

Factores de ajuste óptimos para procesadores CFAR de ventana deslizando operando en *clutter* log-weibull

Optimal scale factors for sliding window cfar processors against log-weibull clutter

stress-strain dynamic analysis in earthen structures

José Raúl Machado Fernández

Universidad Tecnológica de la Habana, José Antonio Echeverría, Cujae, La Habana, Cuba

Correo electrónico: m4ch4do@hispavista.com

Este documento posee una licencia Creative Commons Reconocimiento/No Comercial 4.0 Internacional 

Recibido: 25 de enero de 2018 Aprobado: 5 de junio de 2018

Resumen

El *clutter* es una señal aleatoria interferente que usualmente se elimina con procesadores CFAR de ventana deslizando, para lograr una detección precisa de los blancos de radar. A pesar del éxito de la distribución Log-Weibull en la representación efectiva de varios tipos de *clutter*, no se ha estudiado la relación entre su parámetro de forma y el factor de ajuste óptimo de los procesadores. El artículo propone un sistema basado en redes neuronales que devuelve el factor de ajuste óptimo a aplicar para cualquier parámetro de forma Log-Weibull en el intervalo de valores posibles. Se comprobó mediante simulación computacional que, si se anexan las redes neuronales a los procesadores, se logra mantener la probabilidad de falsa alarma operacional muy cercana al valor concebido en el diseño, garantizándose así el cumplimiento del criterio de Neyman-Pearson. El desarrollo presentado tiene aplicación en la mejoría de la detección en las costas cubanas, donde aparecen escenarios heterogéneos que incluyen alternancia entre altas y bajas profundidades, manglares, aguas salobres, islotes y vegetación acuática prominente. Estos fenómenos afectan el comportamiento del *clutter* provocando fluctuaciones del parámetro de forma de la distribución del fondo.

Palabras claves: *clutter* de radar, distribución Log-Weibull, procesadores CFAR, criterio Neyman-Pearson, probabilidad de falsa alarma

Abstract

The clutter is a random interfering signal that is commonly canceled with sliding window CFAR processors, for achieving an accurate detection of radar targets. Despite the success of the Log-Weibull distribution in the effective representation of several types of clutter, the relationship between its shape parameter and the optimal scale factor of the processors have not been studied. The paper proposes a system based on neural networks for computing the optimal scale factor to be applied for any Log-Weibull

shape parameter in the range of possible values. It was verified through computer simulation that, if the neural networks are attached to the processors, the operational false alarm probability remains close to the value conceived in the design, satisfying thus the Neyman-Pearson criterion. The application of the presented technique lies in the improvement of the detection in Cuban coastal regions, where heterogeneous scenarios are found containing different depth levels, mangrove swamps, brackish water, islets and prominent aquatic vegetation. These scenarios disturb the clutter behavior provoking fluctuations in the shape parameter of the background.

Key words: radar clutter, Log-Weibull distribution, CFAR processors, Neyman-Pearson criterion, false alarm probability.

INTRODUCCIÓN

El *clutter* es una señal aleatoria interferente que aparece en las mediciones de radar y que debe ser cancelada para lograr la detección precisa de los blancos. Cuando el haz de radar explora el medio circundante, además de reflejarse en los objetivos cercanos, produce ecos en otras superficies que no son de interés [1]. Así, se obtiene en el receptor una contribución indeseable que puede alcanzar niveles elevados y confundirse con los blancos. Cuando esta contribución proviene de la superficie del mar, se dice que se está en presencia de *clutter* marino. Otros tipos de *clutter* muy conocidos son el terrestre y el atmosférico [2].

Para el diseño de mecanismos efectivos de cancelación del *clutter* se hace necesaria su modelación estocástica. Las distribuciones Weibull [3], Log-normal [4], K [5] y Pareto [6] se utilizan en la actualidad con este propósito. Sin embargo, se han reportado varios casos donde la distribución Log-Weibull ha proporcionado un mejor ajuste que las anteriores para *clutter* terrestre [7-9], marino [10-13] y atmosférico [14]. Aunque no se han presentado argumentos válidos en su contra, la comunidad de radares aún no ha adoptado esta distribución, por lo que su presencia en la literatura es aún reducida en relación a los desarrollos existentes para Weibull, Log-Normal, K y Pareto. La distribución Log-Weibull, al igual que sus contrapartes, cuenta con un parámetro de escala y uno de forma, siendo el último quien influye sobre la detección.

