



Universidad Nacional Pedro Ruiz Gallo
Facultad de Ciencias Físicas y Matemáticas
Escuela Profesional de Ingeniería Electrónica



Tesis

**Análisis Comparativo del Desempeño de Técnicas de Detección de
Espectro en Entornos Simulados mediante Radios Definidos por Software**

para optar el título profesional de Ingeniero Electrónico

presentado por:

Bach. Julio Jesús Correa Alaya

Bach. Jaime Magno Phan Lung Exebio

Asesor:

Ing. Segundo Francisco Segura Altamirano.

Fecha de sustentación: 24/02/2026

Lambayeque-Perú

2026

Universidad Nacional Pedro Ruiz Gallo
Facultad de Ciencias Físicas y Matemáticas
Escuela Profesional de Ingeniería Electrónica

**Análisis Comparativo del Desempeño de Técnicas de
Detección de Espectro en Entornos Simulados mediante
Radios Definidos por Software**

Autor:

Bach. Julio Jesús Correa Alaya



Bach. Jaime Magno Phan Lung Exebio



Asesor:

Ing. Segundo Francisco Segura Altamirano.



LAMBAYEQUE - PERÚ

2026

**Universidad Nacional Pedro Ruiz Gallo
Facultad de Ciencias Físicas y Matemáticas
Escuela Profesional de Ingeniería Electrónica**

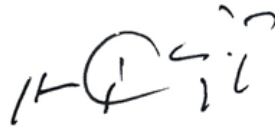
**Análisis Comparativo del Desempeño de Técnicas de Detección de
Espectro en Entornos Simulados mediante Radios Definidos por Software**

Tesis para optar el título profesional de Ingeniero Electrónico

Sustentado y aprobado ante los siguientes miembros del jurado:



M.Sc. Ing. Frank Richard Rodriguez Chirinos.
Presidente



Dr. Ing Hugo Javier Chicalyo Padilla
Secretario



Dra. Ing. Lucia Isabel Chaman Cabrera
Vocal

Lambayeque-Perú

2026



UNIVERSIDAD NACIONAL PEDRO RUIZ GALLO
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DECANATO

Ciudad Universitaria - Lambayeque

LICENCIADA - RESOLUCIÓN DEL CONSEJO DIRECTIVO N° 015 -2023-SUNEDU / CD



0049



ACTA DE SUSTENTACIÓN N°-202...-D/FACFyM

Siendo las 11:30 AM del día 24 febrero del 2026, se reunieron los miembros del jurado evaluador de la Tesis titulada:

Análisis Comparativo del Desempeño de Técnicas de Detección de espectro en entornos Simulados mediante Redes Definidas por Software

Designadas por Resolución N° 496 - 2025 D/FACFyM de fecha 26 de mayo 2025

Con la finalidad de evaluar y calificar la sustentación de la tesis antes mencionada, conformada por los siguientes docentes:

- | | |
|--|-------------------|
| <u>Dr. Ing. Frank Richard Rodríguez Chirinos</u> | Presidente |
| <u>M.Sc. Ing. Hugo Javier Chiclayo Padilla</u> | Secretario |
| <u>Dra. Ing. Lucía Isabel Chaman Cabrera</u> | Vocal |

La tesis fue asesorada por (el) (la) M.Sc. Ing. Segundo Francisco Segura Altamirano nombrado por Resolución N° 496 - 2025 D/FACFyM de fecha 26 de mayo 2025

El Acto de Sustentación fue autorizado por Resolución N° 125 - 2026 D/FACFyM de fecha 12 de febrero de 2026

La Tesis fue presentada y sustentada por (el) (los) Bachiller (es): Correa Alaya Julio Jesus y Phan Luu Exebio Jaime Masua y tuvo una duración de 60 minutos.

Después de la sustentación, y absueltas las preguntas y observaciones de los miembros del jurado se procedió a la calificación respectiva, otorgándole el Calificativo de Dieci y ocho (18) en la escala vigesimal, mención (Muy bueno).

Por lo que queda(n) apto(s) para obtener el Título Profesional de Ingeniero Electrónico, de acuerdo con la Ley Universitaria 30220 y la normatividad vigente de la Facultad de Ciencias Físicas y Matemáticas y la Universidad Nacional Pedro Ruiz Gallo.

Siendo las 12:30 se dio por concluido el presente acto académico, dándose conformidad al presente acto con la firma de los miembros del jurado.

DR. ING. FRANK RICHARD RODRÍGUEZ CHIRINOS
 Presidente

HUGO JAVIER CHICLAYO PADILLA
 Secretario

DRA. ING. LUCÍA ISABEL CHAMAN CABRERA
 Vocal

MSc. Ing. Segundo Francisco Segura Altamirano
 Asesor

CONSTANCIA DE VERIFICACIÓN DE ORIGINALIDAD

Yo, Segundo Francisco Segura Altamirano usuario revisor de:

Tesis

Trabajo de Suficiencia Profesional

Trabajo Académico

Titulado Análisis Comparativo del Desempeño de Técnicas de Detección de Espectro en Entornos Simulados mediante Radios Definidos por Software

Cuyo(s) autor(es) es(son):

Julio Jesús Correa Alaya DNI° 72174197

Jaime Magno Phan Lung Exebio DNI° 74422016

declaro que la evaluación realizada por el Programa informático, ha arrojado un porcentaje de similitud 2 %, verificables en el Resumen del Reporte Automatizado de similitudes que se acompaña.

El(La/Los/Las) suscrito(a/s/as) analizó y concluyó que cada una de las coincidencias detectadas dentro del porcentaje de similitud permitido no constituyen plagio y que el documento cumple con la integridad científica y con las normas para el uso de citas y referencias establecidas en los protocolos respectivos.

Se cumple con adjuntar el Recibo Digital a efectos de la trazabilidad respectiva del proceso.

Lambayeque, 26 de febrero del 2026



Nombres y Apellidos: Segundo Francisco Segura Altamirano

DNI°: 09922587

ASESOR

Defina la modalidad con [X]

Adjuntar

- Reporte Automatizado de similitudes*
- Recibo Digital*

TesisFinalv3

ORIGINALITY REPORT

2%

SIMILARITY INDEX

2%

INTERNET SOURCES

1%

PUBLICATIONS

1%

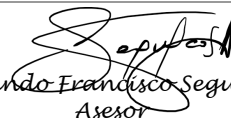
STUDENT PAPERS

MATCH ALL SOURCES (ONLY SELECTED SOURCE PRINTED)

2%

★ repositorio.unprg.edu.pe

Internet Source



Msc. Ing, Segundo Francisco Segura Altamirano
Asesor

DNI 09922587

Exclude quotes

Off

Exclude matches

< 15 words

Exclude bibliography

On

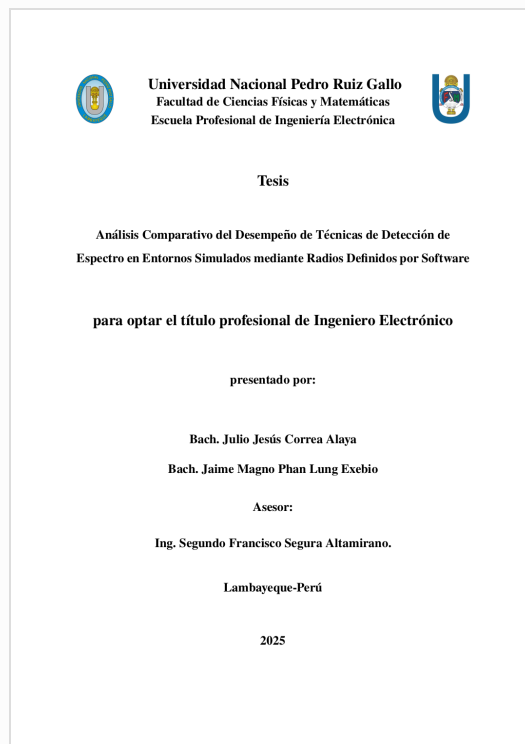



Digital Receipt

This receipt acknowledges that Turnitin received your paper. Below you will find the receipt information regarding your submission.

The first page of your submissions is displayed below.

Submission author: Julio Jesus/jaimemagno Correa Alaya/phang Lung Exebio
Assignment title: Quick Submit
Submission title: TesisFinalv3
File name: sdrTesisPhang.pdf
File size: 3.35M
Page count: 65
Word count: 14,718
Character count: 86,498
Submission date: 05-Feb-2026 05:23PM (UTC-0500)
Submission ID: 2872073333




MSc, Ing. Segundo Francisco Segura Altamirano
Asesor
DNI 09922587

AGRADECIMIENTOS

Por encima de todo, damos gracias a Dios por concedernos la fuerza, la sabiduría y la perseverancia necesaria para completar con éxito esta investigación.

Expresamos nuestra profunda gratitud a nuestros padres y familiares, que constituyen la base de los valores que nos caracterizan, por su apoyo incondicional, su comprensión y su confianza a lo largo de este viaje académico y personal.

Extendemos nuestro más sincero agradecimiento a nuestro asesor de tesis, por su paciencia, orientación, dedicación y sabiduría han sido indispensables para el preciso desarrollo y finalización de esta tesis.

Un agradecimiento especial a los amigos que nos han acompañado y apoyado a lo largo de este viaje. Su apoyo, compañía y sincera amistad han hecho que este proceso fuera más llevadero y nos han ayudado a superar momentos de duda, dificultad y confusión.

Finalmente, extendemos nuestra gratitud a todos aquellos que han apoyado directa o indirectamente la finalización de esta investigación.

Los Autores

Lambayeque 2026

DEDICATORIA

Dedico este trabajo a mi madre, Rósula Marianita Alaya Tejada, ya que me mostró su amor incondicional, su sacrificio y apoyo permanente; a mis hermanos, Juan y Miguel, pues ellos son mi fortaleza y la inspiración constante; y a Kira, mi fiel compañera, por ofrecerme alegría, compañía y consuelo en los momentos más difíciles de esta senda académica.

Bach. Julio Jesús Correa Alaya

Bachiller Ingeniería Electrónica

Lambayeque 2026

Dedico este trabajo a mis padres, Victoria Mercedes Exebio Zapata y Teofilo Segundo Estela Mego, porque son la base de mis valores y convicciones, por su confianza inquebrantable y su compañía en cada etapa de este proceso, por ofrecerme la oportunidad de crecer y aprender como persona, y también a mis leales compañeros felinos, quiénes saben acompañarme, calmarme y ayudarme en el tiempo del cansancio, del estrés y el desánimo.

Bach. Jaime Magno Phan Lung Exebio

Bachiller Ingeniería Electrónica

Lambayeque 2026

RESUMEN

El espectro radioeléctrico es un recurso limitado cuya gestión eficiente requiere técnicas de detección capaces de identificar bandas libres bajo condiciones adversas. En este trabajo se analizó comparativamente el desempeño de técnicas de detección de espectro, clásicas y basadas en aprendizaje automático, implementadas en una plataforma de radio definida por software bajo escenarios simulados con diferentes condiciones de ruido, movilidad y cooperación. Se diseñó un entorno experimental modular utilizando el USRP N210 como plataforma de referencia, se implementaron cuatro detectores clásicos (energía, eigenvalores, cicloestacionario y filtro adaptado) y un ensemble híbrido que combina SVM-RBF, Random Forest y CNN 1D. Se desarrollaron doce modelos especializados para las combinaciones de tres modulaciones (QPSK, 16-QAM, OFDM) y cuatro condiciones de canal (estático, Rayleigh, EVA, ETU), evaluados mediante simulación Monte Carlo en el rango de SNR de -20 a $+5$ dB. Los resultados mostraron que el ensemble de aprendizaje automático alcanzó una probabilidad de detección promedio del 90,8 %, superando al detector de energía (9,8 %) por 80,9 puntos porcentuales, con detección perfecta para QPSK y 16-QAM incluso a -20 dB; la excepción fue OFDM en canales simples donde el espectro plano dificulta la discriminación. Se concluye que las técnicas de aprendizaje automático ofrecen desempeño significativamente superior en condiciones de bajo SNR, lo cual valida la hipótesis planteada, aunque la elección del detector óptimo depende del escenario específico y los recursos disponibles.

Palabras clave: detección de espectro, radio definida por software, aprendizaje automático, ensemble híbrido, probabilidad de detección, USRP.

ABSTRACT

The radio spectrum is a limited resource whose efficient management requires detection techniques capable of identifying free bands under adverse conditions. In this work, the performance of classical and machine learning-based spectrum detection techniques implemented on a software-defined radio platform was comparatively analyzed under simulated scenarios with different noise, mobility, and cooperation conditions. A modular experimental environment was designed using the USRP N210 as the reference platform; four classical detectors (energy, eigenvalue, cyclostationary, and matched filter) and a hybrid ensemble combining SVM-RBF, Random Forest, and CNN 1D were implemented. Twelve specialized models were developed for combinations of three modulations (QPSK, 16-QAM, OFDM) and four channel conditions (static, Rayleigh, EVA, ETU), evaluated through Monte Carlo simulation over an SNR range from -20 to $+5$ dB. Results showed that the machine learning ensemble achieved an average detection probability of 90.8%, outperforming the energy detector (9.8%) by 80.9 percentage points, with perfect detection for QPSK and 16-QAM even at -20 dB; the exception was OFDM in simple channels where the flat spectrum hinders discrimination. It is concluded that machine learning techniques offer significantly superior performance under low SNR conditions, which validates the proposed hypothesis, although the optimal detector choice depends on the specific scenario and available resources.

Keywords: spectrum sensing, software-defined radio, machine learning, hybrid ensemble, detection probability, USRP.

ÍNDICE GENERAL

Reconocimientos	v
Dedicatoria	vi
Resumen	vii
Abstract	viii
Índice de figuras	xiii
Índice de Tablas	xiv
Introducción	xvi
1. Marco Teórico	1
1.1. Antecedentes	1
1.1.1. Antecedentes Internacionales	1
1.2. Bases Teóricas	3
1.2.1. Espectro y necesidad de detección	3
1.2.2. Radio definida por software (SDR)	3
1.2.3. Conceptos básicos de detección	3
1.2.4. Modulaciones digitales	4
1.2.4.1. Modulaciones de portadora única	4
1.2.4.2. Modulación multiportadora	4
1.2.5. Modelos de canal	4
1.2.5.1. Canal estático	4
1.2.5.2. Canal Rayleigh	4
1.2.5.3. Perfiles vehiculares y urbanos (EVA, ETU)	4
1.2.6. Modelos de ruido	4

	x
1.2.7. Técnicas clásicas	5
1.2.7.1. Detector de energía	5
1.2.7.2. Detector de eigenvalores	5
1.2.7.3. Detector cicloestacionario	5
1.2.7.4. Filtro adaptado	5
1.2.8. Cooperación y escenarios multibanda	6
1.2.8.1. Reglas de fusión	6
1.2.9. Técnicas con aprendizaje automático	6
1.2.9.1. Extracción de características	6
1.2.9.2. Máquinas de vectores de soporte (SVM)	6
1.2.9.3. Bosques aleatorios (Random Forest)	7
1.2.9.4. Redes neuronales convolucionales (CNN)	7
1.2.9.5. Ensembles híbridos	7
1.2.10. Handoff y operación cognitiva	7
1.2.11. Métricas, recursos y tiempo real	7
1.2.12. Vacíos y retos	8
1.2.13. Alineación con el problema, hipótesis y objetivos	8
2. Metodología	9
2.1. Tipo de Investigación	9
2.2. Diseño de la Investigación	9
2.3. Población y Muestra	10
2.3.1. Población	10
2.3.2. Muestra	10
2.4. Técnicas e Instrumentos de Recolección de Datos	11
2.5. Análisis y Procesamiento de Datos	11
2.6. Equipos y Materiales	12
2.6.1. Hardware	12
2.6.2. Software	12
2.6.3. Recursos Adicionales	13
3. Resultados	14
3.1. Entorno Experimental de Detección Espectral	14

3.1.1.	Arquitectura del Sistema	14
3.1.2.	Plataforma de Hardware	16
3.1.3.	Escenarios Experimentales	16
3.1.4.	Resultados de Validación	16
3.1.4.1.	Comparación de Detectores Clásicos	17
3.1.4.2.	Comportamiento en Bajo SNR	17
3.1.4.3.	Escenario de Alta Movilidad	17
3.1.4.4.	Detección Cooperativa	19
3.1.5.	Flujo de Procesamiento	20
3.1.6.	Síntesis del Entorno Experimental	21
3.1.7.	Implementación de Módulos Software	21
3.2.	Implementación de Algoritmos de Detección	22
3.2.1.	Arquitectura del Sistema Modular	22
3.2.2.	Detectores Implementados	22
3.2.3.	Procedimiento de Entrenamiento	23
3.2.4.	Resultados del Entrenamiento	24
3.2.5.	Análisis por Modulación	24
3.2.6.	Comportamiento por SNR	25
3.2.7.	Complejidad Computacional	25
3.2.8.	Diferencias de Implementación	26
3.2.9.	Síntesis de la Implementación	27
3.3.	Evaluación del Desempeño	27
3.3.1.	Metodología de Evaluación	28
3.3.2.	Resultados Globales	28
3.3.3.	Análisis por Modulación	28
3.3.3.1.	QPSK y 16-QAM	28
3.3.3.2.	OFDM	29
3.3.4.	Comportamiento por SNR	30
3.3.5.	Visualización Comparativa	30
3.3.6.	Análisis de Robustez	32
3.3.7.	Síntesis de la Evaluación	32
3.4.	Análisis Comparativo	33
3.4.1.	Consolidación de Resultados	33

