

# Detección de Anomalías: Una Solución Inteligente al problema de Detección de Espectro en Redes de Radio Cognoscitivo

## Anomaly Detection: An Intelligent Solution to Spectrum Sensing Problem for Cognitive Radio Networks

Ángel G. Andrade, Guillermo Galaviz, Mauricio Pablos y Enrique R. Bastidas-Puga

Facultad de Ingeniería, Universidad Autónoma de Baja California,

Bldv. Benito Juárez s/n, 21280 Mexicali, BC, México

{*aandrade, ggalaviz, cpablos, ebastidas*}@uabc.edu.mx

<https://ror.org/05xwcq167>

**Resumen.-** La gestión del espectro radioeléctrico será relevante para las futuras redes móviles. Si bien el avance en la habilitación del acceso dinámico al espectro promueve una mayor compartición del espectro, la detección confiable de espectro disponible para entornos de baja relación señal-ruido (SNR) sigue siendo un desafío de la Radio Cognoscitiva. Dado que la inteligencia artificial puede proporcionar conciencia y razonamiento a las redes inalámbricas, en este trabajo se propone un detector de espectro a partir de la teoría de detección de anomalías. El detector de espectro propuesto se construye con un Autoencoder Convolutivo y se entrena con las características extraídas de una señal de ruido. Los análisis numéricos de las señales del mundo real muestran que el rendimiento de detección del esquema propuesto mejora en un régimen SNR bajo y supera el desempeño de la detección de energía convencional.

**Abstract.-** Spectrum management is an important issue in future mobile networks. While the progress in enabling dynamic spectrum access shows promise in advancing increased spectrum sharing, the issue of reliable spectrum sensing under a low signal-to-noise ratio (SNR) remains one of the key challenges faced by Cognitive Radio. As artificial intelligence can provide wireless network intelligence through learning, anomaly detection-based spectrum sensing is proposed to improve spectrum sensing performance. A Convolutional Autoencoder-based detection framework is built to extract features in a data-driven way based on noise-signal samples. Numerical analyses of real-world signals show that the detection performance of the proposed scheme is improved under a low SNR regime and outperforms conventional Energy Detection.

**Keywords:** Detección de espectro, Radio Cognoscitiva, Detección de anomalías, Autoencoder convolutivo, Inteligencia Artificial.

### 1. Introducción

Los primeros sistemas móviles celulares (llamados de primera generación-1G) se lanzaron comercialmente en la ciudad de Chicago a mediados de los 80s. Estos permitieron realizar llamadas telefónicas específicamente a personas y no a lugares fijos, ya que estaban limitadas por

la infraestructura de la Red Telefónica Pública de aquella época. La evolución de las redes móviles celulares ha contribuido no solo a comunicar voz y datos entre personas, sino también a que una clase de dispositivos inteligentes también se comuniquen entre sí, incluso, hoy en día, a la comunicación entre humanos y máquinas. Estas maneras de comunicación habilitarán nuevas aplicaciones y servicios que requerirán un uso intensivo de datos; la experiencia sensorial como la realidad virtual y aumentada, las comunicaciones holográficas de alta fidelidad, la comunicación autónoma entre vehículos (V2V), el Internet de los drones (IoD: *Internet of Drones*) o de todas las cosas (IoE: *Internet of Everything*), la réplica digital (*twin digital*) y las redes integradas marinas-espaciales-terrestres (UTASNet: *Undewater-Terrestrial-Air Space-integrated Networks*), son algunos ejemplos que los futuros usuarios de las redes móviles celulares tendrán a su disposición (Rasti, 2022), (Cui, 2022).

Se estima que para el año 2030, el tráfico de datos inalámbricos alcanzará los 5000 Exabytes y la cantidad de dispositivos conectados podría superar los 50 mil millones (Nguyen, 2022). Aun cuando el desarrollo de los sistemas móviles de quinta generación (5G) progresan hacia un estándar global, por sí solo, no proporcionará el ecosistema conveniente para favorecer las exigencias de aquellas aplicaciones que dependen de una gran cantidad de datos generados a partir de un número masivo de dispositivos interconectados. A pesar de los avances de la 5G, la infraestructura inteligente en evolución y las aplicaciones inalámbricas diversificadas hacen que el lanzamiento de sistemas móviles más allá de la 5G (B5G), como la sexta generación (6G), sea inevitable. A diferencia de la 5G, las redes 6G se conciben como sistemas multibanda, descentralizados, totalmente autónomos e hiperflexibles centrados en el usuario (Yrjölä, 2022). Se espera que los sistemas 6G amplíen las capacidades actuales de los sistemas 5G, y que sean capaces de operar sin problema a velocidades en el orden de terabits por segundo, con movilidad

de hasta 500 km/h, en entornos con densidades mayores de 1000 dispositivos/km<sup>2</sup> y latencias menores a 1 milisegundo. El mayor desafío que enfrentarán estos nuevos sistemas móviles, y del que se ha hablado durante los últimos 20 años, será el déficit de espectro radioeléctrico debido a la proliferación de dispositivos y tecnologías inalámbricas. En este sentido, se menciona que los sistemas 6G operarán en un enfoque híbrido de frecuencias de transmisión en el que se incluyen frecuencias de radiofrecuencia (RF) y la banda de los Terahertz (0.1 a 10 THz), onda milimétrica y la banda de la luz visible (400 a 800 THz). Esta coexistencia de múltiples frecuencias permitirá que las radiobases puedan potencialmente transmitir y recibir en diferentes bandas de frecuencia al mismo tiempo. Sus principales desafíos serán optimizar el lugar de despliegue de las radiobases, integrar mecanismos de activación de red conscientes de la carga de tráfico, gestión de recursos consciente de la movilidad, y la selección de espectro oportunista por el lado de los usuarios (Chen, 2020).

A corto plazo, radiobases y dispositivos móviles no estarán habilitados con la tecnología apropiada para operar en un esquema de compartición de diversas y múltiples bandas de frecuencia. Aunque también, es un hecho que las bandas de frecuencias útiles asignadas a las redes móviles celulares no son, ni serán suficientes, para atender las demandas de tasa de datos y ancho de banda de las nuevas aplicaciones. Mientras se llevan a cabo estrategias de planeación y reorganización de bandas de frecuencias para el desarrollo de las redes 6G (Matinmikko-Blue, 2020), la Radio Cognoscitiva (RC) es considerada, desde hace más de dos décadas, como una propuesta tecnológica para atender el problema de subutilización del espectro, incrementar la capacidad de las redes y mejorar las condiciones de los enlaces de comunicación (Lundén, 2015). No hay duda de que la RC será considerada como una de las tecnologías habilitadoras en los sistemas 6G para el uso híbrido de frecuencias de transmisión.