La detección de los objetivos de radar, y su discriminación del *clutter*, se realiza típicamente a través de procesadores CFAR (*Constant False Alarm Rate*, Razón de Falsa Alarma Constante) de ventana deslizante [15]. Entre ellos, las alternativas CA-CFAR (*Cell Averaging-CFAR*, CFAR de Promediación de Celdas), GO-CFAR (*Greater of-CFAR*, CFAR de Selección Superior), SO-CFAR (*Smaller Of-CFAR*, CFAR de Selección Inferior) y OS-CFAR (*Ordered Statistics-CFAR*, CFAR de Estadística Ordenada) son las más aplicadas [16]. Estas cuentan con un factor de ajuste, o factor de escala, que permite adaptar el sistema a las condiciones del *clutter* y que suele mantenerse fijo en correspondencia con el comportamiento promedio del fondo.

Sin embargo, si el parámetro de forma del *clutter* varía en un amplio rango, el establecimiento de un factor de ajuste fijo provocará que la probabilidad de falsa alarma (P_f) operacional experimente una varianza excesivamente alta alrededor del valor concebido en el diseño [17]. Esto es un problema grave desde la perspectiva teórica pues se deja de cumplir el criterio de Neyman-Pearson y se pierde la propiedad CFAR. Desde el punto de vista práctico, la consecuencia es que ocurrirán ráfagas de falsas alarmas y de pérdidas de blancos en la pantalla del radar, que reducirán las capacidades de vigilancia de los dispositivos que dejarán de ser invariantes en el tiempo.

En los estudios que relacionan a la distribución Log-Weibull con el *clutter* se ha encontrado un amplio rango de variación del parámetro de forma [7, 9-14, 18, 19], lo que coincide a lo hallado para otros modelos. Esto significa que la problemática previamente descrita ocurre constantemente al explorar medios terrestres, marinos y atmosféricos si no se aplica la necesaria adaptación del factor de los procesadores. El problema se agrava cuando se opera en entornos heterogéneos como los de las costas cubanas donde se puede encontrar alternancia entre altas y bajas profundidades, manglares, aguas salobres, islotes, costas irregulares y vegetación acuática prominente, condiciones que alteran el comportamiento estadístico del eco.

Como solución, el autor presenta una técnica basada en redes neuronales para la selección óptima del factor de ajuste del CA-CFAR, el GO-CFAR, el SO-CFAR y del OS-CFAR, a partir del conocimiento a priori del parámetro de forma de la distribución Log-Weibull asumida para el *clutter*. El entrenamiento del mecanismo neuronal se realizó a partir de resultados obtenidos de simulaciones de Monte Carlo realizadas sobre 30 millones de muestras Log-Weibull generadas en computadora. La prueba mediante simulación del método propuesto

demostró que se logra mantener una probabilidad de falsa alarma cercana al valor concebido en el diseño, con una precisión que supera lo logrado en trabajos previos para otras distribuciones.

MATERIALES Y MÉTODOS

Para La sección actual comienza con la introducción de la distribución Log-Weibull que es el modelo de *clutter* asumido para las simulaciones. Se abordan después los principios de operación de los cuatro procesadores utilizados. Seguidamente, se describe el algoritmo de simulaciones de Monte Carlo que produce el factor de ajuste apropiado para cada detector teniendo en cuenta las variaciones del parámetro de forma Log-Weibull, la dimensión de la ventana de deslizante y la probabilidad de falsa alarma de diseño. Por último, se presenta brevemente la estructura de la red neuronal utilizada para generalizar los resultados de las simulaciones de Monte Carlo a todo el rango posible de condiciones de operación.

Distribución Log-Weibull

La expresión de la PDF (*Probability Density Function*, Función de Densidad de Probabilidad) Log-Weibull es [19]:

$$f_x(x; \alpha, \beta) = \frac{\beta}{\alpha x} \left(\frac{\ln x}{\alpha} \right)^{\beta-1} \exp \left[- \left(\frac{\ln x}{\alpha} \right)^{\beta} \right] \quad x > 1 \quad (1)$$

Donde x es la amplitud reflejada, α es el parámetro de escala y β es el de forma, que tiene una influencia marcada en la detección. En cambio, el parámetro de escala modifica la media de las muestras pero preserva la proporción entre ellas, por lo que no afecta el proceso de detección.