3.4.2.	Consolidación de Resultados	33
3.4.3.	Fortalezas de las Técnicas de Aprendizaje Automático	33
3.4.3.1.	Robustez en Bajo SNR	33
3.4.3.2.	Adaptabilidad a Diferentes Modulaciones	33
3.4.3.3.	Explotación de Información Espectral	34
3.4.3.4.	Tiempo de Inferencia Competitivo	34
3.4.4.	Limitaciones de las Técnicas de Aprendizaje Automático	34
3.4.4.1.	Costo de Entrenamiento	34
3.4.4.2.	Dependencia de Datos Etiquetados	34
3.4.4.3.	Caso Límite: OFDM en Canales Simples	34
3.4.5.	Fortalezas del Detector de Energía	34
3.4.6.	Limitaciones del Detector de Energía	35
3.4.7.	Matriz de Rendimiento	35
3.4.8.	Recomendaciones de Uso	35
3.4.9.	Síntesis del Análisis	35

4. Discusión **38**

ÍNDICE DE FIGURAS

3.1. Arquitectura modular del entorno experimental. Las señales fluyen desde la generación hasta la evaluación, pasando por los modelos de canal y ruido.	14
3.2. Arquitectura modular del entorno experimental y resultados del escenario baseline.	15
3.3. Resultados del escenario low_snr: degradación del desempeño en condiciones de bajo SNR.	18
3.4. Resultados del escenario high_mobility: detección de OFDM bajo canal EVA vehicular.	19
3.5. Resultados del escenario cooperative: comparación de reglas de fusión.	20
3.6. Flujo de procesamiento experimental en cuatro fases.	20
3.7. Arquitectura del ensemble	23
3.8. Comparación de AUC por escenario. QPSK y 16-QAM alcanzan rendimiento perfecto; OFDM muestra ligera degradación en canales simples.	25
3.9. Matriz de P_d y P_{fa} por escenario. Los colores indican el nivel de rendimiento.	26
3.10. Tiempos de entrenamiento por escenario. Los escenarios con ruido mixto requieren más tiempo debido a la mayor variabilidad.	27
3.11. Probabilidad de detección en función del SNR. Los modelos de aprendizaje automático mantienen alta detección incluso en SNR muy bajos.	30
3.12. Comparación de detectores por escenario. Las barras muestran la probabilidad de detección para cada combinación de modulación y canal.	31
3.13. Mejora en probabilidad de detección por escenario. Valores positivos indican que el aprendizaje automático supera al detector de energía.	31
3.14. Matriz de rendimiento por escenario. Los colores indican el nivel de P_d alcanzado.	36
3.15. Comparación consolidada de detectores. La diferencia de rendimiento es consistente en la mayoría de escenarios.	36

ÍNDICE DE TABLAS

2.1. Variables del diseño experimental	10
2.2. Composición de la muestra experimental	10
2.3. Instrumentos de recolección de datos	11
2.4. Métricas de evaluación	12
2.5. Especificaciones de hardware	12
2.6. Componentes de software	13
2.7. Módulos de software desarrollados	13
3.1. Especificaciones del hardware SDR	16
3.2. Escenarios experimentales configurados	16
3.3. Desempeño de detectores clásicos (escenario baseline, 300 pruebas)	17
3.4. Desempeño en escenario low_snr (400 pruebas)	17
3.5. Desempeño en escenario high_mobility (300 pruebas)	18
3.6. Ganancia cooperativa respecto a detección individual (5 nodos)	19
3.7. Módulos de software implementados	22
3.8. Características extraídas de cada observación	23
3.9. Resultados de entrenamiento por escenario (12 modelos)	24
3.10. Estadísticas consolidadas del sistema modular	24
3.11. P_d por SNR para escenarios representativos	25
3.12. Complejidad computacional de los componentes	25
3.13. Comparación de implementación: técnicas clásicas vs. aprendizaje automático	26
3.14. Resumen de la implementación	27
3.15. Resultados agregados de la evaluación comparativa	28
3.16. Probabilidad de detección por escenario (QPSK y 16-QAM)	29
3.17. Probabilidad de detección para OFDM	29
3.18. Métricas consolidadas del sistema de detección	33
3.19. Comparación de P_d en bajo SNR (-20 dB)	34

3.20. Escenarios con rendimiento limitado	35
3.21. Recomendaciones según el escenario de aplicación	36

INTRODUCCIÓN

El crecimiento de los sistemas de comunicación inalámbrica y la proliferación de dispositivos conectados ejercen una presión creciente sobre el espectro radioeléctrico, recurso limitado y estratégico para las telecomunicaciones modernas. La coexistencia de múltiples tecnologías en las mismas bandas de frecuencia demanda soluciones que optimicen el uso del espectro disponible. En este contexto, la detección de espectro permite identificar espacios libres en bandas aparentemente ocupadas, habilitando un uso más eficiente sin interferir a los usuarios primarios (Baker et al., 2023; Begum et al., 2025).

La detección de espectro constituye un problema de decisión binaria: determinar si una banda contiene señal primaria o solo ruido. Las técnicas tradicionales, como el detector de energía, presentan limitaciones cuando enfrentan condiciones de bajo SNR, canales con desvanecimiento o movilidad del usuario (Bouzegag et al., 2023; Sabra & Berbineau, 2022). El detector de energía, aunque simple y de baja complejidad computacional, muestra sensibilidad al ruido y a la estimación del umbral de decisión. Los detectores basados en eigenvalores ofrecen mayor robustez cuando las condiciones del ruido varían, aunque requieren procesamiento estadístico más elaborado (Kumar et al., 2020; Lipski et al., 2021).

Ante estas limitaciones, la comunidad científica ha explorado dos direcciones complementarias. La detección cooperativa combina información de múltiples nodos sensores, mejorando la probabilidad de detección al integrar evidencia distribuida (Benzater et al., 2024). Las técnicas de aprendizaje automático ofrecen modelos capaces de aprender patrones directamente de los datos, logrando mejoras en precisión que los métodos convencionales no alcanzan en condiciones adversas (Sabrina et al., 2024).

Los avances en detección mediante plataformas de radio definida por software proporcionan evidencia experimental relevante. Benzater et al. (2024) proponen un esquema de detección cooperativa que demuestra mejoras considerables en la probabilidad de detección bajo condiciones de baja relación señal a ruido. Sabrina et al. (2024) presentan un enfoque basado en máquinas de vectores de soporte que alcanza probabilidades de detección superiores a los detectores convencionales incluso en regímenes de bajo SNR. Subedi et al. (2024) desa-

rollan un marco para segmentación y clasificación conjunta de señales, logrando incrementar la precisión del 41 % al 99 % y reduciendo el tiempo de sensado significativamente.

Las evaluaciones experimentales con plataformas SDR aportan evidencia sobre los retos del diseño metodológico. Sabra y Berbineau (2023) implementan técnicas de detección asistidas por máquinas de vectores de soporte, demostrando que el incremento del número de canales mejora la probabilidad de detección. Bouzegag et al. (2023) investigan la detección cooperativa mediante arquitectura cliente-servidor sobre dispositivos USRP, validando que los métodos basados en bondad de ajuste superan a los detectores convencionales.

La incorporación de movilidad en los escenarios de evaluación constituye un aspecto crítico para la validación realista. Manco y Dayoub (2024) evalúan la detección espectral bajo escenarios de alta movilidad mediante emulación de canales multiantena variantes en el tiempo, encontrando que la selección adecuada del algoritmo permite mantener el desempeño con reducciones de hasta 50 % en el período de sensado. Ben Thameur y Dayoub (2021) proporcionan una evaluación experimental de algoritmos basados en eigenvalores, demostrando mejoras del 35 % en el desempeño de detección.

En el contexto de la gestión dinámica del espectro, Babjan y Rajendran (2024) presentan un marco para verificar la necesidad de traspaso espectral mediante técnicas de aprendizaje automático, logrando mejoras significativas en precisión, sensibilidad y especificidad. Molina-Tenorio et al. (2023) implementan una red de monitoreo multibanda en tiempo real, donde los enfoques basados en aprendizaje automático demuestran mayor precisión en la detección de frecuencia portadora y ancho de banda.

Las arquitecturas de aprendizaje profundo aportan fundamentos para la detección avanzada. Wu et al. (2020) introducen una arquitectura basada en redes Inception-ResNet que alcanza precisiones del 93.76 % en clasificación de modulaciones. Sabrina et al. (2023) proponen una arquitectura híbrida que combina redes convolucionales con memorias de corto y largo plazo, con implementación SDR validada para escenarios de FM, GSM y OFDM en tiempo real.

El concepto de radio definida por software se basa en la implementación de funciones de radio mediante procesamiento digital, proporcionando flexibilidad para modificar parámetros y probar algoritmos sobre hardware real. Las plataformas USRP se han consolidado como herramientas estándar en prototipos académicos por su capacidad de reproducir escenarios de canal controlados (Martian, Lucian Chiper et al., 2020). La cooperación entre múltiples nodos sensores permite combinar información distribuida para mejorar la robustez de la

detección (Molina-Tenorio et al., 2021).

Ante este panorama, surge la necesidad de analizar de manera comparativa el desempeño de diferentes técnicas de detección de espectro mediante su implementación en una plataforma SDR bajo escenarios simulados que incorporen variaciones en el nivel de ruido, movilidad y cooperación. La pregunta que guía esta investigación es: ¿cómo varía el desempeño de las técnicas de detección de espectro, clásicas y basadas en inteligencia artificial, implementadas en una plataforma SDR bajo escenarios simulados con diferentes condiciones de ruido, movilidad y cooperación?

La justificación de esta investigación se sustenta en múltiples dimensiones. Desde la perspectiva teórica, contribuye a sistematizar el conocimiento sobre el desempeño comparativo de técnicas de detección bajo condiciones controladas pero realistas. Desde la perspectiva práctica, los resultados orientan la toma de decisiones en el diseño de sistemas de detección espectral, proporcionando evidencia experimental sobre las fortalezas y limitaciones de cada enfoque. Desde la perspectiva metodológica, el diseño del entorno experimental con plataformas SDR sirve como referencia para futuras investigaciones. Desde la perspectiva institucional, la investigación aprovecha la infraestructura de plataformas Ettus USRP adquiridas por la Escuela Profesional de Ingeniería Electrónica.

El objetivo general de esta investigación es analizar comparativamente el desempeño de técnicas de detección de espectro mediante radios definidos por software en escenarios simulados, considerando técnicas clásicas y de aprendizaje automático, bajo distintas condiciones de ruido, movilidad y cooperación. Para alcanzar este propósito, se plantean los siguientes objetivos específicos: primero, diseñar un entorno experimental de detección espectral utilizando radios definidos por software Ettus USRP N210; segundo, implementar algoritmos clásicos y de inteligencia artificial para la detección de espectro en dicho entorno; tercero, evaluar el desempeño de las técnicas implementadas a través de indicadores como la probabilidad de detección, la tasa de falsos positivos, la robustez al ruido y el consumo de recursos; cuarto, comparar y analizar los resultados obtenidos para identificar fortalezas y limitaciones de cada técnica bajo distintas condiciones simuladas.

La hipótesis general sostiene que las técnicas de detección de espectro basadas en aprendizaje automático presentan un desempeño significativamente superior, en términos de probabilidad de detección, robustez al ruido y eficiencia computacional, frente a las técnicas clásicas cuando se implementan en plataformas SDR bajo escenarios simulados. Esta hipótesis se deriva de la evidencia proporcionada por estudios como los de Subedi et al. (2024),

Sabrina et al. (2024) y Chavez Munoz et al. (2024), que demuestran mejoras sustanciales en las métricas de detección mediante enfoques de aprendizaje automático.

CAPÍTULO 1 MARCO TEÓRICO

1.1 Antecedentes

1.1.1 Antecedentes Internacionales

El uso del espectro radioeléctrico enfrenta presión por la creciente demanda de conectividad. La radio cognitiva surge como una respuesta, al permitir detectar oportunidades de uso sin interferir a los usuarios primarios. En este marco, la detección de espectro es el paso clave: identificar de forma confiable si una banda está ocupada o libre, en condiciones reales y con recursos limitados (Begum, 2025; Baker, 2023).

Los enfoques clásicos han sido la base por su simplicidad y costo. La detección de energía, por ejemplo, permite implementar soluciones asequibles en plataformas SDR comerciales y con cadenas de procesamiento simples, validando su utilidad en escenarios prácticos (Baker, 2023). Otras variantes, como métodos basados en eigenvalores y pruebas de ajuste (GoF), han mostrado ventajas en robustez y menores requerimientos de conocimiento previo del usuario primario, con evaluaciones experimentales en bancos de prueba MIMO con USRP (Sabra, 2022; Bouzegag, 2023). Sin embargo, estos métodos sufren en regímenes de bajo SNR y ante ruidos no ideales, incluyendo correlación espacial del ruido, lo que degrada la probabilidad de detección (Sabra, 2023).

Para superar estas limitaciones, se han explorado estrategias de cooperación entre múltiples sensores. La fusión de decisiones (reglas OR/AND/MAYORÍA) y técnicas de promediado espacial mejoran la detección al combinar evidencia distribuida, con validaciones sobre plataformas USRP y arquitecturas cliente-servidor en escenarios realistas (Bouzegag, 2023). Además, propuestas recientes en compresión y recuperación esparsa han integrado cooperación para acelerar y hacer más preciso el sensado, destacando mejoras en probabilidad de detección y beneficios lineales con el número de canales en condiciones de SNR bajo (Benzater, 2024).

En paralelo, la adopción de aprendizaje automático ha crecido al ofrecer modelos que aprenden patrones útiles directamente de los datos de señal. Se reportan mejoras en precisión

con clasificadores SVM y enfoques de regresión para predecir ocupación espectral, entrenados con datos generados en bancos de prueba SDR (Begum, 2025; Zeghdoud, 2024). En particular, se han propuesto esquemas de sensado de banda ancha que combinan características como energía y GoF con SVM, demostrando mayor probabilidad de detección incluso a bajo SNR y validación con implementación SDR (Zeghdoud, 2024). Estos avances sugieren un cambio desde reglas fijas hacia sistemas guiados por datos.

El aprendizaje profundo amplía esta tendencia. Redes neuronales convolucionales y arquitecturas end-to-end permiten segmentar y clasificar señales de manera conjunta en bandas anchas, reduciendo tiempos de sensado y alcanzando altas precisiones en pruebas sobre el aire con SDR (Subedi, 2024; Hammadi, 2023). Estos resultados indican que, con el preprocesamiento y el diseño adecuados, los modelos de IA pueden capturar la variabilidad del canal y la diversidad de modulaciones mejor que los detectores clásicos en situaciones exigentes.

Las evaluaciones experimentales también han revelado retos que guían el diseño metodológico. Por ejemplo, el ruido correlacionado deteriora notablemente la eficacia de esquemas SVM-asistidos basados en covarianzas si se los entrena o calibra asumiendo ruido blanco, lo que obliga a considerar escenarios de prueba más realistas y a aumentar el número de receptores o ajustar umbrales (Sabra, 2023). Asimismo, la incorporación de movilidad y cooperación en entornos simulados y de laboratorio aporta una visión más fiel del desempeño, alineada con condiciones de despliegue (Slimeni, 2023; Bouzegag, 2023).

Más allá del sensado, el uso de IA se ha extendido a tareas cercanas como la gestión del handoff espectral bajo movilidad y carga, evidenciando mejoras en métricas como precisión y sensibilidad al comparar múltiples clasificadores sobre datos recolectados con SDR y escenarios NOMA (Babjan, 2024). En el ecosistema 5G/ORAN, también se han desarrollado emuladores del O-RU sobre USRP para investigación y prototipado, lo que facilita bancos de prueba abiertos y reproducibles donde validar algoritmos de sensado y control del espectro (Pandeya, 2024).

Este cuerpo de trabajo respalda la relevancia del problema y la dirección de la hipótesis planteada en esta investigación. Los métodos clásicos son valiosos por su simplicidad y costo, pero muestran límites ante SNR bajos, ruido no ideal y escenarios dinámicos. La cooperación mejora la robustez y la cobertura de evidencias. Los enfoques de aprendizaje automático, desde SVM y regresión hasta redes profundas, han demostrado incrementos en probabilidad de detección y reducciones en tiempo de sensado, especialmente cuando se entrenan y verifican con bancos de prueba SDR (Begum, 2025; Subedi, 2024; Zeghdoud,

2024). Por ello, evaluar comparativamente técnicas clásicas y de IA en plataformas SDR, bajo condiciones de ruido, movilidad y cooperación, permite identificar con claridad fortalezas y límites de cada enfoque y, con ello, sustentar decisiones de diseño orientadas a desempeño y eficiencia computacional, en línea con los objetivos del estudio (Benzater, 2024; Sabra, 2022; Bouzegag, 2023).

1.2 Bases Teóricas

1.2.1 Espectro y necesidad de detección

El espectro radioeléctrico es limitado. Hoy hay más usuarios y más dispositivos. Esto genera alta demanda y congestión. Se necesita usar mejor el espectro. Para esto se detectan espacios libres (huecos) con técnicas de *detección de espectro*. Esta detección ayuda a decidir cuándo transmitir sin causar interferencia. Varios trabajos muestran enfoques prácticos con radios definidas por software (SDR) y mediciones en tiempo real (Martian, Lucian Chiper et al., 2020; Poveda et al., 2021).

1.2.2 Radio definida por software (SDR)

Una SDR implementa funciones de radio en software. Esto da flexibilidad. Permite probar algoritmos de forma rápida y en hardware real. La familia USRP (por ejemplo, B210) es común en prototipos académicos. Con SDR se reproducen escenarios de canal y se mide el desempeño con control de parámetros (Martian, Vladeanu & Marghescu, 2020). Estudios comparan plataformas SDR y describen bancos de pruebas para mediciones y validación de algoritmos (Martian, Lucian Chiper et al., 2020; Poveda et al., 2021).

