

Detección de espectro a ciegas en tiempo real basado en procesamiento estadístico de magnitudes instantáneas

Real time blind spectrum sensing based in statistical processing of instantaneous magnitudes

Jorge Y. Hernández García ^{1*}

Recibido: 11/2021 | Aceptado: 01/2022

Palabras clave

Sensado de espectro
Detención de señales
Magnitudes instantáneas
Procesamiento de señales
IMSP.

Resumen

Se presenta un método novedoso para la detección de espectro a ciegas en tiempo real (RTBSS) basado en el procesamiento estadístico de magnitud instantánea (SPIM). La propuesta cubre la necesidad de detectar señales desconocidas en tiempo real, con baja complejidad de implementación y recursos hardware, para minimizar el consumo de energía en sistemas de radio cognitivo para redes inalámbricas. El método SPIM utiliza los fundamentos del procesamiento de señales de magnitud instantánea (IMSP). Mediante el procesamiento estadístico de los valores instantáneos de las magnitudes amplitud y fase, se determina la envolvente de la señal y se establece un umbral automático para la decisión. La solución detecta la presencia de señales desconocidas con solo dos muestras y una baja relación señal ruido (SNR). Posee superior precisión y rendimiento en comparación con el detector de energía (ED). Además de la detección, este método permite caracterizar el comportamiento temporal, amplitud y frecuencia de la señal. Se presentan los resultados numéricos de su aplicación en la detección de es-pectro ensanchado por salto de frecuencia (FHSS).

Keywords

Spectrum sensing
Signal detection
Instantaneous magnitude
Signal processing
IMSP

Abstract

A novel method for real time blind spectrum sensing (RTBSS) based on statistical processing of instantaneous magnitude (SPIM) is presented. The proposal covers need to detect unknown signals in real time, with low implementation complexity and hardware resources, to minimize energy consumption in cognitive radio systems for wireless networks. The SPIM method uses the fundamentals of instantaneous magnitude signal processing (IMSP). By statistical processing the instantaneous values of the amplitude and phase magnitudes, the signal envelope is determined and automatic threshold is set for the decision. The solution detects presence of unknown signals with only two samples and low signal to noise ratio (SNR). Have superior accuracy and performance compared to the energy detector (ED). In addition to detection this approach allows to characterize the temporal behavior, amplitude and frequency of

^{1*} Xetid, Empresa de Tecnologías de la Información para la Defensa, Cuba. jorgeyh@xetid.cu

the signal. The numerical results of its application in the detection of frequency hopping spread spectrum (FHSS) is presented.

Introducción

EL paradigma de la radio cognitiva (CR, por sus siglas en inglés) ha mejorado el estudio de las técnicas de detección del espectro (SS, por sus siglas en inglés). Los usuarios de CR necesitan detectar la presencia o no de la señal transmitida por otros usuarios llamados usuarios primarios (PUs), para determinar la ocupación del espectro y facilitar la toma de decisiones en el proceso de selección de un canal de trabajo.

En (Amrutha & Karthikeyan, 2017; Bagwari, Tuteja, Bagwari, & Samarah, 2020; Gafoor et al., 2018) se realiza un profundo análisis de las técnicas de SS. Éstas pueden dividirse en dos categorías principales: Detección no cooperativa y detección cooperativa. Para la detección de transmisores no cooperativas se utiliza el Detector de Energía (ED) (Nikolaos I. Miridakis, Theodoros A. Tsiftsis, & Guanghua Yang, 2020; Mosa & Algamluoli, 2017; Zhang, 2019), Eigenvalue (Zi-li, Xiao-ou, & Xiao-rong, 2019), Filtros sintonizados (Salahdine, Ghazi, Kaabouch, & Fihri, 2015), Características cicloestacionarias (El-Alfi, Abdel-Atty, & Mohamed, 2019). Otras técnicas como, transformada de Wavelet (Kumar, Saha, & Bhattacharya, 2016), Sensado comprimido (Nasser, Muta, Elsabrouty, & Gacanin, 2019), (Patel & Vithalani, 2014), con variante como Photonic RF channelization y compressive sampling (CS) (Yang et al., 2020), El submuestreo de Nyquist (Shaban & Bayoumi, 2016), (Zhao, Chen, Zheng, Zhuang, & Wen, 2019), el aprendizaje automático (Arjoune, Salahdine, Islam, Ghribi, & Kaabouch, 2020), (Gao, Yi, Zhong, Chen, & Zhang, 2019), basado en el momento (N. I. Miridakis, T. A. Tsiftsis, & G. Yang, 2020) también se utilizan para este propósito. Más recientemente, la técnica de detección de espectro de dos etapas Split-Half Spectrum Sensing (SHSS), versión modificada y que combina el ED con el ME, y el Micro-slotted Dual-stage Spectrum Sensing (MDMS), que determina el estado del canal midiendo la energía de cada micro-ranura y luego compara la energía medida con el primer umbral de decisión (Wasayangkool et al., 2020), también son empleadas.

Entre los métodos más utilizados para la detección ciega del espectro (BSS, en inglés) se encuentran: el

método ED, el método de valor propio como valor propio máximo (ME, en inglés), el algoritmo de relación de valor propio máximo-mínimo (MME, en inglés), el algoritmo de diferencia de valor propio máximo-mínimo (DMM, en inglés), el método de covarianza como valor absoluto de covarianza (CAV, en inglés), la norma de covarianza Frobenius (CFN, en inglés) (Awin, Abdel-Raheem, & Tepe, 2019). Para el RTBSS, el ED es el método de detección más utilizado debido a su baja complejidad computacional. Sin embargo, establecer un umbral para la ED requiere el conocimiento de la potencia de ruido del canal, que puede establecerse mediante métodos de estimación apropiados (Bagwari et al., 2020; Hernández, Gómez, & Hourné, 2018).

Existen varios desafíos para implementar los métodos para el SS en aplicaciones del mundo real. 1. Prolongar la vida de la fuente de energía de CR (eficiencia energética). La energía consumida durante el proceso de la SS produce una disminución del tiempo de vida de la fuente de energía. 2. Seguridad. Una vez que se detecta una banda inactiva, el funcionamiento del CRN puede ser interrumpido por una amenaza interna o externa, ya sea por ataques de Emulación de PU (PUE, en inglés) o de Falsificación de Datos de las SS (SSDF, en inglés). 3. Predicción del tráfico de la PU. A fin de determinar los parámetros del PU cómo, la ubicación, el nivel de potencia de la señal, el tráfico en las tres dimensiones (es decir, tiempo, frecuencia y espacio) para la predicción, es necesario incorporar el Mapa del Entorno Radioeléctrico (REM). Disponer de una técnica de SS que contribuya a estos tres aspectos es de vital importancia en los CRN actuales y futuros (Awin et al., 2019).

