Erazo De La Cruz, Miramá Pérez & Mora Arroyo / INGE CUC, vol. 17 no. 1, pp. 126-145. Enero - Junio, 2021

# Detección de espectro en banda ancha Sub-Nyquist para redes Radio Cognitiva: Compleción de matrices mediante valores semilla

# Sub-Nyquist Wideband Spectrum sensing for Cognitive Radio Networks: Matrix Completion via seed values

DOI: http://doi.org/10.17981/ingecuc.17.1.2021.10

Artículo de Investigación Científica. Fecha de Recepción: 27/08/2020. Fecha de Aceptación: 25/10/2020.

## Olger Ferledy Erazo De La Cruz 💿

Universidad del Cauca. (Colombia) olger@unicauca.edu.co

## Víctor Fabián Miramá Pérez 🗅

Universidad del Cauca. (Colombia) vmirama@unicauca.edu.co

### Jorge Edison Mora Arroyo 回

Universidad del Cauca. (Colombia) jorgemora@unicauca.edu.co

Para citar este artículo:

O. Erazo De La Cruz, V. Miramá Pérez & J. Mora Arroyo, "Detección de espectro en banda ancha Sub-Nyquist para redes Radio Cognitiva: compleción de matrices mediante valores semilla", *INGE CUC*, vol. 17, no. 1, pp. 126–. DOI: http://doi. org/10.17981/ingecuc.17.1.2021.10

#### Resumen

**Introducción**— La Radio Cognitiva (CR) hace un uso eficiente del recurso radioeléctrico, para ello realiza la Detección de Espectro (SS) con el fin de identificar el espectro disponible. Pero debido a la rápida evolución de los transceptores, la microelectrónica y las altas frecuencias de propagación, se hace necesario que en CR se apliquen algoritmos de SS en bandas de frecuencia y se realice un muestreo inferior a la tasa de Nyquist.

**Objetivo**— Adaptar un algoritmo para Detección de Espectro Sub-Nyquist en Banda Ancha (WBSS) para redes de CR mediante la Compleción de Matrices (MC) que integra valores semilla a partir de las muestras conocidas, con el fin de completar las entradas no muestreadas de la banda a evaluar, reconstruir las señales e identificar el espectro disponible.

**Metodología**— Se realizó una adaptación al algoritmo Aproximación Matricial de la Zona de Interés (IZMA), para ello se diseña la etapa de reconstrucción y se elige un método de detección de espectro en banda estrecha para conformar el banco de detectores; el algoritmo que se denomina IZMA\_SV es evaluado a nivel de simulación, por tanto se reconstruyen señales determinísticas en diferentes SNR y se identifica el estado del canal como ocupado o libre.

#### Abstract

**Introduction**— Cognitive Radio (CR) makes efficient use of the radio resource, for this it performs Spectrum Sensing (SS) in order to identify the available spectrum. But due to the rapid evolution of transceivers, microelectronics and high propagation frequencies, it is necessary for SS algorithms to be applied in frequency bands in CR and for sampling below the Nyquist rate.

**Objective**— Adapt an algorithm for Wideband Sub-Nyquist Spectrum Detection (WBSS) for CR networks using Matrix Completion (MC) integrating seed values from known samples, in order to complete the unsampled inputs of the band to evaluate, reconstruct the signals and the identify the available spectrum.

**Methodology**— An adaptation to the Interest Zone Matrix Approximation (IZMA) algorithm was carried out, for this purpose the reconstruction stage is designed and a narrow band spectrum sensing method is chosen to form the detector bank; the algorithm called IZMA\_SV is evaluated at the simulation level, therefore deterministic signals are reconstructed in different SNRs and the channel status is identified as busy or free.

**Resultados**— Las simulaciones indican que el algoritmo adaptado presenta diferencias entre los valores conocidos de la matriz de muestreo M y la matriz recuperada X en SNR inferiores a -8 dB, mientras que la diferencia tiende a cero en SNR superiores a 2 dB.

**Conclusiones**— El algoritmo IZMA-SV logra reducir el número de operaciones para llegar a la matriz aproximada X, reconstruyendo señales muestreadas al 75% de la tasa Nyquist y aún con un muestreo del 20% se mantienen las características de la señal que hacen posible la detección de espectro en banda ancha.

**Palabras clave**— Radio cognitiva; algoritmo de detección de espectro en banda ancha; compleción de matrices; aproximación matricial de la zona de interés; muestreo Sub-Nyquist; detección de energía **Results**— The simulations indicate that the adapted algorithm shows differences between the known values of the sampling matrix M and the recovered matrix X in SNRs lower than -8 dB, while the difference tends to zero in SNRs greater than 2 dB.

**Conclusions**— The IZMA-SV algorithm manages to reduce the number of operations to arrive at the approximate matrix X, reconstructing signals sampled at 75% of the Nyquist rate and even with a sampling of 20% the characteristics of the signal that make possible the detection of wideband spectrum.

**Keywords**— Cognitive radio; algorithm of spectrum sensing in wideband; matrix completion; interest zone matrix approximation; Sub-Nyquist sampling; energy detection

© The author; licensee Universidad de la Costa - CUC. INGE CUC vol. 17 no. 1, pp. 126-145. Enero - Junio, 2021 Barranquilla. ISSN 0122-6517 Impreso, ISSN 2382-4700 Online



#### I. INTRODUCCIÓN

En los últimos años el incremento de usuarios con equipos móviles y las redes inalámbricas en las que estos se apoyan, han superado el tráfico de las redes fijas. Un estudio de CISCO indica que para el año 2022 [1] las redes inalámbricas y los equipos móviles serán responsables del 71% del tráfico IP, mientras los equipos cableados solo generarán el 29% restante; además del creciente uso de redes inalámbricas y en consecuencia del licenciamiento de gran parte del espectro, en diversos estudios se ha demostrado que el espectro radioeléctrico se encuentra infrautilizado [2], así aparece el término de espacio blanco que hace referencia al espectro disponible y huecos espectrales, como variaciones de uso temporal y geográfico de este recurso natural.

Para aprovechar los huecos espectrales aparece la Radio Cognitiva (CR), producto de la adición de capacidades cognitivas a los dispositivos de Radio Definida por Software (SDR), tales como: detectar, usar y compartir el espectro; esta capacidad es el resultado de investigaciones desarrolladas por Mitola y Maguire en el año de 1999 [3]-[4], principales precursores de la CR. Por otra parte, Simon Haykin [5] indica que la CR se caracteriza por conocer el entorno que lo rodea, adaptarse a su ambiente, aprender y adaptar sus estados internos para realizar cambios en ciertos parámetros de operación (por ejemplo, potencia de transmisión, frecuencia de portadora y estrategia de modulación) en tiempo real.

En las redes de Radio Cognitiva se identifica al usuario licenciado, a quien se denominará como Usuario Primario (PU), autorizado para acceder a una parte especifica del espectro y el usuario cognitivo, a quien se denominará como Usuario Secundario (SU), encargado de la detección de espectro y a usarlo siempre que no se interfiera con los PU [6].

En la detección de espectro existen diferentes algoritmos que se clasifican bajo diferentes criterios. La primera clasificación corresponde a la cantidad de señales a evaluar de forma simultánea, identificándose a la NBSS cuando solo se evalúa una señal y WBSS cuando se evalúa más de una señal. También se pueden clasificar como Coherentes y no Coherentes, en la primera se conocen las características de la señal y en la segunda no se conocen las características de la misma [7]. Si la detección se realiza de manera individual por cada SU se denomina detección de espectro Local y si participa un grupo de SU se denomina detección de espectro Cooperativo, los algoritmos pertenecientes a esta última clasificación se caracterizan por minimizar los errores de detección en canales con desvanecimiento y ensombrecimiento, para lograrlo cada usuario cognitivo evalúa su entorno y comparte sus resultados empleando canales de difusión [8]. Para mejorar el desempeño de la SS también se integran diferentes algoritmos, a estos se denominan Híbridos [9].

En bajas frecuencias de propagación los algoritmos WBSS digitalizan las señales a evaluar con muestreo Nyquist, pero en altas frecuencias de propagación se requiere de un muestreo Sub-Nyquist, este último tipo se subclasifica en multicanal y detección compresiva. En la detección de espectro multicanal se realiza la evaluación de múltiples vectores de medición, que ingresan por diferentes canales de muestreo Sub-Nyquist. Mientras que en la detección compresiva se busca encontrar el número mínimo de mediciones para reconstruir una señal y determinar la disponibilidad espectral [10]-[11]. Los algoritmos

relacionados con la detección de espectro identifican diferentes características de la señal, emplean disímiles recursos computacionales, requieren de una determinada cantidad de muestras y periodos de observación, con el único objetivo de mejorar la probabilidad de detección.