1.2.3 Conceptos básicos de detección

El objetivo de la detección de espectro es decidir si hay señal primaria en una banda. Formalmente, se plantea como un test de hipótesis binario:

- \mathcal{H}_0 : solo ruido presente (banda libre)
- \mathcal{H}_1 : señal más ruido (banda ocupada)

Dos métricas son clave: probabilidad de detección (P_d) y probabilidad de falsa alarma (P_{fa}). Se analizan con curvas ROC (*Receiver Operating Characteristic*). La relación señal–ruido (SNR) afecta mucho el desempeño. Bajo SNR la tarea es difícil. Por eso se investigan umbrales adaptativos y técnicas robustas (Lipski et al., 2021). La calibración CFAR

(*Constant False Alarm Rate*) ajusta el umbral de decisión para mantener P_{fa} constante independientemente de las variaciones del ruido.

1.2.4 Modulaciones digitales

Las señales de usuario primario emplean diferentes esquemas de modulación según los requisitos de la aplicación.

Modulaciones de portadora única. QPSK (*Quadrature Phase Shift Keying*) codifica 2 bits por símbolo en la fase de la portadora, ofreciendo buena eficiencia espectral con robustez moderada al ruido. 16-QAM (*Quadrature Amplitude Modulation*) codifica 4 bits por símbolo combinando amplitud y fase, aumentando la tasa de datos a costa de mayor sensibilidad al ruido.

Modulación multiportadora. OFDM (*Orthogonal Frequency Division Multiplexing*) divide el canal en múltiples subportadoras ortogonales, cada una con modulación de banda estrecha. Su espectro de potencia es casi plano, similar al ruido gaussiano, lo que dificulta su detección en canales sin distorsión. Sin embargo, los canales con desvanecimiento selectivo en frecuencia introducen variaciones espectrales que facilitan la discriminación.

1.2.5 Modelos de canal

El canal de propagación afecta significativamente las características de la señal recibida.

Canal estático. El canal estático (AWGN puro) añade ruido gaussiano sin modificar la estructura de la señal. Representa el caso ideal sin desvanecimiento.

Canal Rayleigh. El desvanecimiento Rayleigh modela escenarios sin línea de vista directa (NLOS), donde la señal llega solo por reflexiones. La envolvente de la señal sigue una distribución Rayleigh, causando variaciones aleatorias de amplitud.

Perfiles vehiculares y urbanos (EVA, ETU). Los perfiles 3GPP EVA (*Extended Vehicular A*) y ETU (*Extended Typical Urban*) modelan escenarios de movilidad con múltiples retardos. El desvanecimiento selectivo en frecuencia introduce patrones distintivos en el espectro que los detectores pueden explotar.

1.2.6 Modelos de ruido

El ruido gaussiano blanco (AWGN) es el modelo más común, pero entornos reales pueden presentar ruido impulsivo. El modelo de Middleton clase A caracteriza este tipo de

interferencia, combinando componentes gaussianas e impulsivas.

1.2.7 Técnicas clásicas

Detector de energía. La *detección por energía* es la técnica más simple y ampliamente utilizada. Calcula la potencia media de las muestras recibidas y la compara con un umbral:

$$T_{ED} = \frac{1}{N} \sum_{n=1}^N |x[n]|^2 \quad (1.1)$$

donde N es el número de muestras de la ventana de observación. Su ventaja principal es su baja complejidad computacional $O(N)$. Su desventaja es su sensibilidad al ruido y a la estimación del umbral. Variantes con umbrales adaptativos y mejores estimadores del ruido mejoran su robustez (Kumar et al., 2020; Lipski et al., 2021).

Detector de eigenvalores. Los detectores basados en *autovalores* explotan las propiedades estadísticas de la matriz de covarianza de la señal recibida. El detector MME (*Maximum-Minimum Eigenvalue*) calcula:

$$T_{MME} = \frac{\lambda_{\text{máx}}}{\lambda_{\text{mín}}} \quad (1.2)$$

donde $\lambda_{\text{máx}}$ y $\lambda_{\text{mín}}$ son los autovalores extremos de la matriz de covarianza muestral. Bajo la hipótesis nula (solo ruido), los autovalores tienden a ser similares; bajo la hipótesis alternativa (señal presente), el cociente aumenta. Estos enfoques buscan mayor robustez cuando el ruido cambia, eliminando la dependencia del conocimiento previo del nivel de ruido (Perez & Ibañez, 2023).

Detector cicloestacionario. Las señales moduladas presentan periodicidades inherentes que el ruido no posee. El detector cicloestacionario calcula la función de correlación espectral para detectar estas periodicidades, identificando las frecuencias cíclicas características de cada tipo de modulación. Su ventaja es la capacidad de distinguir diferentes tipos de señales; su desventaja es el alto costo computacional debido al cálculo de la autocorrelación cíclica.

Filtro adaptado. El filtro adaptado correlaciona la señal recibida con una referencia conocida de la señal primaria. Es el detector óptimo cuando se dispone de información completa sobre la forma de onda esperada, maximizando la relación señal a ruido a la salida. Su limitación práctica es la necesidad de conocimiento previo de la señal a detectar.

En plataformas USRP se han evaluado estos métodos para medir P_d y P_{fa} en distintos

SNR (Kumar et al., 2020).

1.2.8 Cooperación y escenarios multibanda

La *detección cooperativa* combina información de varios nodos receptores. Esto ayuda cuando hay desvanecimiento o movilidad, aprovechando la diversidad espacial para mejorar P_d en escenarios difíciles.

Reglas de fusión. Las decisiones de múltiples nodos se combinan mediante reglas de fusión:

- **OR:** Decide \mathcal{H}_1 si cualquier nodo detecta. Maximiza P_d pero aumenta P_{fa} .
- **AND:** Decide \mathcal{H}_1 solo si todos detectan. Minimiza P_{fa} pero reduce P_d .
- **Mayoría:** Decide según el voto mayoritario. Balance entre sensibilidad y especificidad.
- **EGC (Equal Gain Combining):** Combina estadísticas con pesos iguales.
- **MRC (Maximal Ratio Combining):** Pondera según la calidad del canal de cada nodo.

La *detección multibanda* explora varias bandas simultáneamente para aumentar la cobertura. Implementaciones en tiempo real con SDR muestran que cooperación y multibanda son viables y aportan ganancia de desempeño (Molina-Tenorio et al., 2021, 2023).

1.2.9 Técnicas con aprendizaje automático

El aprendizaje automático (AA) aprende patrones de los datos sin requerir modelos analíticos explícitos. En detección de espectro, puede distinguir señal de ruido con mayor precisión en bajo SNR al explotar características que los métodos clásicos ignoran.

Extracción de características. Los clasificadores requieren representaciones numéricas de las señales. Un enfoque común combina características temporales (potencia, media I/Q, varianza, curtosis, PAPR), espectrales (planitud y entropía espectral) y la densidad espectral de potencia (PSD) estimada mediante el método de Welch. Esta representación multidimensional captura información que el simple cálculo de energía no considera.

Máquinas de vectores de soporte (SVM). Las SVM buscan el hiperplano de separación que maximiza el margen entre clases. Con kernel gaussiano (RBF), pueden modelar fronteras de decisión no lineales en el espacio de características. Son efectivas cuando las clases son separables pero requieren ajuste del parámetro de regularización y ancho del kernel.

Bosques aleatorios (Random Forest). El ensemble de árboles de decisión combina múltiples clasificadores débiles para lograr mayor robustez. Cada árbol se entrena con un subconjunto aleatorio de muestras y características, reduciendo la varianza del modelo. Son resistentes a valores atípicos y no requieren normalización de características.

Redes neuronales convolucionales (CNN). Las CNN 1D aplican filtros convolucionales a lo largo de la dimensión de características, aprendiendo patrones locales automáticamente. Son particularmente efectivas cuando las características tienen estructura espacial o secuencial, como en la PSD de una señal.

Ensembles híbridos. La combinación de clasificadores complementarios (SVM, Random Forest, CNN) mediante votación permite aprovechar las fortalezas de cada método. Si un clasificador falla en un caso particular, los otros pueden compensar, mejorando la robustez general del sistema.

Las redes profundas han mostrado buenos resultados en tareas cercanas, como la clasificación de modulaciones, y en detección multibanda con mapas del entorno (*Radio Environment Maps*) (Molina-Tenorio et al., 2023; Wu et al., 2020). También hay propuestas para detección y localización de fuentes con SDR en tiempo real, lo que exige modelos eficientes (**slimeni'2023**). La integración de AA apoya decisiones como el traspaso de canal (*spectrum handoff*) (Babjan & Rajendran, 2024). Estas técnicas pueden requerir más cómputo en la fase de entrenamiento, pero ofrecen mejor P_d y menor P_{fa} en condiciones difíciles (Molina-Tenorio et al., 2023; Wu et al., 2020).

1.2.10 *Handoff y operación cognitiva*

El traspaso de canal es clave cuando cambia el estado del espectro. Se necesita detectar rápido y elegir una banda libre. Modelos de AA ayudan a predecir disponibilidad y a reducir interrupciones. Las evaluaciones experimentales con SDR muestran que el AA mejora la gestión del traspaso y la experiencia del sistema (Babjan & Rajendran, 2024).

1.2.11 *Métricas, recursos y tiempo real*

Para comparar técnicas se usan P_d , P_{fa} y curvas ROC. También importan el tiempo de decisión, el consumo de CPU y memoria, y la latencia de inferencia. En sistemas reales, operar en tiempo real obliga a balancear precisión y complejidad. Hay trabajos que optimizan umbrales, estimación del ruido y pipelines de cómputo en SDR para sostener el rendimiento (Lipski et al., 2021; Poveda et al., 2021). Los enfoques con AA deben considerar compresión

de modelos y cargas de trabajo para no perder velocidad (Slimeni et al., 2023; Wu et al., 2020).

1.2.12 Vacíos y retos

Muchos estudios confirman mejoras en escenarios controlados. Aún faltan comparaciones sistemáticas que integren: bajo SNR, movilidad, cooperación, y restricciones de cómputo al mismo tiempo. También se requiere medir costo–beneficio entre técnicas clásicas y AA en testbeds con SDR y tareas multibanda. Esto conecta con la necesidad de evaluar de forma integrada el desempeño y la eficiencia, en condiciones cercanas al uso real (Martian, Lucian Chiper et al., 2020; Molina-Tenorio et al., 2023).

1.2.13 Alineación con el problema, hipótesis y objetivos

El problema plantea medir cómo cambia el desempeño con ruido, movilidad y cooperación. La literatura muestra que los umbrales adaptativos y la cooperación ayudan en bajo SNR (Lipski et al., 2021; Molina-Tenorio et al., 2023). También muestra que el AA puede mejorar P_d con más costo computacional (Slimeni et al., 2023; Wu et al., 2020). Por ello, la hipótesis de mejor desempeño con AA es plausible, y la hipótesis de mayor carga computacional también. Los objetivos de diseñar el entorno, implementar técnicas clásicas y de AA, y comparar con métricas claras, son coherentes con los estudios revisados y con el uso de USRP B210 y SDR para validar resultados (Kumar et al., 2020; Martian, Lucian Chiper et al., 2020).

CAPÍTULO 2 METODOLOGÍA

2.1 Tipo de Investigación

La investigación es de tipo aplicada, cuantitativa y experimental. Es aplicada porque busca resolver un problema práctico concreto: determinar qué técnicas de detección de espectro ofrecen mejor desempeño bajo condiciones específicas de operación. Es cuantitativa porque las variables de interés se miden numéricamente mediante métricas establecidas como probabilidad de detección, probabilidad de falsa alarma y área bajo la curva ROC. Es experimental porque se manipulan deliberadamente las condiciones del entorno (nivel de ruido, tipo de canal, modulación) para observar su efecto sobre el desempeño de los detectores.

El alcance es explicativo, ya que no solo se describen los resultados obtenidos sino que se analizan las causas de las diferencias observadas entre técnicas clásicas y basadas en aprendizaje automático. La investigación busca responder por qué ciertas técnicas superan a otras bajo condiciones específicas.

2.2 Diseño de la Investigación

El diseño es experimental con simulación controlada. Se construyó un entorno que reproduce condiciones representativas de escenarios reales mediante modelos matemáticos validados de señales, canales y ruido. Este enfoque permite controlar variables que en mediciones de campo serían difíciles de aislar, garantizando reproducibilidad y comparabilidad de resultados.

El diseño contempla tres variables independientes principales: el tipo de modulación de la señal primaria, las condiciones del canal de propagación y el nivel de relación señal a ruido. Las variables dependientes son las métricas de desempeño de los detectores. La Tabla 2.1 resume las variables del estudio.

Tabla 2.1*Variables del diseño experimental*

Tipo	Variable	Niveles
Independiente	Modulación	QPSK, 16-QAM, OFDM
Independiente	Canal	Estático, Rayleigh, EVA, ETU
Independiente	SNR	-20 a +5 dB (11 niveles)
Independiente	Detector	Energía, Eigenvalores, Cicloestacionario, Filtro adaptado, Ensemble ML
Dependiente	P_d	Probabilidad de detección
Dependiente	P_{fa}	Probabilidad de falsa alarma
Dependiente	AUC	Área bajo curva ROC
Dependiente	Tiempo	Tiempo de ejecución

2.3 Población y Muestra

2.3.1 Población

La población está constituida por el conjunto de todas las posibles observaciones de señales de radiofrecuencia en el rango de operación del sistema, bajo las condiciones de modulación, canal y ruido definidas. Dado que se trabaja con simulación, la población es teóricamente infinita y se define por los modelos matemáticos implementados.

2.3.2 Muestra

La muestra se construyó mediante generación sintética controlada. Para cada uno de los doce escenarios (tres modulaciones por cuatro condiciones de canal), se generaron muestras independientes distribuidas a lo largo del rango de SNR. La Tabla 2.2 detalla la composición de la muestra.

Tabla 2.2*Composición de la muestra experimental*

Parámetro	Valor
Escenarios evaluados	12
Niveles de SNR	11 (-20 a +5 dB)
Muestras por nivel de SNR	400 (200 \mathcal{H}_0 + 200 \mathcal{H}_1)
Muestras por escenario (prueba)	4,400
Muestras por escenario (entrenamiento)	15,400
Total de muestras	237,600
Muestras de señal por observación	40,000 (2 ms a 20 MS/s)

El muestreo es estratificado por nivel de SNR y balanceado entre hipótesis, garantizando representación equitativa de condiciones favorables y adversas. La semilla aleatoria fija

(seed=42) asegura reproducibilidad de los resultados.

2.4 Técnicas e Instrumentos de Recolección de Datos

La recolección de datos se realizó mediante simulación Monte Carlo. Cada experimento consiste en generar una señal bajo condiciones controladas, procesarla con los detectores implementados y registrar las decisiones y métricas resultantes.

El proceso de recolección siguió cuatro fases secuenciales. La primera fase calibró los umbrales de decisión mediante 500 pruebas con solo ruido para garantizar una probabilidad de falsa alarma objetivo del 10%. La segunda fase generó las señales moduladas, aplicó el modelo de canal correspondiente y añadió ruido al nivel de SNR especificado. La tercera fase ejecutó los detectores sobre cada observación, registrando decisiones y tiempos. La cuarta fase agregó las métricas por escenario y nivel de SNR.

Tabla 2.3

Instrumentos de recolección de datos

Instrumento	Descripción
Generador de señales	Módulo Python que implementa moduladores QPSK, 16-QAM y OFDM con conformado de pulso RRC
Modelo de canal	Implementación de canales estático, Rayleigh y perfiles 3GPP EVA/ETU con efecto Doppler
Generador de ruido	Ruido gaussiano blanco y modelo de Middleton clase A para ruido impulsivo
Extractor de características	Vector de 72 dimensiones: temporales, espectrales y PSD
Detectores	Cuatro clásicos y ensemble híbrido (SVM-RBF + RF + CNN 1D)
Calibrador CFAR	Ajuste automático de umbrales para P_{fa} objetivo

2.5 Análisis y Procesamiento de Datos

El análisis de datos se estructuró en tres niveles. El primer nivel calcula las métricas primarias para cada detector en cada combinación de escenario y SNR: probabilidad de detección, probabilidad de falsa alarma, exactitud y área bajo la curva ROC.

El segundo nivel agregó los resultados por escenario, modulación y detector, generando estadísticas consolidadas que permitieron identificar patrones de comportamiento. El tercer nivel realizó la comparación sistemática entre técnicas clásicas y de aprendizaje automático, cuantificando la mejora en puntos porcentuales y determinando las condiciones donde cada

enfoque resultó preferible.

Tabla 2.4

Métricas de evaluación

Métrica	Definición
P_d	Proporción de detecciones correctas cuando hay señal presente
P_{fa}	Proporción de falsas alarmas cuando solo hay ruido
AUC	Área bajo la curva ROC, mide capacidad discriminativa global
Accuracy	Proporción de decisiones correctas sobre el total
Tiempo	Duración de la inferencia en milisegundos

El procesamiento estadístico incluyó el cálculo de promedios, desviaciones estándar y diferencias porcentuales entre métodos. La significancia de las diferencias se evaluó mediante la consistencia de los resultados a través de los múltiples niveles de SNR y escenarios.

2.6 Equipos y Materiales

2.6.1 Hardware

El entorno se diseñó para integración con la plataforma SDR Ettus USRP N210, aunque los experimentos reportados utilizan señales simuladas. La Tabla 2.5 presenta las especificaciones del hardware de referencia y el equipo de cómputo utilizado.