La distribución Log-Weibull fue aplicada en la modelación del *clutter* marino *spiky* (con magnitudes elevadas frecuentes) por primera vez en [13], donde demostró su superioridad con respecto al modelo Log-Normal que es utilizado frecuentemente para ángulos rasantes muy bajos, polarización HH y alta resolución. Otras aplicaciones en *clutter* marino fueron presentadas en [10-12], reportándose también casos relacionados a *clutter* terrestre [7-9] y atmosférico [14], donde se logra mejores ajustes que modelos de amplia adopción como la distribución K o la Weibull.

El éxito de la distribución Log-Weibull está en el hecho de que su función de densidad de probabilidad se posiciona entre la Weibull y la Log-Normal. La Log-Normal suele producir estimaciones superiores a las reales sobre todo en la región de la cola, mientras que la Weibull tiende a cometer errores por defecto. En cambio, el modelo Log-Weibull tiene una cola larga y flexible en su forma [19].

El rango de interés de los valores posibles del parámetro de forma Log-Weibull se tomó de los estudios existentes. En [13] se encontró $5,29 \leq \beta \leq 7,35$, en [7] $7,76 \leq \beta \leq 10,77$, en [9] $\beta = 6,55$, en [11] $17,72 \leq \beta \leq 20,99$, en [12] $1,07 \leq \beta \leq 7,82$, en [18] $5,05 \leq \beta \leq 20,68$, en [10] $9,37 \leq \beta \leq 10,76$, en [19] $15,91 \leq \beta \leq 16,44$, y en [14] $11,93 \leq \beta \leq 16,4$. Por tanto, se puede asegurar que el *clutter* distribuido Log-Weibull exhibe un parámetro de forma siempre dentro del rango $2,3 \leq \beta \leq 21$.

Detectores CFAR de Ventana Deslizante

Los detectores de ventana deslizante aplicados en radar buscan garantizar la propiedad CFAR que responde al criterio de Neyman-Pearson [20]. Este criterio plantea que la probabilidad de falsa alarma (P_f) toma precedencia ante la probabilidad de detección, por lo que los procesadores buscarán principalmente garantizar que la P_f , se mantenga lo menos alejada posible del valor de diseño.

Para lograr lo anterior, se han aplicado varias estrategias consistentes en la detección de los blancos por comparación con los valores de las celdas vecinas. La más ampliamente difundida se denomina CA-CFAR, o CFAR de promediación, ya que estima el promedio del fondo a partir del cálculo de la media aritmética de las celdas vecinas.

Como se puede apreciar en la figura 1, el CA-CFAR calcula el promedio de las celdas vecinas X , ejecutando primero la sumatoria y luego dividiendo por el total de celdas (N) que usualmente toma los valores de 8, 16, 32 o 64. Luego, el promedio es multiplicado por el factor de ajuste (T) para elevar el umbral que posteriormente será comparado con la magnitud de la celda bajo evaluación (Y), definiéndose así su pertenencia a la clase blanco.

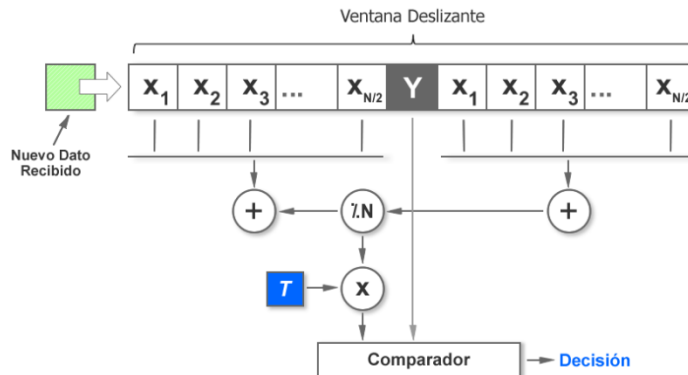


Fig. 1. Diagrama en bloques de un detector CA-CFAR

El punto clave del CA-CFAR, y del resto de las variantes aquí tratadas, es el factor T . A medida que la T aumenta será cada vez menos probable que una muestra de *clutter* sea equivocadamente clasificada como blanco. Para cumplir con la propiedad CFAR se debe subir la T lo suficiente como para que se cumpla un valor determinado de P_f . No obstante, la elevación excesiva perjudica innecesariamente a la probabilidad de detección. Entonces, el factor de ajuste óptimo es aquel que cumple con la P_f de diseño pero no perjudica innecesariamente a la probabilidad de detección.

