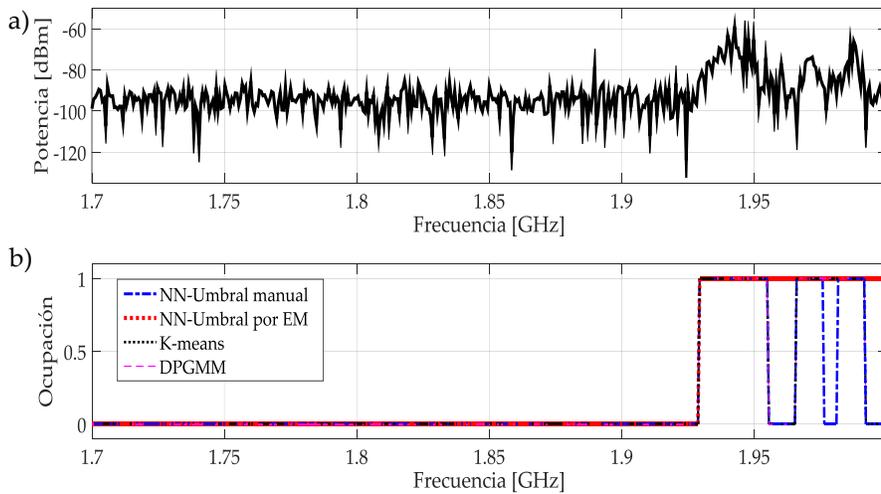


Figura 65. a) Señal real obtenida de la banda de frecuencia [1.7-2] GHz. b) El resultado de aplicar las cuatro técnicas de ML a la 2da metodología a la señal real en términos de ocupación del espectro.

En la *Figura 66* se muestra cómo visualmente todas las metodologías brindan buenos resultados, detectando la aparición de UP (las transmisiones observadas están muy juntas).

Siendo NN con umbral manual la que proporciona el resultado más favorable detectando con más precisión la separación entre las transmisiones.

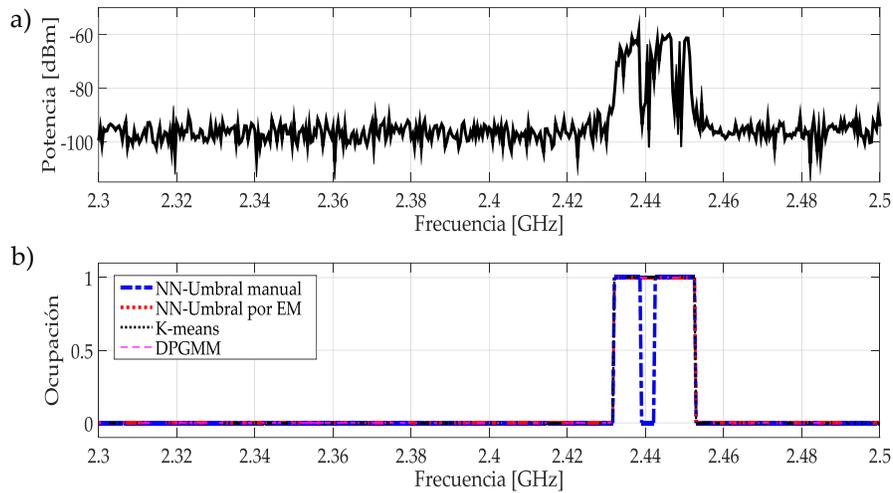


Figura 66. a) Señal real obtenida de la banda de frecuencia [2.3-2.5] GHz. b) El resultado de aplicar las cuatro técnicas de ML a la 2da metodología a la señal real en términos de ocupación del espectro.

En el caso mostrado en la *Figura 67*, visualmente todas las metodologías proporcionan buenos resultados, detectando la aparición de UP. En esta transmisión, KMEANS y DPGMM muestran una mejor precisión para la detección de bordes de frecuencia.