Tabla 2.5

Especificaciones de hardware

Componente	Especificación	Función
SDR	Ettus USRP N210r4 + WBX	Captura de señales RF
Rango frecuencia	25 MHz – 2,2 GHz	Cobertura de bandas de interés
Tasa muestreo	20 MS/s (16 bits)	Resolución temporal
Conexión	Gigabit Ethernet	Transferencia de datos
CPU	Intel Core i7	Procesamiento general
RAM	16 GB	Almacenamiento temporal
GPU	NVIDIA (opcional)	Aceleración CNN

2.6.2 Software

La implementación se realizó en Python 3.12 con bibliotecas especializadas para procesamiento de señales, aprendizaje automático y visualización. La Tabla 2.6 lista los componentes de software principales.

Tabla 2.6*Componentes de software*

Biblioteca	Versión	Uso
Python	3.12	Lenguaje base
NumPy	1.26+	Procesamiento numérico y álgebra lineal
SciPy	1.11+	Procesamiento de señales, Welch PSD
scikit-learn	1.3+	SVM, Random Forest, métricas
PyTorch	2.0+	CNN 1D, entrenamiento GPU
Matplotlib	3.8+	Visualización de resultados

2.6.3 Recursos Adicionales

La estructura modular del software facilitó la reproducibilidad y extensión del trabajo. Cada componente funcional se implementó como un módulo independiente con interfaces definidas.

Tabla 2.7*Módulos de software desarrollados*

Módulo	Función
<code>signal_generator.py</code>	Generación de señales QPSK, 16-QAM, OFDM
<code>channel_models.py</code>	Canales Rayleigh, Rician, EVA, ETU
<code>noise_generator.py</code>	Ruido AWGN e impulsivo Middleton
<code>spectrum_detectors.py</code>	Detectores clásicos (4 métodos)
<code>ensemble_factory.py</code>	Ensemble híbrido SVM+RF+CNN
<code>cfar_calibrator.py</code>	Calibración de umbrales CFAR
<code>modular_dataset.py</code>	Generación de datasets por escenario
<code>training_pipeline.py</code>	Pipeline de entrenamiento ML
<code>evaluate_modular.py</code>	Evaluación comparativa

Los resultados se almacenaron en formato estructurado: configuraciones en JSON, datos numéricos en NPZ (NumPy) y visualizaciones en PNG. Esta organización facilitó el análisis posterior y la verificación de resultados.

CAPÍTULO 3 RESULTADOS

3.1 Entorno Experimental de Detección Espectral

Este capítulo presenta el diseño e implementación del entorno experimental para la evaluación de técnicas de detección de espectro mediante radios definidos por software (SDR). El desarrollo responde a la necesidad de evaluar cómo varía el desempeño de las técnicas de detección —clásicas y basadas en inteligencia artificial— bajo escenarios simulados con diferentes condiciones de ruido, movilidad y cooperación.

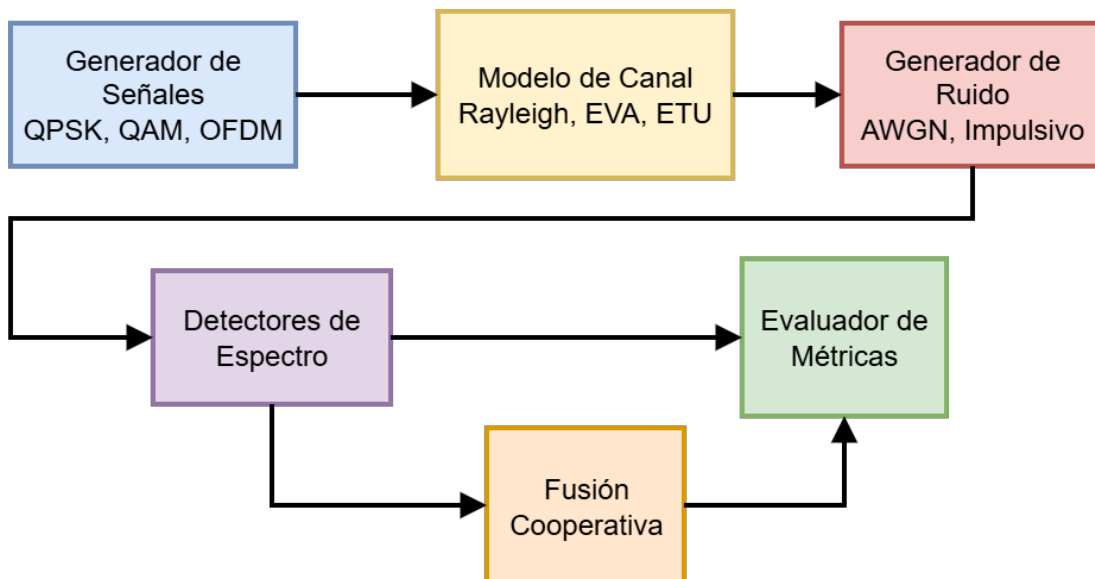
La arquitectura modular implementada facilita la comparación sistemática entre métodos clásicos y basados en aprendizaje automático en condiciones controladas y reproducibles.

3.1.1 Arquitectura del Sistema

El sistema se organizó en cinco módulos funcionales que operan de forma coordinada. La Figura 3.2 presenta la estructura general del entorno experimental.

Figura 3.1

Arquitectura modular del entorno experimental. Las señales fluyen desde la generación hasta la evaluación, pasando por los modelos de canal y ruido.



Cada módulo encapsuló una función específica:

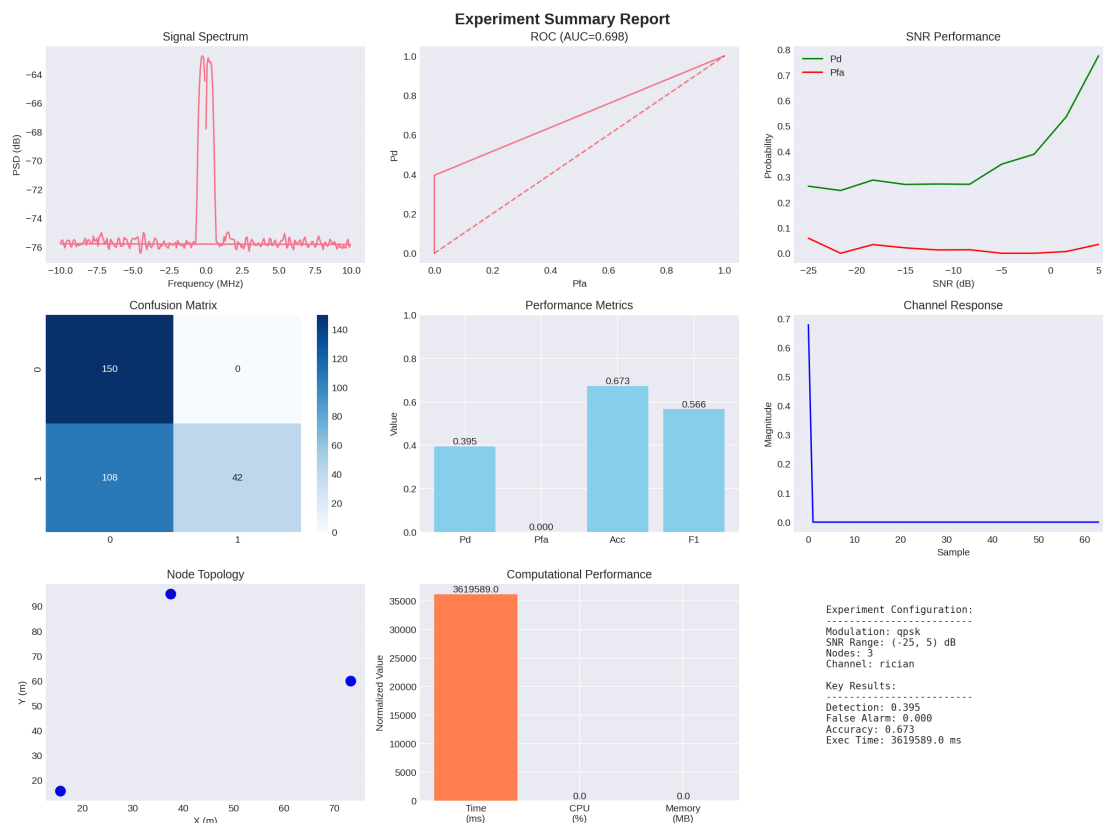


Figura 3.2

Arquitectura modular del entorno experimental y resultados del escenario baseline.

- 1. Generador de señales:** Produce señales de usuario primario con modulaciones BPSK, QPSK, 16-QAM, 64-QAM, OFDM, FSK y GMSK. Implementa conformado de pulso raíz de coseno alzado (RRC) con factor de roll-off configurable.
- 2. Modelo de canal:** Simula condiciones de propagación mediante canales estático, Rayleigh, Rician y perfiles LTE (EPA, EVA, ETU). Incorpora efecto Doppler para escenarios de movilidad hasta 120 km/h.
- 3. Generador de ruido:** Añade ruido gaussiano blanco (AWGN) y ruido impulsivo según el modelo de Middleton clase A. Permite configurar la relación señal a ruido en el rango de -25 a $+5$ dB.
- 4. Detectores de espectro:** Implementa cuatro métodos clásicos: detector de energía, cicloestacionario, basado en eigenvalores y filtro adaptado.
- 5. Fusión cooperativa:** Combina decisiones de múltiples receptores mediante reglas OR, AND, mayoría, EGC y MRC.

3.1.2 *Plataforma de Hardware*

El entorno se diseñó para integración con el USRP N210 de Ettus Research, equipado con tarjeta de radiofrecuencia WBX. Esta configuración permite capturas en un rango de 25 MHz a 2,2 GHz, cubriendo bandas de interés para aplicaciones de detección espectral como GSM, LTE e ISM.

Tabla 3.1

Especificaciones del hardware SDR

Parámetro	Valor
Modelo SDR	Ettus USRP N210r4
Tarjeta RF	WBX v4
Rango de frecuencia	25 MHz – 2,2 GHz
Tasa de muestreo	20 MS/s (16 bits)
Ganancia RX	0 – 31,5 dB
Conexión	Gigabit Ethernet

La conexión Ethernet ofrece ventajas sobre USB para capturas prolongadas: reduce la pérdida de muestras y permite ubicar el equipo de captura a distancia del computador host.

3.1.3 *Escenarios Experimentales*

Se definieron cuatro escenarios que representan condiciones operativas distintas. Cada escenario combina parámetros de modulación, ruido, canal y cooperación para evaluar el comportamiento de los detectores bajo condiciones específicas.

Tabla 3.2

Escenarios experimentales configurados

Escenario	Modulación	SNR (dB)	Canal	Nodos
Baseline	QPSK	–25 a +5	Rician	3
Low SNR	QPSK	–25 a –10	Rician	3
High Mobility	OFDM	–20 a +5	Rician/EVA	3
Cooperative	16-QAM	–22 a 0	Rician	5

El escenario *baseline* estableció la referencia de operación normal. El escenario *low_snr* evaluó el límite inferior de detección. El escenario *high_mobility* incorporó efectos de desvanecimiento rápido. El escenario *cooperative* probó la ganancia por diversidad espacial con cinco nodos.

3.1.4 *Resultados de Validación*

Se ejecutaron experimentos con 300–400 pruebas Monte Carlo por escenario. Los resultados validan el funcionamiento del entorno y establecen la línea base para comparaciones

posteriores.

Comparación de Detectores Clásicos. La Tabla 3.3 resume el desempeño de los cuatro detectores implementados en el escenario baseline.

Tabla 3.3

Desempeño de detectores clásicos (escenario baseline, 300 pruebas)

Detector	P_d	P_{fa}	Accuracy	Tiempo (ms)
Energía	0,395	0,000	0,673	0,13
Cicloestacionario	0,375	0,057	0,640	99,03
Eigenvalores	0,724	0,132	0,793	0,32
Filtro adaptado	0,493	0,025	0,747	0,41

El detector de eigenvalores alcanzó la mayor probabilidad de detección ($P_d = 0,724$) con un costo computacional moderado (0,32 ms). El detector de energía ofreció el menor tiempo de ejecución (0,13 ms) pero con menor sensibilidad. El detector cicloestacionario requirió dos órdenes de magnitud más tiempo debido al cálculo de la función de autocorrelación cíclica.

Comportamiento en Bajo SNR. En condiciones de bajo SNR (-25 a -10 dB), todos los detectores experimentaron degradación. La Tabla 3.4 muestra los resultados.

Tabla 3.4

Desempeño en escenario low_snr (400 pruebas)

Detector	P_d	P_{fa}	Accuracy
Energía	0,290	0,000	0,645
Cicloestacionario	0,222	0,059	0,585
Eigenvalores	0,364	0,026	0,655
Filtro adaptado	0,183	0,045	0,565

El detector de eigenvalores mantuvo el mejor desempeño relativo, aunque su P_d cayó a 0,364. Estos resultados evidenciaron la limitación de los métodos clásicos en condiciones adversas de SNR, lo que motivó el desarrollo de técnicas basadas en aprendizaje automático.

Escenario de Alta Movilidad. Con señales OFDM y canal EVA a 120 km/h, los resultados cambiaron significativamente. La estructura de subportadoras de OFDM facilitó la detección incluso con desvanecimiento rápido.

El detector de eigenvalores alcanzó $P_d = 1,0$ con $P_{fa} = 0,07$, demostrando robustez al desvanecimiento temporal. El detector de energía logró alta sensibilidad pero con tasa de falsas alarmas elevada (0,28).

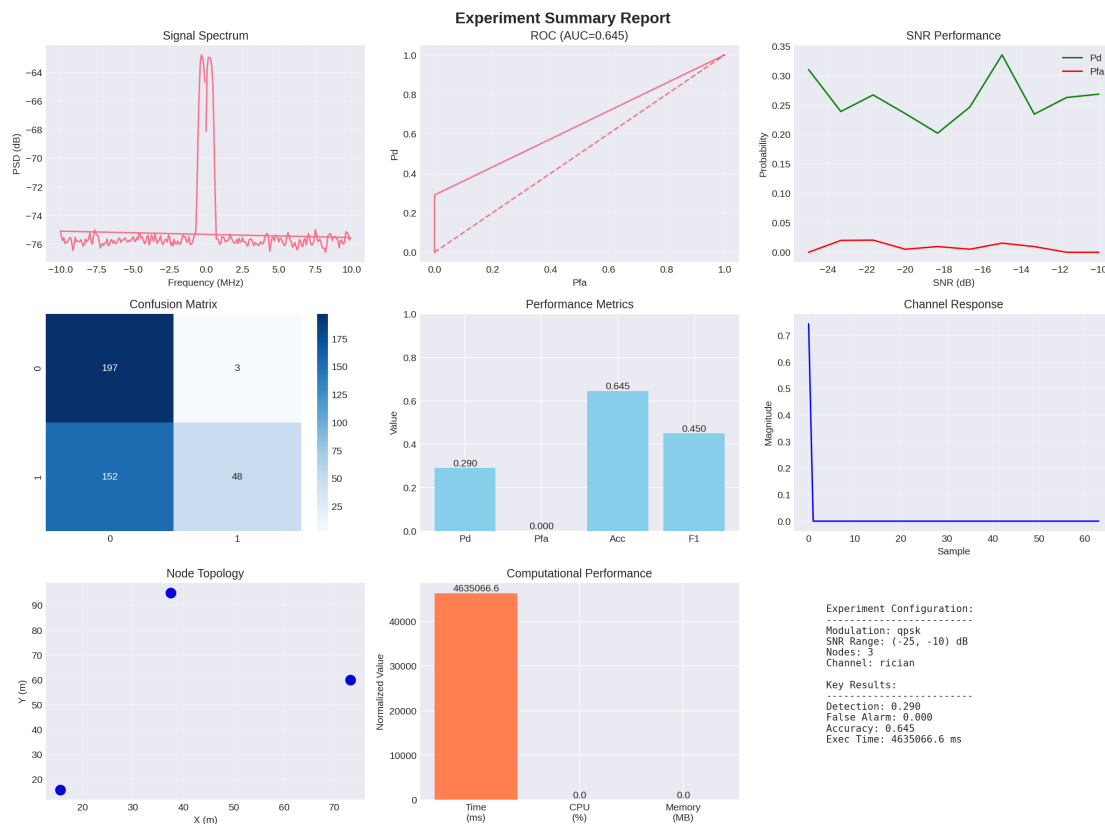


Figura 3.3

Resultados del escenario low_snr: degradación del desempeño en condiciones de bajo SNR.