El trabajo cubre la necesidad de detectar señales desconocidas en tiempo real, con baja complejidad de implementación y recursos de hardware, minimizando el consumo de energía. Otro aspecto interesante es proporcionar información sobre las características de la señal del PU. La determinación del comportamiento temporal, la amplitud, frecuencia y las variaciones de fase de la señal, contribuye a identificar amenazas interna o externa en el proceso de seguridad y a la pre-

dicción del tráfico del PU en el CRN. Partiendo de la hipótesis de que al realizar un procesamiento estadístico con ventana deslizante de los valores sincronizados de las magnitudes instantáneas, amplitud, frecuencia y fase, procesando los vectores discretos I y Q, se puede detectar y caracterizar el espectro de una señal desconocida, en tiempo real minimizando el consumo de energía.

El novedoso método para RTBSS llamado SS-SPIM, utiliza los fundamentos del IMSP. Realiza el procesamiento estadístico de los valores instantáneos de las magnitudes de amplitud y fase. A partir de la amplitud, se determina la envolvente de la señal y con la fase se establece un umbral automático para la decisión.

Entre las principales contribuciones de la solución están:

Detectar señales con $P_d \geq 0.9$ y $P_f \leq 0.1$ usando sólo dos muestras ($N = 2$) para $SNR \geq 0dB$, para $SNR \geq -5dB$ puede detectar con $N = 15$.

Puede ser implementado en aplicaciones en tiempo real y no requiere conocimiento previo de la señal a ser detectada.

Además de la detección, este método permite caracterizar el comportamiento temporal de la amplitud y la frecuencia de una señal desconocida (Por Ej. Para determinar la frecuencia, con $(f_s / f_y) = 4$ el error de frecuencia es de 9,955 % a $SNR > -2dB$, con $(f_s / f_y) = 10$ el error de frecuencia es de 1,045 % a $SNR > 13dB$).

El consumo de energía se minimiza y el rendimiento se maximiza en comparación con otros métodos utilizados en la RTBSS.

Comparado con el ED tiene una complejidad similar, requiere pocos recursos de hardware, tiene mejor rendimiento con pocas muestras y es 20 veces más rápido.

El documento está organizado de la siguiente manera. En la sección II se presenta el modelo del sistema. En la sección III se describe de manera general el sistema y los aspectos teóricos de los tres componentes principales, el acondicionamiento de la señal, la obtención de magnitudes instantáneas y el procesamiento estadístico con ventana deslizante. En la sección IV se describe el método SS-SPIM, el algoritmo y los pasos para su aplicación. En la sección IV se presenta la modelización de MATLAB con resultados numéricos

para la detección de la señal del FHSS en presencia de ruido blanco gaussiano aditivo (AWGN, en inglés). En la sección V se presentan las conclusiones.

Materiales y métodos

El SS se basa en determinar si una señal desconocida $S_x(t)$ está presente o no en una banda de interés. Como el ruido siempre está presente en todo proceso real y en el procesamiento digital funciona en un dominio discreto, se puede denotar como $S_y[n]$. El análisis para la decisión en SS puede resumirse en dos hipótesis H_0 (Solo ruido $w[n]$, PU ausente) y H_1 (Señal más ruido, PU presente) (Gafoor et al., 2018), representada por la Ec. .

$$S_y[n] = \begin{cases} S_x[n] + w[n], & H_1 \\ w[n], & H_0 \end{cases}$$

Para el umbral de decisión automática del detector, es conveniente evaluar independientemente el comportamiento de los eventos de detección. Inicialmente tendremos cuatro hipótesis. La señal se detecta cuando realmente hay una señal (TH_1) o verdadero positivo (TP), con una probabilidad $P(H_1RH_1)$. La señal se detecta cuando realmente es sólo ruido (FH_1) o falso positivo (FP), con probabilidad $P(H_1RH_0)$. La señal no se detecta y en realidad es sólo ruido (TH_0) o verdadero negativo (TN), con probabilidad $P(H_0RH_0)$. Y no se detecta la señal cuando realmente hay una señal (FH_0) o falso positivo (FP), con probabilidad $P(H_0RH_1)$, ver figura 1. Las probabilidades de ocurrencia para cada una de las hipótesis son calculadas por la Ec. , y .

REAL \ DETECT	Señal+ Ruido	Ruido
Señal+ Ruido	$TP = TH_1$	$FP = FH_1$
Ruido	$FN = FH_0$	$TN = TH_0$

Figura 1. Relación de probabilidad entre los eventos detectados y los reales en el proceso de detección.

$$P(H_1RH_1) = (\sum TH_1[n]) / N_H$$

$$P(H_0RH_0) = (\sum TH_0[n]) / N_H$$

$$P(H_0RH_1) = 1 - P(H_1RH_1)$$

$$P(H_1RH_0) = 1 - P(H_0RH_0)$$

Donde $TH_1[n]$ es la cantidad de detecciones correctas de señal presente para el número total de muestras, cuando la señal está realmente presente N_{H_1} y $TH_0[n]$ es la cantidad de decisiones correcta de no presencia de señal para un número total de muestras, cuando realmente sólo hay ruido N_{H_0} .

Los cálculos de la probabilidad total de decisiones correcta (P_{TT}) se realizan sumando las muestras que cumplen las hipótesis TH_1 and TH_0 entre las muestras totales (N) Ec. . El cálculo de la probabilidad total de decisiones incorrecta (P_{TF}) se realiza sumando las muestras que cumplen las hipótesis FH_1 y FH_0 entre N Ec.

$$P_{TT} = \frac{\sum [TH_1[n] + TH_0[n]]}{N}$$

$$P_{TF} = \frac{\sum [FH_1[n] + FH_0[n]]}{N}$$

Para el análisis, se dispone de una señal de banda limitada en tiempo continuo, descrita en Ec. . donde $A(t)$ es la amplitud de la señal en función del tiempo t con la frecuencia f_y y la fase θ .

$$S_y(t) = A(t) \cos(2\pi f_y t - \theta(t))$$

Descripción general del sistema.

En el caso del SS, mediante el procesamiento estadístico de las magnitudes instantáneas, el acondicionamiento de la señal y la obtención de los valores instantáneos deben realizarse previamente. El acondicionamiento de la señal tiene entre otras funciones, la de trasladar en frecuencia la señal de entrada $S(t)$ y obtener los valores discretos $I[n]$ and $Q[n]$ A partir de los valores discretos se calculan la amplitud instantánea $A_i[n]$, la fase instantánea $\theta_i[n]$ y la frecuencia instantánea $f_i[n]$. La $f_i[n]$ no es necesaria para el SS, puede ser usado en procesos de caracterización de las señales. Una vez obtenidos los valores instantáneos, se implementa la técnica de

detección propuesta. El diagrama en bloques general del procesamiento de la señal para la implementación de la propuesta se muestra en.