Si bien realiza una estimación certera del promedio del fondo, el CA-CFAR presenta dificultades cuando aparecen heterogeneidades en el *clutter*. Por ejemplo, si varios blancos ocupan celdas consecutivas sus amplitudes provocarán que el promedio hallado en la ventana deslizando sea demasiado elevado. Como resultado, el blanco que ocupa la posición Y puede no ser detectado. Se dice entonces que ha ocurrido un enmascaramiento del objetivo.

Para prevenir estas situaciones se ha propuesto la aplicación de las alternativas GO-CFAR, SO-CFAR y OS-CFAR, siendo la última la más popular. Las dos primeras variantes comparan las mitades anteriores y posteriores de la ventana deslizando, y efectúan la estimación del promedio solamente con la mayor (GO) o la menor (SO), respectivamente. La diferencia principal es que la primera beneficia la probabilidad de falsa alarma y la segunda la probabilidad de detección. Por su parte, el OS-CFAR ordena las muestras en la ventana y elige como promedio a la que queda justamente en el centro. Así, aunque se perjudica la estimación precisa de la media del fondo, se evitan los enmascaramientos. Cada uno de los procesadores cuenta con su respectivo factor de ajuste que necesita ser reconfigurado para cumplir el criterio de Neyman-Pearson.

Algoritmo de Búsqueda de los Factores de Ajuste Óptimos

Para elegir el factor óptimo (T) es necesario tener en cuenta el total de celdas en la ventana deslizando (N), la probabilidad de falsa alarma de diseño (P_f), la variante de procesamiento aplicada (CA, GO, SO ó OS), y el parámetro de forma del *clutter* que puede asumirse como distribuido Log-Weibull (β). Por tanto, para calcular los valores óptimos hay que producir experimentos de Monte Carlo que incluyan todas estas variables.

Los experimentos se realizaron tomando como base 30 millones de muestras Log-Weibull que fueron generadas utilizando la técnica de inversión de la función de distribución acumulada [21]. Cada millón de muestras fue creado con un valor diferente del parámetro de forma, cubriendo el intervalo previamente discutido de $2,3 \leq \beta \leq 21$. Los primeros 20 valores de β se escogieron con una separación uniforme dentro del rango conocido. Entonces, se adicionaron otros diez valores en la región donde se comprobó que existía una variación más notable del comportamiento.

Las probabilidades de diseño seleccionadas fueron $P_f = 10^{-2}$, $P_f = 10^{-3}$ y $P_f = 10^{-4}$ que coinciden con las empleadas para otras distribuciones en estudios similares [22-25]. Estas probabilidades son útiles en aplicaciones de radar como la detección de blancos móviles.

El procedimiento de obtención de los valores T óptimos siguió una forma iterativa. En la primera iteración se tomó un millón de muestras y se procesó con un detector, por ejemplo el CA-CFAR, y una T de 0,1 que es un valor muy bajo. Como todas las muestras eran de *clutter*, cada detección ocurrida se interpretó como una falsa alarma. Por tanto, se midió la probabilidad de falsa alarma dividiendo la cantidad de detecciones erróneas entre el total de muestras.

Como era de esperar, se obtuvo una P_f muy alta dada la pequeña T elegida. La iteración siguiente repitió el procesamiento tras aumentar T , con lo que se obtuvo una P_f más baja. Así, se siguieron ejecutando iteraciones realizándose una búsqueda binaria donde se aumentó o redujo T hasta encontrar el punto donde ocurrió una $P_f = 10^{-2}$ con un error inferior al 1 %. En este momento concluyó la primera corrida del algoritmo, que requirió de alrededor de 20 iteraciones, donde cada iteración tardó cerca de un minuto en una computadora personal Intel Core i5-4460 CPU (3,20 GHz) con 4 GBs de memoria RAM.

