

ESTIMACIÓN DEL NÚMERO DE SEÑALES EN ANTENAS INTELIGENTES BASADA EN REDES NEURONALES

Yunior Ibarra Guerra¹, Alexander R. Ramírez Zaldívar¹, José E. Vargas Fernández¹, Noslen Rojas Ramírez¹

¹Centro de Investigación y Desarrollo de Electrónica y Mecánica, “CID MECATRONICS”, Calle 15 y 86A, Playa, La Habana, Cuba
¹email: cid3@reduim.cu

RESUMEN

La estimación del número de señales incidentes es un problema de vital importancia en los sistemas de antenas inteligentes para reajustar de forma adaptativa el patrón de radiación. El rendimiento de los métodos tradicionales en este campo se ve gravemente degradado en algunas condiciones extremas como un tiempo de observación de las señales relativamente corto, una baja relación señal/ruido (SNR, por sus siglas en inglés) o una estructura de covarianza de ruido arbitraria. Recientemente, el aprendizaje automático se ha utilizado para la estimación del número de señales debido a las ventajas de no requerir configuraciones de parámetros subjetivos y estar basado en datos. Sin embargo, posee como deficiencia fundamental la fluctuación en el rendimiento en entornos complejos, por lo que es necesario un mayor número de muestras de entrenamiento. En vista de este problema, se propone un esquema de preprocesamiento y una red neuronal para manifestar las características de los datos de entrada. El esquema concebido ajusta el rango de los datos de entrada en tiempo real para mejorar la capacidad de predicción y reducir las muestras de entrenamiento. El método propuesto permite la aplicación de algoritmos más simples para el proceso de clasificación enfocado en la detección de señales. Los resultados experimentales y de simulación verifican que los esquemas propuestos son capaces de mejorar el rendimiento de la estimación al tiempo que reducen el costo computacional.

PALABRAS CLAVES: Estimación de número de fuentes de señal, Aprendizaje automático, procesamiento de arreglo de señales.

SIGNALS NUMBER ESTIMATION IN SMART ANTENNAS BASED ON NEURAL NETWORKS

ABSTRACT

Incident signals number estimation is a vital importance problem in smart antenna systems to adaptively readjust the radiation pattern. The performance of traditional methods in this field is seriously degraded in some extreme conditions such as observation of relatively short signals, a low signal/noise ratio (SNR) or an arbitrary noise covariance structure. Recently, machine learning has been used to estimate the number of signals due to the advantages of not requiring subjective parameter settings and being based on data. However, it has as fundamental deficiency the fluctuation in performance in complex environments, so a greater number of training samples is necessary. In view of this problem, a preprocessing scheme and a neuronal network are proposed to manifest the characteristics of the input data. The conceived scheme adjusts in real time the input data range to improve prediction capacity and reduce training samples. The proposed method allows the application of simpler algorithms for the classification process focused on signal detection. Experimental and simulation results verify that the proposed schemes are able to improve estimation performance while reducing the computational cost.

INDEX TERMS: Source signal number estimation, Machine learning, Array signal processing

1. INTRODUCCIÓN

El interés por los sistemas de antenas inteligentes ha aumentado en la última década con el desarrollo de tecnologías inalámbricas emergentes como el uso de 5G [1, 2], Internet de las cosas [3, 4], radares para vehículos autónomos [5] y redes inalámbricas de sensores (WSN) [6]. Las antenas inteligentes optimizan su diagrama direccional de forma

autónoma mediante el procesamiento espacio-temporal de las señales provenientes de un conjunto de antenas. Con respecto a las antenas convencionales, sus principales ventajas son una mejor cobertura, eficiencia espectral, capacidad de canal y elevada robustez al efecto multitrayecto, la interferencia e interceptación de las señales [7]. La Figura 1 muestra un diagrama funcional genérico de un sistema de antenas inteligentes, el cual debe dirigir los máximos del patrón de radiación de la antena hacia la dirección de las fuentes de interés θ_2 y θ_3 y formar nulos en la de la interferencia θ_1 . Para realizar esta función, luego de la conversión analógico-digital de las señales de radio recibidas de forma independiente por cada antena, el sistema de procesamiento debe ponderar cada uno de los canales de recepción con coeficientes de pesos.

El proceso de formación de los coeficientes de pesos generalmente se implementa por métodos adaptativos y requiere el conocimiento a priori de la dirección de incidencia, tanto de las señales de interés como de las interferencias. El proceso de determinación de este parámetro se conoce como estimación de la Dirección de Arribo o Ángulo de Arribo (DOA y AOA, por sus siglas en inglés, respectivamente) [1, 8-11].

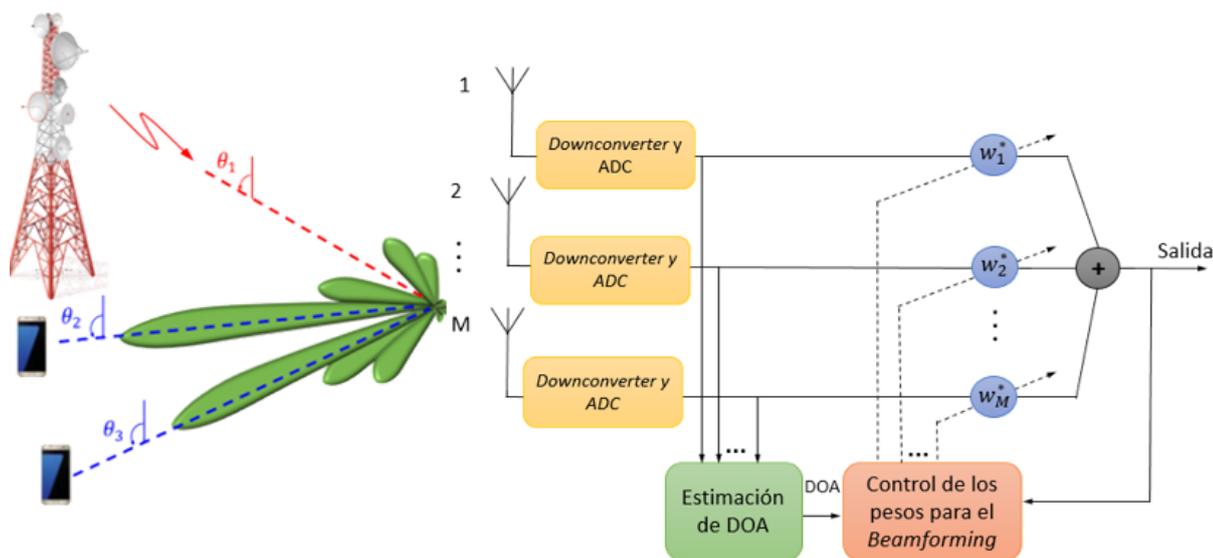


Figura. 1: Diagrama funcional de un sistema de antenas inteligentes.