Acondicionamiento de señal

Si $S_y(t)$ es una señal compleja, tendremos dos componentes fundamentales, una en fase $I(t)$ y el otra en cuadratura $Q(t)$, que se describe en la Ec. .

$$S_y(t) = A(t) \{ \cos(2\pi f_y t) - j \sin(2\pi f_y t) \}$$

Para trabajar con señales complejas en tiempo discreto, podemos transformar $S_y(t)$ para obtener la Ec. , (ElAli, 2016), (Niranjan & Naik, 2014).

$$S_y[n] = I[n] \cos[2\pi f_y T_s n] - Q[n] \sin[2\pi f_y T_s n]$$

$$I[n] = A[n] \cos \theta[n]$$

$$Q[n] = A[n] \sin \theta[n]$$

Obtención de magnitudes instantánea.

El análisis integral de los valores instantáneos de las tres magnitudes, amplitud $A_i[n]$, fase $\theta_i[n]$ y frecuencia $f_i[n]$, puede utilizarse para determinar la presencia de una señal desconocida en tiempo real, identificar y estimar sus parámetros. (Zhu & Nandi, 2015), (Ortatatli et al., 2017), (Jiang & Suter, 2017).

Para las señales con un comportamiento de amplitud discontinua en el tiempo, se obtiene la envolvente de la amplitud $A_i[n]$, independientemente de su valor de frecuencia. A partir de la descomposición de la señal en sus componentes discretas de fase y cuadratura $I[n]$, $Q[n]$, se puede calcular la amplitud instantánea $A_i[n]$ por la Ec. .

$$A_i[n] = |S_i[n]| = \sqrt{I^2[n] + Q^2[n]}$$

Para medir la fase de la señal, el procesador necesita realizar dos operaciones fundamentales 1) calcular el arcotangente de la división entre $Q[n]$ y $I[n]$ para obtener la fase en el instante n , 2) calcular el

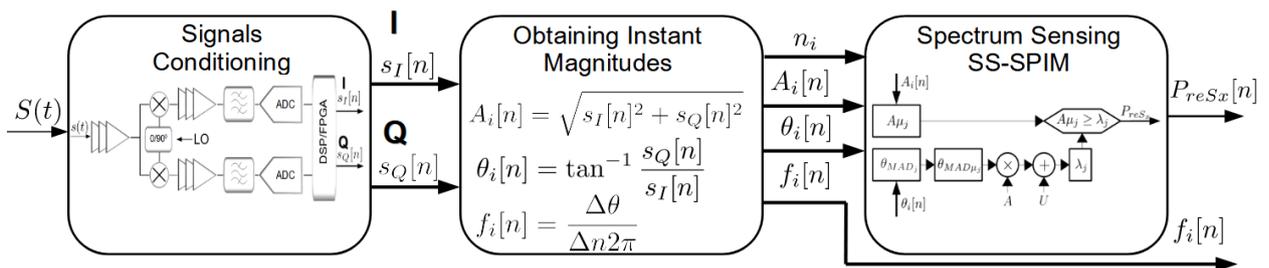


Figura 2. Diagrama en bloques del método de sensado de espectro mediante procesamiento estadístico de las magnitudes instantáneas (SS-SPIM).

desfase entre los diferentes intervalos n . Las expresiones utilizadas se describen en la Ec. and .

$$\theta_i[n] = \tan^{-1} \left[\frac{Q[n]}{I[n]} \right]$$

$$\Delta\theta_i[n] = \theta_i[n] - \theta_i[n-i] = 2\pi f_i T_s$$

Donde $\theta_i[n]$ representa el ángulo de la fase en el instante de tiempo n y $\Delta\theta_i[n]$ es la diferencia entre dos ángulos de fase separados por números enteros i del tiempo de muestreo T_s . Es aconsejable realizar los cálculos con valores de $i=1$.

Si se toman dos valores consecutivos de fase $\theta_i[n]$ y $\theta_i[n-1]$, la diferencia de tiempo $\Delta\theta_i[n]$ estará dada por Ec. . Para simplificar las operaciones necesarias, se obtiene la constante ω_s , la cual se deriva de la Ec. sustituyendo a T_s por $1/f_s$, Ec. . Por lo que la frecuencia instantánea f_i se determina según la Ec.

$$\Delta t = t_2 - t_1 = T_s$$

$$\omega_s = \frac{f_s}{2\pi}$$

$$f_i = \frac{\Delta\theta}{\Delta t 2\pi} = \Delta\theta \omega_s$$

Algorithm 1: Obtención de magnitudes instantáneas

Input: $I[n]$ and $Q[n]$

Output: $S_i[n]$ [Ec.(19)]

begin

PASO 1: Obtener parámetros iniciales $\theta_0[0]$ y ω_s

1.1 Calcular: $\theta_0[0]$ [Ec. (14)]

1.2 Calcular: ω_s [Ec. (17)]

for $n = 1$ **to** N **do**

$i = n;$

1 PASO 2: Obtener: $A_i[n]$ y $\theta_i[n]$

2.1 Calcular: $A_i[n]$ [Ec. (13)]

2.2 Calcular: $\theta_i[n]$ [Ec. (14)]

2 PASO 3: Obtener: $\Delta\theta_i[n]$

3.1 Calcular: $\Delta\theta_i[n]$ [Ec. (15)]

3 PASO 4: Obtener: $f_i[n]$

4.1 Calcular: $f_i[n]$ [Ec. (18)]

4 PASO 5: Sincronismo

5.1 Obtener: $S_i[n]$ [Ec. (19)]

En (García, 2020) se presenta un algoritmo que obtiene las magnitudes instantáneas en tiempo real de una señal desconocida (**Algoritmo 1**). La matriz de vectores $S_i[n]$ obtenida, está compuesta por los vec-

tores con las magnitudes instantáneas, amplitud, fase y frecuencia indexadas por el número de muestra que se describe en la Ec. .

$$S_i[n] = \begin{bmatrix} n_i \\ A_i[n] \\ \theta_i[n] \\ f_i[n] \end{bmatrix}$$

Procesamiento estadístico con ventana deslizante.