En la segunda sección de este artículo encuentra el desarrollo metodológico por fases, para adaptar el algoritmo de Aproximación Matricial de la Zona de Interés (IZMA) en la detección de espectro local en banda ancha con muestreo Sub-Nyquist; esto implica el diseño de la etapa de reconstrucción de la señal y la selección de un método de detección de espectro en banda estrecha que conforme el banco de detectores. La tercera sección corresponde a las pruebas, así como los resultados a nivel de simulación tras reconstruir señales determinísticas en diferentes condiciones de canal e identificar las oportunidades espectrales. Las conclusiones y la identificación de trabajos futuros se presentan en la cuarta sección.

#### II. DESARROLLO METODOLÓGICO

En esta sección se presenta el desarrollo metodológico del algoritmo propuesto, basado en las fases del modelo de simulación por computadora [12]. En la primera fase se realizó el diseño del estudio, que comprende el entorno, las condiciones, restricciones y la presentación del modelo general. En la segunda fase se modeló el sistema considerando el muestreo sub-Nyquist. En la tercera fase se diseñó el modelo conceptual del algoritmo. En la cuarta fase se adaptó el algoritmo para la detección de espectro en banda ancha y se detalló la función de cada componente. En la quinta fase se eligió un algoritmo de detección de espectro en banda estrecha que conforma el banco de detectores. En la sexta fase se construyó, verificó y validó el algoritmo propuesto, evidenciado en el proceso de reconstrucción de señales determinísticas; al mismo tiempo se planificaron los experimentos a nivel de simulación. En la séptima fase se experimentó con el modelo de simulación en la etapa de reconstrucción y se evaluó el desempeño del algoritmo elegido en banda estrecha. Finalmente, en la octava fase se integró en un modelo la etapa de reconstrucción y de detección de espectro para evaluar 4 canales muestreados de forma serial.

### A. Diseño del estudio

El algoritmo propuesto requiere de la simulación para evaluar su desempeño, por tal motivo en la primera fase de la metodología se tiene en cuenta los aspectos técnicos. El primer paso consiste en determinar los supuestos, en otras palabras, el entorno en el cual se ejecutará el algoritmo; identificadas las condiciones junto a las restricciones, en el segundo paso se establece: el modelo general del algoritmo y los componentes software necesarios para su evaluación; ya en el tercer paso se describen las herramientas de diseño, al igual que las herramientas de construcción necesarias para la simulación en computador, así como la evaluación.

El algoritmo propuesto se diseña con respecto a condiciones y restricciones, por ello en el proceso de simulación se considera la existencia de un solo dispositivo radio cognitivo que realiza WBSS en un dispositivo de única antena; no se contemplan mecanismos de detección de errores, interesa determinar el estado del canal; a nivel de simulación existe un transmisor con bajas frecuencias de propagación que emplea modulaciones digitales, sin control de potencia; durante el tiempo de simulación siempre existe una señal presente; además, la posición del equipo CR es fijo en tiempo de simulación.

La Fig. 1 muestra el modelo general del algoritmo local de WBSS en redes de Radio Cognitiva basado en muestreo Sub-Nyquist y MC considerando las entradas y salidas. El algoritmo requiere de las entradas que se obtienen de un sistema muestreador Sub-Nyquist, el cual recorre diferentes frecuencias preestablecidas; las entradas se almacenan en una matriz y tras aplicar el algoritmo de reconstrucción se completan los datos no muestreados; posterior a ello se evalúa la frecuencia seleccionada y con ayuda de un banco de detectores en banda estrecha se determina el estado del canal.



#### Fig. 1. Modelo general del algoritmo local de WBSS Sub-Nyquist IZMA\_SV ED. Fuente: Autores.

El algoritmo propuesto es evaluado en modulaciones BPSK y QPSK, al igual que en SNR comprendidas entre los -40 dB a 20 dB, para lograrlo se emplea en el proceso de simulación MAT-LAB, programa de computo basado en operaciones matriciales y orientado al cálculo numérico, esta herramienta integra un lenguaje de alto nivel, así como un entorno de programación visual empleado para simular el comportamiento de los sistemas de comunicaciones e interactuar con diferentes dispositivos. Las simulaciones generan datos que deben ser sistematizados para su análisis estadístico, en consecuencia, se desarrolla un aplicativo de escritorio en Microsoft Visual Studio 2019 denominado Aplicativo Detección Espectro (SSA) y una base de datos en MySQL.

#### B. Modelo del sistema

La segunda fase se presenta el modelo del sistema, se supone que todos los dispositivos radio cognitivos no hacen uso del espectro durante el intervalo de detección, por lo tanto, la señal observada solo surge de un PU y el ruido de fondo. Suponemos que existe una señal continua en el tiempo denominada y(t), y el rango de frecuencia de y(t) es de  $0 \sim W$  (Hz). Además en un tiempo de observación T la señal y(t) es muestreada a una tasa de frecuencia  $f_{e}$  Hz, las muestras de la señal pueden ser denotadas como  $y[k] = y(n/f_s)$ , n = 0, 1, 2, ..., N-1, para conformar un vector de la forma  $\vec{y} \in C^{NX1}$  donde el entero  $N \equiv f_s T$ . Luego  $\vec{y}$  es el espectro de  $\vec{y}$ , calculado al aplicar la Transformada Discreta de Fourier (DFT) denotada como F, es decir,  $\vec{Y} = F{\vec{y}}$ . La dificultad se presenta al reconstruir la señal para ser evaluada por algún algoritmo de detección de espectro si se desconoce el ancho de banda W y en consecuencia la  $f_s$  es menor al doble del ancho de banda de la señal, es decir,  $f_s < 2W$ , de este modo se incumple el teorema de muestreo de Shannon-Nyquist. No solo el desconocimiento del ancho banda afecta la detección de espectro, también observar portadoras con altas frecuencias implica mayor recurso computacional a nivel de procesamiento, memoria y consumo energético; además exigen conversores analógicos a digitales con elevadas  $f_s$  y bits de resolución, que dificulta la implementación. Este dilema motiva a investigadores a desarrollar tecnologías para reducir la tasa de muestreo  $f_s$  y evaluar el mismo ancho de banda W.

La detección compresiva basada en la poca densidad permite muestrear una o varias señales y(t) a una tasa inferior a Nyquist para conformar una matriz de detección M y obtener una matriz aproximada X que contenga los datos perdidos de M [13]-[14] se espera que de la matriz X se recuperen las señales y[k] sin perder las características del espectro  $\vec{Y}$ .

Una vez recuperada la señal existen algoritmos en banda estrecha que a partir de Y realizan la detección de espectro, uno de ellos es el detector de energía en el dominio de la frecuencia, donde se estima la energía de la señal en un rango de frecuencias de interés, comparándolo con un valor umbral  $\lambda$  que depende de la estadística del ruido, para elegir el estado de la banda a partir de dos hipótesis H<sub>0</sub> o H<sub>1</sub>, ausencia de PU o la presencia de PU respectivamente. Así que la eficiencia del detector se da en términos de la probabilidad de detección (PD), es decir que se determina de forma apropiada el estado de la banda como libre H<sub>0</sub> u ocupada H<sub>1</sub>, representada en (1) [15], donde corresponde a la medición compresiva que contiene información importante para la detección, *r* representa el ruido blanco aditivo gaussiano,  $\Omega$  es la matriz de detección conocida de orden ( $n1 \times n2$ ) con (n1 < n2) y es la señal del PU.

$$y = \begin{cases} H_0: & \Omega r \\ H_1: & \Omega s + \Omega r \end{cases}$$
(1)

Pero independiente de la técnica empleada en detección de espectro, los errores son inevitables debido al ruido aditivo, el número limitado de muestras y la aleatoriedad de los datos observados, hecho que conlleva a dos tipos de error. El primer tipo de error involucra la falsa alarma, que ocurre cuando un canal que está libre se detecta como ocupado, en consecuencia, no se pueda ocupar el canal libre; el segundo tipo de error se presenta cuando existe una detección

fallida, que hace referencia a que un canal ocupado es detectado como libre, en este caso un SU interfiere a un PU. Por ello el desempeño de un detector se caracteriza por dos parámetros, la probabilidad de falsa alarma ( $P_{\rm FA}$ ), descrita en (2) y la probabilidad de detección fallida ( $P_{\rm MD}$ ), la cual se define en (3) [15].

$$P_{FA} = Prob\{Decidir H_1 | H_0\}$$
<sup>(2)</sup>

$$P_{MD} = Prob\{Decidir H_0 | H_1\}$$
(3)

Reducir la  $P_{\text{FA}}$  y  $P_{\text{MD}}$  es un desafío para la detección compresiva, ya que la calidad de recuperación de la señal a partir de la medición compresiva se ve limitada por el tamaño de la matriz de detección M, el número de muestras, la implementación en hardware y la incertidumbre ante el

ruido. En este artículo se presenta el algoritmo IZMA\_SV para muestrear las señales usando técnicas con  $f_s$  Sub\_Nyquist, obtener una matriz aproximada X que además contenga los valores perdidos no muestreados y determinar el estado de cada canal por medio de un método de detección de espectro en banda estrecha que conforma un banco de detectores.