En varios algoritmos de estimación de DOA propuestos, se asume que se conoce el número de señales incidentes [7,11,12]. Sin embargo, este parámetro es desconocido en la práctica y debe estimarse a partir de las muestras recibidas en el arreglo de antenas. En la literatura han sido ampliamente empleados varios métodos clásicos para resolver el problema de estimación del número de señales incidentes en los arreglos de antenas [13, 14]. Los más conocidos incluyen pruebas de hipótesis anidadas y métodos basados en la teoría de la información sobre los valores propios de la matriz de covarianza espacial [13, 14]. El principal inconveniente que estos presentan es que, en circunstancias críticas, como un bajo número de muestras, elementos del arreglo de antena y SNR, su rendimiento puede degradarse gravemente y la mayoría de los métodos de estimación de DOA tienden a arrojar resultados inestables.

A diferencia de los métodos de detección, la mayor parte de los métodos de estimación de DOA aún pueden tener un buen desempeño en escenarios donde los valores propios de la señal y el ruido son claramente diferenciables. Este hecho motivó la aplicación de algoritmos de aprendizaje automático basados en la observación directa de los valores propios para tratar el problema con un enfoque de clasificación [15, 16] o agrupamiento [17]. Aunque los algoritmos de aprendizaje automático se han aplicado en áreas de procesamiento de señales de arreglos de antenas, como la estimación de DOA y la formación de haces, solo unos pocos trabajos se centran en la estimación del número de fuentes emisoras [18]. En comparación con los métodos tradicionales, los que aplican el aprendizaje automático no están limitados por las suposiciones del modelo porque se basan en los datos de entrada y pueden proporcionar mejores rendimientos con una SNR baja y menor número de muestras.

En [15], los autores proponen una red de regresión (ERNet) y una red de clasificación (ECNet) para la estimación del número de fuentes emisoras en función de los valores propios de la matriz de covarianza de la señal recibida. Los resultados numéricos muestran las mejoras sobre las soluciones existentes. Aunque este método utiliza la información de bajo rango de la señal recibida, su desempeño es fluctuante debido a que los valores propios pueden tomar valores arbitrarios dependiendo de la ortogonalidad del ruido y el subespacio de la señal. El principal inconveniente es que el clasificador produce resultados erróneos en condiciones diferentes a las concebidas durante la etapa de entrenamiento [16]. La situación existente demanda el diseño de un clasificador más complejo y con una fase de entrenamiento más prolongada en entornos comunes donde el número de emisores y su posición espacial es diverso y las señales involucradas tienen diferentes duraciones de tiempo y SNR. Además, las diferencias en la disposición del hardware y la antena utilizados también pueden determinar que la magnitud de los valores propios en un sistema real difiera de los utilizados durante el entrenamiento.

En vista de este problema, en [19], los autores proponen dos esquemas de preprocesamiento para resaltar en mayor medida las características de entrada del modelo de la red en función de las características estadísticas de los valores propios de la matriz de covarianza espacial. Los valores de entrada transformados por los métodos de preprocesamiento propuestos, poseen distribuciones específicas que pueden mejorar la discriminación entre características por lo que se aumenta la capacidad de predicción de la red. Aunque estos métodos tienen rendimientos superiores a los existentes, el principal inconveniente es que las distribuciones de ruido supuestas solamente son válidas con un gran número de antenas y un tamaño de muestras que no siempre es posible en escenarios reales [19]. Además, el esquema propuesto utiliza los mismos esquemas de redes neuronales que la propuesta en [6] por lo que requiere más muestras de entrenamiento y una complejidad considerable. Para resolver este problema, en [17], cada valor propio se normaliza con respecto a la traza de la matriz de covarianza que es igual a la suma de todos los valores propios. Luego, los autores proponen dos enfoques de enumeración de fuentes utilizando la proporción de la separación de los valores propios y el umbral entrenado por un algoritmo de agrupamiento. Este enfoque puede dar resultados engañosos en el caso de señales de potencia desigual en las que los valores propios de señales débiles pueden confundirse con ruido. Por esa razón, el algoritmo se entrena con un número significativo de épocas y muestras. Además, solo se consideran separaciones angulares considerables de los emisores con respecto al lóbulo principal del arreglo de antenas, lo que puede acarrear resultados engañosos al aplicar algoritmos de estimación de DOA con superresolución [7,9].

En este trabajo, se propone un nuevo esquema de normalización para acotar el rango de entrada de la red neuronal que estima la dimensión del subespacio de señal y consigo, el número de fuentes emisoras. El objetivo principal es desarrollar un modelo de red neuronal de pocos recursos con entrada normalizada para estimar de manera efectiva el número de señales incidentes con una complejidad y un tamaño de las muestras de entrenamiento reducidos. La simulación numérica y los resultados experimentales con señales reales validan que los esquemas de preprocesamiento propuestos son capaces de mejorar la estimación de la red en un entorno complejo con un número reducido de antenas y recursos.

2. MODELO DE LAS SEÑALES

En varios problemas dentro del área del procesamiento de señales, el vector de las observaciones puede modelarse como la superposición de un número finito de señales embebido en ruido aditivo [1]. Este es el caso de las señales provenientes de arreglos de sensores que incluye las antenas como un caso particular. El modelo de las señales relaciona las muestras recibidas a la salida de las antenas con las señales emitidas por las fuentes distribuidas en el espacio. Como se muestra la Figura 2, se considera que al arreglo compuesto por M antenas isotrópicas (A_1, A_2, \dots, A_M), inciden las señales $s_p(t)$ provenientes de P fuentes emisoras desde las direcciones θ_p . La señal recibida en cada canal de recepción puede modelarse según la ecuación (1).