La secuencia anterior fue repetida cambiando cada una de las variables. Primero se establecieron $P_f = 10^{-3}$ y $P_f = 10^{-4}$ en reemplazo de la $P_f = 10^{-2}$ original. Luego se cambió el tamaño de la ventana entre los valores de 8, 16, 32 y 64. Después se modificó el procesador probando las cuatro alternativas más utilizadas (CA, GO, SO y OS). Por último, tras terminar con el primer millón de muestras se repitió la secuencia con el millón siguiente hasta completar los 30 millones. Como resultado del algoritmo de búsqueda, se obtuvieron 1 440 valores de T que caracterizan el comportamiento para un gran número de ocurrencias de las variables tratadas.

Red Neuronal para Reproducir Resultados

Las 1 440 T s extraídas de los experimentos pueden ser almacenadas en tablas para su posterior aplicación en ambientes operacionales. Sin embargo, esto traería dos problemas: (1) el tiempo de búsqueda en la tabla puede retrasar la operación del detector, y (2) los valores intermedios no tabulados de β tendrían que ser aproximados por algunos de los 30 incluidos en los experimentos.

Para evitar estos inconvenientes, se entrenaron cuatro redes neuronales para que devolvieran el valor de T a aplicar ante cualquier ocurrencia de β y el resto de las variables de operación. Cada red correspondió a uno de los cuatro detectores en cuestión. Nótese que en realidad no es necesaria la obtención de valores intermedios para P_f o N , que siempre tomarán alguno de los valores discretos tabulados.

La red neuronal entrenada tiene las características mostradas en la tabla 1, que fueron tomadas de lo aplicado en investigaciones relacionadas [26-28]. Para el mejor entendimiento del significado de estos parámetros el lector es referido a literatura especializada [29].

Tabla 1. Configuración de las variables internas de la red neuronal

Variables de la Red	Selección
Tipo de Red	Red Alimentada hacia Adelante (Perceptrón Multicapa)
Función de Entrenamiento	<i>BackPropagation</i> (Levenberg-Marquardt)
Número de Capas	3 (Capa de Entrada – Capa Oculta– Capa de Salida)
Función de Transferencia o Activación	Tangente Hiperbólica Sigmoide (Capa Oculta), Función de Transferencia Lineal (Capa de Salida)
Medición del Error	Error Medio Cuadrático
División del Conjunto de Entrenamiento	70 % Entrenamiento – 15 % Validación - 15 % Prueba
Presentación de las Muestras	Entrenamiento por Lotes

RESULTADOS Y DISCUSIÓN

La presente sección está dedicada a ofrecer al lector los resultados obtenidos de las simulaciones, así como un análisis de los mismos. Para ello se divide la sección en dos acápites. El primero analiza la influencia de las variables de la simulación sobre el valor del factor de ajuste obtenido; mientras que el segundo discute la generalización de los resultados lograda a través de redes neuronales.

Influencia de las variables sobre el factor de ajuste

Para estudiar la influencia de las distintas variables sobre los resultados se divide el análisis en varias gráficas que reducen la dimensión de la salida. Las curvas que se muestran en las figuras 2, 3 y 4 presentan la relación entre el parámetro de forma Log-Weibull y el factor de ajuste del detector para diferentes combinaciones de variables de entrada. Las tendencias representadas son comunes al resto de los casos específicos no abordados.

Una primera aproximación a lo obtenido a través de las simulaciones de Monte Carlo se observa en la figura 2, que incluye los factores T producidos por diferentes probabilidades de falsa alarma (P_f), operando con un CA-CFAR de 64 celdas. Como puede apreciarse, a medida que se disminuye la P_f aumenta la T , siendo más notable la diferencia para la región de los valores inferiores de β . Este hecho se debe a la propia relación entre β y T . Los factores de ajuste muestran poca variación para cifras elevadas del parámetro de forma, donde ocurre un efecto de "saturación" del ritmo de cambio. Lo aquí mostrado coincide con el efecto que producen las distribuciones Weibull y K tratadas en [23, 25].