En el procesamiento estadístico con ventana deslizante, donde (k) es la longitud de ventana, se procesan las k muestras previas del elemento actual i dentro del vector X . Los elementos se desplazan dentro de la ventana, con un incremento $i+1$. Como resultado, se obtiene un nuevo vector de igual longitud con los valores procesados (X_e). El número de muestras mínimas (N_m) necesarias para obtener el primer valor de X_e , depende del valor k y su paridad o no, Ec. . El retardo introducido (D_{SW}) depende de N_m y del período de muestreo ($T_s = 1/F_s$), y puede ser calculado por la Ec. .

$$N_m = \begin{cases} \lfloor k/2 \rfloor + 1, & k\{Odd\} \\ \lfloor k/2 \rfloor, & k\{Even\} \end{cases}$$

$$D_{SW} = (N_{Sm} - 1)T_s$$

La elección del valor k para cada estadístico depende de la frecuencia de la señal (f_y), la frecuencia de muestreo (f_s) y el tiempo de duración mínima en nivel alto de la señal detectada ($T_{A_{min}}$). El valor óptimo de k se obtiene mediante la Ec. .

$$k = \frac{f_s}{f_y}$$

En una señal de FHSS, cada salto se realiza a diferentes frecuencias, por lo que en la Ec. f_y debe reemplazarse por la frecuencia más baja probable. Por otra parte, si para el cálculo del promedio el tamaño de la ventana (k_μ) es igual o mayor que el número de muestras totales del salto de duración mínima, el promedio de la amplitud instantánea dará valores menores que el real. Por lo tanto, para una señal FHSS el valor de k_μ debe seleccionarse mediante la Ec. .

$$\frac{f_s}{f_{y_{min}}} \leq k_\mu < T_{A_{min}} f_s$$

Algorithm 2: Algoritmo de sensado de espectro SS-SPIM

Input: $A_i[n]$ y $\theta_i[n]$ [Ec.(19)]
Output: $P_{reSx}[n]$
begin
 for $n = 1$ **to** N **do**
 $j = n$;
 PASO 1: Procesamiento estadístico
 1.1 Calcular: $A_{\mu j}$ [Ec. (26)]
 1.2 Calcular: θ_{MADj} [Ec. (27)]
 1.3 Calcular: $\theta_{MAD\mu j}$ [Ec. (28)]
 PASO 2: Determinación del umbral
 2.1 Calcular el umbral de detección: λ_j [Ec. (29)]
 PASO 3: Detección de señal
 if ($A_{\mu j} > \lambda_j$) **then**
 | $P_{reSx}[n] = 1$
 else
 | $P_{reSx}[n] = 0$

Detección basada en el método SS-SPIM

EL SS por medio de las magnitudes instantáneas requiere un procesamiento estadístico de los valores calculados. La solución busca procesar y obtener la información necesaria con el menor uso de recursos de hardware y tiempo. Para reducir los efectos de las variaciones a corto plazo causadas por el ruido, una forma de filtrar es promediar los datos. Para la amplitud instantánea, los estadísticos más útiles son las relacionadas con la centralización, la media y la mediana. Los niveles de amplitud instantánea, indican la presencia de la señal en la banda del espectro analizado. Para la fase instantánea, la DMA se puede utilizar para determinar el umbral de decisión en la detección automática. Estos estadísticos deben ser calculadas previamente para realizar la detección. El **Algoritmo 2** describe el SS con el método SS-SPIM.

Procesamiento estadístico de las magnitudes instantáneas.

Cada estadístico tiene su propio valor de longitud de ventana k , para la media de la amplitud instantánea ($k_{A\mu}$), para la desviación absoluta respecto a la mediana ($k_{\theta_{MAD}}$), para la media de la desviación absoluta respecto a la mediana ($k_{\theta_{MAD\mu}}$) y para la media de frecuencia instantánea ($k_{F\mu}$).

A fin de mantener el sincronismo entre las muestras, los valores de longitud de la ventana deben ser iguales, tal como se muestra en la Ec. , para obtener $k_{A\mu}$ se utiliza la Ec. . El valor de $k_{\theta_{MAD}}$ debe ser impar.

Si la ventana es muy grande, el resultado descartará cambios importantes en la fase instantánea. De esta forma $k_{\theta_{MAD}}$ toma un valor constante de tres unidades $k_{\theta_{MAD}} = 3$. Basado en la Ec. , $k_{\theta_{MAD\mu}}$ es calculado por la Ec. .

$$k_{A\mu} = k_{F\mu} = k_{\theta_{MAD}} + 2$$

$$k_{\theta_{MAD\mu}} = k_{A\mu} - 2$$

Una vez obtenida la amplitud instantánea, para reducir las variaciones causadas por el ruido, se procesa promediando las muestras. El promedio de la variable A_i se calcula utilizando la Ec. .

$$A_{\mu j} = \frac{1}{k_{A\mu}} \sum_{i=j-\lfloor k/2 \rfloor}^{j+N_m-1} A_i$$

Donde k es la longitud de la ventana y A_i se calcula empleando la Ec. y N_m son las muestras mínimas requeridas según Ec. .

En el caso del análisis de fase instantánea, la desviación media absoluta (MAD, por sus siglas en inglés) es una medida muy útil para determinar si las variaciones corresponden a ruido aditivo solo o con señal. La MAD de la fase instantánea, (θ_{MADj}) se obtiene con la Ec. . El resultado obtenido debe ser promediado, para reducir la dispersión de los valores. Entonces se obtiene ($\theta_{MAD\mu j}$) a través de la Ec. .

$$\theta_{MADj} = Med(|\theta_i - Med(\theta)|)$$

$$\theta_{MAD\mu j} = \frac{1}{k_{\theta_{MAD\mu}}} \sum_{i=j-\lfloor k/2 \rfloor}^{j+N_m-1} \theta_{MADi}$$

Determinación del umbral

El siguiente reto es tomar la decisión que permita para diferentes SNR determinar cuál de las dos hipótesis H_0 o H_1 es válida. Esto implica la necesidad de determinar el umbral de decisión a partir del cual, al compararlo con la media de la amplitud instantánea, se pueda seleccionar la hipótesis correcta. A partir del análisis del procesamiento estadístico de la fase instantánea, se determinó que la desviación absoluta con respecto a la mediana θ_{MAD} arroja valores mínimos en presencia de señal más ruido y máximos cuando sólo hay ruido. Estos valores fluctúan de una muestra a otra debido al comportamiento del ruido, por lo que es necesario promediar el resultado y obtener $\theta_{MAD\mu j}$.