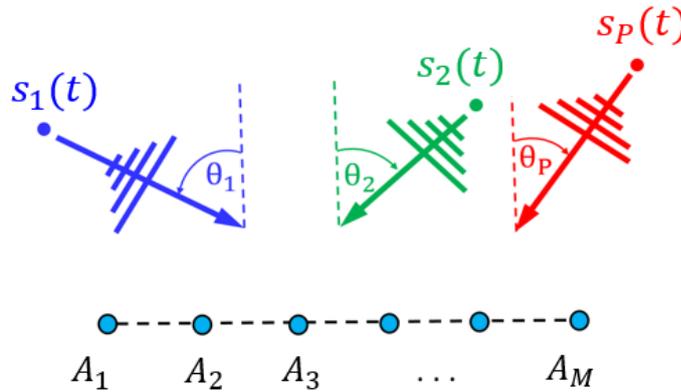


Figura. 2: Estimación de la dirección de arribo de P emisores en el espacio con un arreglo de M antenas.

$$X(t) = AS(t) + N(t) \quad (1)$$

donde: $X(t) = [x_1(t), x_2(t), \dots, x_M(t)]^T \in \mathbb{C}^{M \times 1}$ es el vector de las muestras tomadas a la salida del arreglo de antenas y $x_m(t) (m = 1, 2, \dots, M)$ es la salida del m -ésimo elemento del arreglo en el instante t . $S(t) = [s_1(t), s_2(t), \dots, s_P(t)]^T \in \mathbb{C}^{P \times 1}$ es el vector de señales provenientes de P fuentes emisoras de señal y $s_p(t) (p = 1, 2, \dots, P)$ es la p -ésima señal en el instante t . $N(t) = [n_1(t), n_2(t), \dots, n_M(t)]^T \in \mathbb{C}^{M \times 1}$ es un vector de muestras de ruido considerado aditivo Gaussiano [1] donde $n_m(t)$ es el ruido en el m -ésimo elemento de antena en el instante t . $A \in \mathbb{C}^{M \times P}$, como muestra la ecuación (2), es una matriz cuyas columnas se componen de un arreglo de vectores directivos $a(\theta_p)$ para la p -ésima fuente emisora de señal. Este último representa los cambios relativos de amplitud y fase que experimentan los frentes de onda planos de las señales cuando incide en cada una de las antenas del arreglo.

$$A = [a(\theta_1), a(\theta_2), \dots, a(\theta_p)] \quad (2)$$

Los métodos para solucionar el problema de estimación de DOA pueden clasificarse en dos categorías: los espectrales y los paramétricos. En los primeros se forma una función espectral de los parámetros de interés (en este caso la DOA). Las ubicaciones de los mayores picos en el espectro en cuestión constituyen las DOA estimadas. Las técnicas paramétricas requieren una búsqueda simultánea de todos los parámetros de interés sobre la base del modelo de los datos. Estos métodos con frecuencia arrojan estimados más exactos a expensas de un incremento de la complejidad computacional.

3. ESTIMACIÓN DEL NÚMERO DE SEÑALES BASADA EN REDES NEURONALES

En esta sección se presenta un nuevo esquema de normalización que permite ajustar en tiempo real el rango de valores propios de entrada de una manera simple y eficiente. A diferencia de [15], en lugar de aplicar una red neuronal más compleja, como ER-Net y ECNet, se introducen modificaciones en los valores propios de entrada al clasificador, que permiten simplificar el entrenamiento y mejorar el proceso de clasificación. Además, la mayor ventaja es que permite lograr resultados satisfactorios con algoritmos simples como la red neuronal basada en perceptrones.

Modelo propuesto

La Figura 3 ilustra el modelo propuesto de estimación del número de fuentes de señal, está compuesto por un bloque de cálculo de matriz de covarianza espacial seguido de una descomposición de valores propios (EVD, por sus siglas

en inglés), un bloque de normalización y otro de clasificación. Al igual que los métodos AIC, MDL y las propuestas de [15, 16], R_x se estima a partir de la ecuación (3), donde T es el número de muestras recibidas en el conjunto de antenas por cada elemento independiente [4].

$$R_x = \frac{1}{T} \sum_{t=1}^T x(t)x(t)^H \quad (3)$$

Después del cálculo de la matriz de covarianza espacial, se realiza el EVD de R_x y los valores propios se ordenan de forma descendente. Los valores propios de salida del bloque EDV pasan al de normalización para estandarizar los valores propios en tiempo real.

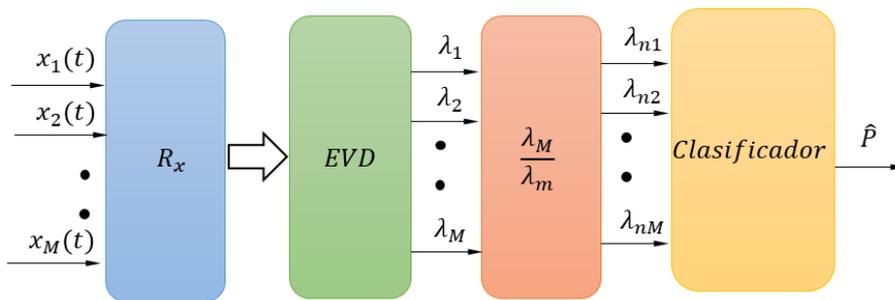


Figura. 3: Modelo propuesto para la estimación del número de fuentes de señal.