#### C. Diseño del modelo conceptual IZMA-SV

En la tercera fase de la metodología se desarrolla el modelo conceptual del algoritmo local de WBSS IZMA\_SV en redes de Radio Cognitiva con muestreo Sub-Nyquist, como una adaptación de la primera versión de detección de espectro en banda estrecha Sub\_Nyquist propuesta por los autores de este artículo [18].

El primer bloque representado en la Fig. 2 genera el vector de entradas mm[k] que se obtiene al digitalizar y(t) por medio del bloque "Muestreador Sub-Nyquist" que recorre diferentes frecuencias con un ancho de banda preestablecido; el segundo bloque "acondicionador de muestras canal" se encarga de promediar algunos valores de muestra y de encontrar el segmento con la máxima SD, generando el vector mm2; el tercer bloque "Constructor de matriz a completar" organiza los datos muestreados mm2 en una matriz X que debe cumplir con por lo menos una muestra por fila y columna; el cuarto bloque, denominado "Reconstrucción de datos perdidos matriz" se encarga de aplicar el algoritmo para completar los datos no muestreados en la matriz M y generar la matriz aproximada X. En el quinto bloque "Selector de rango de frecuencia" selecciona de la matriz X los vectores xj correspondientes a la frecuencia a evaluar. Finalmente, con ayuda de j bloques detectores de espectro que conforman el "Banco de Detectores" se determina el estado de cada canal como ocupado o libre.



Fig. 2. Modelo general del sistema por bloques. Fuente: Autores.

Se busca recuperar los datos perdidos en una matriz M con el objetivo de reconstruir la señal en la matriz X. MC permite completar los datos no muestreados, sin cambiar el valor de las entradas conocidas de la matriz M mientras se minimiza la función objetivo, en este caso se desea minimizar el rango de la matriz X, como se describe en (4).

$$\begin{array}{ll} minimizar & rango(X)\\ sujeto \; a \; X_{ij} = M_{ij} \; \; (i,j) \in \Omega \end{array} \tag{4}$$

Dado que minimizar el rango se convierte en un problema de optimización en el que no se puede determinar el tiempo para obtener una respuesta, pero si comprobar si es correcta o no, se convierte en un problema NP-hard. Ciertos investigadores [16] plantean como solución aproximar la matriz por medio de la minimización de la norma nuclear de la matriz X, descrita en (5).

$$\begin{array}{ll} minimizar & \|X\|_{*} \\ sujeto \ a & X_{ij} = M_{ij} \ (i,j) \in \Omega \end{array}$$
(5)

Donde  $||X||_*$  denota la norma nuclear de X, que es igual a la suma de los k-*ésimo* valores singulares, identificada en (6) como  $\sigma_k(X)$  y n es el número de filas de la matriz a recuperar. Este proceso minimización se ejecuta hasta llegar a un valor pequeño en  $||X||_*$  que indica que la matriz es de bajo rango.

$$\|X\|_{*} = \sum_{k=1}^{n} \sigma_{k}(X)$$
(6)

Otros investigadores [17] debido a la complejidad computacional que representa aplicar MC en matrices de bajo rango por medio de la Optimización Convexa propuesta por [16], implementan una red de CR en la cual los SU muestrean los diferentes canales y conforman paquetes que se transmiten a un centro de fusión, equipo hardware con elevadas prestaciones de procesamiento, quien una vez recupera la matriz X ejecuta un algoritmo detector de energía en los diferentes canales y comparte la información de los canales disponibles. Además, en ciertas investigaciones [18] no solo consideran centralizar el procesamiento en la etapa de reconstrucción, también la transferencia de energía inalámbrica, la asignación de intervalos de tiempo de muestreo sub-Nyquist y la potencia de transmisión para mejorar el desempeño en un solo SU y en toda la red. Por otro lado, estudios sobre el tema [19] aplican la MC en la detección de usuarios maliciosos quienes acceden a protocolos de baja capa y realizan ataques al falsificar datos de detección de espectro que afectan la  $P_{\rm D}$  e incrementan la  $P_{\rm FA}$ . El algoritmo propuesto busca reducir el tiempo requerido en la etapa de reconstrucción, disminuir la complejidad computacional y en consecuencia bajar el consumo eléctrico, requerimientos a tener en cuenta en la implementación de la detección cooperativa.

Científicos de la Universidad de Aviv [20] plantean que la aproximación de se obtiene cuando el error de Frobenius es menor a un valor de tolerancia *tol* cercano a cero y la norma nuclear es menor  $\lambda_{tol}$ , valor establecido de forma heurística. El error de Frobenius  $\|PX-PM\|_F$  es la diferencia entre la matriz proyectada de X y la matriz proyectada de M, una vez aplicada la norma de Frobenius si el resultado tiende a cero significa que la matriz proyectada de no presenta cambios significativos en la aproximación de los elementos no muestreados y en consecuencia se requiere ajustar el valor de la norma nuclear  $\lambda$ .

La proyección de *X* es  $PX = B \odot X$ , donde *B* es la matriz binaria conformada de ceros y unos, los ceros representan los datos perdidos y los unos los valores muestreados de la señal; el operador  $\odot$  representa la multiplicación matricial. La norma de Frobenius se describe en (7),  $a_{ij}$  es la diferencia entre *PX* y *PM*.

$$\left\|a_{ij}\right\|_{F} = \sqrt[2]{\sum_{i=1}^{m} \sum_{j=1}^{n} a_{ij}^{2}}$$
(7)

Por otra parte las formas de ondas en telecomunicaciones se pueden representar como la implementación de funciones seno y coseno en un sistema de coordenadas, si además se considera la señal como periódica se puede asignar a un elemento no muestreado un valor semilla

tras conocer el valor anterior y siguiente, así como la desviación estándar de las muestras conocidas, es por ello que en este artículo se propone una modificación al algoritmo IZMA con estos criterios y además se establece la configuración de una matriz de muestreo, al algoritmo adaptado por los autores de este artículo en banda estrecha se denominó IZMA\_SD [21], mientras que en banda ancha se denomina IZMA\_SV. Al adicionar estos valores semi-lla se logró reducir el número de iteraciones para encontrar la aproximación a la matriz , en consecuencia se reduce el tiempo de procesamiento y el número de operaciones matemáticas.

D. Especificaciones del modelo conceptual IZMA-SV

En la cuarta fase de la metodología se adapta el algoritmo para WBSS a nivel de implementación, adicionando dos bloques fundamentales como el acondicionador de muestras de canal y la adaptación del selector del rango de frecuencias para un banco de detectores, el cual se describe en el Algoritmo 1.

Algoritmo 1. WBSS basado en Matrix Completion IZMA \_ SV

Entrada:					
mm	Vector con frecuencia de muestreo sub Nyquist a partir del selector de frecuencia central				
${\mathcal P}$	Operador de proyección que especifica las entradas importantes				
Sali	la:				
Deci	$sión: H_1 o H_0.$				
1: m	$m2 \leftarrow$				
асот	ndicionador muestras canal desde mm[k]				
2: L	$\leftarrow$ constructor matriz incompleto desde mm2				
3: B	$\leftarrow$ constructor matriz binaria				
4: N	$\leftarrow L \odot B$				
5:M	$\leftarrow$				
Inte	gre semilla desviación estandar desde N				
6: λ <sub>1</sub>	$\lambda \leftarrow infinito  \lambda_{tol} \leftarrow 10  tol \leftarrow 10^{-\gamma}$				
$7:\lambda_n$	$max \leftarrow   M  _*$				
8:Re	petir:				
9:	$\lambda_{prev} \leftarrow \lambda$				
10:	$\lambda \leftarrow (\lambda_{max} + \lambda_{min})/2$				
11:	$X \leftarrow IZMASD$ aproxima $M \odot B$ para				
	los puntos sujetos a $  X  _* \leq \lambda$				
12:	$error \leftarrow   \mathcal{P}X - \mathcal{P}M  _F$				
13:	si error $\geq$ tol entonces				
14:	$\lambda_{min} \leftarrow \lambda$				
15:	si no				
10:	$\lambda_{max} \leftarrow \lambda$				
1/:	f in si				
18:h	asta (error < tol) y $[(\lambda - \lambda_{prev}) < \lambda_{tol}]$				
<i>19</i> :	$x_i \leftarrow Selector frecuencia central a evaluar desde X.$				
20: 7	Aplication NBSS al vector $x_i$ en cada detector i.				
21.1	<i>Decisión ← Estado del canal.</i>				

Fuente: Adaptado desde [20].