La RC basa su funcionamiento en tres atributos principales; observación, reconfiguración, y razonamiento (cognición). La RC incorpora un elemento conocido como motor cognitivo, el cual es un agente “inteligente” que se encarga de comprender todo el entorno de propagación (conciencia), encontrar una acción adecuada para cumplir con un requisito de calidad de servicio (razonamiento) y conocer el impacto de estas acciones en el rendimiento de la red (aprendizaje). Este motor cognitivo interactúa con el transceptor de radio (reconfigurable e implementado con radio definido por software), y ante la observación de su entorno, analiza y clasifica la situación, determina la respuesta adecuada al estímulo y lleva a cabo la decisión (reconfiguración). Como ejemplo, esta respuesta puede ser la adaptación de parámetros de radio como el esquema de codificación del canal, el esquema de modulación o la frecuencia de operación. En otras palabras, la conciencia, el razonamiento y el aprendizaje en un RC interactúan y se influyen mutuamente. Entre estos tres, la conciencia es el punto de partida de un proceso de RC y es la base del aprendizaje y el razonamiento (He, 2010).

La RC, concebida como una estrategia apropiada para eficientizar el uso del espectro a partir de su compartición requiere, como primera etapa de su conciencia, identificar aquellas bandas de frecuencia que se encuentran libres, para que posteriormente puedan utilizarse oportunamente. Cualquier técnica de Detección de Espectro puede explotar cualquier canal de comunicación desocupado de cualquier banda de frecuencia siempre y cuando no genere interferencia dañina (Gupta, 2019).

Recientemente, diversas técnicas de Inteligencia Artificial (IA) se han utilizado para resolver diversos problemas identificados en los sistemas B5G, por ejemplo, codificación de canal, detección de símbolo, optimización de energía, estimación de canal, entre otros (Shafin, 2020). Recientemente, el problema de detección de espectro se ha modelado como un problema de

clasificación y se han aplicado técnicas de IA para resolverlo, algunas para inferir uno de dos posibles resultados, ocupado o libre (Liu, 2019), (Liu, 2021), (Yadav, 2022), mientras que otras, además de resolver sobre la ocupación del canal también, para determinar el tipo de señal de comunicación que lo ocupa (Zheng, 2020), (Patel, 2020), (La Rosa Centeno, 2018).

En este trabajo se presenta un novedoso esquema de Detección de Espectro modelado a partir de la teoría de detección de anomalías (Pimentel, 2014), (Zhou, 2021), (Pang, 2022). La detección de anomalías es un método no supervisado, lo que significa que no requiere un conjunto de datos de entrenamiento que contenga casos conocidos para utilizarlos como punto de partida, tal y como sucede en los trabajos antes mencionados (Liu, 2019), (Liu, 2021), (Yadav, 2022), (Zheng, 2020), (Patel, 2020) y (La Rosa Centeno, 2018).

Para este modelo, implementamos un Autoencoder Convolutivo (CAE) (Ribeiro, 2018), el cual está formado por redes neuronales artificiales que aprenden primero las representaciones de muestras de señales de ruido, y luego las genera a partir de las representaciones codificadas aprendidas. Por lo que cualquier señal de información (distinta a la señal de ruido) que se observe en el canal inalámbrico se considerará como un valor atípico, resolviéndose el dilema de la detección de espectro como un canal ocupado. Los resultados experimentales demuestran que esta propuesta de detección de espectro basada en la detección de anomalías puede identificar la presencia de señales de información con mayor precisión (alta detección y baja tasa de falsas alarmas) que la detección convencional de espectro basada en la energía (Umar, 2014).

## **2. Radio Cognoscitiva y el proceso de detección de espectro**

El espectro radioeléctrico es un recurso natural, limitado, de dominio público, que sirve como medio de comunicación para el intercambio de información entre una red de telecomunicaciones y el usuario. El espectro radioeléctrico se divide en porciones (llamadas bandas de frecuencias), y se asignan una o más a cada sistema de radiocomunicación (televisión, radio, celular, o satélite). Para evitar algún tipo de interferencia, ningún sistema de telecomunicaciones puede utilizar la porción de espectro asignada a otro sistema. Las redes móviles celulares requieren bandas de frecuencia que cuenten con características adecuadas para la propagación de señales. Por lo que no cualquier porción del espectro radioeléctrico es apta para este servicio.

La mayor parte del espectro útil se encuentra asignado a algún servicio de telecomunicaciones, sin embargo, estudios recientes indican que la mayor parte del tiempo son subutilizado (Fernando, 2022), (Zhu, 2022), (Shen, 2022), (Liu, 2021). Los periodos de tiempo en los que no se utilizan las bandas de frecuencia se conocen como “huecos espectrales” (ver Figura 1). Las redes de Radio Cognoscitiva aprovechan oportunamente estos huecos espectrales para incrementar el espectro radioeléctrico de las redes móviles celulares. La detección de espectro o identificación de dichos huecos espectrales es el proceso que habilita la compartición de espectro. Compartir espectro se refiere a que un usuario de un sistema celular pueda utilizar bandas de frecuencias de otro sistema de comunicaciones, siempre y cuando no interrumpa la transmisión de algún usuario o cause interferencias perjudiciales. Básicamente, la detección de espectro le permite a un dispositivo móvil con capacidades de RC identificar oportunamente bandas de frecuencias disponibles, desocupar la banda de frecuencias en caso de que las condiciones lo requieran y buscar inmediatamente otro canal para continuar con su transmisión de datos.