La normalización basada en el menor valor propio λ_M , como se aprecia en la ecuación (4), garantiza que los valores propios siempre estén entre 0 y 1. Este enfoque es diferente al propuesto por los autores en [16, 17] debido a que permite reajustar el rango de valores propios en tiempo real, de acuerdo con los valores normalizados previamente entrenados, sin asumir un modelo de ruido ni afectar la detección de las señales. Esta nueva función permite reducir el tiempo de entrenamiento, así como la complejidad de la implementación.

$$\lambda_{nm} = \frac{\lambda_M}{\lambda_m} \quad (4)$$

La normalización se realiza sobre la base del menor valor propio λ_M en lugar del mayor λ_1 , de lo contrario se obtendría un conjunto de datos ambiguo para el caso de una y ninguna señal incidente. Esta aproximación es válida siempre que $P < M$, ya que se supone que al menos λ_M pertenece al subespacio de ruido, al igual que AIC, MDL y la mayoría de los métodos de estimación de DOA. Bajo diferentes condiciones, se deben aplicar soluciones basadas en arreglos virtuales o algoritmos de estimación de DOA de sistemas indeterminados, donde esta propuesta también es válida [10, 21].

Para demostrar las ventajas de este enfoque y mantener el bajo costo computacional requerido, en lugar de usar un clasificador con aprendizaje profundo, se empleó un clasificador más simple compuesto por N perceptrones como se muestra en la Figura 4, donde se debe cumplir la relación $2^N \geq M$. No obstante, no se descarta el empleo de topologías y algoritmos más complejos que potencialmente pueden arrojar mejores resultados.

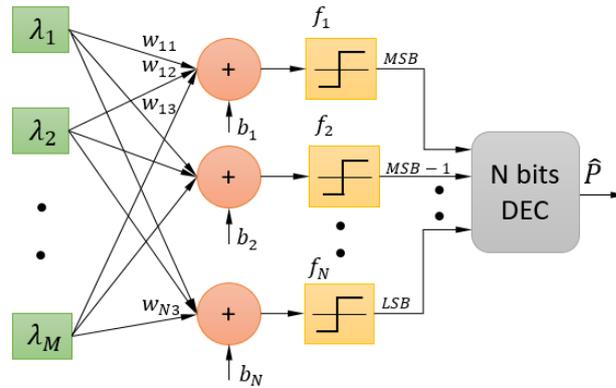


Figura. 4: Topología de red neuronal con bajos recursos para clasificar los datos normalizados.

Como se aprecia en la Figura 4, cada perceptrón toma como entrada los valores propios de la matriz de covarianza espacial después de ser normalizados en tiempo real. Luego de la aplicación de los pesos se emplea como función de activación un escalón unitario que conforma la entrada de un decodificador de datos binarios a decimal. La salida del decodificador contiene el valor estimado del número de señales incidentes en el arreglo de antenas \hat{P} .

Análisis de complejidad

Las complejidades computacionales de ERNet, ECNet, AIC, MDL, CNN [18] y las propuestas se enumeran en la Tabla 1, donde n_1 y n_2 es el número de neuronas de ECNet y ERNet en la capa 1 y 2, respectivamente. Se puede observar que el método propuesto posee una complejidad relativamente menor que los demás.

Tabla 1: Comparación de la complejidad computacional con respecto a otros métodos.

Método	MD	AS	LOG	C
ERNet	$Mn_1 + n_2$	$n_1 + n_2 + 1$	0	0
ECNet	$M(n_1 + n_2)$	$n_1 + n_2 + M$	0	M
AIC	$M^2 + 7M$	$0.5(M^2 + M)$	$2M$	M
MDL	$M^2 + 7M$	$0.5(M^2 + M)$	M	M
CNN	$180P(M^2 + M)$	$20MP + M$	0	M
Propuesto	M	$M - 1$	0	M

donde:

MD: Número de multiplicaciones/divisiones.

AS: Número de adiciones/sustracciones.

LOG: Número de operadores logarítmicos.

C: Número de comparaciones.

4. RESULTADOS DE SIMULACIÓN Y EXPERIMENTALES

En esta sección se validan tanto las simulaciones numéricas como los resultados experimentales. En primer lugar, se comprueba el rendimiento de la topología de red neuronal en función del conjunto de datos simulados. Luego, se

describe la configuración de la validación experimental y se presentan los resultados de estimación del método en un sistema de antenas inteligentes.

Simulaciones numéricas

En esta sección, se utiliza un arreglo lineal uniforme con $M = 4$ antenas para recibir las señales. A menos que se especifique lo contrario, los parámetros de simulación se establecen de la siguiente manera: el número de muestras es 200, el número de fuentes P se genera aleatoriamente en el rango $[0; M-1]$, y la dirección de cada fuente se genera aleatoriamente sobre $[0; 180]$. Matlab 2020b se emplea como marco para el entrenamiento de la red neuronal que en este caso requiere 2 perceptrones simples. El número de muestras de entrenamiento es 40 y el número inicial de épocas es 4000 para evaluar más a fondo la convergencia neta. La red se entrenó con muestras generadas en diferentes SNR con distribución uniforme de $[0; 40]$ dB.

La Figura 5 representa los valores propios de la matriz de covarianza en el caso de una señal incidente antes y después del preprocesamiento con el bloque de normalización para diferentes valores de SNR. Como se aprecia en la Figura 5(a), para valores bajos de SNR, la separación entre los valores propios de señal y los de ruido resulta más pequeña, lo que dificulta el proceso de estimación del número de señales. Además, las diferentes condiciones pueden producir un rango de entrada de los valores propios no acotado y arbitrario a la red neuronal.

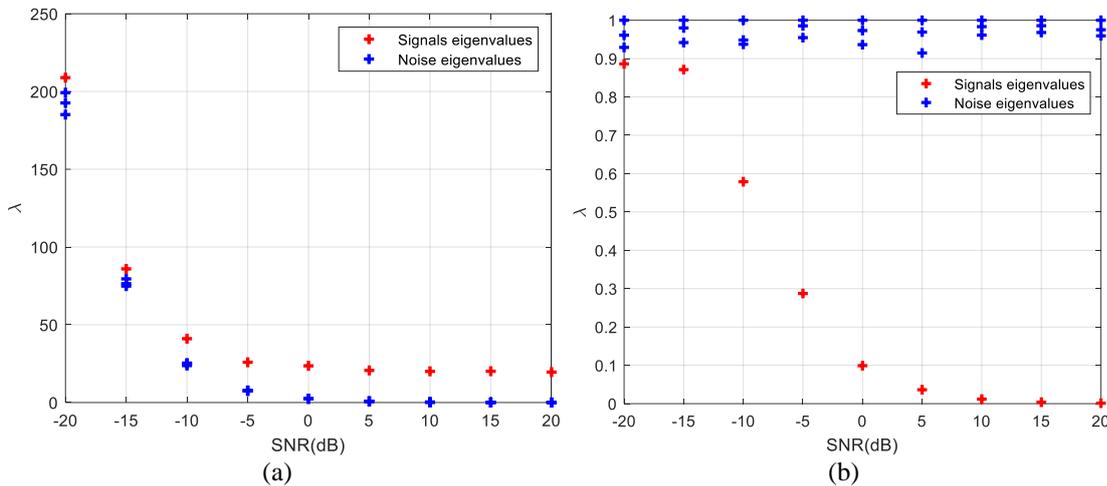


Figura. 5: Magnitud de valores propios de la covarianza espacial de una señal incidente en función de la SNR. a) Antes del preprocesamiento de normalización. b) Después del preprocesamiento de normalización.