Si la SNR es muy grande los valores mínimos de $\theta_{MAD\mu j}$ están muy cerca de 0, esto causa errores en la

toma de decisiones. Por otro lado, cuando SNR está cerca de 0 dB o menos, $\theta_{MAD\mu_j}$ no tiene la amplitud necesaria o el desplazamiento respecto a 0 para una decisión correcta. También se tiene en cuenta que la magnitud de $\theta_{MAD\mu_j}$ está en radianes y siempre estará en el rango entre 0 y π . Esto implica establecer una constante que modifique el límite mínimo y la escala de los valores de $\theta_{MAD\mu_j}$. La solución propuesta para este fenómeno es modificar los valores de $\theta_{MAD\mu_j}$ con las constantes U y A para obtener el umbral de decisión automático (λ_j) para cada índice j como se muestra en la Ec. . Una aproximación para obtener los valores de U y A puede ser a través de la Ec. .

$$\lambda_j = U + A \times \theta_{\mu MAD_j}$$

$$A = X - U \begin{cases} 0 > U \leq 0.3 \\ 1.3 > X \leq 1.5 \end{cases}$$

Donde $\theta_{MAD\mu_j}$ es el vector que contiene los valores promediados de la desviación absoluta de la mediana. A es la constante que controla el escalado de $\theta_{MAD\mu_j}$. U es la constante que introduce el desplazamiento de los valores $A \times \theta_{MAD\mu_j}$. El umbral automático λ_j se compara con la amplitud instantánea promedio $A\mu_j$, como resultado se obtiene la variable $P_{resx}[n]$ que determina la presencia o no de la señal de interés.

La **Tabla 1** representa el mapa de asignación de valores para retardo mínimo, ordenado por el número de muestras, de los parámetros involucrados en la detección. Se muestra como λ_j tiene valores disponibles para

n_i [Eq. (19)]	1	2	3	4	...
A_i [Eq. (19)]	A_1	A_2	A_3	A_4	$A...$
$A\mu_j$ ($k = 4$) [Eq. (26)]	-	$A\mu_1$	$A\mu_2$	$A\mu_3$	$A\mu...$
θ_i [Eq. (19)]	θ_1	θ_2	θ_3	θ_4	$\theta...$
θ_{M_j} ($k = 3$) [Eq. (27)]	-	θ_{M_1}	θ_{M_2}	θ_{M_3}	$\theta_{M...}$
$\theta_{\mu M_j}$ ($k = 2$) [Eq. (28)]	-	$\theta_{\mu M_1}$	$\theta_{\mu M_2}$	$\theta_{\mu M_3}$	$\theta_{\mu M...}$
λ_j [Eq. (29)]	-	λ_1	λ_2	λ_3	$\lambda...$

realizar la detección a partir de la segunda muestra.

Tabla 1. Mapeo de valores para retardo mínimo.

La decisión es evaluada en cada tiempo de muestra $j = n$ por la Ec. . La variable $P_{resx}(t)$ toma valores en el tiempo entre uno y cero dependiendo de la presencia o no de la señal. La Ec. muestra los posibles valores en función del número de muestra.

$$A\mu_j \geq \lambda_j$$

$$P_{resx}[n] = \begin{cases} 1, & n_{IH} \leq n \leq n_{FH} \\ 0, & n_{IL} \leq n \leq n_{FL} \end{cases}$$

Donde n_{IH} es el número de muestra que coincide con el momento en que la señal comienza a ser detectada $t_{IH} \cdot n_{FH}$ es el número de muestra que coincide con el instante de tiempo en que la señal deja de ser detectada $t_{FH} \cdot n_{IL}$ es el número de muestra que coincide con el instante de tiempo en que sólo se empieza a detectar el ruido $t_{IL} \cdot n_{FL}$ es el número de muestra que coincide con el instante de tiempo en que se deja de detectar sólo ruido t_{FL} .

El diagrama de flujo del método SS-SPIM descrito en **Algoritmo 2** se muestra en la Figura 3. Donde $A\mu_j$ es calculada por Ec. , θ_{MAD_j} por la Ec. , $\theta_{MAD\mu_j}$ por la Ec. y λ_j por la Ec. .

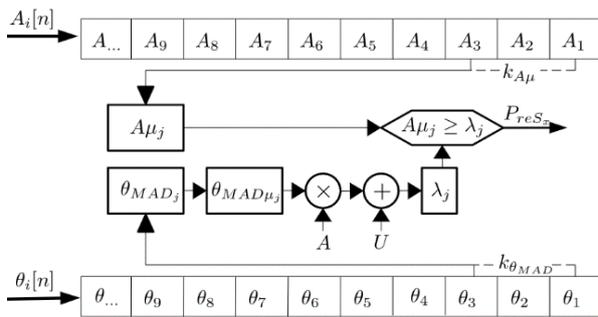


Figura 3. Diagrama de flujo para algoritmo de sensado de espectro basado en el procesamiento estadístico de las magnitudes instantáneas (SS-SPIM).

Resultados numéricos y discusión.

El experimento se llevó a cabo en MATLAB, utilizando el código presentado por [28]. El generador se implementó programando las expresiones matemáticas de las señales con manipulación pseudo aleatoria de la frecuencia portadora (FHSS). Para la adición de ruido aditivo, se utilizó la función (*awgn(x,snr,'medio')*), donde x es la señal generada $S_x[n]$

Prueba de umbral

Para comprobar la eficiencia del parámetro $\theta_{MAD\mu_j}$ utilizado en el umbral de detección automática (λ_j), se analiza la función de densidad de probabilidad (PDF, en inglés) con media μ y la varianza σ^2 . Se determina la PDF para las hipótesis H_0 y de las variables $A\mu_j$ y $\theta_{\mu MAD_j}$ para la comparación Fig 4 a) and b). La PDF de H_0 y H_1 de $A\mu_j$ se representa por ($A\mu_j H_1$) trazo rojo y ($A\mu_j H_0$) trazo azul respectivamente. Se realizaron cálculos para $SNR = 5dB$ y $N = 2$.

La Figura. 4 a) representa la PDF de $\theta_{MAD\mu_j}$ para H_1 ($\theta_{MAD\mu_j}H1$) trazo negro y para H_0 ($\theta_{MAD\mu_j}H0$) trazo verde. Se observa como $\mu(\theta_{MAD\mu_j}H1) < \mu(A\mu_jH1)$ con solapamiento mínimo, lo que garantiza un $P_d > 0.9$. En el caso de H_0 $\mu(\theta_{MAD\mu_j}H0) > \mu(A\mu_jH0)$ pero hay un solapamiento significativo por lo tanto $P_f \gg 0.1$. Es por eso que el estadístico $\theta_{MAD\mu_j}$ requiere un desplazamiento U y un escalado A para garantizar la correcta detección (Ec.). La Figura. 4 b) representa la PDF de λ_j para H_1 (λ_jH1) trazo negro y para H_0 (λ_jH0) trazo verde. Es cierto que $\mu(\lambda_jH1) < \mu(A\mu_jH1)$ garantiza una $P_d > 0.95$, con una mínima superposición, lo que garantiza un $P_d > 0.95$, en este caso para H_0 $\mu(\lambda_jH0) > \mu(A\mu_jH0)$ con una mínima superposición, así que $P_f < 0.01$.