Fig. 2. Relación entre el parámetro de forma Log-Weibull y el factor de ajuste CA-CFAR para varias probabilidades de falsa alarma

Por otra parte, la consecuencia de aumentar la cantidad de muestras en la ventana deslizante (N) se ilustra en la figura 3, la cual grafica la respuesta obtenida por un SO-CFAR con P_f de diseño igual a 10^{-4} . La relación es también inversamente proporcional: dimensiones superiores de la ventana provocan factores inferiores. La explicación se encuentra en el hecho de que al emplear una menor cantidad de celdas para estimar el promedio del fondo, un procesador CFAR realizará un cálculo impreciso de la media del *clutter*. Así, serán frecuentes las sobreestimaciones que requerirán de un factor elevado para asegurar la mantención de la probabilidad de falsa alarma de diseño.

También la elección de la variante CFAR a aplicar influye en el valor óptimo de T , según lo mostrado en la figura 4, que fue elaborada con los datos correspondientes a $N = 8$ y $P_f = 10^{-3}$. El SO-CFAR es quien exhibe las cifras superiores, dado que su mecanismo de selección de la subventana de menor promedio produce subestimaciones de la media del *clutter* que precisan de mayores T s. Por su parte, el OS-CFAR sostiene valores de

ajuste muy reducidos en comparación al resto, debido a que el proceso de estadística ordenada devuelve estimaciones muy variables de la media. Por último, las respuestas del CA-CFAR y el GO-CFAR mostraron comportamientos bastante similares.




Fig. 3. Relación entre el parámetro de forma Log-Weibull y el factor de ajuste SO-CFAR para cantidades variables de celdas en la ventana deslizante




Fig. 4. Relación entre el parámetro de forma Log-Weibull y el factor de ajuste de múltiples procesadores

Como resumen de este acápite, se demuestra que cada una de las variables consideradas tiene un aporte en la selección de T . A medida que aumentan N , P_f o β la T será menor, aunque con ritmos de cambio diferentes. Por otra parte, el empleo del procesador SO-CFAR maximiza la respuesta, mientras que el OS-CFAR la minimiza.

Generalización con Redes Neuronales

Una vez concluidas las simulaciones, se requería de un mecanismo para sintetizar los resultados en un solo ente que permitiera su aplicación directa en la práctica. El uso de una tabla de búsqueda (*look-up table*) es una alternativa realizable; sin embargo, retrasa la velocidad de ejecución como consecuencia de la búsqueda que es necesario realizar entre todos los elementos listados. Además, los valores de β distintos de las 30 realizaciones

utilizadas en los experimentos deben ser aproximados por su homólogo discreto más cercano, lo cual acarrea imprecisiones en la estabilidad de los sistemas que presentarán saltos bruscos en su flujo de operación.

En los estudios de [22, 23] se utilizaron ajustes de curva y superficie del tipo racional y de potencia con buenos resultados. No obstante, en la investigación actual se encontró que el ajuste podía mejorarse empleando redes neuronales. Este tipo de aproximador por inteligencia artificial es capaz de imitar diversos comportamientos, evitando la rigidez de las expresiones matemáticas cuya capacidad de adaptación es limitada.




Fig. 5. Cercanía de la respuesta de la red neuronal y los valores T obtenidos de las simulaciones

La figura 5 compara la respuesta de una red neuronal con 30 valores de T producidos con un GO-CFAR de ocho celdas en la ventana deslizante y probabilidad de falsa alarma de diseño de 10^{-2} . Nótese como la red logra permanecer cercana a la respuesta deseada para todo el rango del parámetro de forma, manteniendo una interpolación suave entre los distintos valores de T .

En total, fueron entrenadas cuatro redes neuronales, donde cada una se correspondía con uno de los procesadores CFAR. Las diferencias entre la respuesta del aproximador inteligente y el valor T extraído de las simulaciones de Monte Carlo se muestra en la tabla 2. Se cuantificaron los errores promedios y porcentuales, siendo este último un valor relativo que se calcula con respecto al rango de variación de T de cada variante de detección. El autor considera que se logró un ajuste de gran calidad dado que el error porcentual está siempre por debajo del 0,22 %.

Tabla 2. Errores promedio y porcentual de la aproximación neuronal.