Los algoritmos convencionales de detección de espectro requieren de cierta información característica de la señal a detectar, denominado estadístico de prueba  $\beta$ . Este estadístico de prueba, que pueden ser la energía, potencia, cicloestacionariedad o entropía de la señal, se calculan a partir del conjunto de muestras  $\mathbf{x}(\mathbf{n})$  recolectadas por el receptor. El detector de espectro decide con cierto nivel de confiabilidad, si en un periodo de detección la información obtenida corresponde a la presencia de una señal de información (hipótesis  $H_1$ ) o a un hueco espectral (hipótesis  $H_0$ ). El problema de detección de espectro se modela como un problema de hipótesis binaria definido por la ecuación (1), donde,  $\sigma(\mathbf{n})$  representa una señal de ruido o hueco espectral, mientras que  $\mathbf{h}(\mathbf{n})$  es la ganancia del canal por el que se transmite la señal de información  $\mathbf{s}(\mathbf{n})$ . El ruido es otra señal pero que no contiene información (similar a ver un canal de televisión sin sintonizar).

$$\mathbf{x}(\mathbf{n}) = \begin{cases} \sigma(\mathbf{n}), & H_0 \\ \mathbf{h}(\mathbf{n})\mathbf{s}(\mathbf{n}) + \sigma(\mathbf{n}), & H_1 \end{cases} \quad (1)$$

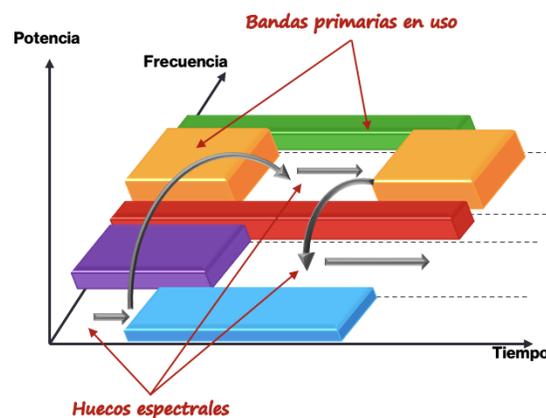


Figura 1. Características de la utilización de un canal de comunicaciones.

Además del estadístico de prueba  $\beta$ , el detector de espectro también necesita de un umbral de

detección  $\gamma$  que utiliza como referencia para decidir sobre el estado del canal (Peng, 2020).

Si el valor de  $\beta$  (por ejemplo, la energía de la señal de información) es mayor a  $\gamma$  (considerado como la energía de una señal de ruido), entonces se cumple la hipótesis  $H_1$ , lo que significa que el canal está ocupado, pero si sucede lo contrario, se decide por  $H_0$ , y la banda de frecuencia se considera un hueco espectral, como se establece en la ecuación (2).

$$\begin{array}{c} H_1 \\ \beta \geq \gamma \\ H_0 \end{array} \quad (2)$$

Parece obvio suponer que la energía de la señal de información siempre será mayor a la energía de la señal de ruido, sin embargo, esto no siempre es así, lo que puede confundir al detector de espectro. Equivocarse en la decisión, esto es, si el detector de espectro decide que el canal está libre cuando en realidad está ocupado, generará interferencia perjudicial al usuario que lo está utilizando. En caso contrario, si decide que el canal está ocupado cuando en realidad está disponible, entonces se desaprovechará el hueco espectral.

### 3. Aplicación de técnicas de IA al proceso de detección de espectro

El rendimiento que ofrecen las técnicas de detección de espectro convencionales (no-basadas en IA) es afectado por los efectos de propagación de las señales. Por ejemplo, las señales de información se atenúan o pierden energía mientras viajan por el aire. Entre mayor sea la distancia que recorre la señal, mayor será la atenuación que padezca. Esta atenuación puede ser de tal magnitud, que, al momento de que el detector calcule su energía, ésta puede ser tan baja que la podría confundir con una señal de ruido. Para contrarrestar este efecto de enmascaramiento de la señal de información, recientemente se ha modelado el problema de detección de espectro como un problema de clasificación binario o multi-clase (Zheng, 2020), (Gupta, 2019). Si es binario, las técnicas de Inteligencia Artificial (IA) determinan si el canal está ocupado o libre a partir de

muestras de la señal que el detector observa en el canal de comunicación. Si se modela como multi-clase, además, infieren el tipo de señal que está ocupando el canal.

Básicamente, el proceso para generar un modelo de detección de espectro basado en IA se muestra en la Figura 2. Esta estrategia consiste en entrenar alguna técnica de Aprendizaje Profundo (i.e., Redes Neuronales o alguna de sus variantes) con dos tipos de conjuntos de muestras de datos debidamente etiquetadas. Un conjunto contiene una vasta y diversa cantidad de muestras de señales de información, las cuales representan a los distintos tipos de señales que utilizan las distintas tecnologías de redes inalámbricas. El otro conjunto de datos contiene solo muestras de una señal de ruido. El algoritmo de IA se entrena con las características más representativas de estos dos conjuntos de datos y, aprende a distinguir entre una señal de información y una de ruido. Clasificar una muestra como señal de información representa un canal ocupado, el cual no se puede utilizar. Mientras que clasificar una muestra como señal de ruido, significa que se identificó un hueco espectral (un canal disponible para utilizarse).

Esta forma de crear un modelo de detección de espectro pertenece a la categoría de aprendizaje supervisado. El “buen” desempeño de estos métodos depende de la disponibilidad de datos y que estos representen todas las posibles condiciones a las que se expone una señal de información cuando se transmite por el aire, lo cual sería difícil de conseguir. Además, propicia que el entrenamiento se vuelva exhaustivo para cualquier algoritmo de clasificación.

Estos inconvenientes nos motivaron a adoptar un enfoque en el que se utilicen métodos de IA no-supervisados. La idea que aquí se presenta es modelar el problema de detección de espectro

como un problema de detección de anomalías. En este caso, el detector de espectro se modela como un clasificador de una sola clase. Este tipo de clasificador se entrena solamente con un conjunto de datos de un único tipo de muestras, denominada como la *clase normal*. Cualquier otro dato que se identifique durante la evaluación diferente a los ya conocidos de la *clase normal*, será clasificado como una *clase anómala*.