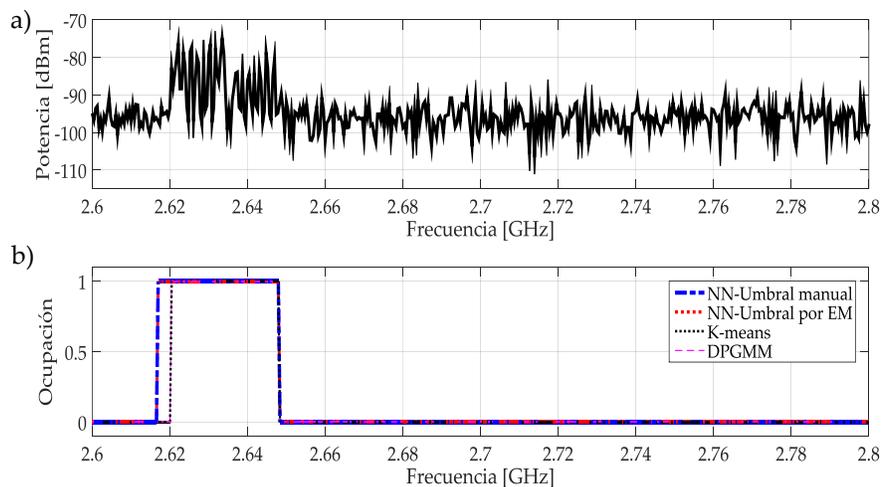


Figura 67. a) Señal real obtenida de la banda de frecuencia [2.6-2.8] GHz. b) El resultado de aplicar las cuatro técnicas de ML a la 2da metodología a la señal real en términos de ocupación del espectro.

Capítulo 7

Conclusiones y perspectivas de investigación

En general este trabajo se puede dividir en dos etapas. En la primera parte, se proponen dos metodologías novedosas basadas en *wavelets* y la dimensión fractal de Higuchi aplicada a la detección de espectro multibanda. La diferencia entre estas dos metodologías reside en la detección de los bordes de frecuencia. La primera utiliza el módulo máximo de la TCW de la señal reconstruida a partir de los coeficientes de aproximación del AMR. La segunda usa directamente estos coeficientes interpolados y normalizados. La regla de decisión para ambas metodologías se basa en la dimensión fractal de Higuchi. A partir de los diferentes resultados obtenidos de simulaciones y su implementación en señales reales, se pueden obtener algunas conclusiones importantes:

- La DFH de una serie que corresponde a un ruido blanco gaussiano, tendrá un valor cercano a 2, ya que no existe auto-similitud en esta señal.
- Con base en este elemento y en las simulaciones realizadas, es posible discriminar el ruido de una transmisión de un UP para ambas metodologías.
- Los mejores resultados se obtienen considerando ventanas de tamaño no uniforme. Aquí la detección de bordes de frecuencia es muy importante. Ambos métodos propuestos para esta tarea, el módulo máximo de la TCW o directamente los coeficientes de aproximación del AMR, dan excelentes resultados para la detección de estos bordes; donde la segunda metodología muestra ventaja en cuestión de implementación y complejidad computacional.
- Se puede concluir, a partir de los resultados de la simulación, que la primera metodología para la detección de espectro multibanda funciona en al menos el 95 % de los casos con una SNR mayor o igual a 0 dB. Este rendimiento se mejora con la segunda metodología que alcanza porcentajes de éxito de alrededor del 98 %, en promedio.
- Para señales reales, se debe enfatizar que con las dos metodologías propuestas, aplicadas a las bandas mencionadas en la *Tabla 2*, se han obtenido resultados favorables en todos los casos analizados.

Finalmente, la posibilidad de una implementación en tiempo real especialmente de la segunda metodología es factible.

Como segunda parte del trabajo, se considera la inclusión de técnicas de ML para evitar los umbrales de decisión y automatizar el proceso completo de detección, para ello se han propuesto cuatro técnicas de ML aplicadas a la segunda metodología. Algunos puntos destacables son los siguientes:

- Agregar ML a la segunda metodología evitó colocar un umbral en los coeficientes de aproximación normalizados e interpolados. Y no sólo se mantuvo el mismo porcentaje de éxito sino que se mejoró la precisión para detectar los bordes de aparición de un UP.
- De la etapa de detección de bordes y el porcentaje de éxito para detectar correctamente la presencia de un UP podemos determinar que, la NN con umbral manual, la NN con umbral basado en el algoritmo EM y *K-means* presentan excelentes resultados. Mejorando los desempeño de la segunda metodología teniendo el 99 % de porcentaje de éxito y entre [1, 2] muestras de error en la detección de bordes para una $SNR \geq 0$ dB.
- La técnica más viable de ML propuesta en este trabajo es *K-means*. No requiere una gran complejidad computacional, en comparación con una NN donde requiere *hardware* más potente, lo que pone más limitaciones en los dispositivos de tamaño reducido (que traería como consecuencia un alto tiempo de procesamiento y ejecución).
- A lo largo de las diferentes simulaciones, se ha percibido, que la precisión no depende sólo de la técnica de ML utilizada, o del método de monitorización del espectro, sino también de cuántos puntos contiene la señal a evaluar. Esto es porque el procesamiento se realiza directamente sobre los coeficientes de aproximación, que corresponden al número original de puntos de la señal divididos por 2^L donde L es el nivel de descomposición por *wavelet*.
- Cabe destacar que la segunda metodología con las diferentes técnicas de ML se probó en señales de un entorno real, obteniendo resultados visualmente aceptables, donde podría ubicar la aparición de múltiples UP.
- DPGMM no es una técnica viable para implementar en esta segunda metodología. El mal desempeño, el alto tiempo de ejecución y procesamiento la descartan.
- Recibir una señal aleatoria (es decir, no tener conocimiento de la aparición del UP ni frecuencias en las que aparece, SNR, modulación, etc.), determinar la ocupación de la señal y donde podrían colocarse posibles US, es la principal idea de las propuestas mencionadas. Esto obliga a no tener un punto de referencia, por lo cual, no es posible utilizar algunas otras técnicas de ML como teoría de juegos.
- Utilizar una NN con umbral basado en el algoritmo EM nace de la pregunta, ¿Será posible enseñarle a un algoritmo a entrenarse? En este caso buscamos un

algoritmo que tenga un buen desempeño, sea rápido y además este completamente automatizado (es decir, que no dependa de un tercero para ser entrenado). Para los fines de este trabajo, la respuesta es sí. En comparación con la NN con umbral manual se mejoró la etapa de detección de bordes de frecuencia y el porcentaje de éxito para $SNR = 2$ dB. Para $SNR \geq 0$ dB se mantiene al menos la misma eficiencia. Enfatizando que el usuario que definió el umbral manual en las diferentes simulaciones conocía del tema, buscando siempre que el umbral categorizara lo más exacto posible los coeficientes de aproximación en la etapa de entrenamiento de la NN.

Respecto a las perspectivas de investigación, se prevé que los métodos presentados aquí podrían ser considerados en un escenario para las comunicaciones inalámbricas recientes. Además, las metodologías propuestas se podrían implementar en *hardware* de comunicaciones genérico para conocer su eficiencia en un entorno real.

Referencias

- [1] “Cuadro Nacional de Atribución de Frecuencias (CNAF) | Cuadro Nacional de Atribución de Frecuencias (CNAF) - IFT.” [Online]. Available: <http://cnaft.ift.org.mx/>. [Accessed: 25-Mar-2019].
- [2] 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.
- [3] 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.
- [4] 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.
- [5] 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.
- [6] 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.
- [7] 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, p. 1322, Mar. 2019.
- [8] Sai 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, 2005, pp. 160–169.
- [9] T. Yucek and H. Arslan, “A survey of spectrum sensing algorithms for cognitive radio applications,” *IEEE Communications Surveys & Tutorials*, vol. 11, no. 1, pp. 116–130, 2009.
- [10] T. Yucek and H. Arslan, “Spectrum Characterization for Opportunistic Cognitive Radio Systems,” in *MILCOM 2006*, Washington, DC, USA, 2006, pp. 1–6.
- [11] 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, 2000, vol. 2, pp. 1054–1059.
- [12] J. G. Proakis, *Digital Communications*, 4th ed. McGraw-Hill, 2001.
- [13] R. Tandra and A. Sahai, “Fundamental limits on detection in low SNR under noise uncertainty,” in *2005 International Conference on Wireless Networks, Communications and Mobile Computing*, Maui, HI, USA, 2005, vol. 1, pp. 464–469.
- [14] Jun Ma, Guodong Zhao, and Ye Li, “Soft Combination and Detection for Cooperative Spectrum Sensing in Cognitive Radio Networks,” *IEEE Transactions on Wireless Communications*, vol. 7, no. 11, pp. 4502–4507, Nov. 2008.