En el paso 1, del Algoritmo 1, el vector mm[k] contiene las entradas generadas por el Muestreador Sub-Nyquist. Una vez se tiene el vector con las muestras se acondiciona y se obtiene un segmento del vector que contiene la máxima SD, al cual se denomina mm2.

En el paso 2, el bloque *Constructor matriz a completar*, estima la matriz L como el resultado de tomar el vector mm2 y adicionar ceros en los espacios entre muestra y muestra, posterior a ello a la matriz se adicionan 12 filas, las cuales contienen muestras de 3 señales muestreadas de la misma forma. La Fig. 3 describe la matriz B, construida en el paso 3, que se conforma de unos y ceros, celdas de color negro y blanco respectivamente, la matriz B contiene el mismo número de filas y columnas de la matriz L, organizada de tal manera que en cada fila y columna se intercalan los ceros y unos, para evitar que existan filas o columnas con solo ceros.



Fig. 3. Datos de la matriz IZMA\_SV a recuperar. Fuente: Autores.

En el paso 4, la matriz N es el resultado de una multiplicación de elementos entre la matriz a completar L y la matriz B, conformada por ceros y unos. En el paso 5, si se considera a la señal como periódica, la función *integre semilla desviación estandar* asigna a los espacios vacíos, identificados en la Fig. 3 con celdas de color blanco, un valor que corresponde a la SD ajustada con respecto al valor previo y próximo de las muestras conocidas.

Los valores de  $\lambda_{\min}$  y  $\lambda_{\max}$  son fundamentales para determinar el valor de  $\lambda$ . En el paso 7, la suma de los valores singulares de la matriz que tiene valores perdidos M, es decir  $||X||_*$  identificada como la norma nuclear se asigna inicialmente a  $\lambda_{\max}$ , mientras  $\lambda_{\min}$  es 0. A partir de estos valores iniciales se inicia un ciclo, pasos 8 a 18, su objetivo fundamental es aproximar la matriz M mientras se cumpla que el ultimo valor de la norma nuclear  $\lambda$  con respecto al anterior  $\lambda_{\text{prev}}$  sea menor que un valor de tolerancia; por otra parte, también el ciclo se mantiene hasta que el error de Frobenius, en los que interviene la proyección de la matriz M y la proyección de la matriz X, se aproxime a cero.

En los pasos 9 y 10 se estima el valor de  $\lambda_{prev}$  y  $\lambda$  en este último caso es el promedio entre  $\lambda_{min}$  y  $\lambda_{max}$ . En el paso 11 se ejecuta el procedimiento *IZMASD* que aproxima la matriz X a partir de los valores semilla, esta aproximación se ejecuta hasta que la diferencia entre el último error de Frobenius con respecto al error previo tienda a cero, es decir que la minimización de la norma nuclear de X ya no presenta grandes cambios al cumplir con la restricción de ser menor que  $\lambda$ .

En el paso 12 se calcula el error de Frobenius a partir de la matriz proyectada de X y la matriz proyectada de M, que se denota como  $\|PX-PM\|_{F}$ . En los pasos 13 a 17, se evalúa el error previamente calculado si es mayor que la tolerancia se reajustan los valores de  $\lambda_{\min}$  y  $\lambda_{\max}$ ; el objetivo es incrementar el valor de  $\lambda$ , siempre que el error sea mayor que la tolerancia, para ello  $\lambda$  se asigna a  $\lambda_{\min}$ , esto sucede si la norma nuclear de X indica que los datos perdidos hasta el momento se encuentran distantes a las entradas conocidas; si el error es menor que la tolerancia,  $\lambda$  se asigna a  $\lambda_{\max}$ , con esto se decrementa el valor de  $\lambda$ , valido para la próxima iteración.

El paso 19, *Selección del rango de frecuencia* permite seleccionar el canal a evaluar del total de la banda de frecuencia muestreada y completada en la matriz X; el resultado de este bloque es un vector denominado  $x_i$  que se envía al siguiente paso. En el paso 20, Aplicación de NBSS al vector  $x_i$  para ser evaluado; finalmente en el paso 21 se decide el estado del canal.

### E. Selección del Algoritmo NBSS

Hoy en día es posible la detección de espectro en varios canales al mismo tiempo, esto debido al avance de los sistemas de procesamiento, así como a la frecuencia de muestreo de los módulos de conversión analógico a digital. En la quinta fase de la metodología se muestra los resultados del desempeño de 4 algoritmos de NBSS, con el objetivo de elegir a uno de ellos para conformar el banco de detectores y determinar el estado del canal una vez se reconstruye la señal por parte de IZMA\_SV Sub-Nyquist, correspondientes al paso 20 y 21 del Algoritmo 1. El proceso de elección considera tres métricas: sensibilidad de detección, el tiempo de respuesta y la facilidad de implementación.

Entre los diferentes algoritmos de detección de espectro en banda estrecha se eligen: Detector de Energía (ED), Detector Características Cicloestacionarias (CFD), Detector por Filtro Adaptado (MFD) y Detector por Red Neuronal Artificial (ANN).

La detección de espectro con ED identifica la señal primaria sin conocer características de la señal del PU, por tal razón se clasifica como un algoritmo no Coherente; la ED se puede

implementar en el dominio del tiempo o en el dominio de la frecuencia [22].

El CFD identifica la periodicidad de la señal como resultado de los trenes de pulsos, los códigos de ensanchamiento, las secuencias de salto o prefijos cíclicos; el algoritmo evalúa la correlación existente entre los componentes espectrales, diferenciando el ruido de la señal del PU, ya que el ruido es estacionario en sentido amplio y sin correlación [23].

El MFD es una técnica Coherente, generalmente se utiliza un filtro lineal para eliminar las frecuencias no deseadas y por medio de la sincronización de la señal entrante con respecto a una señal conocida se determina la presencia del PU [24]. Parte de un conocimiento previo de la señal y en la demodulación se debe determinar el ancho de banda, la frecuencia, el tipo de modulación, la forma de pulso y trama; la ventaja de este método radica en que requiere de una menor cantidad de muestras, la respuesta es rápida, pero tiene mayor consumo ya que se deben implementar varios filtros y ejecutar comparaciones con diferentes señales patrón.

La detección de espectro con ANN se utiliza para clasificar las señales, permite identificar la presencia de un PU a partir del reconocimiento de la modulación en un canal en especial [25]. La arquitectura de la red neuronal artificial corresponde a un perceptrón multicapa, que cuenta con dos capas ocultas, 30 neuronas en el primer nivel, en este caso mantiene una proporción de 10 multiplicado por las clases a identificar; en la segunda capa se mantiene una proporción de 5 neuronas por cada clase, por tanto, se conforma de 15 neuronas; la capa de salida es de 3 neuronas. La arquitectura emplea una función de transferencia tipo sigmoideo, conocida como la función sigmoidal tangente hiperbólica, empleando un algoritmo de aprendizaje de retro-propagación.

La ANN en la etapa de diseño se ejecuta en tres fases, la primera corresponde a la generación de datos, la segunda al entrenamiento y finalmente la prueba; en la fase de generación de datos se crean paquetes con las señales BPSK, QPSK y solo ruido, las cuales se desean identificar bajo diferentes SNR; en la segunda etapa se entrenan las neuronas hasta llegar a la función objetivo de reconocimiento y en la tercera etapa se realizan las pruebas para determinar el desempeño del clasificador. De forma general la señal y(t) una vez es filtrada y digitalizada ingresa al bloque clasificador del perceptrón multicapa para identificar el tipo de señal, así como determinar si el canala se encuentra libre u ocupado.