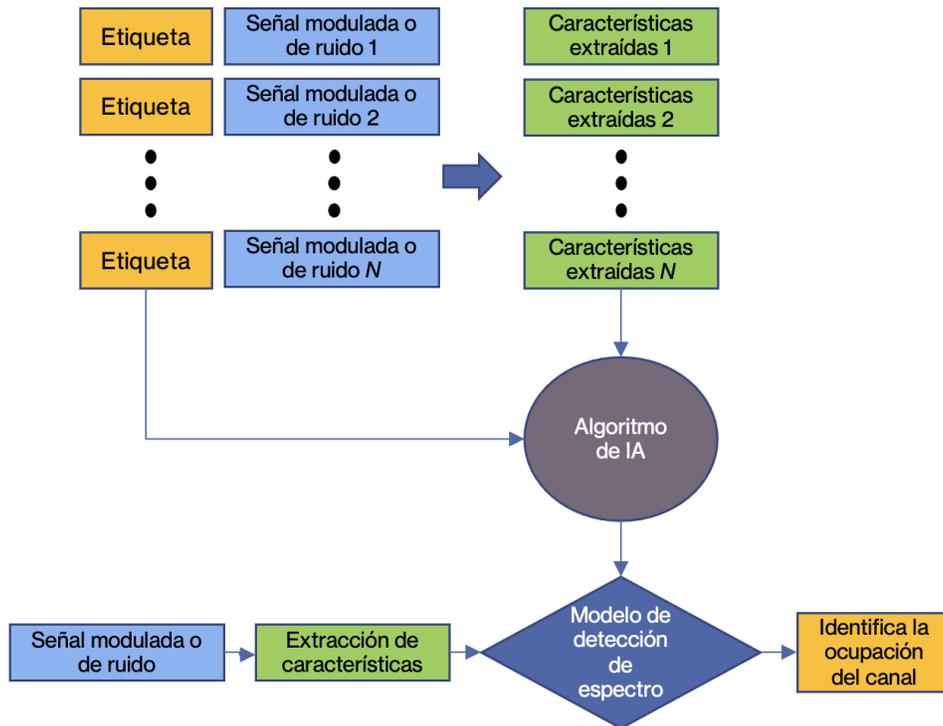


Figura 2. Generación de un detector de espectro modelado como un clasificador inteligente.

#### 4. Estructura del Detector de Anomalías como estrategia para la detección de espectro

La detección de anomalías es una técnica que permite reconocer patrones en un conjunto de datos que no se comportan de la manera esperada (Xie, 2019). Sus aplicaciones se enfocan principalmente en las áreas, por mencionar algunas, médica, informática, o bursátil. Recientemente, se han implementado detectores de anomalías con base en técnicas no-

supervisadas para resolver el problema de detección de espectro en redes de Radio Cognoscitiva (Rajendan, 2019). Nuestra propuesta consiste en implementar un Autoencoder Convolutivo (CAE) para detectar las anomalías. Un CAE está formado por redes neuronales artificiales, entrenadas de manera no supervisada, que tienen como objetivo aprender primero las representaciones codificadas de los datos (esto es, se reducen o comprimen los datos de entrada) y luego generar los datos de entrada (lo más cerca posible) a partir de las representaciones codificadas aprendidas. Básicamente, el CAE reconstruye a la salida una aproximación  $\hat{\mathbf{X}}_i$  de la señal entrada  $\mathbf{X}_i$  extrayendo las características más dominantes  $\mathbf{Z} \in \mathbb{R}^{d'}$  (que pueden ser entropía o correlación) de las muestras de la señal de entrada. La idea es que el CAE no solo copie y pegue las muestras de entrada para producir la salida, sino que a partir de un conjunto de restricciones lo obliguen a aprender nuevas formas de representar los datos, diferentes de simplemente copiar la salida.

La estructura del CAE que se utilizó en este trabajo, está formado por un codificador y un decodificador, cada uno con una estructura básica de neuronas, capas y conexiones entre neuronas, como se muestra en la Figura 3. La estructura del codificador es una red secuencial con tres capas convolucionales, una función de activación y una capa de normalización. Mientras que el decodificador tiene la misma estructura que el codificador, solo que en proceso inverso.

Los datos de entrada  $\mathbf{X} \in \mathbb{R}^d$  se comprimen en un nuevo conjunto de datos  $\mathbf{Z} \in \mathbb{R}^{d'}$ , los datos de entrada se multiplican por un peso  $\boldsymbol{\theta}_k$  y se le suma un sesgo o bias  $\mathbf{b}_k$  como se muestra en la ecuación (3). La salida  $\hat{\mathbf{X}}_i$  es el resultado de pasar  $\mathbf{Z}$  por una función de activación  $\boldsymbol{\rho}$ , que en el caso más simple suele ser una función escalón o función signo.

$$\mathbf{f}_{\boldsymbol{\theta}}(\mathbf{X}) = \mathbf{Z}_k = \boldsymbol{\rho}(\mathbf{X} * \boldsymbol{\theta}_k + \mathbf{b}_k) \quad (3)$$

El proceso de aprendizaje para estas redes neuronales requiere de varias iteraciones en las que se actualizan los pesos y los sesgos, de forma que se reduzca el error de reconstrucción entre los datos de entrada  $\mathbf{X}_i$  y la salida reconstruida  $\widehat{\mathbf{X}}_i$ , minimizando la función de costo. El método de la retropropagación (backpropagation) es uno de los más utilizados y se aplica a las redes neuronales del tipo *feedforward*, es decir, que tienen una arquitectura en la que las conexiones entre las neuronas no forman bucles (este es el modelo más simple). Este procedimiento aplica el método de descenso de gradiente, es decir, emplear la regla de la cadena para distribuir el error a la salida de la red entre los diferentes parámetros de esta. Un hiperparámetro importante de la retropropagación es la tasa de aprendizaje (learning rate), que controla la velocidad de aprendizaje de la red neuronal. Si es muy alto, los valores de los parámetros dan grandes saltos (alta probabilidad de saltarse la solución óptima), mientras que si es bajo los valores evolucionan muy lentamente (se tarda mucho en alcanzar la solución y se puede quedar en mínimos locales). La función de costo a minimizar durante este proceso de aprendizaje es el error cuadrático medio (MSE),  $\min_{\theta, \psi} \varepsilon(\mathbf{X}_i, \widehat{\mathbf{X}}_i)$  donde

$$\varepsilon = \sum_i (\mathbf{X}_i - \widehat{\mathbf{X}}_i)^2 \quad (4)$$

El modelo del detector de espectro se genera a partir de entrenar el CAE utilizando solo muestras de una señal de ruido (*clase normal*), las cuales representan la inactividad en el canal de comunicación. Durante su entrenamiento, el CAE recibe una muestra compuesta de 1024 diferentes valores de amplitud de una señal de ruido, como se observa en la Figura 3. El codificador comprime la muestra de la señal de ruido para extraer sus características más representativas. El decodificador aprende a reconstruir la muestra de la señal de ruido original  $\widehat{\mathbf{X}}_i$  a partir de las características que le proporcionó el codificador. Este proceso de entrenamiento se repite hasta que

el CAE reconstruye la señal de ruido original  $\mathbf{x}_i$  con un mínimo error de reconstrucción  $\beta$ . En este caso el error de reconstrucción es utilizado como el estadístico de prueba del detector de anomalías y se calcula a partir de la ecuación (5),

$$\beta = 1 - \frac{\sum_i (\mathbf{x}_i - \hat{\mathbf{x}}_i)^2}{\sum_i (\mathbf{x}_i - \bar{\mathbf{x}})^2} \quad (5)$$

donde  $\bar{\mathbf{x}}$  es la media de las amplitudes de los datos de la señal original  $\mathbf{x}_i$  y  $\hat{\mathbf{x}}_i$  es la señal reconstruida.