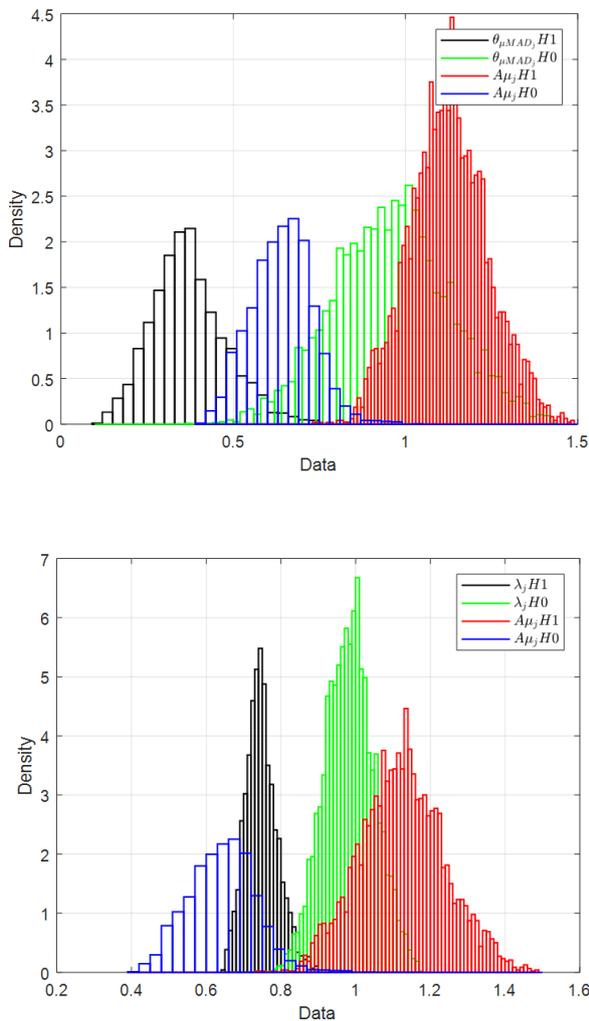


Figura 4. PDF de las hipótesis H_1 y H_0 de $A\mu_j$ comparada con a) $\theta_{MAD\mu_j}$, b) λ_j . $SNR = 5dB$, $N = 2$.

El algoritmo de detección controla el valor umbral con dos constantes (U y A) como se expresa en la Ec. . Para determinar los valores apropiados de U y A , se determinó la probabilidad de decisión correcta total para diferentes valores de estas constantes en base a SNR hasta la Ec. . La Figura 5 muestra los resultados.

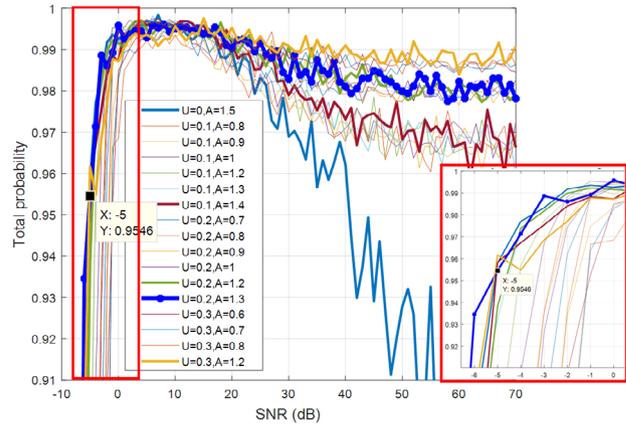


Figura 5. Probabilidad de detección total para diferentes valores de U y A según SNR.

Para ($U = 0,2$ y $A = 1,3$), (línea azul gruesa) está entre la mejores respuestas de probabilidad total, hay un equilibrio en los valores para $SNR > 10dB$ y $SNR < 10dB$. Aunque para el rango de $-5 < SNR < -1$ las probabilidades son mayores de 0,95, es en el área de mayor inestabilidad, por lo que se establece como límite mínimo de $-5dB$. Para valores de $U = 0$ (Color Azul Claro) Figura 5 la P_{TT} disminuye mientras que el SNR aumenta. Es por eso que $U \neq 0$.

Precisión

Para determinar la sensibilidad frente a la especificidad del detector al variar el umbral, se determinó la curva característica operativa del receptor (ROC) para varios casos, $SNR = -5, 0, 5dB$ y el número de muestras $N = 2, 15$ Figura 6. El gráfico muestra cómo el método SS-SPIM puede realizar la detección del espectro con $P_d > 0,9$ y $P_f < 0,1$ para $N = 15$, $SNR = -5$ (Trazo azul), y para $N = 2$, $SNR = 0$ (Trazo amarillo). Se obtienen mejores respuestas con $N = 2$, $SNR = 5$ (trazo púrpura) y por $N = 15$, $SNR = 0$ (trazo rojo) donde se obtienen $P_d > 0,99$ y $P_f < 0,005$. Esto demuestra la capacidad del método para detectar señales con sólo dos muestras y SNR baja.

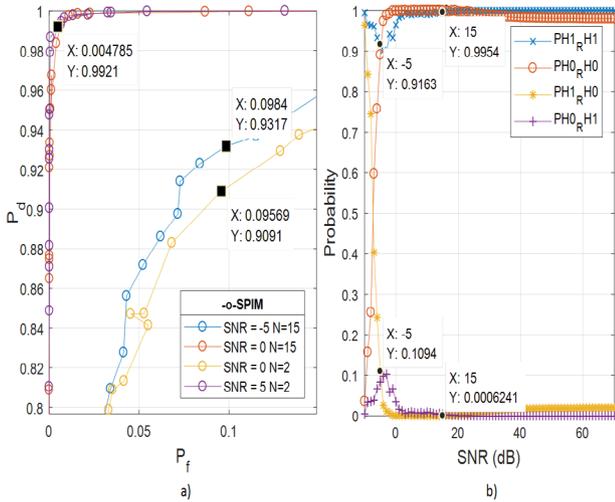


Figura 6. Curva ROC del método SS-SPIM para SNR y N mínima.