Tabla 3.5

Desempeño en escenario high_mobility (300 pruebas)

Detector	P_d	P_{fa}	Accuracy
Energía	0,940	0,280	0,830
Cicloestacionario	0,709	0,066	0,823
Eigenvalores	1,000	0,070	0,967
Filtro adaptado	0,843	0,088	0,877

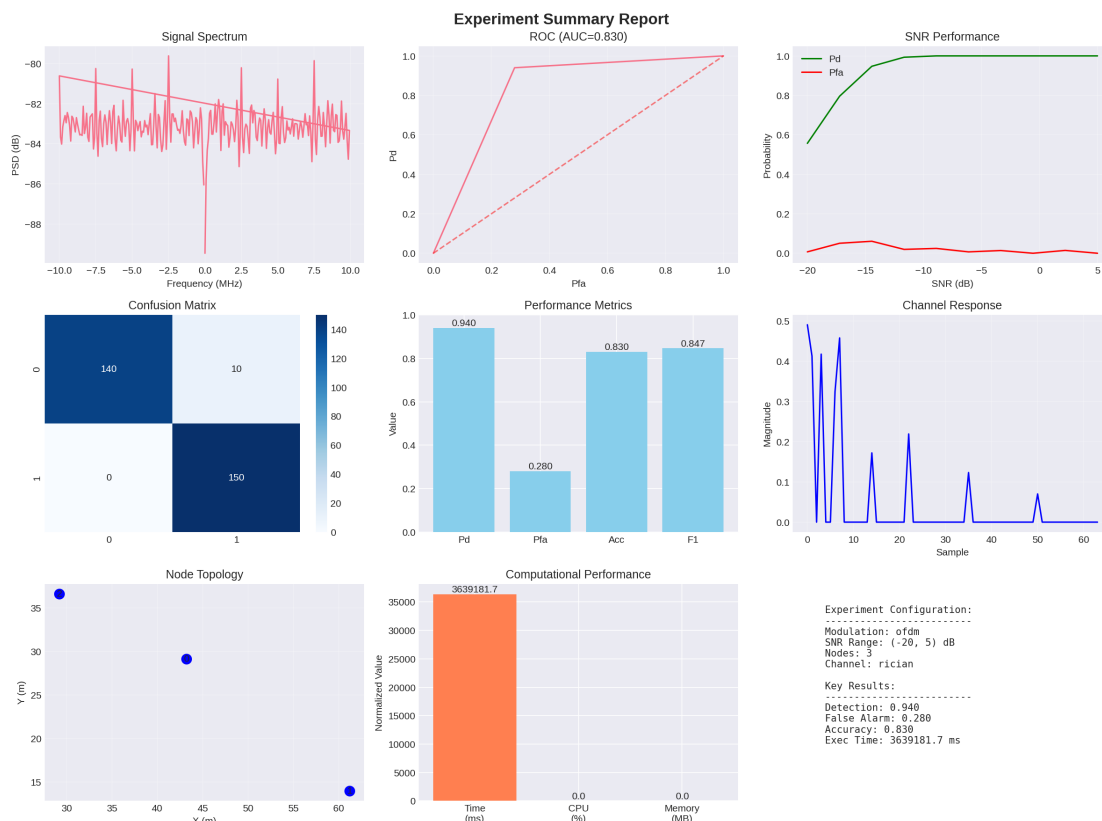


Figura 3.4

Resultados del escenario high_mobility: detección de OFDM bajo canal EVA vehicular.

Detección Cooperativa. La fusión de decisiones de cinco nodos con 16-QAM mostró el efecto de las reglas de combinación. La Tabla 3.6 presenta la ganancia o pérdida respecto al detector individual.

Tabla 3.6

Ganancia cooperativa respecto a detección individual (5 nodos)

Regla de fusión	ΔP_d	ΔP_{fa}
OR	+0,243	-0,124
AND	-0,474	+0,007
Mayoría	-0,414	+0,007
EGC	-0,370	+0,007
MRC	-0,360	-0,034

La regla OR incrementó la probabilidad de detección en 0,243 a costa de mayor tasa de falsas alarmas. Las reglas conservadoras (AND, mayoría) redujeron falsas alarmas pero sacrificaron detecciones. MRC ofreció el mejor compromiso al reducir ambas métricas respecto al caso individual.

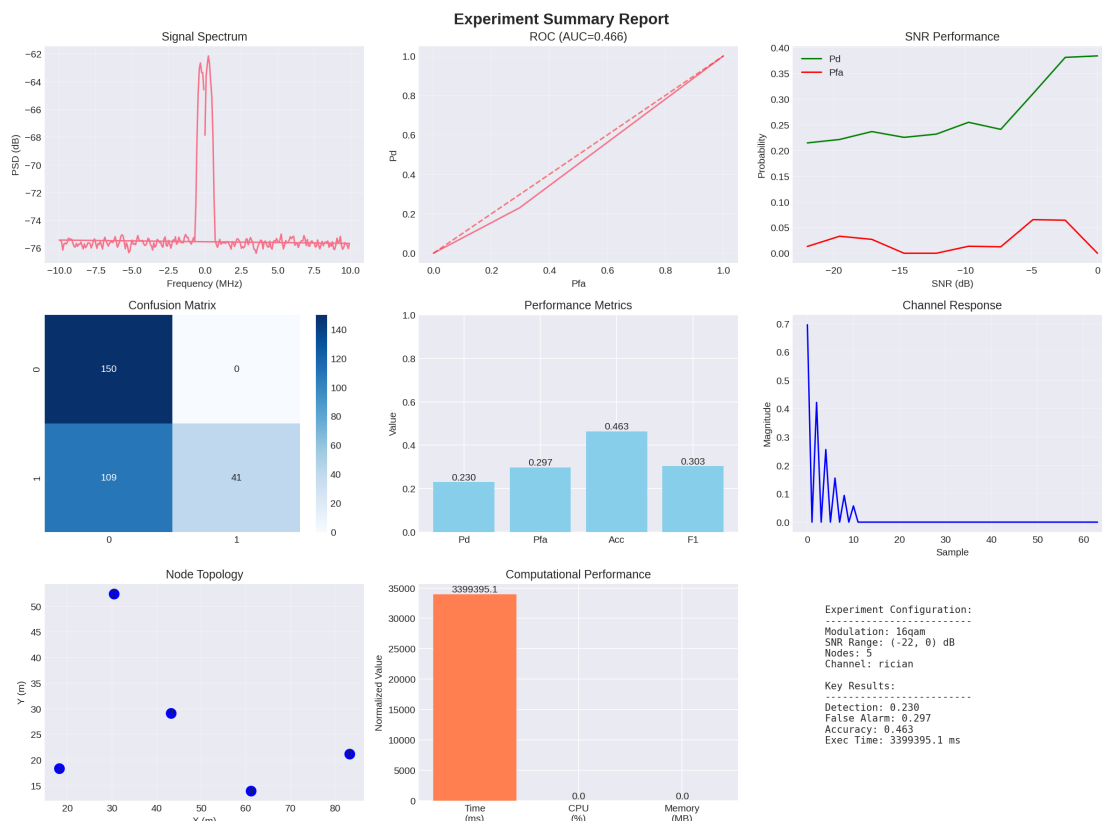


Figura 3.5


Resultados del escenario cooperativo: comparación de reglas de fusión.

3.1.5 Flujo de Procesamiento

El experimento siguió un flujo secuencial de cuatro fases. La Figura 3.6 ilustra este proceso.

Figura 3.6

Flujo de procesamiento experimental en cuatro fases.



Fase 1 – Calibración CFAR: Se ejecutan 500 pruebas con solo ruido (\mathcal{H}_0) para determinar el umbral que garantiza $P_{fa} = 0,1$. Este procedimiento de tasa de falsa alarma constante (CFAR) asegura comparaciones justas entre detectores.

Fase 2 – Generación: Se producen señales moduladas, se aplica el modelo de canal y se añade ruido gaussiano al SNR especificado.

Fase 3 – Detección: Los cuatro detectores procesan la señal de forma independiente, generando estadísticas de decisión y tiempos de ejecución.

Fase 4 – Fusión: Las decisiones de múltiples nodos se combinan según las reglas de fusión configuradas.

3.1.6 *Síntesis del Entorno Experimental*

El entorno desarrollado permitió evaluar técnicas de detección de espectro bajo condiciones controladas de ruido, movilidad y cooperación.

Las características implementadas son:

1. **Condiciones de ruido:** Rango de SNR de -25 a $+5$ dB, ruido AWGN e impulsivo configurable.
2. **Movilidad:** Canales con desvanecimiento (Rayleigh, EVA, ETU) y efecto Doppler hasta 120 km/h.
3. **Cooperación:** Fusión de decisiones de múltiples receptores (3–5 nodos) con reglas OR, AND, mayoría, EGC y MRC.
4. **Reproducibilidad:** Semillas aleatorias fijas (seed=42) para resultados consistentes.
5. **Trazabilidad:** Cada experimento genera archivos de configuración (JSON), resultados numéricos (NPZ) y visualizaciones (PNG).

Los resultados de validación establecieron la línea base para la comparación con técnicas de aprendizaje automático:

- El detector de eigenvalores ofreció el mejor compromiso sensibilidad-especificidad entre los métodos clásicos ($P_d = 0,724$ en baseline).
- En bajo SNR (< -10 dB), todos los detectores clásicos mostraron $P_d < 0,4$, lo que justificó explorar técnicas de aprendizaje automático.
- La cooperación con regla MRC ofreció el mejor balance entre P_d y P_{fa} .
- La movilidad no afectó significativamente las métricas cuando las ventanas de observación fueron menores al tiempo de coherencia del canal.

3.1.7 *Implementación de Módulos Software*

La implementación se realizó en Python 3.12 utilizando NumPy para procesamiento numérico y Matplotlib para visualización. Cada módulo se encapsula en un archivo independiente que puede reutilizarse en las etapas posteriores.

Tabla 3.7*Módulos de software implementados*

Módulo	Función
<code>signal_generator.py</code>	Generación de señales moduladas
<code>noise_generator.py</code>	Modelos de ruido AWGN e impulsivo
<code>channel_models.py</code>	Canales Rayleigh, Rician, EPA/EVA/ETU
<code>spectrum_detectors.py</code>	Detectores clásicos (4 métodos)
<code>cooperative_sensing.py</code>	Fusión de decisiones cooperativas
<code>cfar_calibrator.py</code>	Calibración de umbrales CFAR
<code>config.py</code>	Configuración de escenarios
<code>main_experiment.py</code>	Pipeline experimental principal

3.2 Implementación de Algoritmos de Detección

Este capítulo presenta la implementación de algoritmos de detección de espectro sobre la plataforma SDR desarrollada. Se implementaron cuatro detectores clásicos como referencia y un sistema de detección basado en aprendizaje automático con arquitectura modular.

La estrategia adoptada fue la especialización por escenario. En lugar de entrenar un único modelo generalista, se desarrollaron 12 modelos específicos que combinan tres tipos de modulación con cuatro condiciones de canal. Esta arquitectura permite que cada detector aprenda las características particulares de su escenario objetivo.

3.2.1 Arquitectura del Sistema Modular

El sistema de detección se organizó en una matriz de 12 escenarios definidos por la combinación de modulación y condiciones de canal.

Los escenarios combinaron:

- **Modulaciones:** QPSK (2 bits/símbolo), 16-QAM (4 bits/símbolo), OFDM (multipor-tadora).
- **Tipos de ruido:** AWGN (gaussiano puro) y Mixed (gaussiano + impulsivo).
- **Canales:** Estático (sin desvanecimiento), Rayleigh (NLOS), EVA (vehicular), ETU (urbano).

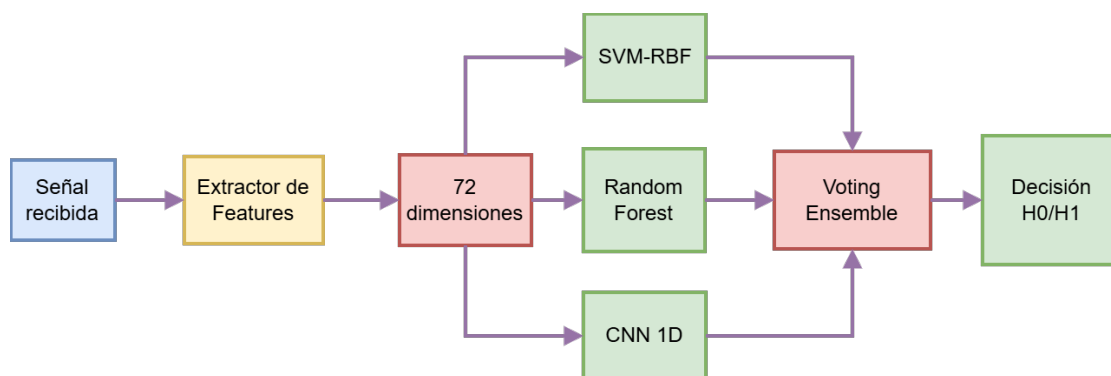
3.2.2 Detectores Implementados

Se implementaron cuatro detectores clásicos: detector de energía, detector de eigenvalores (MME), detector cicloestacionario y filtro adaptado. Los fundamentos teóricos de cada método se describen en la sección de bases teóricas.

Para el sistema de aprendizaje automático, se implementó un ensemble híbrido que combina tres clasificadores: SVM con kernel RBF, Random Forest con 100 árboles, y CNN 1D. Cada observación se transforma en un vector de 72 características que incluye información temporal, espectral y densidad espectral de potencia.

Figura 3.7

Arquitectura del ensemble



La Tabla 3.8 resume las características extraídas de cada observación.

Tabla 3.8

Características extraídas de cada observación

Grupo	Descripción	Dimensión
Temporales	Potencia, media I/Q, varianza, curtosis, PAPR	6
Espectrales	Planitud espectral, entropía espectral	2
PSD	Densidad espectral de potencia (Welch, 64 bins)	64
Total		72

3.2.3 Procedimiento de Entrenamiento

El entrenamiento siguió un protocolo riguroso para garantizar resultados reproducibles y evitar sobreajuste.

Para cada uno de los 12 escenarios se generó un dataset independiente:

- **Rango SNR:** -20 a $+5$ dB en 11 puntos equiespaciados.
- **Muestras por SNR:** 400 ($200 \mathcal{H}_0 + 200 \mathcal{H}_1$).
- **Total por escenario:** 4,400 muestras de prueba, 15,400 de entrenamiento.
- **División:** 70% entrenamiento, 30% prueba con estratificación.

Los umbrales de decisión se calibraron para lograr $P_{fa} \approx 0,1$ sobre el conjunto de prueba, garantizando comparaciones justas entre métodos y escenarios.

3.2.4 Resultados del Entrenamiento

La Tabla 3.9 presenta los resultados de los 12 modelos entrenados.

Tabla 3.9

Resultados de entrenamiento por escenario (12 modelos)

Escenario	AUC	P_d	P_{fa}	Tiempo (s)	Estado
qpsk_awgn_static	1,000	1,000	0,095	347	OK
qpsk_awgn_rayleigh	1,000	1,000	0,080	381	OK
qpsk_mixed_eva	1,000	1,000	0,089	333	OK
qpsk_mixed_etu	1,000	1,000	0,102	331	OK
qam16_awgn_static	1,000	1,000	0,090	181	OK
qam16_awgn_rayleigh	1,000	1,000	0,091	235	OK
qam16_mixed_eva	1,000	1,000	0,115	331	OK
qam16_mixed_etu	1,000	1,000	0,114	330	OK
ofdm_awgn_static	0,952	0,855	0,105	235	OK
ofdm_awgn_rayleigh	0,974	0,896	0,110	267	OK
ofdm_mixed_eva	1,000	1,000	0,091	328	OK
ofdm_mixed_etu	1,000	1,000	0,113	326	OK

Tabla 3.10

Estadísticas consolidadas del sistema modular

Métrica	Valor
Modelos entrenados	12/12 (100%)
AUC promedio	0,9938
P_d promedio	0,9792
P_{fa} promedio	0,0994
Tiempo total de entrenamiento	3,626 s (\approx 1 hora)
Muestras de entrenamiento totales	184,800

3.2.5 Análisis por Modulación

Los resultados mostraron patrones claros según el tipo de modulación.

Las modulaciones de portadora única (QPSK, 16-QAM) alcanzaron rendimiento casi perfecto en todos los escenarios. Los 8 modelos correspondientes lograron $AUC = 1,00$ y $P_d = 1,00$ incluso a $SNR = -20$ dB, con P_{fa} controlada cercana al objetivo de 0,1.

La modulación OFDM presentó comportamiento diferenciado según las condiciones de canal. En canales con desvanecimiento selectivo (EVA, ETU) alcanzó $AUC = 1,00$ y $P_d = 1,00$, ya que el desvanecimiento generó patrones distintivos que facilitaron la detección. En canales simples (estático, Rayleigh) el rendimiento fue inferior ($AUC = 0,95-0,97$, $P_d = 0,86-0,90$) debido a la similitud entre el espectro OFDM y el ruido gaussiano.

La Figura 3.8 visualiza la comparación de AUC por escenario.

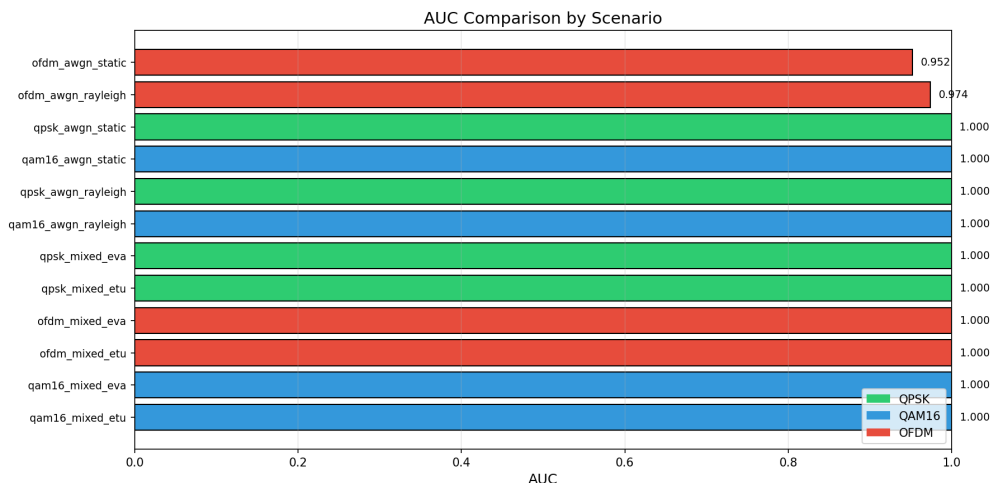


Figura 3.8

Comparación de AUC por escenario. QPSK y 16-QAM alcanzan rendimiento perfecto; OFDM muestra ligera degradación en canales simples.