Como se detalla en la Figura 5(b), después de la normalización, el rango de entrada de la red se ajusta entre 0 y 1 lo que disminuye la cantidad de muestras necesarias sin conocimiento de la distribución de ruido. Además, alivia el proceso de etiquetado y tiempo de entrenamiento para una implementación práctica donde las condiciones sean fluctuantes como es el caso del entorno electromagnético que se caracteriza por ser complejo, denso e inestable. Con el método de normalización propuesto, la relación entre el ruido y los valores propios de la señal se invierte, es decir, los valores propios más grandes corresponden al ruido y los más pequeños pertenecen al subespacio de señales.

La Figura 6 muestra la norma de los pesos de la red neuronal en función de cada época durante el proceso de entrenamiento, como se muestra, después de las 2400 épocas, el peso converge y la red está completamente entrenada.

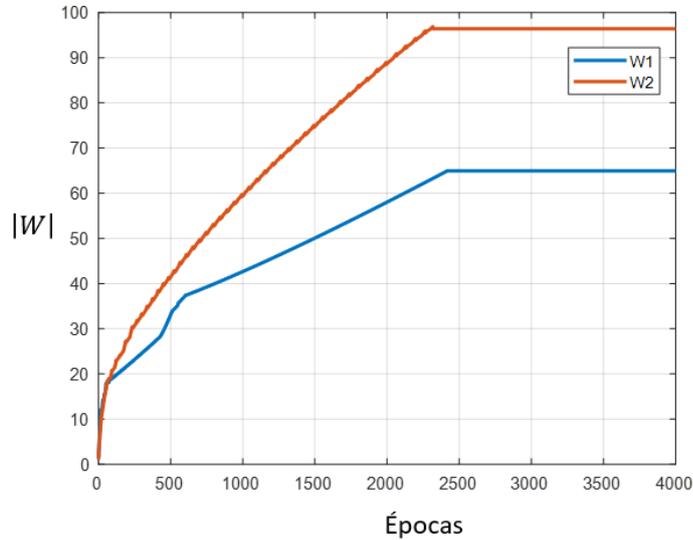


Figura. 6: Norma de los pesos del perceptrón en función de las épocas durante el proceso de entrenamiento.

En comparación con el esquema propuesto en [15], aunque el número de épocas es relativamente alto, el tamaño de la muestra de entrenamiento es significativamente menor.

La Figura 7 muestra el rendimiento expresado en la exactitud de AIC, MDL y el método propuesto (NN-norm) frente a la SNR, donde se emplean 200 muestras para estimar la matriz de covarianza del arreglo de antenas. Se evidencia que el esquema propuesto supera significativamente a todos los demás estimadores. Cuando la SNR sobrepasa los 8 dB, el método propuesto (NN-norm) arroja una clasificación del número de señales cercana al 100 % para las condiciones establecidas.

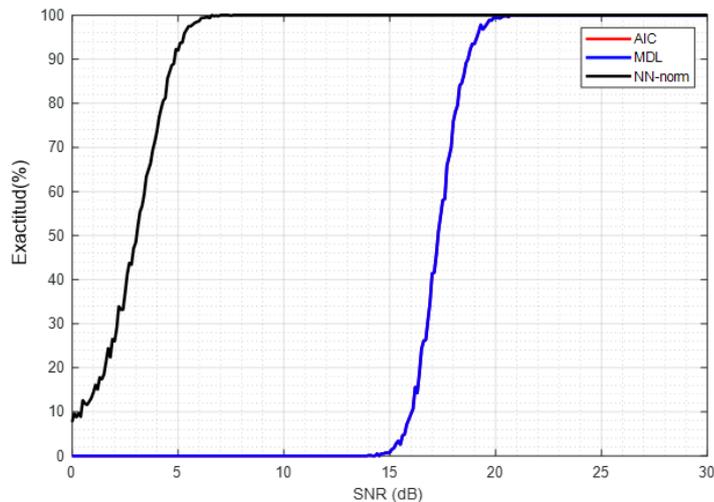


Figura. 7: Exactitud del método propuesto en comparación con los métodos tradicionales de estimación del número de fuente MDL y AIC.

Un análisis comparativo de los requisitos del método propuesto frente a los más destacados consultados en la literatura se detalla en la Tabla 2. El esquema adoptado requiere un tamaño del conjunto de entrenamiento y una cantidad de sensores significativamente menor. Esto permite la reducción del coste, la complejidad y el tiempo de entrenamiento. Otros métodos, como ECNet/ ERNet y Norm+ ECNet/ ERNet, utilizan menos muestras del arreglo de antenas, lo que se compensa con un tamaño de conjunto de entrenamiento significativo, así como un aumento de la complejidad del método que por lo general resulta prohibitivo para ejecutar en tiempo real en un sistema práctico.

Tabla 2: Comparación de los requerimientos del método propuesto con respecto a otros trabajos.