- [15] 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.
- [16] M. Sanna and M. Murrone, "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.
- [17] 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.
- [18] 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.
- [19] 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.
- [20] 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.
- [21] 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.
- [22] G. Hattab and M. Ibnkahla, "Multiband Spectrum Sensing: Challenges and Limitations," *arXiv:1409.6394 [cs, math]*, Sep. 2014.
- [23] H. Joshi, H. H. Sigmarsson, Sungwook Moon, D. Peroulis, and W. J. Chappell, "High-Q Fully Reconfigurable Tunable Bandpass Filters," *IEEE Transactions on Microwave Theory and Techniques*, vol. 57, no. 12, pp. 3525–3533, Dec. 2009.
- [24] Ling Luo, N. M. Neihart, S. Roy, and D. J. Allstot, "A two-stage sensing technique for dynamic spectrum access," *IEEE Transactions on Wireless Communications*, vol. 8, no. 6, pp. 3028–3037, Jun. 2009.
- [25] W. Ejaz, N. U. Hasan, and H. S. Kim, "iDetection: Intelligent Primary User Detection for Cognitive Radio Networks," 2012, pp. 153–157.
- [26] B. Farhang-Boroujeny, "Filter Bank Spectrum Sensing for Cognitive Radios," *IEEE Transactions on Signal Processing*, vol. 56, no. 5, pp. 1801–1811, May 2008.
- [27] Z. Tian and G. B. Giannakis, "A Wavelet Approach to Wideband Spectrum Sensing for Cognitive Radios," in *2006 1st International Conference on Cognitive Radio Oriented Wireless Networks and Communications*, Mykonos Island, Greece, 2006, pp. 1–5.
- [28] Z. Tian and G. B. Giannakis, "Compressed Sensing for Wideband Cognitive Radios," 2007, pp. IV-1357–IV-1360.
- [29] A. Mahram, M. G. Shayesteh, and S. B. Kordan, "A novel wideband spectrum sensing algorithm for cognitive radio networks based on DOA estimation model," 2012, pp. 359–362.
- [30] 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, p. 96, Aug. 2017.
- [31] I. Daubechies, *Ten lectures on wavelets*, 9. print. Philadelphia, Pa: Soc. for Industrial and Applied Mathematics, 2006.