El umbral de decisión  $\gamma$  se calcula para discriminar entre los datos normales y atípicos. Convencionalmente,  $\gamma$  se modela en función de la probabilidad de falsas alarmas ( $P_{fA}$ ). La  $P_{fA}$  se refiere a la probabilidad de clasificar incorrectamente un canal vacante como uno ocupado. Lo deseable es que el detector de espectro nunca cometa este error. El valor  $P_{fA}$  se calcula como la función  $Q$  del conjunto de errores de reconstrucción  $\epsilon_i$  obtenidos por el CAE utilizando solo muestras de señal de ruido ( $H_0$ ). La  $P_{fA}$  es el complemento de la función de distribución acumulativa  $F(\epsilon)$  de los errores de reconstrucción  $\epsilon_i$ , como se muestra en la ecuación (6),

$$P_{fA} = 1 - F(\epsilon) = Q\left(\frac{\gamma - \bar{\epsilon}}{\sigma_\epsilon}\right) \quad (6)$$

donde  $\bar{\epsilon}$  y  $\sigma_\epsilon$  corresponden a las media y desviación estándar de  $\epsilon_i$ , el valor de  $\gamma$  se puede calcular a partir de la función Q-inversa de la siguiente manera;

$$\gamma = Q^{-1}(P_{fA}) \quad (7)$$

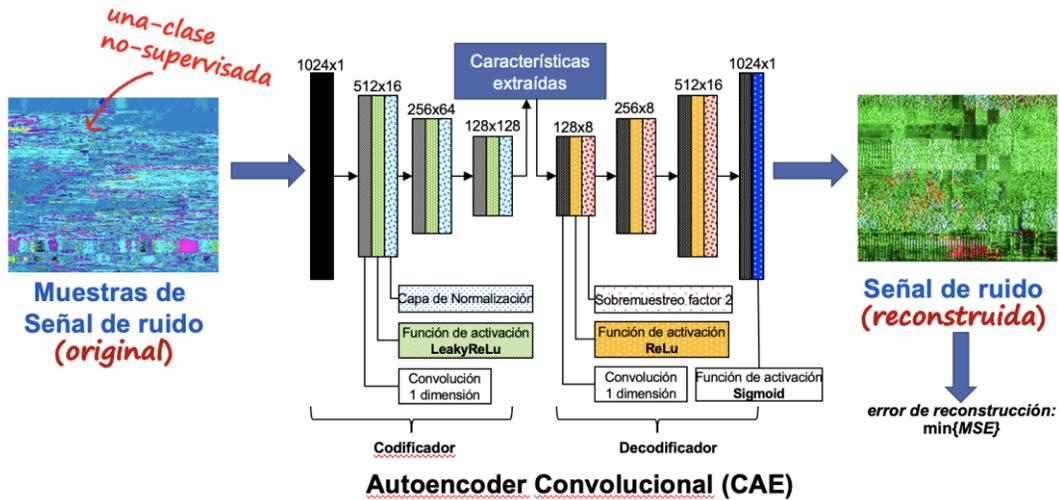


Figura 3. Procedimiento de entrenamiento del CAE.

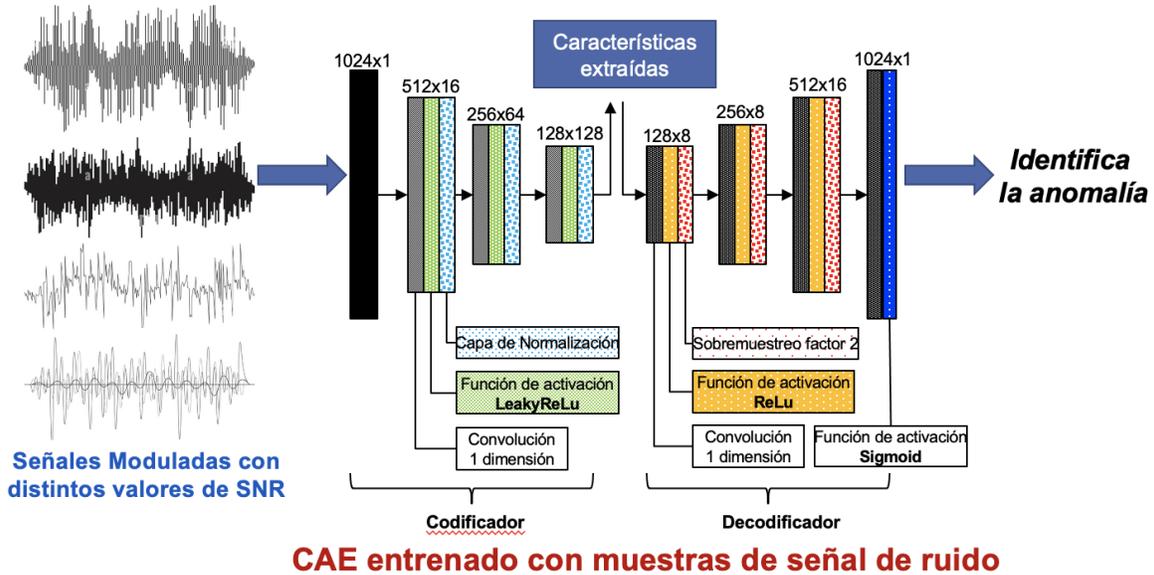


Figura 4. Procedimiento de evaluación del CAE ya entrenado para la detección de anomalías.