Método	Ref.	Tamaño de la muestra de entrenamiento	Número de muestras del arreglo	Número de Sensores	Número de corridas
Agrupamiento ML	[2]	10000	1000	7	30000
ERNet, ECNet	[3]	8000	20	10	400
Norm + (ERNet, ECNet)	[4]	10800	20	10	400
Norm + Perceptrón	Propuesto	38	200	4	2500

Configuración experimental

Para validar el método propuesto, en un escenario real con un número reducido de muestras y antenas del arreglo, se implementó método de estimación del número de señales en un sistema de antenas inteligentes en la banda L de frecuencias. La misma red entrenada durante las simulaciones se utilizó para la implementación práctica. La Figura 8 muestra un banco de pruebas configurado con un arreglo de antenas lineal uniforme (ULA, por sus siglas en inglés) de cuatro dipolos de media longitud de onda con reflector trasero, un receptor digital multicanal coherente con ocho canales y una computadora personal que ejecuta Matlab 2020b. El arreglo de antenas se conectó a los primeros cuatro canales receptores y el generador de señales vectoriales Signal Hound VSG 25A se utilizó como oscilador local. La distancia entre dipolos es de 137 mm que representan la mitad de la longitud de onda a la frecuencia de 1090 MHz.

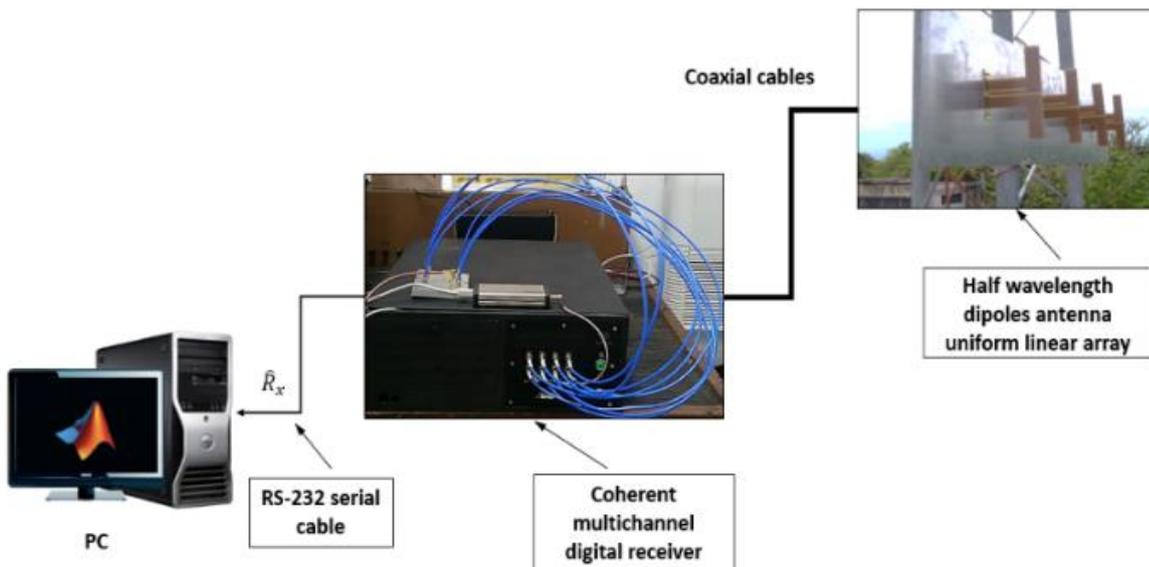


Figura.8: Configuración experimental para validar el método propuesto.

Como patrón de señal se utilizaron las señales de transmisión de tráfico de la aviación comercial para Radiodifusión Dependiente Automática- Modo S (ADS-B, por sus siglas en inglés) para enumerar el número de señales incidentes en el arreglo de antenas. Aunque estas señales están limitadas en el tiempo y son transmitidas de forma asíncrona por la aviación, dependiendo del tráfico aéreo es muy común que lleguen múltiples señales al mismo tiempo de observación en el arreglo de antenas.

Después de detectar una señal ADS-B en el receptor multicanal mediante un filtro adaptado al preámbulo de la trama, se calcula la matriz de covarianza espacial y se transmite mediante un cable serie RS-232 a la PC que ejecuta Matlab. En el PC se realizan los pasos que se muestran en la Figura 3 luego de la estimación de la matriz de covarianza espacial.

Resultados experimentales

Para validar el rendimiento del método propuesto, el arreglo de antenas se montó en un mástil a una altura de 7 m desde el suelo. Se realizaron 100000 estimaciones, de las cuales, 83272 fue en presencia de señal cuya cantidad varió entre 1 y 3, el resto de las estimaciones fue en presencia de solo ruido (16728). Los valores estimados y su matriz de covarianza correspondiente se guardaron en la PC para luego verificar su desempeño. La Figura 9 muestra la matriz de confusión calculada con el número de señales presentes calculado a partir del preámbulo ADS-B y el valor estimado por la red neuronal.