- [32] 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.
- [33] Y. Zeng, Y.-C. Liang, and M. W. Chia, "Edge based wideband sensing for cognitive radio: Algorithm and performance evaluation," in *2011 IEEE International Symposium on Dynamic Spectrum Access Networks (DySPAN)*, Aachen, Germany, 2011, pp. 538–544.
- [34] Y.-L. Xu, H.-S. Zhang, and Z.-H. Han, "The Performance Analysis of Spectrum Sensing Algorithms Based on Wavelet Edge Detection," in *2009 5th International Conference on Wireless Communications, Networking and Mobile Computing*, Beijing, China, 2009, pp. 1–4.
- [35] 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, 2013, pp. 418–423.
- [36] S. G. Mallat, "A theory for multiresolution signal decomposition: the wavelet representation," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 11, no. 7, pp. 674–693, Jul. 1989.
- [37] B. B. Mandelbrot, *Fractals: form, chance, and dimension*. San Francisco: Freeman, 1977.
- [38] T. Higuchi, "Approach to an irregular time series on the basis of the fractal theory," *Physica D: Nonlinear Phenomena*, vol. 31, no. 2, pp. 277–283, Jun. 1988.
- [39] 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.
- [40] V. Sharma and V. Bohara, "Exploiting machine learning algorithms for cognitive radio," in *2014 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, Delhi, India, 2014, pp. 1554–1558.
- [41] J. Han and M. Kamber, *Data mining: concepts and techniques*, 3rd ed. Burlington, MA: Elsevier, 2012.
- [42] A. P. Dempster, N. M. Laird, and D. B. Rubin, "Maximum Likelihood from Incomplete Data Via the EM Algorithm," *Journal of the Royal Statistical Society: Series B (Methodological)*, vol. 39, no. 1, pp. 1–22, Sep. 1977.
- [43] A. K. Jain, "Data clustering: 50 years beyond K-means," *Pattern Recognition Letters*, vol. 31, no. 8, pp. 651–666, Jun. 2010.
- [44] M. Meilă, "The uniqueness of a good optimum for K-means," in *Proceedings of the 23rd international conference on Machine learning - ICML '06*, Pittsburgh, Pennsylvania, 2006, pp. 625–632.
- [45] Y. W. Teh, M. I. Jordan, M. J. Beal, and D. M. Blei, "Hierarchical Dirichlet Processes," *Journal of the American Statistical Association*, vol. 101, no. 476, pp. 1566–1581, Dec. 2006.
- [46] S. F. Barrett and D. J. Pack, *Microcontrollers fundamentals for engineers and scientists*, 1. ed. San Rafael, Calif.: Morgan & Claypool, 2006.
- [47] K. M. Thilina, Kae Won Choi, N. Saquib, and E. Hossain, "Machine Learning Techniques for Cooperative Spectrum Sensing in Cognitive Radio Networks," *IEEE Journal on Selected Areas in Communications*, vol. 31, no. 11, pp. 2209–2221, Nov. 2013.
- [48] J. Oksanen, J. Lunden, and V. Koivunen, "Reinforcement learning method for energy efficient cooperative multiband spectrum sensing," in *2010 IEEE International Workshop on Machine Learning for Signal Processing*, Kittila, Finland, 2010, pp. 59–64.

- [49] 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, 2011, pp. 1–6.
- [50] 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, 2013, pp. 200–203.
- [51] Z. Han, R. Zheng, and H. V. Poor, "Repeated Auctions with Bayesian Nonparametric Learning for Spectrum Access in Cognitive Radio Networks," *IEEE Transactions on Wireless Communications*, vol. 10, no. 3, pp. 890–900, Mar. 2011.
- [52] N. Shetty, S. Pollin, and P. Pawelczak, "Identifying Spectrum Usage by Unknown Systems using Experiments in Machine Learning," in *2009 IEEE Wireless Communications and Networking Conference*, Budapest, Hungary, 2009, pp. 1–6.



MONITORIZACION DEL ESPECTRO
MULTIBANDA EN RADIOS
COGNOSCITIVOS.

En la Ciudad de México, se presentaron a las 12:00 horas del día 27 del mes de septiembre del año 2019 en la Unidad Iztapalapa de la Universidad Autónoma Metropolitana, los suscritos miembros del jurado:

DR. MARCO AURELIO CARDENAS JUAREZ
DR. RAFAEL AGUILAR GONZALEZ
DR. MIGUEL LOPEZ GUERRERO

Bajo la Presidencia del primero y con carácter de Secretario el último, se reunieron para proceder al Examen de Grado cuya denominación aparece al margen, para la obtención del grado de:

MAESTRO EN CIENCIAS (CIENCIAS Y TECNOLOGIAS DE LA INFORMACION)

DE: YANQUELETH ANTONIO DE JESUS MOLINA TENORIO

y de acuerdo con el artículo 78 fracción III 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.



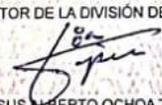
YANQUELETH ANTONIO DE JESUS MOLINA TENORIO
ALUMNO

REVISÓ



MTRA. ROSA L. FERRANO DE LA PAZ
DIRECTORA DE SISTEMAS ESCOLARES

DIRECTOR DE LA DIVISION DE CBI



DR. JESUS ALBERTO OCHOA TAPIA

PRESIDENTE



DR. MARCO AURELIO CARDENAS JUAREZ

VOCAL



DR. RAFAEL AGUILAR GONZALEZ

SECRETARIO



DR. MIGUEL LOPEZ GUERRERO