## 5. Evaluación del Detector de Espectro modelado como un detector de anomalías

El desempeño de cualquier detector de espectro se evalúa a partir de su Probabilidad de detección ( $P_D$ ), esto es, la probabilidad de decidir que un canal de comunicación se encuentra

ocupado, cuando en realidad lo está y, por la Probabilidad de Falsa Alarma ( $P_{fA}$ ), que se refiere a la probabilidad de decidir sobre la presencia de una señal de información, cuando en realidad no existe alguna. Cuando la  $P_D$  es máxima, existe un nivel alto de protección hacia las transmisiones de los usuarios que ocupan un canal de comunicación. Por otro lado, cuando la  $P_{fA}$  es mínima, el algoritmo de detección es capaz de identificar confiablemente todos los huecos espectrales. En este sentido, incrementar la  $P_D$  mientras la  $P_{fA}$  se mantiene al mínimo es el reto y compromiso de cualquier detector de espectro.

Para todas las muestras capturadas, las tasas de muestra y símbolo son de 1 MHz y 100 kHz, respectivamente, con un nivel de ruido fijo de -50 dBm. La frecuencia central de las señales moduladas es de 50 MHz y se capturaron mediante un dongle USB Nooelec con un sintonizador IC R820T. Se utilizó GNU radio para el procesamiento de señales. El detector de espectro basado en CAE se entrenó en un kit de desarrollo Jetson AGX Xavier y se evaluó en una CPU Intel I7-3520M de 2.9 GHz. Durante las evaluaciones se asumió que el receptor cognitivo cuenta con  $N=1024$  muestras en cada período de detección y la frecuencia de muestreo es de 500 kHz. En este caso, la duración de un período de detección es de 0.036 segundos. La red CAE profunda se entrena con un enfoque no supervisado y los datos de anomalías (señales moduladas) no se utilizan en la etapa de entrenamiento.

En total, se utilizaron 500,242 muestras de una señal de ruido, generadas con un generador vectorial de señales (modelo SMU200A) de manera sintética. Este conjunto de datos se dividió en dos subconjuntos, uno para utilizarse durante el entrenamiento (450,220 muestras) y el otro (50,022 muestras) para validar el entrenamiento. Al finalizar el entrenamiento, el error de reconstrucción obtenido fue de 0.00099.

Para evaluar el CAE entrenado, se construyeron tres nuevos conjuntos de datos, cada uno con

1000 muestras de un tipo de señal de información, QPSK, 16-QAM, 32-QAM, respectivamente. Cada señal de información representa a un tipo de red inalámbrica (pueden ser celular, Wi-Fi o HDTV). Una señal de ruido gaussiano se agregó a cada conjunto de muestras hasta lograr un nivel de Relación Señal a Ruido (SNR) específico. Los niveles de energía (o calidad) de la señal medido en términos del SNR varían de entre 0 (valor de calidad alto) y -15 (valor de calidad bajo) decibeles (dB). Estos valores de calidad representan la pérdida de energía (nivel de atenuación) que padece la señal de información debido a su propagación inalámbrica.

En la Figura 4 se muestra el proceso utilizado para evaluar el detector de espectro como un detector de anomalías. Se ingresan al CAE (ya entrenado como un detector de espectro) los conjuntos de datos que contienen las señales de información. El detector estima el error de reconstrucción de cada muestra a la salida del decodificador. Si el valor del error de reconstrucción estimado es menor a un umbral de detección pre-definido  $\gamma$ , entonces el detector clasifica dicha muestra como una señal de ruido. Por el contrario, si el valor del error reconstrucción obtenido es mayor  $\gamma$ , entonces el detector de espectro identifica la muestra como una *anomalía* o señal de información. El umbral de detección  $\gamma$  es el valor que utiliza el detector de espectro como referencia para decidir si lo que está observando es una señal de información o un hueco espectral. Para estimar  $\gamma$  se establece un valor de  $P_{fA}$  deseable igual a 0.1 y se sustituye en las ecuaciones (6) y (7). Clasificar una muestra como señal de ruido significa, desde el punto de vista de la Radio Cognoscitiva, que el canal esta libre, y clasificarla como una anomalía, representa que el canal está ocupado.

Las cuatro curvas ROC (Características de Operación del Receptor) que se muestran en la Figura 5, determinan el compromiso entre la  $P_D$  y la  $P_{fA}$  para la señal de información QPSK para

diferentes valores de SNR. Cada punto que se observa en cada curva ROC es el resultado de la  $P_D$  obtenida para un específico valor de umbral de detección  $\gamma$ . Cada valor de  $\gamma$  representa la  $P_{fA}$  esperada en el desempeño del detector. Por cada conjunto de datos se evaluaron cien diferentes valores de  $\gamma$  (de 0.01 a 1). Se puede observar en la Figura 5 que conforme aumenta el valor SNR de la señal de información (esto es, incrementa su calidad), también aumenta la sensibilidad del detector para detectar su presencia (aumenta su  $P_D$ ). Este desempeño del detector también se presenta cuando se evalúan los otros dos conjuntos de datos correspondientes a las señales 16-QAM y 32-QAM. Por otro lado, cuando las señales de información son de baja calidad, por ejemplo, SNR=-12 dB, el detector de espectro tiende a confundir la señal de información con una de ruido, por lo que se reduce la  $P_D$  en comparación con una señal con SNR=-6 dB. De las 1000 muestras de señal QPSK evaluadas, 740 fueron clasificadas como *anomalías* (verdaderos positivos) y 260 como *normales* (es decir, falsos negativos).