Los 4 algoritmos NBSS se codifican en MATLAB, en la experimentación se toman entradas aleatorias, se modulan en BPSK así como en QPSK a una frecuencia de operación de Hz, formas de onda muestreadas a Hz y después de agregar ruido, tras pasar a través de un canal AWGN, la señal recibida alimenta los diferentes detectores encargados de la detección de espectro.

#### 1) Sensibilidad de Detección

La sensibilidad de detección corresponde al desempeño del algoritmo al estimar la , la así como la de señales moduladas y afectadas por las condiciones de canal AWGN; la detección de espectro se realiza en señales con SNR desde –22 dB hasta +22 dB, ejecutando 400 simulaciones por cada intervalo; los resultados de las 17600 simulaciones se almacenan en archivos planos, un formulario del software SSA desarrollado por los autores decodifica el archivo y los almacena en la base de datos MySQL.



#### Fig. 4. PD en la modulación BPSK y QPSK. Fuente: Autores.

En la Fig. 4 se observa que tras ejecutar 8 800 simulaciones de una señal modulada en BPSK y QPSK el algoritmo ANN en bajas SNR presenta un menor desempeño con respecto a los otros métodos, la desventaja de este método radica en el conocimiento previo de las características de la señal. Si se comparan los algoritmos no coherentes CFD y ED, el primero presenta un mejor desempeño ya que evalúa la periodicidad de la señal.

Otro aspecto importante al momento de seleccionar el algoritmo NBSS a integrar en el banco de detectores es la estimación de la  $P_{FA}$ ; la Fig. 5 es el resultado de ejecutar 8800 simulaciones en las cuales no existe PU, al comparar las técnicas de SS coherente que esperan evaluar una señal modulada en BPSK y QPSK se observa que un MFD presenta mejor desempeño que la ANN, en este caso el filtro adaptado realiza la correlación cruzada del ruido con respecto a las señales patrón y existe una alta probabilidad de detección. Por otra parte, en los métodos no coherentes, la CFD presenta una menor PFA con respecto a ED, esto se debe a que el ruido blanco es aleatorio y no guarda correlación estadística entre los componentes de frecuencia.



Fig. 5. PFA en la modulación BPSK. Fuente: Autores.

#### 2) Tiempo de Respuesta

En CR se evalúa de forma continua en entorno radio en busca de huecos espectrales, sin embargo, no se puede transmitir y detectar al mismo tiempo, en consecuencia, se necesitan algoritmos de detección de espectro con el menor tiempo de respuesta.

La ANN y MFD son buenas técnicas de detección de espectro en Radio Cognitiva si se tiene un conocimiento previo de la forma de onda del PU. Una vez se ejecutan los cuatro algoritmos NBSS en un computador que cuenta con un procesador Intel Core i5, 4 núcleos a 2.50 GHz y 8 GB de memoria RAM, se promedia el tiempo de respuesta de 17600 simulaciones por cada tipo de señal primaria. La Tabla 1 muestra que en los algoritmos no coherentes el ED tarda menos tiempo en evaluar una señal con respecto a CFD, esto se debe a que en CFD estima varias veces la densidad espectral de potencia de la señal desplazada en frecuencia, mientras que en ED solo se realiza una vez.

Tipo de Señal Primaria	ED	$\operatorname{CFD}$	MFD	ANN
BPSK	0.009	1.364	0.010	0.021
QPSK	0.007	0.725	0.016	0.018
Sin PU, se espera BPSK	0.009	1.261	0.011	0.020
Sin PU, se espera QPSK	0.010	0.927	0.021	0.024
Promedio	0.009	1.069	0.015	0.021

TABLA 1. TIEMPO DE RESPUESTA EN SEGUNDOS PARA LA DETECCIÓN DEL TRANSMISOR.

Fuente: Autores.

Al evaluar los algoritmos coherentes, la detección de espectro por MFD tarda menos tiempo que la ANN, esto se debe a que en MFD se analiza la correlación cruzada de la señal con respecto a 6 tipos de portadoras, mientras que la detección de espectro por ANN la señal recorre la red neuronal con 400 conexiones y se realizan diversas operaciones que producen dos valores de salida, señal o ruido. Por lo tanto, los resultados experimentales en la tabla 1 muestran que el ED tarda menos tiempo en dar respuesta con respecto a otros métodos.

#### 3) Facilidad de Implementación

La ventaja del detector de energía es el bajo costo de implementación, esto lo hace un buen candidato para conformar el banco de detectores del algoritmo IZMA\_SV. El MFD no es fácil de implementar porque requiere la generación de portadoras en el receptor que incrementa el costo a nivel de hardware. El CFD al igual que la ANN son algoritmos que requieren una alta complejidad computacional debido a la cantidad de operaciones requeridas.

Tipo de Señal Primaria	ED	CFD	MFD	ANN
Tiempo de respuesta	0.01 s	$1.069 \mathrm{~s}$	$0.015 \mathrm{~s}$	$0.021 \mathrm{~s}$
$P_D = 1 \text{ en SNR} > a$	-2  dB	-7  dB	1 dB	-11dB
$P_{FA} \le 0.1 \text{ en SNR} \ge a$	14 dB	-20  dB	4 dB	-20dB
Conocimiento de la señal	No	No	Si	Si

TABLA 2. RESUMEN DE COMPARACIÓN DE ALGORITMOS DE NBSS BASADOS EN EL TRANSMISOR.

Fuente: Autores.

La Tabla 2 muestra que el ED presenta facilidad de implementación, un menor tiempo de respuesta con respecto a las otras técnicas, no requiere un conocimiento de las características de la señal, pero presenta un mal desempeño ante el ruido, aspecto se puede solucionar en la implementación de IZMA\_SV si se determina de forma previa el nivel del ruido a partir de medidas reales.

#### 4) Algoritmo Detector de energía AVG\_SD

El algoritmo ED se elige para conformar el banco de detectores, este último es el encargado de evaluar el estado de los canales una vez se reconstruyen las señales con IZMA\_SV; sin embargo, el nivel de potencia del ruido puede cambiar según las condiciones del canal, en bajas SNR la clasificación de ocupado o libre genera incertidumbre, como solución se considera que la SD de una señal ocupada por PU es mayor a la SD de una señal libre.

Algoritmo 2. Detección de Energía con Promedio y Desviación Estándar - ED AVG \_ SD

Entradas: $x_i$ Vector a evaluar. $\Lambda$ Limite índice de energía, igual a -10.Salida:Estado\_del\_canal Resultado de evaluación. $1:Pxx \leftarrow Periodograma_DSP(x_i)$  $2:vdbm \leftarrow Convierte Pxx$  watts a dBm $3:i \leftarrow 129$  $j \leftarrow 1$ 4:Repetir:

5:  $valor \leftarrow vdbm(i, 1)$ 6:  $recorte(j, 1) \leftarrow valor$ 7:  $acum \leftarrow acum + valor$  $i \leftarrow i + 1$ 8: 9:Mientras i<=385  $10:prom \leftarrow acum/256$ 11:  $desvi \leftarrow desviacion\_estandar(recorte)$ 12: *if* (*desvi*>0.1) 13: indice\_energia  $\leftarrow$  prom/desvi 14:else 15: *indice\_energia*  $\leftarrow -15$ 16:*fin si 17:Si* (indice\_energia $<\Lambda$ ) 18:  $Estado_del_canal \leftarrow 0$  "libre" 19:si no 20:  $Estado\_del\_canal \leftarrow 1$  "ocupado" 21:Fin si

Fuente: Adaptado desde [23].

Tras implementar en hardware la detección de espectro por ED en el dominio de la frecuencia, se adapta el algoritmo descrito por [23], al cual se denomina Detección de Energía con Promedio y Desviación Estándar (ED AVG\_SD), detallado paso a paso en el Algoritmo 2, donde a partir del vector  $x_i$  recuperado por el algoritmo IZMA\_SV se determina la Densidad Espectral de Potencia (PSD) de 4000 muestras para conformar el vector Pxx de 512 componentes, los resultados del mismo se convierten a dBm y se almacenan en el vector vdbm, el flujo resultante ingresa a una etapa en la cual solo se tienen en cuenta 128 componentes de frecuencia a la izquierda y 128 componentes a la derecha de la frecuencia central; en el paso 7 del Algoritmo 2 se suman los elementos del vector seleccionado y el total se asigna en *acum*, en el paso 10 se promedia, en el paso 11 se calcula la SD y en el paso 12 al cociente de dividir el promedio de la potencia con respecto a la SD se denomina indice\_energia. En el paso 17 se evalúa si el indice\_energia es mayor al umbral  $\Lambda$ , de ser afirmativa la respuesta se elige la hipótesis H<sub>1</sub>, en caso contrario se elige H<sub>0</sub>.