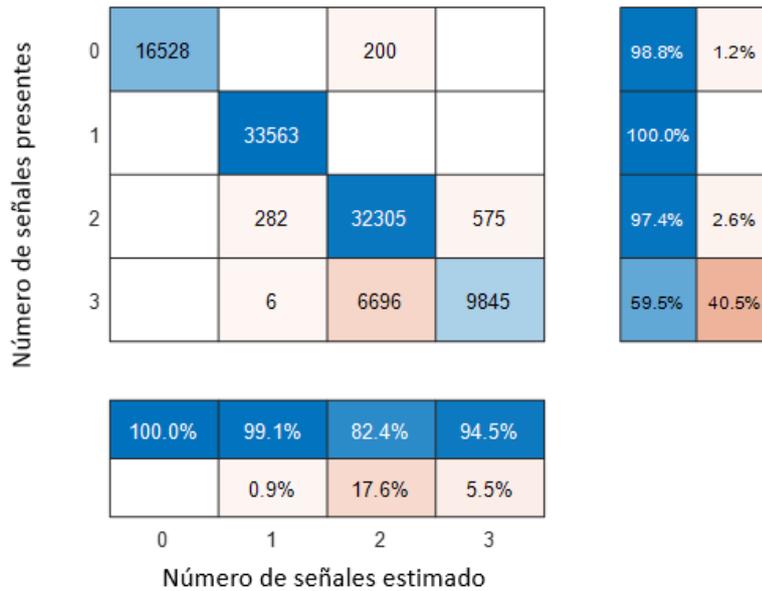


Figura. 9: Matriz de confusión calculada a partir de los datos reales

Como se aprecia, la red es capaz de obtener una exactitud del 98.8%, 100%, 97.4%, y 59.5% cuando clasifica(estima) que inciden ninguna, una, dos y tres señales, respectivamente. La mayor probabilidad de desacierto ocurre en presencia de tres fuentes emisoras, donde solo se alcanzó una exactitud del 59.5% como se refleja en la columna de la derecha de la figura 9. Este último resultado puede deberse a los efectos indeseables del desbalance de la SNR cuya probabilidad de ocurrencia aumenta cuando incide un mayor número de señales. Además, debido a que se emplearon 4 elementos en el arreglo de antenas, el arribo de tres señales simultáneas es un caso extremo en el que la cercanía del subespacio de señal al de ruido es mínimo [21]. El empleo de un mayor número de elementos del arreglo de antenas (físicos o virtuales [22]) puede mejorar los resultados alcanzados. No obstante, para esta aplicación particular, el mayor interés existe en el caso de la estimación de ninguna o una señal, debido a que la probabilidad de que incidan dos o tres o señales del tipo ráfaga disminuye de manera gradual. Además, la exactitud total de la estimación es de 92.2 %, resultante de la división de la suma de todos los elementos de la diagonal principal de la matriz de confusión (92241) entre el total de muestras (100000) y expresado en porciento. El resultado anterior se considera satisfactorio

si se consideran los problemas asociados a una validación con señales en tiempo real como son los efectos indeseables de la propagación por múltiples trayectos, el descontrol de la SNR y separación angular de las señales incidentes, los errores de amplitud y fase del sistema, entre otros [23].

5. CONCLUSIONES

En este trabajo, se propuso un método de estimación del número señales incidentes en un arreglo de antenas con el empleo de redes neuronales. El método propuesto permite el preprocesamiento en tiempo real de los datos de entrada a una red neuronal de bajos recursos. En este enfoque no es necesario el conocimiento de la naturaleza del ruido, a diferencia de varios detectores clásicos, como AIC y MDL, que se derivaron bajo la suposición de ruido Gaussiano. Dado que la solución propuesta se basa en los datos de entrada, se pueden emplear muestras de múltiples escenarios complejos durante la etapa de entrenamiento y aprender el umbral para separar los valores propios de la señal y el ruido. Las principales ventajas se basan en que, debido al proceso de normalización, la etapa de entrenamiento solo requiere un pequeño conjunto de datos representativos. Los resultados experimentales y de simulación proporcionados demuestran que el método propuesto posee mejores rendimientos que los métodos existentes con una complejidad reducida. El proceso de detección puede alcanzar una mejor probabilidad de detección dentro de una SNR baja, por lo que es más confiable que los detectores clásicos. Si bien se utilizó como clasificador una red neuronal con múltiples perceptrones, principalmente por su bajo costo computacional, es posible la aplicación de otras arquitecturas o clasificadores con mejor desempeño, incluso la evaluación de un proceso de agrupamiento.

REFERENCIAS

- [1] N. Ruan, H. Wang, F. Wen, and J. Shi, "DOA Estimation in B5G/6G: Trends and Challenges," *Sensors*, vol. 22, p. 5125, 07/08 2022.
- [2] C. N. Hu, A. Tsai, K. J. Wong, and P. Lo, "Angle Estimation through Millimeter Wave MIMO in 5G Systems," presented at the 2019 Photonics & Electromagnetics Research Symposium, Xiamen; China, 2019.
- [3] J. Datta and H.-P. Lin, "Interference Avoidance using Spatial Modulation based Location Aware Beamforming in Cognitive Radio IOT Systems," *Advances in Science, Technology and Engineering Systems Journal*, vol. 3, no. 2, 2018.
- [4] G. Yuniór Ibarra, R. R. Z. Alexander, and F. Eugenio Boudet, "Control de acceso basado en RFID sobre plataforma IoT," *Tono, Revista Técnica de la Empresa de Telecomunicaciones de Cuba S.A.*, vol. 17, no. 1, pp. 12-19, 09/14 2021.
- [5] M. Gall, M. Gardill, J. Fuchs, and T. Horn, "Learning Representations for Neural Networks Applied to Spectrum-Based Direction-of-Arrival Estimation for Automotive Radar," presented at the IEEE/MTT-S International Microwave Symposium(IMS), Los Angeles; USA, 2020.
- [6] S. Surekha and M. Z. U. Rahman, "Cognitive Energy-Aware Spectrum Sensing With Improved Throughput for Medical Sensor Networks," *IEEE Sensors Letters*, vol. 6, no. 6, pp. 1-4, 2022.
- [7] H. L. Van Trees, *Optimum Array Processing (Detection, Estimation and Modulation Theory)*. John Wiley & Sons, Inc, 2002.
- [8] L. Liu, Y. Cao, and G. Muran, *FPGA Implementation of DOA Estimation Method Based on Polarization Sensitive Array*. 2022.
- [9] A. A. Hussain, N. Tayem, and A.-H. Soliman, "Computationally Efficient Forward/ Backward Averaged DOA Estimation of Coherent Source Pairs," presented at the 94th Vehicular Technology Conference, Helsinki; Finlandia, 2021.
- [10] K. Hameed *et al.*, "DOA Estimation in Low SNR Environment through Coprime Antenna Arrays: An Innovative Approach by Applying Flower Pollination Algorithm," *Applied Sciences*, vol. 11, no. 17, 2021.
- [11] A. Abdelbari and B. Bilgehan "A novel DOA Estimation Method of Several Sources for 5G Networks," presented at the 2020 International Conference on Electrical, Communication and Computer Engineering (ICECCE), Istanbul; Turkey, 2020.
- [12] H. S. Vu, K. T. Truong, L. T. Bang, V. Y. Vu, and M. T. Le, "An Investigation of Adaptive Digital Beamforming Antenna for gNode 5G," presented at the International Conference on Advanced Technologies for Communications (ATC), Hanoi, Vietnam, 2019.
- [13] M. Wax and I. Ziskind, "Detection of the number of coherent signals by the MDL principle," *IEEE Transactions on Acoustics, Speech, and Signal Processing*, vol. 37, no. 8, pp. 1190-1196, 1989.
- [14] M. Wax and T. Kailath, "Detection of signals by information theoretic criteria," *IEEE Transactions on Acoustics, Speech, and Signal Processing*, vol. 33, no. 2, pp. 387-392, 1985.