El valor del umbral de detección es uno de los parámetros que afectan el desempeño del detector de espectro basado en detección de anomalías. Una forma de identificar el umbral de detección que garantiza el mejor desempeño del detector de espectro (es decir, máxima  $P_D$  y mínima  $P_{fA}$ ) es calculando el índice de Youden  $J$  (ver ecuación (8)). El índice de Youden se calcula para cada valor  $\gamma$  de cada curva ROC (Rajendan, 2019). El valor óptimo de  $\gamma$  de entre 0.1 y 1, es aquel que obtiene el valor  $J$  más alto. Cada valor de la curva ROC mostrado en la Figura 5 representa el compromiso entre la  $P_D$  y  $P_{fA}$  del detector para un valor de umbral de detección pre-definido (representado en la Figura 5 por la letra  $\gamma_i$ ).

$$J = P_d + P_{fA} - 1 \quad (8)$$

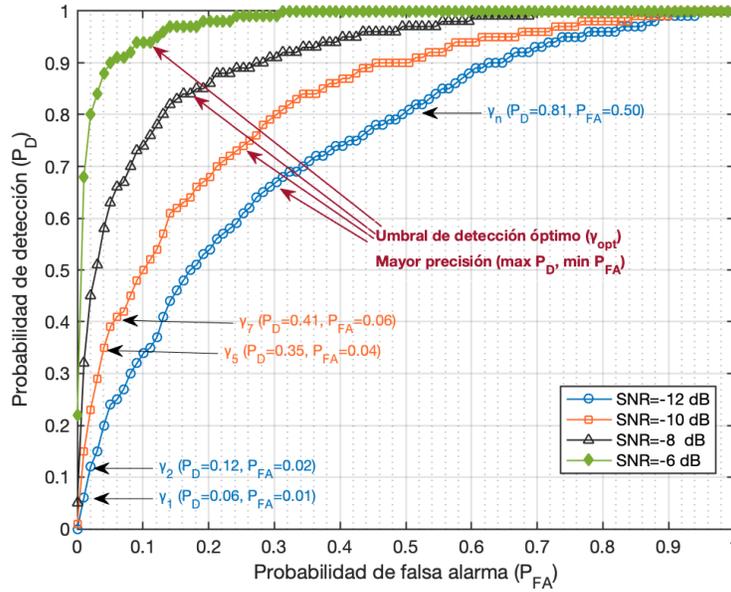


Figura 5. Curvas ROC que representan el compromiso entre la  $P_D$  y  $P_{fA}$  de la señal de información QPSK para distintos valores de calidad (SNR) y de umbral de detección.

El Área Bajo la Curva ROC (AUC) que se muestra en la Figura 6, permite evaluar el grado de separabilidad entre la  $P_D$  y la  $P_{fA}$ . Cada punto en la curva AUC representa, para un conjunto de datos (tipo de señal de información a un nivel de SNR), el promedio de todos los valores de  $P_D$  que conforman su curva ROC. Entre mayor es el valor de AUC mejor es el modelo de detección de espectro. Se puede observar en la Figura 6 que, para cualquier tipo de señal de información, conforme se incrementa su calidad (mayor SNR), el desempeño del detector de espectro, medido en términos de la  $P_D$ , también se incrementa. Este efecto también se observa con el detector de energía mostrado en la Figura 6 y, de hecho, también se presenta en cualquier detector de espectro reportado en literatura. Sin embargo, de este estudio es posible destacar dos hallazgos relevantes; el primero que se puede observar, es que el desempeño del detector de espectro basado en la teoría de detección de anomalías es superior, para cualquier caso (tipo de señal y nivel de SNR), al del detector de energía. El segundo, se refiere a que el detector de espectro propuesto, a diferencia del detector de energía, resuelve con el mismo rendimiento la detección de cualquiera de las señales

de información analizadas, lo que significa que la teoría de detección de anomalías permite construir un detector de espectro independiente del tipo de señal. Sin olvidar que conforme se incrementa el nivel de SNR de la señal mejor será el desempeño del detector. Este hallazgo, de que el detector de espectro sea independiente de la señal a detectar, es importante porque si en el futuro una nueva tecnología inalámbrica utiliza una nueva señal de información, esta propuesta de detección de espectro no requerirá entrenarse con la nueva señal, ya que automáticamente la clasificará como una anomalía.

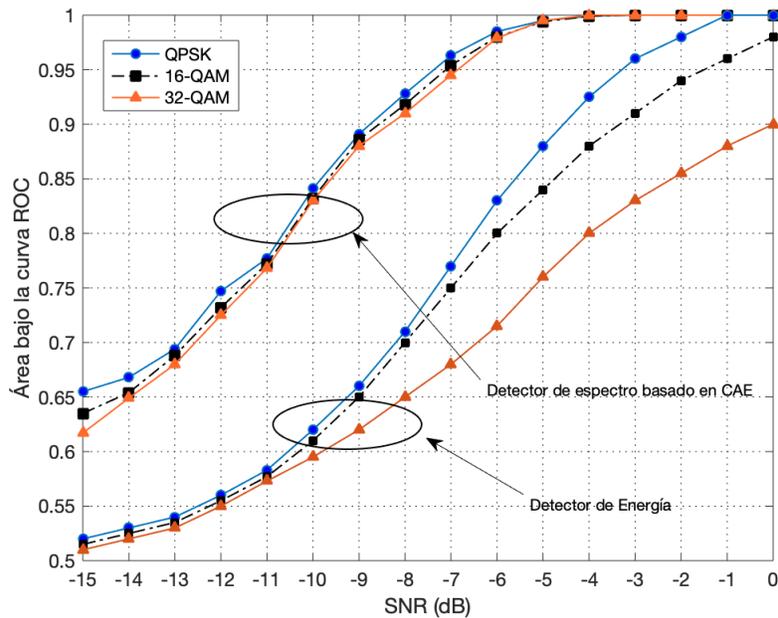


Figura 6. Análisis comparativo del detector de espectro basado en la detección de anomalías y un detector convencional (no utiliza IA) de espectro basado en la energía.

## 6. Conclusiones

En este trabajo, se presenta la implementación de un detector de espectro con base a la teoría de detección de anomalías. Se utilizó un Autoencoder Convolutivo (CAE) como clasificador de una sola clase. El entrenamiento se realizó solo con muestras no-supervisadas de señales de ruido.

Utilizar una sola clase resulta en un entrenamiento menos complejo, evita errores comunes de etiquetado manual y la necesidad de recopilar conjuntos masivos de datos para el entrenamiento. Los resultados experimentales demuestran que es posible detectar la presencia de señales moduladas (actividad del usuario) independientemente de su esquema de modulación. Por lo tanto, el detector es adaptable a entornos inalámbricos dinámicos. Utilizar redes neuronales con mayor número de capas, u optimizar los parámetros de operación del CAE mediante alguna técnica de optimización del tipo vecinos cercanos (k-NN), mejoraría el desempeño del detector de espectro basado en IA, aunque al mismo tiempo incrementarían la complejidad computacional del modelo. Sin embargo, es posible implementar otras estrategias de menor complejidad, que influyen en la forma de medir el error de reconstrucción, lo que resultaría en utilizar otros tipos de Autoencoders como, por ejemplo, Denoising Autoencoder, Sparse Autoencoder o Variational Autoencoder.