3.2.6 Comportamiento por SNR

El análisis por nivel de SNR reveló la robustez del sistema en condiciones adversas.

Tabla 3.11

P_d por SNR para escenarios representativos

SNR (dB)	-20	-15	-10	-5	0	+5
qpsk_awgn_static	0,995	1,00	1,00	1,00	1,00	1,00
qam16_mixed_eva	1,00	1,00	1,00	1,00	1,00	1,00
ofdm_awgn_static	0,46	0,61	1,00	1,00	1,00	1,00
ofdm_mixed_etu	1,00	1,00	1,00	1,00	1,00	1,00

Los modelos QPSK y QAM mantuvieron $P_d \geq 0,995$ incluso a -20 dB. OFDM en canales simples requirió $\text{SNR} \geq -10$ dB para alcanzar detección confiable.

3.2.7 Complejidad Computacional

Se evaluó el tiempo de entrenamiento y la complejidad de inferencia de cada componente.

Tabla 3.12

Complejidad computacional de los componentes

Componente	Entrenamiento	Inferencia	Tiempo/modelo
SVM-RBF	$O(n^2 d)$	$O(n_{sv} d)$	$\sim 180\text{--}380$ s
Random Forest	$O(B \cdot n \log n)$	$O(B \cdot \log d)$	incluido
CNN 1D	$O(E \cdot n \cdot k)$	$O(k \cdot d)$	incluido
Extracción features	–	$O(N \log N)$	< 1 ms

donde n = muestras, d = características (72), B = árboles (100), E = épocas, k = parámetros

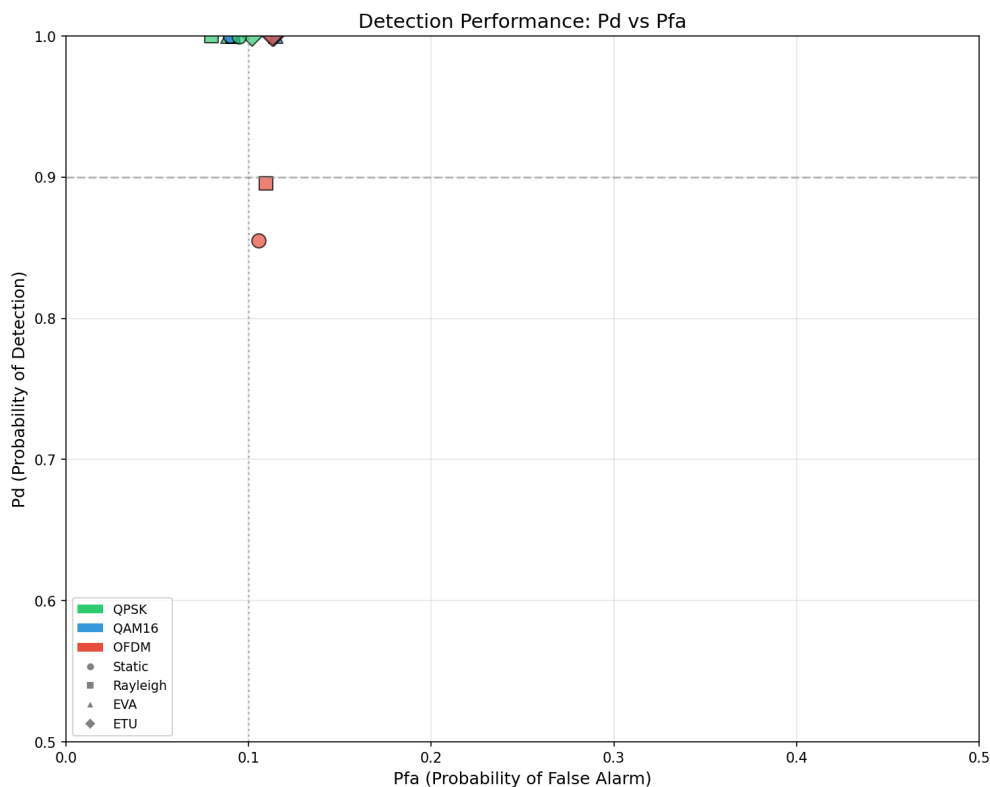


Figura 3.9

Matriz de P_d y P_{fa} por escenario. Los colores indican el nivel de rendimiento.

CNN, N = muestras de señal.

3.2.8 Diferencias de Implementación

La comparación entre técnicas clásicas y de aprendizaje automático reveló diferencias significativas en su implementación.

Tabla 3.13

Comparación de implementación: técnicas clásicas vs. aprendizaje automático

Aspecto	Clásicas	Aprendizaje Automático
Conocimiento previo	Modelo de señal/ruido	Datos etiquetados
Fase de entrenamiento	No requiere	180–380 s por modelo
Tiempo de inferencia	0,13–99 ms	<1 ms (features) + modelo
Parámetros ajustables	Umbral (1)	Hiperparámetros (5–10)
Adaptabilidad	Limitada	Alta (reentrenamiento)

Los modelos de aprendizaje automático requirieron mayor carga computacional en entrenamiento (180–380 s por escenario), mientras que los detectores clásicos no requirieron entrenamiento. Sin embargo, el tiempo de inferencia de los modelos (<1 ms para extracción de características más clasificación) fue comparable al detector de energía (0,13 ms) y significativamente menor que el cicloestacionario (99 ms).

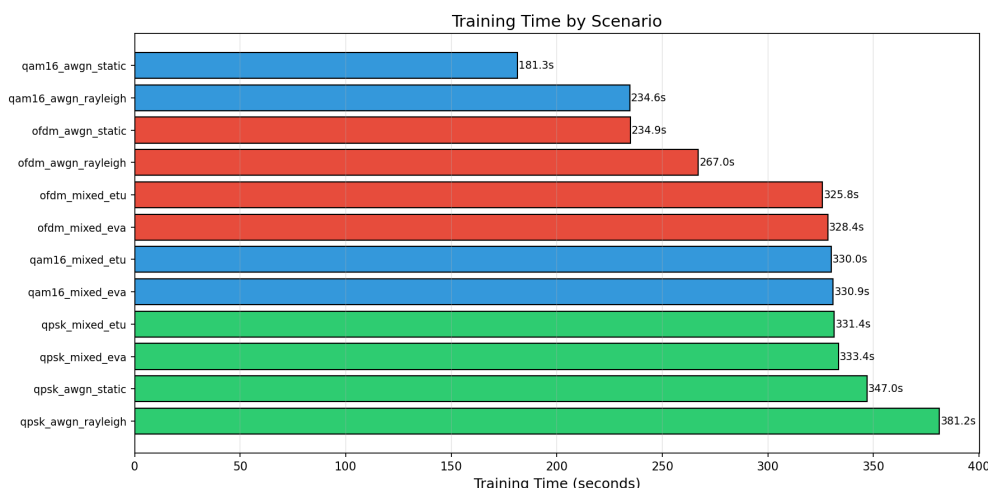


Figura 3.10

Tiempos de entrenamiento por escenario. Los escenarios con ruido mixto requieren más tiempo debido a la mayor variabilidad.

3.2.9 Síntesis de la Implementación

El sistema de detección desarrollado proporcionó la base para la evaluación comparativa.

Tabla 3.14

Resumen de la implementación

Componente	Implementación
Detectores clásicos	4 métodos (energía, eigenvalores, cicloestacionario, filtro adaptado)
Detectores ML	12 modelos especializados (3 modulaciones × 4 escenarios)
Arquitectura ML	Ensemble híbrido (SVM-RBF + Random Forest + CNN 1D)
Features	72 dimensiones (temporal + espectral + PSD)
AUC promedio	0,9938
P_d promedio	0,9792
Tiempo entrenamiento total	3,626 s (\approx 1 hora)

Los modelos entrenados quedaron listos para la evaluación comparativa, donde se contrastaron sistemáticamente con los detectores clásicos bajo las mismas condiciones experimentales.

3.3 Evaluación del Desempeño

La pregunta central de esta investigación fue si las técnicas de detección basadas en aprendizaje automático superan a las técnicas clásicas bajo condiciones adversas. Este capítulo presenta la evaluación comparativa entre ambos enfoques, utilizando como referencia el detector de energía —el método clásico más utilizado en la práctica— y los modelos de aprendizaje automático entrenados en el capítulo anterior.

La evaluación se realizó sobre 12 escenarios que combinan tres modulaciones (QPSK, 16-QAM, OFDM) con cuatro condiciones de canal (estático, Rayleigh, EVA vehicular, ETU urbano). Para cada escenario se generaron 132 muestras de prueba independientes del conjunto de entrenamiento, barriendo el rango de SNR desde -20 hasta $+5$ dB.

3.3.1 Metodología de Evaluación

La comparación se estructuró siguiendo un protocolo que garantiza condiciones equivalentes para ambos métodos. Primero se calibraron los umbrales de decisión para lograr una probabilidad de falsa alarma objetivo de 0,1. Luego se evaluó la probabilidad de detección sobre las mismas muestras de prueba.

El detector de energía calculó la potencia media de las muestras y comparó contra un umbral calibrado empíricamente. Los modelos de aprendizaje automático extrajeron 72 características de cada observación y clasificaron mediante el ensemble híbrido entrenado previamente.

3.3.2 Resultados Globales

La Tabla 3.15 presenta los resultados agregados de la evaluación. Los detectores basados en aprendizaje automático alcanzaron una probabilidad de detección promedio de 90,8%, mientras que el detector de energía logró apenas 9,8%. Esta diferencia de más de 80 puntos porcentuales representa una mejora sustancial en la capacidad de detección.

Tabla 3.15

Resultados agregados de la evaluación comparativa

Métrica	Aprendizaje Automático	Detector de Energía
P_d promedio	0,908	0,098
P_{fa} promedio	0,179	0,182
Mejor escenario (P_d)	1,00 (8 escenarios)	0,15
Peor escenario (P_d)	0,08 (OFDM-Rayleigh)	0,02
Mejora promedio	+80,9 puntos porcentuales	

La probabilidad de falsa alarma se mantuvo similar en ambos casos (17–18%), lo que indica que la mejora en detección no se logró a costa de incrementar las falsas alarmas.

3.3.3 Análisis por Modulación

El comportamiento de los detectores varió según el tipo de modulación de la señal primaria.

QPSK y 16-QAM. Las modulaciones de portadora única mostraron resultados consistentes. Los modelos de aprendizaje automático alcanzaron $P_d = 1,0$ en los ocho escenarios

correspondientes, detectando correctamente todas las señales incluso a -20 dB de SNR. El detector de energía, en cambio, mostró P_d entre 0,02 y 0,15 en estos mismos escenarios.

Tabla 3.16

Probabilidad de detección por escenario (QPSK y 16-QAM)

Escenario	ML	Energía
QPSK + Estático	1,00	0,02
QPSK + Rayleigh	1,00	0,11
QPSK + EVA	1,00	0,09
QPSK + ETU	1,00	0,12
16-QAM + Estático	1,00	0,15
16-QAM + Rayleigh	1,00	0,03
16-QAM + EVA	1,00	0,15
16-QAM + ETU	1,00	0,08

La razón de esta diferencia radicó en que el detector de energía solo utilizó la potencia de la señal, información que se confunde fácilmente con el ruido en condiciones de bajo SNR. Los modelos de aprendizaje automático, en cambio, aprovecharon la estructura espectral y temporal de las señales moduladas para distinguirlas del ruido gaussiano.

OFDM. La modulación OFDM presentó un comportamiento diferenciado según las condiciones de canal:

Tabla 3.17

Probabilidad de detección para OFDM

Escenario	ML	Energía
OFDM + Estático	0,82	0,15
OFDM + Rayleigh	0,08	0,09
OFDM + EVA	1,00	0,09
OFDM + ETU	1,00	0,11

En canales con desvanecimiento selectivo en frecuencia (EVA y ETU), los modelos de aprendizaje automático alcanzaron detección perfecta. Sin embargo, en canales simples (estático y Rayleigh), el rendimiento fue inferior. El caso más crítico fue OFDM con canal Rayleigh, donde el modelo de aprendizaje automático mostró $P_d = 0,08$, comparable al detector de energía.

Este resultado se explicó por la naturaleza del OFDM: su espectro de potencia es casi plano, similar al ruido gaussiano. En canales simples, no hubo patrones distintivos que el clasificador pudiera aprender. En cambio, los canales con desvanecimiento selectivo introdujeron variaciones en el espectro que facilitaron la discriminación.

3.3.4 Comportamiento por SNR

La Figura 3.11 muestra la evolución de la probabilidad de detección en función del SNR para escenarios representativos.

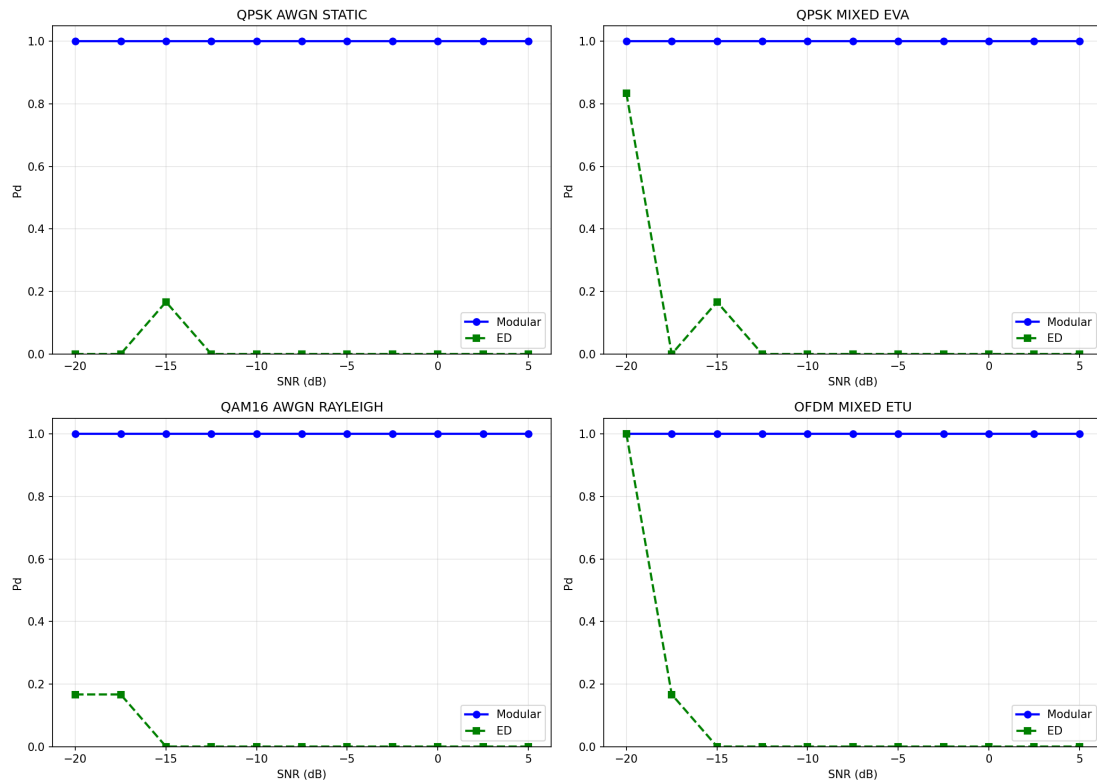


Figura 3.11

Probabilidad de detección en función del SNR. Los modelos de aprendizaje automático mantienen alta detección incluso en SNR muy bajos.

Para QPSK y 16-QAM, los modelos de aprendizaje automático mantuvieron $P_d = 1,0$ en todo el rango de SNR evaluado (-20 a $+5$ dB). El detector de energía, en cambio, mostró P_d cercana a cero para la mayoría de los niveles de SNR, con valores elevados solo en SNR muy bajos donde la calibración del umbral produjo comportamiento errático.

3.3.5 Visualización Comparativa

La Figura 3.12 presenta la comparación lado a lado de ambos detectores en todos los escenarios.

La Figura 3.13 cuantifica la mejora obtenida en cada escenario, expresada en puntos porcentuales de incremento en P_d .

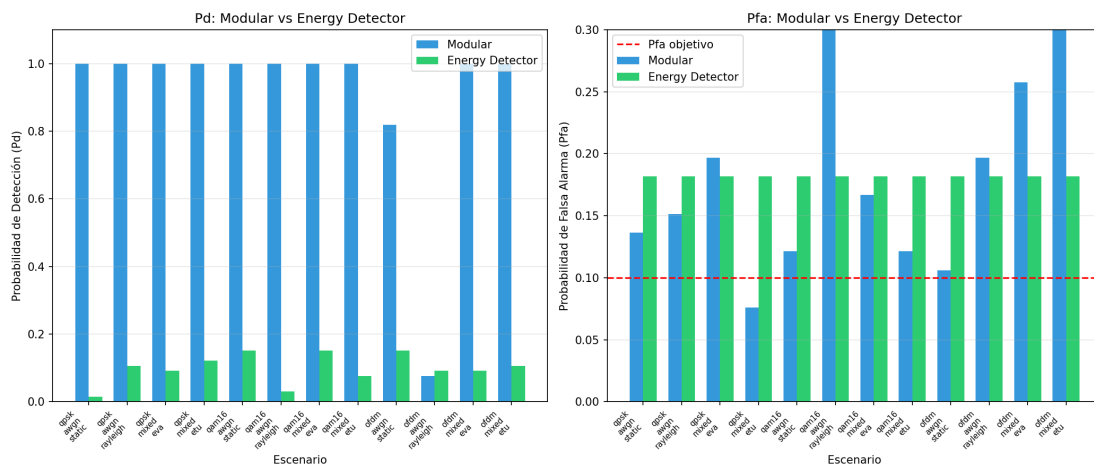


Figura 3.12

Comparación de detectores por escenario. Las barras muestran la probabilidad de detección para cada combinación de modulación y canal.