	CA-CFAR	OS-CFAR	GO-CFAR	SO-CFAR
Error Promedio	0,011 8	0,006 3	0,010 8	0,017 3
Rango de Variación	6,601 0	3,948 2	5,994 8	8,055 0
Error Porcentual	0,178 8 %	0,159 6 %	0,180 2 %	0,214 8 %

Una vez entrenadas las redes neuronales, se sometieron los detectores CA-CFAR, OS-CFAR, GO-CFAR y SO-CFAR a conjuntos de muestras Log-Weibull generadas en computadora con variaciones del parámetro de forma. Cuando no se aplicó la corrección del factor de ajuste por redes neuronales los resultados fueron muy malos, observándose desviaciones superiores al 200 % con respecto a la P_f de diseño. En cambio, al utilizar la red neuronal como selector del factor de ajuste, la desviación se redujo según se muestra en la figura 6.

Para $P_f = 10^{-2}$ y $P_f = 10^{-3}$ las diferencias entre el valor P_f obtenido y el de diseño fueron inferiores al 10 % en la mayoría de los casos. Por su parte, la desviación para $P_f = 10^{-4}$ fue cercana al 24 %. El aumento del error es producto de que las simulaciones de Monte Carlo incluyeron conjuntos invariables de un millón de muestras para las tres P_f s de diseño; cuando en realidad la población de falsas alarmas es menor para $P_f = 10^{-4}$, donde ocurren 100 falsas alarmas por cada millón de muestras.




Fig. 6. Desviación Porcentual con Respecto a la Probabilidad de Falsa Alarma de Diseño obtenida realizando la estimación del factor de ajuste con redes neuronales

Como conclusión del acápite, se comprobó, mediante simulaciones computacionales, que los valores óptimos T hallados permiten reducir la variación en la probabilidad de falsa alarma de diseño a un 12 %, aun cuando se procesan muestras con parámetro de forma variable en el rango de valores posibles. El método de Monte Carlo aplicado es efectivo en la obtención de valores T óptimos; en este sentido, se recomienda mantener la población de falsas alarmas cercana a 1 000 si se desea que la desviación sea de un 10 %.

VALORACIÓN DEL ESTUDIO

La investigación actual realizó simulaciones de Monte Carlo sobre 30 millones de muestras Log-Weibull generadas en computadora, modificando sucesivamente cuatro variables: 1. el procesador a utilizar; 2. la dimensión de la ventana deslizante; 3 la probabilidad de falsa alarma de diseño; 4. el parámetro de forma de la distribución del *clutter*. Como resultado se obtuvieron una gran cantidad de valores óptimos del factor de ajuste que deben aplicarse en cada una de las combinaciones de variables de operación abordadas. Para generalizar este comportamiento, se entrenaron cuatro redes neuronales que reproducen la respuesta más allá de los valores discretos obtenidos en las simulaciones.

Este desarrollo permitió obtener un sistema que estima los factores de ajuste óptimos CA-CFAR, OS-CFAR, GO-CFAR y SO-CFAR a ser aplicados para garantizar que la probabilidad de falsa alarma operacional permanezca cercana a la de diseño. Una propuesta similar había sido presentada con anterioridad para la distribución Log-Normal [19], señalándose la necesidad de realizar simulaciones computacionales para cada nueva realización del factor de ajuste. Sin embargo, la propuesta aquí defendida constituye un paso de avance pues utiliza un método costoso computacionalmente (simulaciones de Monte Carlo) para obtener una gran cantidad de datos; estos son entonces generalizados por una red neuronal que realiza una estimación muy rápida, lo que permite prescindir de cualquier tipo de simulación computacional que retrase la ejecución.

La solución actual da continuación a lo publicado previamente en [22] por el autor para las distribuciones Weibull, Log-Normal y K. Ahora se logró un mejor ajuste a los datos gracias al empleo de redes neuronales, en contraposición al ajuste racional aplicado en [22]. Las redes neuronales demostraron ser más adaptables a diversas respuestas, gracias a que no están sujetas a las restricciones de la definición matemática rígida de los ajustes numéricos como el racional. Por otra parte, aunque el estudio de [23] logra una precisión mejor que la

aquí presentada aplicando ajustes numéricos, la calidad del resultado se sustenta en un número limitado de variables, que no incluyeron variaciones en el tamaño de la ventana deslizante, o múltiples probabilidades de falsa alarma en un mismo estimador.