### F. Construcción, verificación y validación del modelo de simulación

Una vez descritos los dos algoritmos fundamentales de IZMA\_SV, en la sexta fase se presentan los bloques de programación para la etapa de muestreo, conformación de la matriz a completar y la reconstrucción de la señal.

En la Fig. 6 se observa que con respecto a los autores se adiciona un bloque generador de señal determinística s(t) afectada por el ruido r(t), un "muestreador Sub-Nyquist" genera el vector mm[k] a partir de las muestras y(t) y el bloque "Integre semilla desviación estándar", los otros bloques se han descrito en los pasos 3 a 19 del Algoritmo 1. Los scripts se codifican en Matlab y en el proceso de simulación se asumen diferentes señales deterministicas como seno, coseno, BPSK y QPSK, las cuales se generan a diferentes frecuencias, así como se muestrean con tasas inferiores a Nyquist.



Fig. 6. Bloques de programación IZMA\_SV etapa reconstrucción. Fuente: Autores.

IV. PRUEBAS Y RESULTADOS

La séptima fase de la metodología corresponde a la experimentación del modelo de simulación en la etapa de reconstrucción de las señales y en la etapa de detección de espectro por medio de un detector de energía adaptado al cual se denominó ED AVG\_SD. Además, al final de esta sección se presenta la octava fase, relacionada con los resultados obtenidos al integrar en un modelo las dos etapas y evaluar 4 canales de forma serial.

A. Simulación etapa de reconstrucción de la señal

Una vez se codifican los algoritmos se valida la efectividad IZMA\_SV al reconstruir señales seno, coseno, BPSK y QPSK con diferentes SNR. Las señales a reconstruir se generan a una frecuencia de 9 Hz y con solo 12 muestras válidas; una vez se aplica la reconstrucción de la señal se cuenta con 24 muestras. Al finalizar 6000 simulaciones interesa determinar la diferencia de norma nuclear, la cantidad de operaciones para recuperar la matriz y la diferencia de la señal recuperada con respecto a la señal determinística.

El proceso de minimización de la norma nuclear de la matriz recuperada X se realiza hasta  $||M| \odot B||_* - ||X||_* \le 10$ , B es la matriz binaria que se conforma de unos y ceros, M es la matriz con los elementos no muestreados sin adicionar los valores semilla. En la Fig. 7 se puede evidenciar que la diferencia entre las normas es cercana a cero cuando la SNR es superior a 8 dB, luego el proceso de minimización genera una matriz de bajo rango en buenas condiciones de canal; por el contrario en bajas SNR la diferencia en las normas es mayor a 5, indica que los datos recuperados distan de los valores previamente conocidos.



Fig. 7. Diferencia entre la norma nuclear inicial y la norma nuclear final de la señal recuperada vs SNR. Fuente: Autores.

Además se presenta un comportamiento similar al analizar el Error Medio Cuadrático (RMSE), el objetivo es medir la cantidad de error que existe entre la matriz X con respecto a M, en otras palabras, se comparan los valores conocidos de M con respecto a los valores aproximados de X en la misma fila y columna. La RMSE se presenta en (8), en donde n es el número de muestras conocidas.

$$RMSE = \sqrt[2]{\frac{\sum_{i=1}^{n} [(X-M) \odot B]}{n}}$$
(8)

La Fig. 8 demuestra que el RMSE se aproxima a 0.04 en SNR superiores a -4 dB, de nuevo el algoritmo presenta un menor error en la aproximación de las muestras perdidas bajo buenas condiciones de canal.



Fig. 8. Error medio cuadrático entre la señal original y la señal recuperada vs SNR. Fuente: Autores.

El tiempo de procesamiento y complejidad de implementación se relacionan con el número de aproximaciones necesarias para llegar a la matriz, en la Fig. 9 se observa que se requieren más de aproximaciones en SNR inferiores a dB y esta se reduce a aproximaciones en SNR superiores a -8 dB, nuevamente el algoritmo presenta mayor velocidad al recuperar muestras perdidas en buenas condiciones de canal. Una aproximación hace referencia al cálculo de la norma nuclear y a dar solución al problema de programación cuadrática que permita aproximar la matriz *X*.



Fig. 9. Número de aproximaciones necesarias para llegar a la señal recuperada vs SNR. Fuente: Autores.

Para estimar la diferencia de las señales inicialmente se estima la correlación cruzada de  $x_1[n]$  con respecto a  $x_2[n]$ , en (9) el primer vector corresponde a las muestras de la señal conocida sin perder el 50% de las muestras y el segundo corresponde a la señal recuperada, donde  $x_1[n]$  y  $x_2[n]$  son dos vectores de la misma longitud N. k inicia en 1 - N hasta N - 1, si n - k < 0 se asigna a la multiplicación 0 y también si n - k es > N se asigna a la multiplicación 0. El vector c tiene 1 fila y 2N - 1 columnas.

$$c[k] = \sum_{n=0}^{N-1} x_1[n] \cdot x_2[n-k]$$
(9)

Existe otro vector denominado p, el cual contiene los retrasos para el cálculo de correlaciones, si N es la longitud de  $x_1[n]$  o  $x_2[n]$  y el número de columnas de p es 2N - 1, el vector se define como p = [1 - N, ..., N - 1].

Se normaliza los elementos del vector para que tenga un valor máximo de 1 o un mínimo de -1, se obtiene el vector  $n_c$  que es el resultado de dividir cada elemento del vector c entre el máximo valor del mismo como se indica en (10).

$$n_{c}[k] = \frac{c[k]}{\max(c)}$$
(10)

Ahora se normalizan los elementos del vector denominado p asignando un valor máximo de 1 y un valor mínimo de -1, luego como se muestra en (11). el vector  $n_p$  es el resultado de dividir cada elemento del vector c entre el máximo valor del mismo.

$$n_{p}[k] = \frac{p[k]}{\max(p)}$$
(11)

Así que la diferencia *dif* de la señal recuperada con respecto a la señal determinística presentada en (12) se define como la sumatoria de la multiplicación de los elementos del vector  $n_c$ con  $n_p$ , los dos vectores tienen la misma longitud de  $x_1[n]$  y  $x_2[n]$ .

$$dif = \sum_{n=0}^{N-1} n_c[n] \cdot n_p[n]$$
(12)

Si *dif* es igual a 0 indica que no existe diferencia entre la señal recuperada con respecto a la señal determinística, por el contrario un valor de *dif* cercano a uno revela que existe una marcada diferencia en la señal recuperada.

La normalización de la correlación cruzada es un indicador de la diferencia existente entre la señal original con todos sus elementos y la señal recuperada tras sufrir una pérdida del 50% de las muestras; difiere del RMSE ya que este último estima el error con respecto a la aproximación de las muestras conocidas y no contempla la totalidad de elementos de la matriz recuperada.

En la Fig. 10 se evidencia que en los cuatro tipos de señales la diferencia tiende a cero en SNR superior a 2 dB, cabe recordar que dif = 0 significa que la señal recuperada es igual a la señal original, así como valores superiores a 0.3 indican la diferencia existente entre las dos señales. Se observa en la Fig. 10 que la señal coseno no presenta diferencias en SNR superiores a 4 dB, esto se debe a que el proceso de inserción de valores semilla con SD se acerca al comportamiento de este tipo de señal.



Fig. 10. Diferencia entre la señal de referencia y la señal recuperada vs SNR. Fuente: Autores.

B. Simulación etapa de detección de espectro Detector Energía AVG\_SD

Tras reconstruir la señal el algoritmo 2, ED AVG\_SD, se codifica en Matlab y se realizan 12000 simulaciones con modulaciones BPSK y QPSK. Para sistematizar el proceso de estimación de  $P_D$ , la  $P_{FA}$  y la  $P_{MD}$ , un módulo del software SSA es el encargado de decodificar los resultados de las simulaciones, se almacenan los registros en una tabla de la base de datos diseñada en Mysql y se estiman las probabilidades bajo diferentes condiciones de canal.

La Fig. 11 muestra el comportamiento del algoritmo clásico de detección de energía AVG\_SD de señales moduladas BPSK y QPSK en diferentes SNR, donde la  $P_{FA}$  es cercana a 1 si se presentan SNR inferiores a –2dB, es decir que detecta una señal y en realidad en el canal solo existe ruido; mientras que la  $P_{D}$  se aproxima a en SNR superiores a 3 dB y la  $P_{MD}$  es superior al 0.25 en SNR inferiores a –8dB.