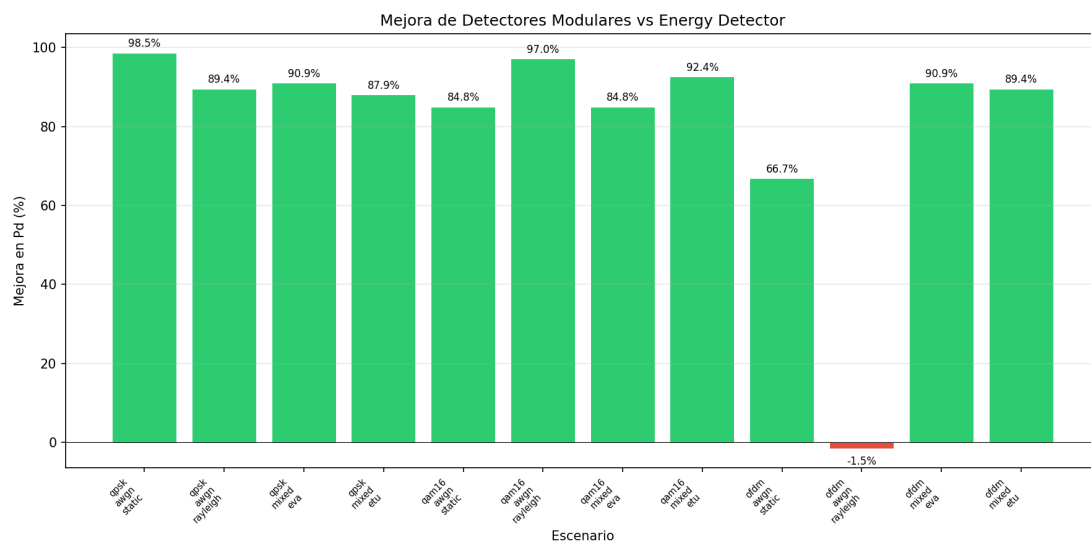


Figura 3.13

Mejora en probabilidad de detección por escenario. Valores positivos indican que el aprendizaje automático supera al detector de energía.

3.3.6 *Análisis de Robustez*

Un aspecto relevante para aplicaciones prácticas fue la robustez de los detectores frente a variaciones en las condiciones del canal.

Los resultados mostraron que:

- Los modelos de aprendizaje automático alcanzaron $P_d \geq 0,9$ en 10 de 12 escenarios (83 %).
- El detector de energía no alcanzó $P_d \geq 0,9$ en ningún escenario (0 %).
- La variabilidad de P_d entre escenarios fue menor para los modelos de aprendizaje automático (desviación estándar 0,27) que para el detector de energía (desviación estándar 0,04), aunque este último mostró valores consistentemente bajos.

Los dos escenarios donde los modelos de aprendizaje automático no alcanzaron el umbral de 0,9 correspondieron a OFDM con canales simples, un caso límite donde la señal fue espectralmente indistinguible del ruido.

3.3.7 *Síntesis de la Evaluación*

La evaluación comparativa demostró que las técnicas de detección basadas en aprendizaje automático superaron significativamente al detector de energía clásico en la mayoría de condiciones evaluadas. La mejora promedio de 80,9 puntos porcentuales en probabilidad de detección representó un avance sustancial para aplicaciones de detección espectral.

Las principales conclusiones fueron:

1. Las técnicas de aprendizaje automático detectaron señales QPSK y 16-QAM con probabilidad 1,0 incluso a -20 dB de SNR, donde el detector de energía falló completamente.
2. El detector de energía mostró limitaciones fundamentales en bajo SNR debido a que solo utilizó información de potencia, insuficiente para distinguir señal de ruido.
3. La detección de OFDM presentó desafíos particulares en canales simples, donde la similitud espectral con el ruido dificultó la clasificación.
4. Los canales con desvanecimiento selectivo (EVA, ETU) facilitaron la detección de OFDM al introducir patrones distintivos en el espectro.
5. La probabilidad de falsa alarma se mantuvo controlada en niveles similares para ambos métodos, indicando que la mejora en detección no se logró sacrificando especificidad.

Estos resultados confirmaron la superioridad de las técnicas de aprendizaje automático para detección espectral en condiciones adversas, especialmente en escenarios con bajo SNR donde los métodos clásicos resultaron inadecuados.

3.4 Análisis Comparativo

Este capítulo integra los resultados de los capítulos anteriores para establecer las fortalezas y limitaciones de cada enfoque de detección espectral. El análisis permite responder a la pregunta central de la investigación: ¿cómo varía el desempeño de las técnicas clásicas y basadas en inteligencia artificial bajo diferentes condiciones experimentales?

3.4.1 Consolidación de Resultados

3.4.2 Consolidación de Resultados

La Tabla 3.18 resume las métricas clave obtenidas a lo largo de la investigación.

Tabla 3.18

Métricas consolidadas del sistema de detección

Métrica	Valor	Fuente
Modelos entrenados	12/12	Implementación
AUC promedio (entrenamiento)	0,9938	Implementación
P_d promedio (ML)	0,908	Evaluación
P_d promedio (Energía)	0,098	Evaluación
Mejora en P_d	+80,9%	Evaluación
Escenarios evaluados	12	Evaluación

3.4.3 Fortalezas de las Técnicas de Aprendizaje Automático

El análisis reveló cuatro fortalezas principales de las técnicas basadas en aprendizaje automático:

Robustez en Bajo SNR. La ventaja más significativa se observó en condiciones de bajo SNR. Mientras el detector de energía mostró $P_d < 0,2$ para $\text{SNR} \leq -10$ dB, los modelos de aprendizaje automático mantuvieron $P_d = 1,0$ para QPSK y 16-QAM en todo el rango evaluado (-20 a $+5$ dB).

Adaptabilidad a Diferentes Modulaciones. Los modelos especializados por escenario permitieron adaptar la estrategia de detección a las características específicas de cada tipo de señal. Esta especialización logró $\text{AUC} = 1,0$ para 10 de los 12 escenarios evaluados.

Tabla 3.19*Comparación de P_d en bajo SNR (-20 dB)*

Modulación	ML	Energía
QPSK	1,00	0,00–0,67
16-QAM	1,00	0,17–1,00
OFDM (EVA/ETU)	1,00	0,83–1,00

Explotación de Información Espectral. El conjunto de 72 características extraídas capturó información que el detector de energía ignora: la estructura espectral de la señal, su planitud, entropía y distribución de potencia en frecuencia. Esta información adicional permitió distinguir señales de ruido incluso cuando sus potencias fueron similares.

Tiempo de Inferencia Competitivo. Contrario a la expectativa inicial, el tiempo de inferencia de los modelos de aprendizaje automático fue comparable al del detector de energía. La extracción de características requirió menos de 1 ms, y la clasificación mediante el ensemble fue prácticamente instantánea una vez entrenado el modelo.

3.4.4 Limitaciones de las Técnicas de Aprendizaje Automático

El análisis también reveló limitaciones importantes:

Costo de Entrenamiento. Cada modelo requirió entre 180 y 380 segundos de entrenamiento, totalizando aproximadamente una hora para los 12 modelos. El detector de energía, en cambio, solo requirió calibrar un umbral. Esta diferencia resulta relevante para sistemas que deben adaptarse dinámicamente a nuevas condiciones.

Dependencia de Datos Etiquetados. El entrenamiento supervisado requirió ejemplos etiquetados de ambas hipótesis (\mathcal{H}_0 y \mathcal{H}_1). En aplicaciones donde no se dispone de esta información, las técnicas clásicas ofrecen una alternativa viable.

Caso Límite: OFDM en Canales Simples. Los modelos de aprendizaje automático mostraron rendimiento inferior al esperado para OFDM en canales estático y Rayleigh. Este caso límite se explica por la similitud espectral entre OFDM y ruido gaussiano, que dificulta la extracción de características discriminativas.

3.4.5 Fortalezas del Detector de Energía

El detector de energía, a pesar de su rendimiento inferior, presentó ventajas en ciertos contextos:

Tabla 3.20*Escenarios con rendimiento limitado*

Escenario	P_d ML	P_d ED	Mejora
OFDM + Estático	0,82	0,15	+67%
OFDM + Rayleigh	0,08	0,09	-1%

- **Simplicidad:** Solo requiere calcular la potencia media, sin necesidad de conocer la estructura de la señal.
- **Universalidad:** No requiere entrenamiento previo ni datos etiquetados.
- **Bajo costo computacional:** Complejidad $O(N)$ para N muestras.
- **Implementación en hardware:** Fácilmente realizable en FPGA o ASIC.

3.4.6 Limitaciones del Detector de Energía

Las limitaciones del detector de energía fueron fundamentales y derivaron de su principio de operación:

- **Sensibilidad al ruido:** En bajo SNR, la potencia de la señal se confunde con la del ruido.
- **Incertidumbre del piso de ruido:** Variaciones en el nivel de ruido afectan directamente el umbral de decisión.
- **Información desperdiciada:** Ignora toda la estructura espectral y temporal de la señal.

3.4.7 Matriz de Rendimiento

La Figura 3.14 presenta la matriz completa de rendimiento por escenario, permitiendo identificar visualmente los casos donde cada técnica fue más efectiva.

La Figura 3.15 presenta la comparación visual consolidada.

3.4.8 Recomendaciones de Uso

Basándose en los resultados, se pudieron establecer recomendaciones para la selección de técnicas:

3.4.9 Síntesis del Análisis

El análisis comparativo permitió responder a las preguntas planteadas al inicio de la investigación:

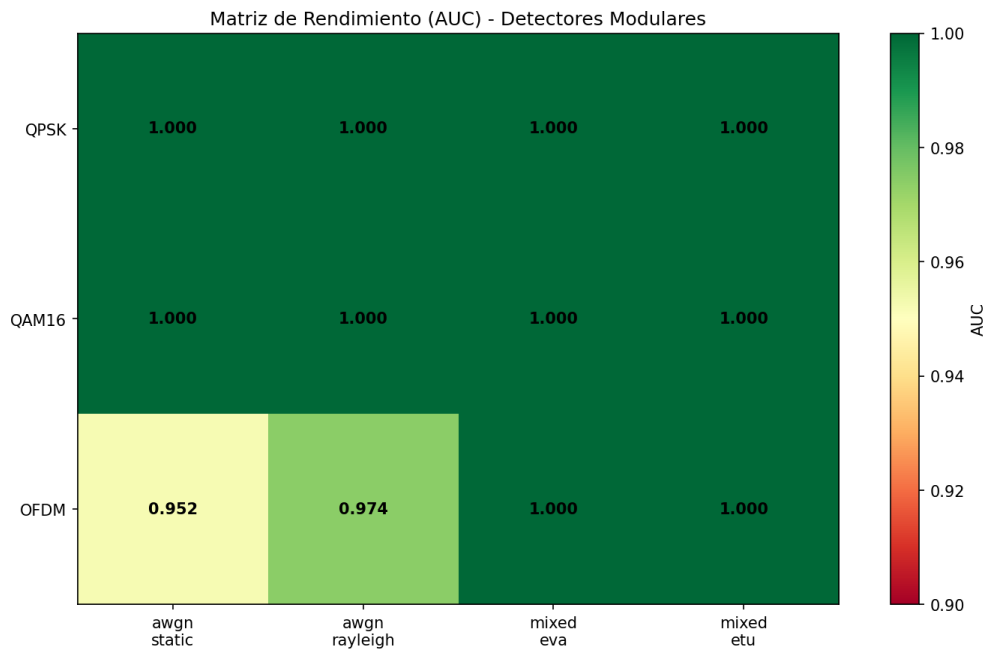


Figura 3.14

Matriz de rendimiento por escenario. Los colores indican el nivel de P_d alcanzado.

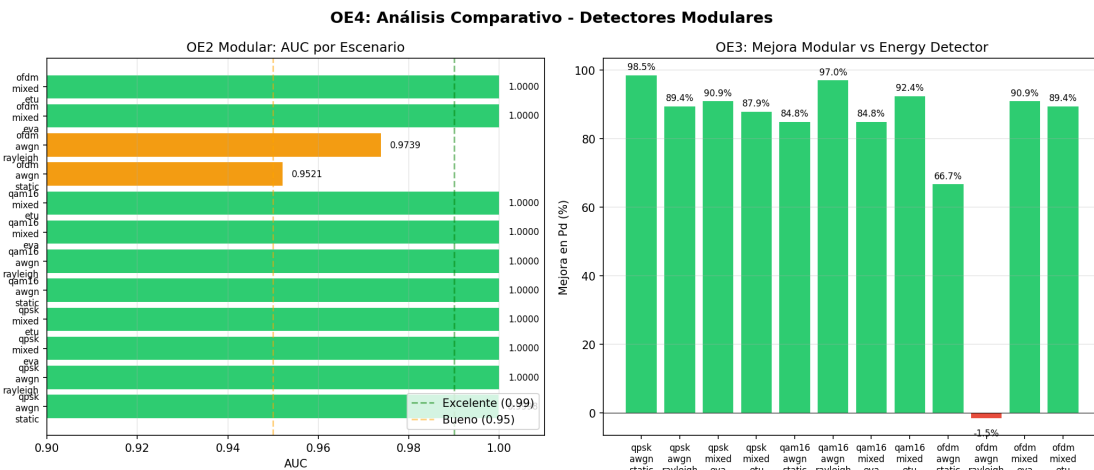


Figura 3.15

Comparación consolidada de detectores. La diferencia de rendimiento es consistente en la mayoría de escenarios.

Tabla 3.21

Recomendaciones según el escenario de aplicación

Condición	Técnica Recomendada
Bajo SNR (< -10 dB)	Aprendizaje automático
QPSK o QAM (cualquier canal)	Aprendizaje automático
OFDM + canal con desvanecimiento	Aprendizaje automático
OFDM + canal simple	Detector de energía o híbrido
Recursos limitados	Detector de energía
Sin datos de entrenamiento	Detector de energía
Alta precisión requerida	Aprendizaje automático

¿Las técnicas de aprendizaje automático superaron a las clásicas? Sí, con una mejora promedio de 80,9 puntos porcentuales en probabilidad de detección. Esta superioridad se mantuvo en 10 de 12 escenarios evaluados.

¿En qué condiciones fue más pronunciada la diferencia? La ventaja de las técnicas de aprendizaje automático fue máxima en bajo SNR (< -10 dB) y para modulaciones de portadora única (QPSK, 16-QAM). En estas condiciones, el detector de energía falló completamente mientras los modelos de aprendizaje automático mantuvieron detección perfecta.

¿Existieron casos donde las técnicas clásicas fueron preferibles? Sí, para OFDM en canales simples (estático, Rayleigh), el detector de energía mostró rendimiento comparable o superior. También resultó preferible cuando no se dispuso de datos de entrenamiento o los recursos computacionales fueron limitados.

¿Cuál fue el costo de la mejora? El entrenamiento de modelos requirió datos etiquetados y tiempo de cómputo (aproximadamente 1 hora para 12 modelos). Sin embargo, el tiempo de inferencia fue comparable entre ambos enfoques.

La investigación confirmó que las técnicas de detección basadas en aprendizaje automático representan un avance significativo para aplicaciones de detección espectral, especialmente en condiciones adversas donde los métodos clásicos resultan inadecuados. La especialización por escenario permitió adaptar la estrategia de detección a las características específicas de cada tipo de señal y canal, maximizando el rendimiento en cada caso.

CAPÍTULO 4 DISCUSIÓN

Los resultados obtenidos confirmaron la superioridad del ensemble híbrido (SVM-RBF, Random Forest y CNN 1D) sobre el detector de energía en la mayoría de escenarios evaluados. La mejora promedio de 80,9 puntos porcentuales en probabilidad de detección representa un avance significativo para aplicaciones de detección espectral en plataformas SDR.

Esta diferencia se explica por la naturaleza de la información explotada. El detector de energía considera únicamente la potencia de la señal, insuficiente para distinguir señal de ruido cuando ambas tienen magnitudes comparables. En bajo SNR, la potencia de la señal se confunde con las fluctuaciones del ruido, generando decisiones incorrectas. El ensemble, en cambio, aprovecha 72 características que capturan la estructura espectral completa: planitud, entropía, distribución de potencia en frecuencia y patrones temporales. SVM-RBF aporta fronteras de decisión no lineales, Random Forest ofrece robustez ante valores atípicos, y CNN 1D captura patrones secuenciales en la densidad espectral de potencia.

Sin embargo, la superioridad observada no es absoluta. El caso de OFDM en canales simples reveló una limitación fundamental: cuando el espectro de la señal es plano y similar al ruido gaussiano, no existen patrones distintivos que aprender. Ninguna técnica ofreció ventaja clara en estos escenarios. La efectividad del aprendizaje automático depende de la existencia de estructura explotable en la señal.

El costo computacional presentó un balance favorable. Aunque el entrenamiento requirió aproximadamente una hora para los doce modelos especializados, el tiempo de inferencia resultó comparable al del detector de energía. Una vez entrenados, los modelos operan en tiempo real sin penalización de latencia.