- [15] Y. Yang, F. Gao, C. Qian, and G. Liao, "Model-Aided Deep Neural Network for Source Number Detection," *IEEE Signal Processing Letters*, vol. 27, pp. 91-95, 2020.
- [16] S. Zhou, T. Li, Y. Li, R. Zhang, and Y. Ruan, "Source Number Estimation via Machine Learning Based on Eigenvalue Preprocessing," *IEEE Communications Letters*, vol. 26, no. 10, pp. 2360-2364, 2022.
- [17] Y. Lee *et al.*, "Source Enumeration Approaches Using Eigenvalue Gaps and Machine Learning Based Threshold for Direction-of-Arrival Estimation," *Applied Sciences*, vol. 11, no. 4, 2021.
- [18] W. Hu, R. Liu, X. Lin, Y. Li, X. Zhou, and X. He, "A deep learning method to estimate independent source number," in *2017 4th International Conference on Systems and Informatics (ICSAI)*, 2017, pp. 1055-1059.
- [19] Z. Meng and W. Zhou, "Direction-of-Arrival Estimation in Coprime Array Using the ESPRIT-Based Method. LID - 10.3390/s19030707 [doi] LID - 707," (in eng), no. 1424-8220 (Electronic), 2019.
- [20] H. Krim and M. Viberg, "Two Decades of Array Signal Processing Research: The Parametric Approach," *IEEE Signal Processing Magazine*, vol. 13, no. 4, pp. 67-94, 1996.
- [21] Amar A., Weiss A. J., "Resolution limits of closely spaced random signals given the desired success rate". *IEEE Conference on Advanced Video and Signal Based Surveillance*. 2007 5-7 Sept. 2007.
- [22] A. Liu, Q. Yang, X. Zhang, and W. Deng, "Direction-of-Arrival Estimation for Coprime Array Using Compressive Sensing Based Array Interpolation," *International Journal of Antennas and Propagation*, vol. 2017, p. 6425067, 2017/02/16 2017.
- [23] Amar A., Weiss A. J. "Fundamental Limitations on the Resolution of Deterministic Signals". *IEEE Transactions on Signal Processing*. 2008;56(11):5309-5318. doi:10.1109/TSP.2008.929654.

SOBRE LOS AUTORES

Yunior Ibarra Guerra, es ingeniero en Telecomunicaciones, graduado del ITM "José Martí" en el año 2015. Obtuvo el título académico de Máster en Sistemas Digitales en la Universidad Tecnológica de la Habana "José A. Echeverría" en el año 2023. En la actualidad opta por el grado científico de Doctor en Ciencias Técnicas en el ITM "José Martí". Trabaja como Investigador Agregado en el Centro de Investigación y Desarrollo de Electrónica y Mecánica, "CID MECATRONICS" del cual es miembro de su consejo científico. Correo electrónico: yuniorig2016@hotmail.com, No. ORCID: 0000-0002-0538-4053.

Alexander Rogelio Ramírez Zaldívar, es ingeniero en Telecomunicaciones, graduado del ITM "José Martí" en el año 2015. Obtuvo el título académico de Máster en Sistemas Digitales en la Universidad Tecnológica de la Habana "José A. Echeverría" en el año 2023. En la actualidad opta por el grado científico de Doctor en Ciencias Técnicas en el ITM "José Martí". Trabaja como Investigador Agregado en el Centro de Investigación y Desarrollo de Electrónica y Mecánica, "CID MECATRONICS" del cual es miembro de su consejo científico. Correo electrónico: alex.r_92@outlook.com, No. ORCID: 0000-0002-0372 0746.

José E. Vargas Fernández, es ingeniero en Telecomunicaciones y Electrónica, graduado de la Universidad Central "Marta Abreu" de las Villas en el año 2013. En la actualidad opta por el título académico de Máster en Automática en la Universidad Tecnológica de la Habana "José A. Echeverría". Trabaja como Investigador Agregado en el Centro de Investigación y Desarrollo de Electrónica y Mecánica, "CID MECATRONICS". Correo electrónico: jevargas910127@gmail.com, No. ORCID: 0000-0003-4897-1618.

Noslen Rojas Ramírez, graduado de Ingeniero Radioelectrónico en el año 1994, Máster en Radioelectrónica en el año 1997 y Doctor en Ciencias Técnicas en el año 2008 en el ITM "José Martí". Posee la categoría científica de Investigador Titular desde el año 2012 y en 2018 recibió la Orden "Carlos J. Finlay" por los resultados alcanzados en la actividad científica. Labora en el Centro de Investigación y Desarrollo de Electrónica y Mecánica, "CID MECATRONICS" del cual es presidente de su consejo científico. Correo electrónico: noslenrr71@outlook.com, No. ORCID: 0000-0002-8884-320X.

CONFLICTO DE INTERESES

No existe conflicto de intereses entre los autores, ni con ninguna institución a la que cada uno está afiliado, ni con ninguna otra institución.

CONTRIBUCIONES DE LOS AUTORES

Yunior Ibarra Guerra: conceptualización, preparación, creación y desarrollo del artículo, revisión crítica de cada una de las versiones del borrador del artículo y aprobación de la versión final a publicar.

Alexander R. Ramírez Zaldívar: revisión crítica de cada una de las versiones del borrador del artículo, contribución a la idea y organización del artículo, sugerencias acertadas para la conformación de la versión final.

José E. Vargas Fernández: conceptualización, preparación, creación y desarrollo del artículo.

Noslen Rojas Ramírez: conceptualización, preparación y aprobación de la versión final a publicar.

Esta revista provee acceso libre inmediato a su contenido bajo el principio de hacer disponible gratuitamente investigación al público. Los contenidos de la revista se distribuyen bajo una licencia Creative Commons Attribution-NonCommercial 4.0 Unported License. Se permite la copia y distribución de sus manuscritos por cualquier medio, siempre que mantenga el reconocimiento de sus autores y no se haga uso comercial de las obras.