El método SS-SPIM puede proporcionar valores instantáneos de amplitud y frecuencia, útiles en aplicaciones en las que, además de la detección, es necesario estimar los parámetros de la señal. La precisión de estos parámetros en presencia de ruido AWGN se muestra en la Figura 7. La figura representa las curvas del Error Medio Absoluto (MAE), la amplitud (línea azul con círculos) y la frecuencia instantánea, calculadas para diferentes relaciones de frecuencia de muestreo y frecuencia de señal (f_s / f_y). Los valores se normalizaron para representar la magnitud del error en porcentaje con respecto al valor real.

Para la medición de la amplitud ($ErrAm_i$), hay errores por debajo del 1% para $SNR > 10dB$ y para $SNR < 4dB$ los errores son mayores del 5%. Para las mediciones de frecuencia ($ErrFr_i$), los errores dependen de la relación f_s / f_y . Cuanto más baja es la relación, mayor es el error de la constante (Err_c) para todos los SNR y menor es el error límite para el SNR mínimo ($Err_L @ SNR$) donde los errores se vuelven mayores que la constante. (es decir, para $(f_s / f_y) = 4$ el $Err_c = 9.955\%$ y el $Err_L = 9.749 @ -2dB$) (Trazo amarillo Figura 7). Por $(f_s / f_y) = 10$ el $Err_c = 1.644\%$ y el $Err_L = 1.046 @ 13dB$ (Rastreo Rojo Figura 7).

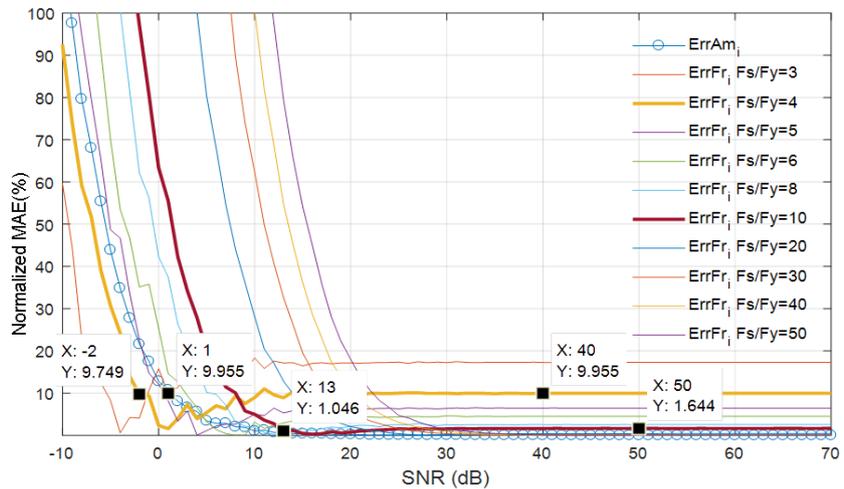


Figura 7. Errores en la determinación de amplitud y frecuencia para diferentes SNR y relaciones F_s / F_y .

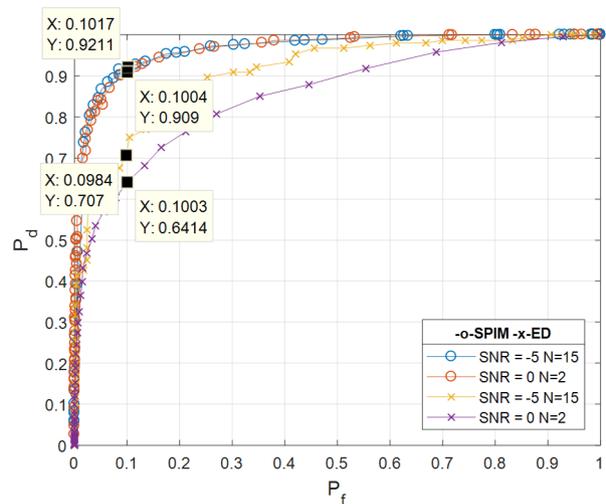


Figura 8. Curva ROC comparativa con el método ED. Para SNR = -5dB y 0dB, cantidad de muestras N=15 and 2

Desempeño

Para analizar el desempeño, el método SS-SPIM se compara con el detector de energía (ED, siglas en inglés). Primero, se analiza la curva ROC para ambos métodos y una configuración similar, Figura 8. Para $N=15$, $SNR = -5dB$ y $N=2$, $SNR = 0dB$ el método SS-SPIM detecta con $P_d > 0.9$ para un $P_f = 0.1$. El ED para la misma P_f , N y SNR, es $P_d < 0.75$ y $P_d < 0.65$ respectivamente. Se demuestra entonces que el método SS-SPIM posee mejor desempeño respecto al ED con un P_d más alta requiriendo pocas muestras $N \leq 15$.

La complejidad computacional se analiza en la Tabla 2 y se compara con el enfoque ED como el menos complejo para la RTBSS. En cuanto a las operaciones matemáticas del método, no se realiza ninguna multiplicación desde la y Eq. pueden resolverse

utilizando tablas LUT. Para determinar el promedio de las magnitudes o parámetros de la Ec. y Ec. es necesario realizar N sumas de por cada una, para un total de $2N$. El tiempo de demora se calcula por la Ec. , se añade T_s que se produce al implementar el Algoritmo. Por el mínimo de N se tiene en cuenta que debe cumplir con $P_d \geq 0.9$ y $P_f \leq 0.1$.

Approach	Multip.	Add.	Delay	N Min.
SPIM	(LUT)	$2N$	$(1 + N)T_s$	2
Energy Detector [20]	N	N	$N * T_s$	25

Tabla 2. Requerimientos computacionales y retardos

El método SS-SPIM tiene una complejidad computacional similar al ED, lo que lo hace fácil de implementar con recursos de hardware reducidos. Al requerir menos muestras que el ED (≈ -20) es más rápido al realizar el SS.

Conclusiones

Este artículo presenta y analiza los resultados numéricos del enfoque para RTBSS basado en el procesamiento estadístico de magnitud instantánea denominado SS-SPIM. La solución propuesta logra los siguientes resultados principales: Permite detectar la presencia de señales con solo dos muestras y relaciones SNR $> -5dB$; Tienen baja complejidad de implementación y requieren pocos recursos de hardware; Permite caracterizar el comportamiento temporal, en amplitud y frecuencia de la señal. El método SS-SPIM aporta eficiencia energética, seguridad y predicción de tráfico PU en CRNs. El análisis de precisión y rendimiento muestra una característica superior en comparación con ED y sus posibles aplicaciones en CR, Radar, EW, IoT y sistema de procesamiento de señales.