Fig. 11. PD, PFA y PMD de una señal en BPSK y QPSK con detección de espectro ED AVG\_SD. Fuente: Autores.

C. Integración etapa de reconstrucción y detección de espectro



#### Fig. 12. Modelo en Simulink MC IZMA\_SV con un ED en banco. Fuente: Autores.

La prueba final del algoritmo propuesto, correspondiente a la octava fase de la metodología, al integrar en un modelo en Simulink la etapa de reconstrucción y la detección de espectro para evaluar cuatro canales de forma serial.

En la etapa de detección de espectro por medio de un detector de energía AVG\_SD se requiere determinar el límite del índice de energía descrito en el Algoritmo 2, por tal razón a partir de muestras obtenidas de una señal en FM sin presencia de un PU se fija el umbral  $\Lambda$  en -10.

En la Fig. 12 el bloque "selector\_4frec" permite cambiar la frecuencia central cada 0.25 s, intervalo de tiempo que se puede configurar en el bloque denominado "Counter Limited". El bloque "generador\_senal\_4\_frec" suma a una señal determinística el ruido y genera muestras con una tasa inferior a Nyquist a partir de la frecuencia central establecida. El bloque "const\_matriz\_integra\_sd" selecciona un segmento de las muestras con la máxima SD, además integra los valores semilla en los elementos perdidos. El bloque "matrix\_completion\_sd" construye la matriz M y realiza las aproximaciones hasta llegar a la matriz X, flujo de salida denominado como matrix\_aprox. El bloque "recorte\_periodograma" selecciona los componentes de espectro que presentan mayor densidad espectral de potencia. Finalmente el bloque "guardar\_res\_y\_evaluar" determina el estado del canal tras comparar si el índice\_energia es menor a  $\Lambda$ , de ser afirmativa la evaluación el canal se considera libre; además el bloque guarda los resultados de la simulación en un archivo.

#### 1) Evaluación serial de 4 canales

Se configura el bloque "generador\_senal\_4frec" para conformar 10000 muestras por segundo de una señal con un ancho de banda de 6600 Hz, muestreado al 75% de la tasa de Nyquist, generando 10 paquetes de 1000 muestras. El algoritmo selecciona de cada paquete un vector de 100 elementos con la máxima SD para ser aproximado, si existe un PU tarda 1.2 s en completar las 100 muestras perdidas, mientras que si el canal solo tiene ruido tarda 0.34 s. Por otra parte, completar la totalidad de las muestras perdidas tarda 120 s, el vector resultante se conforma de 20000 muestras que equivale al 150% de la tasa de Nyquist. Por tanto, una de las limitantes del algoritmo es el tiempo de respuesta, el cual se incrementa en bajas SNR y a mayor número de muestras a recuperar.

La Fig. 13 grafica el índice de energía de los cuatro canales muestreados con un intervalo de 0.25 s; en este caso se observa que le índice de energía presentan un valor superior o inferior a –10, ocupado y libre respectivamente; los resultados son correctos ya que se evalúa en el siguiente orden: BPSK, solo ruido, QPSK, solo ruido. Los primeros 0.4 s no existen resultados, este tiempo corresponde a la puesta en marcha del modelo de simulación.



Fig. 13. Índice de energía de 4 señales. Fuente: Autores.

Si solo interesa determinar el estado del canal, se configura el bloque "generador\_senal\_4frec" para conformar 2640 muestras por segundo de una señal con un ancho de banda de 6600 Hz, 20% tasa de Nyquist, generando 2 paquetes de 1000 muestras. El algoritmo selecciona de cada paquete un vector de 50 elementos con la máxima SD para ser aproximado, si existe un PU tarda 0.8 s en completar las 50 muestras perdidas, mientras que en un canal sin PU tarda 0.27 s.

En el Algoritmo 1 se describe que la convergencia existe cuando  $(\lambda - \lambda_{prev}) < \lambda_{tol}$ , con  $\lambda_{tol} = 10$  y  $\lambda = \|X\|_*$ , es decir que encuentra la norma nuclear aproximada y el algoritmo termina la etapa de reconstrucción si además  $\|PX - PM\|_F < tol$ , con  $tol = 10^{-7}$ ; así que en la evaluación de las señales con presencia del PU el proceso de minimización de la norma nuclear de la matriz recuperada X cumple con  $\|M \odot B\|^* - \|X\|_* \leq \lambda_{tol}$ , puesto que para este tipo de señales  $\|M \odot B\|_* - \|X\|_* \approx 2.75$ , existe convergencia y además la norma de Frobenius es menor a  $10^{-7}$ .

Un canal con solo ruido cumple con encontrar la norma nuclear aproximada de *X* al obtener  $||M| \odot B||_* - ||X||_* \approx 0.61$ , sin embargo no cumple con  $||PX - PM||_F < tol$ , ante esta condición el algoritmo reasigna el valor  $\lambda$  e incrementa un contador denominado *no\_convergencia*, cuando *no\_convergencia* > 4 no se continua con el proceso de reconstrucción. El valor máximo de aproximaciones para llegar a  $||X||_* \leq \lambda$  es 50, por ello el promedio de aproximaciones a la matriz en los dos canales sin presencia del PU es de 200. En este tipo de señales no existe convergencia debido a que  $||M \odot B||_*$  es pequeña comparada con la norma de un canal ocupado.

Se puede entonces establecer que una métrica para determinar el estado del canal puede ser el número de *no\_convergencia* > 4, si el canal esta libre, reduciendo de este modo la aplicación del ED en la etapa de detección de espectro.

El algoritmo adaptado IZMA\_SV logra mostrar que en la etapa de reconstrucción puede ser aplicado para completar datos de señales que se caractericen por la periodicidad.

#### IV. CONCLUSIONES

El algoritmo adaptado denominado IZMA\_SV recupera la matriz de muestro con un 50% de pérdidas muestreado al 75% de Nyquist si se asigna en los elementos desconocidos un valor semilla obtenido a partir de la evaluación de la SD, el valor anterior y próximo al elemento no muestreado; además de estructurar la matriz de tal manera que en las filas consecutivas exista por lo menos una muestra por columna. Por otra parte, si solo interesa determinar el estado de los canales como libre u ocupado basta con muestrear al 20% de la tasa de Nyquist.

El algoritmo a nivel de simulación es evaluado en la etapa de reconstrucción de señales seno, coseno, BPSK y QPSK bajo diferentes SNR, muestreados al 75% de la tasa de Nyquist; los resultados indican que en SNR inferiores a -8 dB se requiere de 300 operaciones para dar solución a un problema de programación cuadrática que busca minimizar el rango de la matriz aproximada X, además en esas condiciones existen diferencias entre la norma nuclear inicial de la matriz M con respecto a la norma nuclear final de la matriz recuperada X que reflejan diferencias entre los valores conocidos de M con todos sus elementos y la matriz X recuperada tras sufrir una pérdida del 50% de las muestras; la diferencia entre las muestras de las matrices tiende a cero en SNR superiores a 2 dB, en consecuencia el algoritmo MC IZMA\_SV recupera los elementos no muestreados de señales en buenas condiciones de canal.

Para compensar el recurso computacional requerido en la etapa de reconstrucción, el algoritmo de detección de energía es seleccionado para conformar el banco de detectores por su facilidad de

implementación y el menor tiempo de respuesta; el bajo desempeño en la sensibilidad de detección se soluciona al estimar el *índice de energía* como el cociente entre el promedio de la PSD de la señal y su desviación estándar, logrando  $P_D$  cercana a 1 en SNR superior a -2 dB.

En próximos trabajos el algoritmo propuesto requiere ser implementado y evaluado con medidas reales bajo diferentes escenarios, en especial analizar el efecto de la SD en la estimación de valores semilla para recuperar señales con espectro ensanchado. De la misma forma se requiere la evaluación del algoritmo en redes detección cooperativa que permita identificar las oportunidades espectrales en menor tiempo.

# $F {\rm inanciamiento}$

Artículo de investigación científica derivado del proyecto de investigación "Sensado de espectro en banda ancha basado en matrix completion para redes de radio cognitiva", financiado por "Universidad del Cauca". Año de inicio: 2018, año de finalización: 2020.