## REFERENCIAS

- Chen, S., Liang, Y., Sun, S., Kang, S., Cheng, W., and Peng, M. 2020. Vision, Requirements, and Technology Trend of 6G: How to Tackle the Challenges of System Coverage, Capacity, User Data-Rate and Movement Speed, *IEEE Wireless Communications*, 27: 218-228.
- Cui, H., *et al.* 2022. Space-air-ground integrated network (SAGIN) for 6G: Requirements, architecture and challenges, *China Communications*, 19: 90-108.
- Fernando, P., Dadallage, L., Gamage, T., Seneviratne, C., Madanayake, A., Liyanage, M. 2022. Proof of Sense: A Novel Consensus Mechanism for Spectrum Misuse Detection, *IEEE Transactions on Industrial Informatics*, 18: 9206-9216.
- Gupta, M.S., Kumar, K. 2019. Progression on spectrum sensing for cognitive radio networks: A survey, classification, challenges and future research issues, *Journal of Network Computing and Applications*, 143: 47-76.
- He, A., *et al.* 2010. A Survey of Artificial Intelligence for Cognitive Radios, *IEEE Transactions on Vehicular Technology*, 59: 1578-1592.
- La Rosa Centeno, L., De Castro, F.C.C., De Castro, M.C.F. *et al.* 2018. Cognitive radio signal classification based on subspace decomposition and RBF neural networks, *Wireless Network*,

24: 821–831.

Liu, D., Huang, Y., Gao, Z. 2021. Spectrum Situation Completion Based on Model-Enhanced Generative Learning, *13th International Conference on Wireless Communications and Signal Processing (WCSP)*, pp. 1-5.

Liu, C., Wang, J., Liu, X., Liang, Y. 2019. Deep CM-CNN for Spectrum Sensing in Cognitive Radio, *IEEE Journal on Selected Areas in Communications*, 37: 2306-2321.

Liu, R., Ma, Y., Zhang, X., Gao, Y. 2021. Deep Learning-Based Spectrum Sensing in Space-Air-Ground Integrated Networks, *Journal of Communications and Information Networks*, 6: 82-90.

Lundén J., Koivunen V., Poor HV. 2015. Spectrum exploration and exploitation for cognitive radio: recent advances, *IEEE Signal Process Magazine*, 32: 123–140.

Matinmikko-Blue, M., Yrjölä, S., and Ahokangas, P. 2020. Spectrum Management in the 6G Era: The Role of Regulation and Spectrum Sharing, *2nd 6G Wireless Summit (6G SUMMIT)*, 2020: 1-5.

Nguyen,D.C., et al. 2022. 6G Internet of Things: A Comprehensive Survey, *IEEE Internet of things Journal*, 9: 359-383.

Pang G., Shen C., Cao L., Van Den Hengel A. 2022. Deep Learning for Anomaly Detection: A Review, *ACM Computing Surveys*, 54: 1-38.

Patel, D.K., López-Benítez, M., Soni, B. *et al.* 2020. Artificial neural network design for improved spectrum sensing in cognitive radio. *Wireless Network*, 26: 6155–6174.

Peng Q., Gilman, A., Vasconcelos N., Cosman P., Milstein B. 2020. Robust Deep Sensing Through Transfer Learning in Cognitive Radio, *IEEE Wireless Communications Letters*, 9: 38-41.

Pimentel, M., Clifton, D., Clifton, L., Tarassenko, L. 2014. A review of novelty detection, *Signal Processing*, 99: 215-249.

Rajendan S., Meert W., Lenders V. 2019. Unsupervised wireless spectrum Anomaly detection with interpretable features, *IEEE Transactions on Cognitive Communications and networking*, 5: 637-647.

Rasti, M., Taskou, SK., Tabassum, H., and Hossain, E. 2022. Evolution Toward 6G Multi-Band Wireless Networks: A Resource Management Perspective, *IEEE Wireless Communications*, 29: 118-125.

Ribeiro, M., Lazzaretti, A., Silverio, H. 2018. A study of deep convolutional auto-encoders for anomaly detection in videos, *Pattern Recognition Letters*, 105: 13-22.

Shafin, R., Liu, L., Chandrasekhar, V., Chen, H., Reed, J., Zhang, J. 2020. Artificial Intelligence-Enabled Cellular Networks: A Critical Path to Beyond-5G and 6G, *IEEE Wireless Communications*, 27: 212-217.

Shen, F., Wang, Z., Ding, G., Li, K., Wu, Q. 2022. 3D Compressed Spectrum Mapping With Sampling Locations Optimization in Spectrum-Heterogeneous Environment, *IEEE Transactions on Wireless Communications*, 21: 326-338.

Umar, R., Sheikh, A., Deriche, M. 2014. Unveiling the Hidden Assumptions of Energy Detector Based Spectrum Sensing for Cognitive Radios, *IEEE Communications Surveys & Tutorials*, 16: 713-728.

Xie J., Fang J., Liu C., Yang L. 2019. Unsupervised Deep Spectrum Sensing: A Variational Auto-Encoder Based Approach, *IEEE Transactions on Vehicular Technology*, 69: 5307-5319.

Yadav, M., Li, Y., Fang, G., Shen, B. 2022. Deep Q-network Based Reinforcement Learning for Distributed Dynamic Spectrum Access, *IEEE 2nd International Conference on Computer Communication and Artificial Intelligence (CCAI)*, 2022: 1-6.

Yrjölä, S., Ahokangas, P., and Matinmikko-Blue, M. 2022. Visions for 6G Futures: a Causal Layered Analysis, *Joint European Conference on Networks and Communications & 6G Summit (EuCNC/6G Summit)*, 2022: 535-540.

Zheng, S., Chen, S., Qi, P., Zhou, H., Yang, X. 2020. Spectrum sensing based on deep learning classification for cognitive radios, *China Communications*, 17: 138-148.

Zhou, X., Xiong, X. Zhang, J., Liu, X., Wei, J. 2021. A Radio Anomaly Detection Algorithm Based on Modified Generative Adversarial Network, *IEEE Wireless Communications Letters*, 10: 1552-1556.

Zhu, Q., et al. 2022. DEMO Abstract: An UAV-based 3D Spectrum Real-time Mapping System, *IEEE INFOCOM 2022 - IEEE Conference on Computer Communications Workshops* 1-2.