La especialización por escenario demostró ser efectiva. Adaptar cada modelo a las características de su combinación modulación-canal maximizó el rendimiento. Esta arquitectura modular permite seleccionar dinámicamente el detector apropiado según las condiciones detectadas. Los resultados validan el uso de ensembles híbridos para detección espectral en condiciones adversas, reconociendo que la elección óptima depende del escenario específico.

CONCLUSIONES

Se diseñó un entorno experimental de detección espectral basado en el radio definido por software Ettus USRP N210. La arquitectura modular implementada integra cinco componentes funcionales: generador de señales con modulaciones QPSK, 16-QAM y OFDM; modelos de canal que incluyen condiciones estáticas, desvanecimiento Rayleigh y perfiles vehiculares EVA y ETU con efecto Doppler hasta 120 km/h; generador de ruido gaussiano e impulsivo configurable en el rango de -25 a $+5$ dB de SNR; cuatro detectores clásicos operando en paralelo; y un módulo de fusión cooperativa con reglas OR, AND, mayoría, EGC y MRC para hasta cinco nodos. La validación mediante experimentos Monte Carlo confirmó que el entorno reproduce condiciones representativas de escenarios reales, estableciendo una base sólida para la evaluación comparativa de técnicas de detección.

Se implementaron algoritmos clásicos y de aprendizaje automático para la detección de espectro. Los detectores clásicos incluyen el detector de energía, el detector de eigenvalores, el detector cicloestacionario y el filtro adaptado, todos calibrados mediante el procedimiento CFAR para mantener una probabilidad de falsa alarma del 10%. El sistema de aprendizaje automático consiste en un ensemble híbrido que combina SVM con kernel RBF, Random Forest con 100 árboles y CNN 1D, operando sobre un vector de 72 características que integra información temporal, espectral y densidad espectral de potencia. Se desarrollaron doce modelos especializados correspondientes a las combinaciones de tres modulaciones y cuatro condiciones de canal, alcanzando un AUC promedio de 0,9938 y una probabilidad de detección promedio de 97,9% en la fase de entrenamiento.

La evaluación del desempeño reveló diferencias sustanciales entre los enfoques. El ensemble de aprendizaje automático alcanzó una probabilidad de detección promedio de 90,8%, mientras que el detector de energía logró apenas 9,8%, representando una mejora de 80,9 puntos porcentuales. Esta superioridad se manifestó de forma consistente en diez de los doce escenarios evaluados. Para modulaciones de portadora única como QPSK y 16-QAM, los modelos de aprendizaje automático mantuvieron detección perfecta incluso a -20 dB de SNR, donde el detector de energía falló completamente. La modulación OFDM en canales

con desvanecimiento selectivo también alcanzó detección perfecta. La probabilidad de falsa alarma se mantuvo controlada en niveles similares para ambos métodos, confirmando que la mejora en detección no se logró sacrificando especificidad. El tiempo de inferencia del ensemble resultó comparable al del detector de energía, demostrando viabilidad para operación en tiempo real.

El análisis comparativo identificó fortalezas y limitaciones claras de cada enfoque. Las técnicas de aprendizaje automático destacan por su robustez en bajo SNR, su capacidad de explotar información espectral que el detector de energía ignora, y su adaptabilidad mediante especialización por escenario. Sus limitaciones incluyen el costo de entrenamiento, la dependencia de datos etiquetados, y el rendimiento inferior en OFDM con canales simples donde el espectro de la señal es indistinguible del ruido gaussiano. El detector de energía ofrece simplicidad, universalidad y operación sin entrenamiento previo, pero presenta sensibilidad crítica al ruido y desperdicia información estructural de la señal. La cooperación multiusuario con regla MRC demostró el mejor balance entre probabilidad de detección y falsa alarma, validando su utilidad como estrategia complementaria.

El análisis comparativo del desempeño de técnicas de detección de espectro mediante radio definida por software confirma que las técnicas basadas en aprendizaje automático presentan un desempeño significativamente superior frente a las técnicas clásicas en la mayoría de condiciones evaluadas. La mejora de 80,9 puntos porcentuales en probabilidad de detección valida la hipótesis principal de la investigación, particularmente en escenarios de bajo SNR donde los métodos clásicos resultan inadecuados. El entorno experimental desarrollado, la arquitectura de ensemble híbrido y los doce modelos especializados constituyen una contribución tangible para futuras investigaciones en detección espectral. Los resultados demuestran que la elección del detector óptimo depende del escenario específico: el aprendizaje automático es preferible cuando se requiere alta probabilidad de detección en condiciones adversas y se dispone de datos de entrenamiento; el detector de energía sigue siendo válido para aplicaciones con recursos limitados o cuando no hay datos etiquetados disponibles; y la cooperación puede complementar cualquier enfoque cuando se dispone de múltiples nodos receptores.

Recomendaciones

La selección del detector debe considerar las condiciones específicas del escenario de aplicación. Para entornos con bajo SNR donde se requiere alta probabilidad de detección,

el ensemble híbrido de aprendizaje automático constituye la opción preferible, siempre que se disponga de datos etiquetados para el entrenamiento. En aplicaciones donde los recursos computacionales son limitados o no existen datos de entrenamiento disponibles, el detector de energía representa una alternativa válida para condiciones de SNR moderado a alto. Cuando se dispone de múltiples nodos receptores, la cooperación con regla MRC ofrece el mejor balance entre probabilidad de detección y falsa alarma, independientemente del tipo de detector individual utilizado.

La arquitectura de especialización por escenario demostró mayor efectividad que un modelo generalista. Se recomienda entrenar modelos específicos para cada combinación de modulación y condiciones de canal esperadas en el entorno de operación. Esta estrategia maximiza el rendimiento al permitir que cada modelo aprenda las características particulares de su escenario objetivo. El sistema puede implementar un selector automático que identifique las condiciones actuales y active el modelo correspondiente.

Para implementaciones en plataformas SDR, se recomienda utilizar conexión Gigabit Ethernet en lugar de USB para capturas prolongadas, ya que reduce la pérdida de muestras y permite mayor distancia entre el equipo de captura y el computador host. Los umbrales del detector de energía deben recalibrarse periódicamente para adaptarse a variaciones en el piso de ruido del entorno. Los modelos de aprendizaje automático pueden preentrenarse en modo offline y desplegarse como funciones de inferencia ligeras, evitando la necesidad de entrenamiento en tiempo real.

Limitaciones

Los resultados obtenidos corresponden a señales generadas sintéticamente mediante simulación. Aunque los modelos de señal y canal implementados son representativos de escenarios reales, no capturan completamente la variabilidad y complejidad de señales radiadas en entornos operativos. La validación con señales de usuarios primarios reales fortalecería las conclusiones y permitiría identificar factores no considerados en la simulación.

El rango de SNR evaluado abarcó desde -20 hasta $+5$ dB. Este rango resultó favorable para los modelos de aprendizaje automático, que mantuvieron detección perfecta en la mayoría de escenarios. Evaluaciones en rangos de SNR más bajos podrían revelar el punto de quiebre donde la diferencia entre técnicas se reduce o invierte, proporcionando información valiosa sobre los límites operativos de cada enfoque.

La modulación OFDM en canales simples constituyó un caso límite donde el aprendizaje

automático no ofreció ventaja significativa. El espectro plano de OFDM, similar al ruido gaussiano, dificulta la extracción de características discriminativas. Esta limitación indica que la efectividad del aprendizaje automático depende de la existencia de estructura explotable en la señal, condición que no siempre se cumple.

El entrenamiento de los doce modelos especializados requirió aproximadamente una hora de cómputo y datos etiquetados de ambas hipótesis. En aplicaciones donde las condiciones cambian dinámicamente o no se dispone de datos de entrenamiento, esta dependencia representa una barrera práctica. Los detectores clásicos, que no requieren entrenamiento, ofrecen mayor flexibilidad en estos contextos.

Trabajo Futuro

La extensión del rango de evaluación hacia SNR más bajos permitiría identificar el límite inferior de operación efectiva para cada técnica. Evaluaciones en -30 dB o inferior revelarían si la superioridad del aprendizaje automático se mantiene en condiciones extremas o si existe un punto donde ambos enfoques convergen hacia el desempeño aleatorio.

La evaluación de los modelos de aprendizaje automático bajo ruido no gaussiano constituye una línea de investigación pendiente. Determinar si el ensemble híbrido mantiene su robustez frente a ruido impulsivo y coloreado proporcionaría criterios adicionales para la selección de detectores según las características del entorno.

La implementación de técnicas de aprendizaje en línea permitiría que los modelos se adapten continuamente a condiciones cambiantes del canal sin requerir reentrenamiento completo. Esta capacidad resulta relevante para sistemas desplegados en entornos dinámicos donde las características del espectro varían con el tiempo.

La validación del sistema en entornos operativos reales con señales de estaciones base GSM, LTE o WiFi confirmaría la transferibilidad de los resultados de simulación. Esta validación podría realizarse utilizando las capacidades de captura del USRP N210 en bandas de interés como GSM-900, LTE-700 o ISM-2400.

La extensión hacia detección multibanda permitiría explorar múltiples bandas de frecuencia simultáneamente, aumentando la cobertura del sistema y habilitando estrategias de handoff espectral más sofisticadas. La integración con módulos de decisión de traspaso de canal evaluaría el desempeño completo de un sistema de detección espectral desde la identificación de banda hasta la selección de frecuencia.

BIBLIOGRAFÍA

- Babjan, P., & Rajendran, V. (2024). Experimental Evaluation of Spectrum Handoff Management with Machine Learning Algorithms Using Software Defined Radio. *Wireless Personal Communications*, 138(1), 149-170. <https://doi.org/10.1007/s11277-024-11476-7>
- Baker, D., Beal, A., Joiner, L., & Syed, T. (2023). A Low-Cost Modified Energy Detection-Based Spectrum Sensing Algorithm with GNU Radio for Cognitive Radio [Cited By :6], 2023-April, 833-837. <https://doi.org/10.1109/SoutheastCon51012.2023.10115163>
- Begum, A., Rani, M., Reddy, V., Reddy, B., & Papachari, B. (2025). Experimental Testing and Analysis of Regression Algorithms for Spectrum Sensing in Cognitive Radio Networks. *Wireless Networks*, 31(1), 247-260. <https://doi.org/10.1007/s11276-024-03750-0>
- Ben Thameur, H., & Dayoub, I., Senior. (2021). On Experimental Evaluation of Eigenvalue-based Spectrum Sensing Using a Real-time SDR Testbed [Cited By :4], 1982-1987. <https://doi.org/10.1109/IWCMC51323.2021.9498884>
- Benzater, H., Lassami, N., & Tegui, D. (2024). New Scheme of Cooperative Compressed Spectrum Sensing. *Physica Scripta*, 99(11). <https://doi.org/10.1088/1402-4896/ad87bf>
- Bouzegag, Y., Tegui, D., & Maali, A. (2023). Experimental SDR Implementation of Cooperative Spectrum Sensing in Cognitive Radio Networks [Cited By :2]. *Physica Scripta*, 98(1). <https://doi.org/10.1088/1402-4896/aca56d>
- Chavez Munoz, P., Manco-Vasquez, J., & Soto-Cordova, M. (2024). Experimental Evaluation of Multiantenna Spectrum Sensing: Unsupervised Learning Approach. <https://doi.org/10.1109/ANDESCON61840.2024.10755793>
- Falih, M., & Abdullah, H. (2022). A Spectrum Sensing Profile Based SDR for Cognitive Radio System: An Experimental Work. *Communications in Computer and Information Science*, 1548 CCIS, 282-295. https://doi.org/10.1007/978-3-030-97255-4_21

- Hammadi, Y., Alsaeedi, M., Mahmood, O., Sameen, A., Muthanna, M., & Aziz, A. (2023). Various Modulation Types Classification on the Air by Convolutional Neural Network, 779-786. <https://doi.org/10.1145/3644713.3644855>
- Huang, Y., Qiu, H., Zheng, L., & Yang, C. (2023). Rapid and Precise Spectrum Sensing Over Broad Spectral Range with Energy Detection Using Software-Defined Radio [Cited By :2], 1405-1409. <https://doi.org/10.1109/ICCT59356.2023.10419567>
- Kumar, A., Khan, A., Modanwal, N., & Saha, S. (2020). Experimental Studies on Energy and Eigenvalue Based Spectrum Sensing Algorithms Using USRP Devices in OFDM Systems [Cited By :10]. *Radio Science*, 55(8). <https://doi.org/10.1029/2019RS006973>
- Lin, J. F., Caushi, E., Dudko, A., Morehouse, T., Montes, C., Savage, E., & Zhou, R. (2024). Demonstration of FPGA-Accelerated ML-based Wideband Spectrum Awareness and Signal Characterization in Real-Time. *2024 IEEE International Conference on Machine Learning for Communication and Networking (ICMLCN)*, 1-2. <https://doi.org/10.1109/ICMLCN59089.2024.10624804>
- Lipski, M., Kompella, S., & Narayanan, R. (2021). Practical Implementation of Adaptive Threshold Energy Detection Using Software Defined Radio [Cited By :11]. *IEEE Transactions on Aerospace and Electronic Systems*, 57(2), 1227-1241. <https://doi.org/10.1109/TAES.2020.3040059>
- Manco, J., & Dayoub, I. (2024). Experimental Assessment of Spectrum Sensing under Time-Varying Channels for Cognitive Radio. *IEEE Sensors Letters*, 8(8). <https://doi.org/10.1109/LENS.2024.3432738>
- Martian, A., Lucian Chiper, F., Mohammed Khodayer Al-Dulaimi, O., Jalal Ahmad Al Sammarraie, M., Vladeanu, C., & Marghescu, I. (2020). Comparative Analysis of Software Defined Radio Platforms for Spectrum Sensing Applications [Cited By :5], 369-374. <https://doi.org/10.1109/COMM48946.2020.9142024>
- Martian, A., Vladeanu, C., & Marghescu, I. (2020). Novel Software Defined Radio Testbed for Spectrum Occupancy Measurements [Cited By :3]. <https://doi.org/10.1109/ISETC50328.2020.9301075>
- Molina-Tenorio, Y., Prieto-Guerrero, A., & Aguilar-Gonzalez, R. (2021). Real-Time Implementation of Multiband Spectrum Sensing Using Sdr Technology [Cited By :15]. *Sensors*, 21(10). <https://doi.org/10.3390/s21103506>

- Molina-Tenorio, Y., Prieto-Guerrero, A., Aguilar-Gonzalez, R., & Lopez-Benitez, M. (2023). Cooperative Multiband Spectrum Sensing Using Radio Environment Maps and Neural Networks [Cited By :5]. *Sensors*, 23(11). <https://doi.org/10.3390/s23115209>
- Pandey, M., Chauhan, A., Chowdhury, D., & DasMahapatra, S. (2023). Experimental Investigation on Spectrum Sensing Testbed Using GNU Radio and SDR. *Lecture Notes in Electrical Engineering*, 1046 LNEE, 303-308. https://doi.org/10.1007/978-981-99-2710-4_24
- Perez, J., & Ibañez, J. (2023). Method of Moments Estimation for Energy Spectrum Sensing [Cited By :1], 1440-1444. <https://doi.org/10.23919/EUSIPCO58844.2023.10289880>
- Poveda, H., Navarro, K., Merchan, F., Ramos, E., & González González, D. (2021). A Software Defined Radio-Based Prototype for Wireless Metrics Studies in IoT Applications [Cited By :3]. *Wireless Personal Communications*, 120(3), 2291-2306. <https://doi.org/10.1007/s11277-021-08281-x>
- Sabra, A., & Berbineau, M. (2022). Experimental Assessment of Eigenvalue-Based Spectrum Sensing Using USRP-Based MIMO Testbed for Cognitive Radio Applications [Cited By :8]. *IEEE Sensors Letters*, 6(10). <https://doi.org/10.1109/LSENS.2022.3212096>
- Sabra, A., & Berbineau, M. (2023). SDR-Implementation of a Support Vector Machine-Assisted Covariance-Based Spectrum Sensing Algorithm in the Presence of Correlated Noise [Cited By :7]. *IEEE Sensors Letters*, 7(6). <https://doi.org/10.1109/LSENS.2023.3275215>
- Sabrina, Z., Djamel, T., Camel, T., Ammar, M., Said, S., & Okba, N. (2023). SDR Implementation of Spectrum Sensing Using Deep Learning [Cited By :1]. *International Journal of Sensors, Wireless Communications and Control*, 13(4), 226-236. <https://doi.org/10.2174/2210327913666230719152400>
- Sabrina, Z., Camel, T., Djamel, T., Ammar, M., Said, S., & Belqassim, B. (2024). SDR Implementation of Wideband Spectrum Sensing Using Machine Learning. *International Journal of Communication Systems*, 37(16), e5907. <https://doi.org/10.1002/dac.5907>
- Slimeni, F., Delleji, T., Agrebi, A., Trabilsi, A., & Boulejfen, N. (2023). Real Time Implementation of SDR-based RF Source Detection and Localization in Restricted Area [Cited By :2]. *Telecommunication Systems*, 84(3), 399-408. <https://doi.org/10.1007/s11235-023-01055-9>

- Subedi, P., Shin, S., & Vuran, M. (2024). Seek and Classify: End-to-end Joint Spectrum Segmentation and Classification for Multi-signal Wideband Spectrum Sensing [Cited By :1]. <https://doi.org/10.1109/LCN60385.2024.10639826>
- Wu, P., Sun, B., Su, S., Wei, J., Zhao, J., & Wen, X. (2020). Automatic Modulation Classification Based on Deep Learning for Software-Defined Radio [Cited By :31]. *Mathematical Problems in Engineering*, 2020. <https://doi.org/10.1155/2020/2678310>