#### REFERENCIAS

- Cisco, "Cisco Visual Networking Index: Forecast and Trends, 2017–2022," *Informe técnico 2018-2023*, [online], 2017. Available: https://www.cisco.com/c/en/us/solutions/collateral/service-provider/visualnetworking-index-vni/white-paper-c11-741490.html
- [2] Federal Communications Commission, "Spectrum Policy Task Force," *Wikia.org*, [online], Nov. 2002. Available: https://itlaw.wikia.org/wiki/Spectrum\_Policy\_Task\_Force
- [3] J. Mitola & G. Q. Maguire, "Cognitive Radio: making software radios more personal," *IEEE Personal Communicant*, vol. 6, no. 4, pp. 13–18, Aug. 1999. https://doi.org/10.1109/98.788210
- [4] J. Mitola, "Cognitive Radio an Integrated Agent Architecture for Software Defined Radio," *Ph.D. dissertation*, KTH, SK, SE, 2000.
- S. Haykin, "Cognitive Radio: Brain-Empowered Wireless Communications," IEEE J Sel Areas Commun, vol. 23, no. 2, pp. 201–220, Feb. 2005. https://doi.org/10.1109/JSAC.2004.839380
- [6] J. C. Clement, K. V. Krishnan & A. Bagubali, "Cognitive Radio: Spectrum Sensing Problems in Signal Processing," Int J Comput App, vol. 40, no. 16, pp. 37–40, Feb. 2012. https://doi.org/10.1109/ JSAC.2004.839380
- [7] T. Yucek & H. Arslan, "A Survey of Spectrum Sensing Algorithms for Cognitive Radio Applications," *IEEE Commun Surv Tutor*, vol. 11, no. 1, pp. 116–130, 2009. https://doi.org/10.1109/SURV.2009.090109
- [8] M. M. Mabrook & A. I. Hussein, "Major Spectrum Sensing Techniques for Cognitive Radio Networks: A Survey," *IJEIT*, vol. 5, no. 3, pp. 24–37, Sep. 2015. Available from https://www.ijeit.com/Vol%205/ Issue%203/IJEIT1412201509\_05.pdf
- S. Chinchu & T. R. Sangeeta, "Hybrid Detection Method for Improving Spectrum Sensing Performance in Cognitive Radio," *IJSR*, vol. 5, no. 6, pp. 948–951, Jun. 2016. https://doi.org/10.21275/v5i6. NOV164316
- [10] H. Sun, A. Nallanathan, C.-X. Wang & Y. Chen, "Wideband spectrum sensing for cognitive radio networks: a survey," *IEEE Wirel Commun*, vol. 20, no. 2, pp. 74–81, Apr. 2013. https://doi.org/10.1109/ MWC.2013.6507397
- [11] H. Sun, W.-Y. Chiu, J. Jiang, A. Nallanathan & H. V. Poor, "Wideband spectrum sensing with sub-Nyquist sampling in cognitive radios," *IEEE Trans Signal Process*, vol. 60, no 11, pp. 6068–6073, Nov. 2012. https://doi.org/10.1109/TSP.2012.2212892
- [12] R. Al-Aomar, E. J. Williams & O. M. Ülgen, Process Simulation Using WITNESS. NJ, USA: John Wiley & Sons, 2015.
- [13] S. Qaisar, R. M. Bilal, W. Iqbal, M. Naureen & S. Lee, "Compressive Sensing: From Theory to Applications, A survey," J Commun Net IEEE (KICS), vol. 15, no. 5, pp. 443–456, Oct. 2013. https://doi. org/10.1109/JCN.2013.000083
- [14] H. Huang, S. Misra, W. Tang, H. Barani & H. Al-Azzawi, "Applications of compressed sensing in communications networks," ARXIV, vol. 1305.3002, pp. 1–18, Feb. 2014. Available: https://arxiv.org/ pdf/1305.3002.pdf
- [15] F. Salahdine, N. Kaabouch & H. El Ghazi, "A survey on compressive sensing techniques for cognitive radio networks," *Phys Commun*, vol. 20, no. 1, pp. 61–73, Sep. 2016. https://doi.org/10.1016/j. phycom.2016.05.002
- [16] E. J. Candes & B. Recht, "Exact Matrix completion via convex optimization," FoCM, vol. 9, no. 6, pp. 717–766, Apr. 2009. https://doi.org/10.1007/s10208-009-9045-5
- [17] Z. Qin, Y. Gao, M. D. Plumbey & C. G. Parini, "Wideband Spectrum Sensing on Real-Time Signals at Sub-Nyquist Sampling Rates in Single and Cooperative Multiple Nodes," *IEEE Trans Signal Process*, vol. 64, no. 12, pp. 3106–3117, Jun. 2016. https://doi.org/10.1109/TSP.2015.2512562
- [18] Z. Qin, Y. Liu, Y. Gao, M. Elkashlan & A. Nallanathan, "Wireless Powered Cognitive Radio Networks With Compressive Sensing and Matrix Completion," *IEEE Trans Commun*, vol. 65, no. 4, pp. 1464– 1476, Apr. 2017. https://doi.org/10.1109/TCOMM.2016.2623606
- [19] Z. Qin, Y. Gao & M. D. Plumbey, "Malicious User Detection Based on Low-Rank Matrix Completion in Wideband Spectrum Sensing," *IEEE Trans Signal Process*, vol. 66, no. 1, pp. 5–17, Jan. 2018. https:// doi.org/10.1109/TSP.2017.2759082
- [20] G. Shabat & A. Averbuch, "Interest zone matrix approximation," ELA, vol. 23, no. 1, pp. 678–702, Aug.

2012. https://doi.org/10.13001/1081-3810.1551

- [21] M. Subhedar & G. Birajdar, "Spectrum Sensing Techniques In Cognitive Radio Networks: A Survey," IJNGN, vol. 3, no. 2, pp. 37–51, Jun. 2011. https://doi.org/10.5121/ijngn.2011.3203
- [22] M. A. Abdulsattar & Z. A. Hussein, "Energy Detection Technique For Spectrum Sensing In Cognitive, Radio: A Survey," *IJCNC*, vol. 4, no. 5, pp. 223–242, Sep. 2012. https://doi.org/10.5121/ijcnc.2012.4514
- [23] P. S. Aparna & M. Jayasheela, "Cyclostationary Feature Detection in Cognitive Radio using Different Modulation Schemes," Int J Comp App, vol. 47, no. 21, pp. 12–16, Jun. 2012. https://doi.org/10.5120/7472-0517
- [24] D. Bhargavi & C. R. Murthy, "Performance comparison of energy, matched-filter and cyclostationarity-based spectrum sensing," *IEEE 11th International Workshop on Signal Processing Advances in Wireless Communications*, SPAWC, MAR, MA, pp. 1–5, 20-23 Jun. 2010. https://doi.org/10.1109/ SPAWC.2010.5670882
- [25] S. Pattanayak, P. Venkateswaran & R. Nandi, "Artificial Intelligence Based Model for Channel Status Prediction: A New Spectrum Sensing Technique for Cognitive Radio," *IJCNS*, vol. 6, no. 3, pp. 139–148, Mar. 2013. https://doi.org/10.4236/ijcns.2013.63017

**Olger Ferledy Erazo De La Cruz** es Ingeniero de Sistemas de la Universidad Mariana (Pasto, Colombia). Especialista en redes y servicios telemáticos de la Universidad del Cauca (Popayán, Colombia). Especialista en administración de la informática educativa de la Universidad de Santander (Bucaramanga, Colombia). Estudiante de la maestría en Electrónica y telecomunicaciones de la Universidad del Cauca (Popayán, Colombia). Actualmente es profesor en la facultad de Ingeniería de la Universidad CESMAG (Pasto, Colombia). Miembro del grupo de investigación RAMPA de la Universidad CESMAG. https://orcid.org/0000-0003-2995-648X

**Víctor Fabián Miramá Pérez** es Ingeniero en Electrónica y telecomunicaciones de la Universidad del Cauca (Popayán, Colombia). Magister en Electrónica y telecomunicaciones, Universidad del Cauca (Popayán, Colombia). Actualmente es profesor en la facultad de Ingeniería de la universidad del Cauca (Popayán, Colombia). Miembro del Grupo de I+D Nuevas Tecnologías en Telecomunicaciones GNTT y grupo de radio e inalámbricas GRIAL de la Universidad del Cauca. https://orcid.org/0000-0003-3845-1985

**Jorge Edison Mora Arroyo** es Ingeniero Electrónico de la Universidad de Nariño (Pasto, Colombia). Ingeniero de Telecomunicaciones de la Universidad Nacional Abierta y a Distancia, (Colombia). Estudiante de maestría en electrónica y telecomunicaciones de la Universidad del Cauca (Popayán, Colombia). Actualmente trabaja en el Servicio Geológico Colombiano (Pasto). https://orcid.org/0000-0003-3850-4506