Referencias Bibliográficas

- Amrutha, V., & Karthikeyan, K. V. (2017, February 2017). *Spectrum sensing methodologies in cognitive radio networks: A survey*. Paper presented at the 2017 International Conference on Innovations in Electrical, Electronics, Instrumentation and Media Technology (ICEEIMT).
- Arjoune, Y., Salahdine, F., Islam, M. S., Ghribi, E., & Kaabouch, N. (2020, January 2020). *A Novel Jamming Attacks Detection Approach Based on Machine Learning for Wireless Communication*. Paper presented at the 2020 International Conference on Information Networking (ICOIN).
- Access*, 7, 115339-115347. doi:10.1109/ACCESS.2019.2935735
- Awin, F., Abdel-Raheem, E., & Tepe, K. (2019). Blind Spectrum Sensing Approaches for Interweaved Cognitive Radio System: A Tutorial and Short Course. *IEEE Communications Surveys Tutorials*, 21(1), 238-259. doi:10.1109/COMST.2018.2863681
- Bagwari, A., Tuteja, S., Bagwari, J., & Samarah, A. (2020, April 2020). *Spectrum Sensing Techniques for Cognitive Radio: A Re-examination*. Paper presented at the IEEE 2020 9th International Conference on Communication Systems and Network Technologies (CSNT).
- El-Alfi, N. A., Abdel-Atty, H. M., & Mohamed, M. A. (2019). Sub-Nyquist Cyclostationary Detection of GFDM for Wideband Spectrum Sensing. *IEEE Access*, 7, 86403-86411. doi:10.1109/ACCESS.2019.2925047
- ElAli, T. S. (2016). *Discrete Systems and Digital Signal Processing with MATLAB* (Second Edition ed.): CRC Press.
- Gafoor, R. A., Kuriakose, R., M, S., K, L. C., S, R., & Kumar, A. S. (2018, March 2018). *A Survey on Traditional and Advanced Spectrum Sensing Techniques in Cognitive Radio Networks*. Paper presented at the 2018 International Conference on Control, Power, Communication and Computing Technologies (ICCPCT).
- Gao, J., Yi, X., Zhong, C., Chen, X., & Zhang, Z. (2019). Deep Learning for Spectrum Sensing. *IEEE Wireless Communications Letters*, 1-1. doi:10.1109/LWC.2019.2939314
- García, J. Y. H. (2020). Determination of instantaneous features of signals for real-time applications in cognitive radio. *Revista Telemática*, 18(2), 78-95.

- Hernández, M. G., Gómez, J. T., & Hourné, E. A. P. (2018). Digital spectrum sensing technique implemented on FPGA devices for digital television applications. *RIELAC*, XXXIX(2/2018), 10-23.
- Jiang, Q., & Suter, B. W. (2017). Instantaneous Frequency Estimation Based on Synchrosqueezing Wavelet Transform. *Signal Processing*. doi:10.1016/j.sigpro.2017.03.007
- Kumar, A., Saha, S., & Bhattacharya, R. (2016, June 2016). *Improved wavelet transform based edge detection for wide band spectrum sensing in Cognitive Radio*. Paper presented at the 2016 USNC-URSI Radio Science Meeting.
- Miridakis, N. I., Tsiftsis, T. A., & Yang, G. (2020). Generalized Energy Detection Under Generalized Noise Channels. *IEEE Wireless Communications Letters*, 1-1. doi:10.1109/LWC.2020.3009677
- Miridakis, N. I., Tsiftsis, T. A., & Yang, G. (2020). Moment-based Spectrum Sensing Under Generalized Noise Channels. *IEEE COMMUNICATIONS LETTERS*, 1-1. doi:10.1109/LCOMM.2020.3023740
- Mosa, B., & Algamluoli, A. F. (2017). Performance of Energy Detector for Cognitive Radio System over AWGN and Rayleigh Channel. *International Journal of Computer Applications*, 167(3).
- Nasser, A., Muta, O., Elsabrouty, M., & Gacanin, H. (2019). Compressive Sensing Based Spectrum Allocation and Power Control for NOMA HetNets. *IEEE Access*, 7, 98495-98506. doi:10.1109/ACCESS.2019.2929185
- Niranjan, R., & Naik, B. R. (2014, August 2014). *FPGA based implementation of pulse parameters measurement*. Paper presented at the 2014 Science and Information Conference.
- Ortatatli, I. E., Orduyilmaz, A., Özdil, Ö., Serin, M., Gürel, A. E., Yildirim, A., & Kurt, H. (2017, May 2017). *Real-time instantaneous radar frequency measurement for pulse on pulse condition*. Paper presented at the 2017 25th Signal Processing and Communications Applications Conference (SIU).
- Patel, C. A., & Vithalani, C. H. (2014). Compressive Spectrum Sensing: An Overview. *International Journal of Innovative Research in Electronics and Communications (IJIREC)*, 1(6), 1-10.
- Salahdine, F., Ghazi, H. E., Kaabouch, N., & Fihri, W. F. (2015, October 2015). *Matched filter detection with dynamic threshold for cognitive radio networks*. Paper presented at the IEEE 2015 International Conference on Wireless Networks and Mobile Communications (WINCOM).
- Shaban, M., & Bayoumi, M. (2016, July 2016). *On sub-Nyquist spectrum sensing for wideband cognitive radios*. Paper presented at the 2016 Eighth International Conference on Ubiquitous and Future Networks (ICUFN).
- Wasayangkool, K., Ngahom, C., Klomnak, P., Pakdeejun, S., Leelachai, R., & Kraiyawong, S. (2020, March 2020). *A Performance Comparison of four Moderns Spectrum Sensing techniques under Noise Uncertainty and different User Accessing Time*. Paper presented at the IEEE 2020 8th International Electrical Engineering Congress (iEECON).
- Yang, B., Chi, H., Yang, S., Cao, Z., Ou, J., & Zhai, Y. (2020). Broadband Microwave Spectrum Sensing Based on Photonic RF Channelization and Compressive Sampling. *IEEE Photonics Journal*, 12(1), 1-9. doi:10.1109/JPHOT.2019.2960377
- Zhang, P. (2019, May 2019). *Energy Detection using Savitzky-Golay Smoothing Method for Spectrum Sensing in Cognitive Radio*. Paper presented at the IEEE 2019 8th Joint International Information Technology and Artificial Intelligence Conference (ITAIC).
- Zhao, Y., Chen, Y., Zheng, Y., Zhuang, Y., & Wen, W. (2019). Wideband Power Spectrum Estimation Based on Sub-Nyquist Sampling in Cognitive Radio Networks. *IEEE*
- Zhu, Z., & Nandi, A. K. (2015). *Automatic Modulation Classification: Principles, Algorithms and Applications*: Wiley.