El uso de los factores óptimos aquí encontrados mejorará la estabilidad en la probabilidad de falsa alarma de los detectores frente a cambios estadísticos en la señal de *clutter* terrestre, marino y atmosférico. La mejora se reflejará en una pantalla de radar más clara y menos propensa a alterar su funcionamiento ante el cambio de la zona de exploración. La solución propuesta es ideal para aplicarse en radares costeros fijos o situados sobre embarcaciones explorando las costas cubanas. Ellos pueden encontrar alternancia entre altas y bajas profundidades, manglares, aguas salobres, islotes, costas irregulares y vegetación acuática prominente, condiciones que modifican el parámetro de forma de la distribución del fondo. Adicionalmente, la diversidad de variables incluidas en las simulaciones hace que puedan usarse los ajustes del factor CFAR aun cuando se cambia el procesador o la dimensión de la ventana deslizante. Por tanto, la aplicación de los resultados se extiende a variantes de procesamiento que alternan el tipo de CFAR o la cantidad de celdas en la ventana como respuesta a necesidades o condiciones variables [30-32].

La implementación cabal del método presentado para la corrección del factor de ajuste requiere de una técnica de estimación del parámetro de forma de la distribución Log-Weibull, ya que las simulaciones ejecutadas trabajaron bajo la suposición de conocimiento a priori. En [33] se utilizó una aproximación por máxima verosimilitud para el cómputo de la β Log-Weibull. Sin embargo, el procedimiento descrito consiste en la evaluación iterativa de una expresión, lo cual retrasa el cálculo. En radares es necesaria la operación en tiempo real para la correcta visualización de los blancos. Por tanto, se recomienda la búsqueda de estimadores más rápidos. Una posible solución puede alcanzarse con redes neuronales entrenadas a partir de histogramas de las muestras, puesto que ya se han obtenido excelentes resultados para las distribuciones Weibull, K y Pareto [34-36].

Una vez se disponga de la técnica de estimación, se recomienda la implementación de la solución completa en FPGA (*Field Programmable Gate Array*, Arreglo de Compuertas Programables). Las capacidades de procesamiento paralelo de este sistema sacan el mejor partido de las redes neuronales que destacan también por la ejecución paralela simultánea de sus elementos internos.

CONCLUSIONES

Se comprobó, mediante simulaciones computacionales, que aplicando una red neuronal adjunta a un procesador CFAR se logran minimizar los efectos perjudiciales introducidos por la variación constante del parámetro de forma de la distribución Log-Weibull del *clutter*. Específicamente, el sistema alcanza a mantener la probabilidad de falsa alarma operacional con una desviación promedio del 12 % con respecto al valor concebido en el diseño, gracias a la selección constante del factor de ajuste óptimo. Los resultados son válidos para los procesadores CA-CFAR, OS-CFAR, GO-CFAR y SO-CFAR, además de para tres probabilidades de falsa alarma de diseño y un intervalo del parámetro de forma Log-Weibull que se corresponde con lo reportado para *clutter* terrestre, marino y atmosférico.

La aplicación fundamental del estudio está en el diseño de nuevos detectores adaptados a escenarios cambiantes, como los que aparecen en las costas cubanas, donde se modifica el parámetro de forma del *clutter* producto del cambio en las características físicas de la región de exploración. Conjuntamente, se viabiliza la implementación de variantes de detección que alternan entre varios procesadores y tamaños de ventana, en respuesta al comportamiento del *clutter*.

Como futuras proyecciones, se prevé la codificación de la solución presentada en FPGA para su aplicación directa en ambientes operacionales. La construcción de un esquema funcional precisa también de un método rápido de estimación del parámetro de forma Log-Weibull, de lo contrario el sistema no podría funcionar en tiempo real.

REFERENCIAS

1. Ward K, Tough R, Watts S. Sea Clutter Scattering, the K Distribution and Radar Performance. 3ra edición. 2013. The Institution of Engineering and Technology, London, United Kingdom. ISBN: 0863415032. doi: 10.1049/PBRA025E
2. Melvi WL, Scheer JA. Principles of Modern Radar. Vol III Radar Applications. 2014, Scitech Publishing, New Jersey, USA. ISBN: 978-1891121548

3. Palama R, et al. Statistical Analysis of Bistatic and Monostatic Sea Clutter. *IEEE Transactions on Aerospace and Electronic Systems*. 2015, 51(4): 3036-3054. doi: 10.1109/TAES.2015.140438.
4. Mezache A, et al. Model for non-Rayleigh Clutter Amplitudes Using Compound Inverse Gaussian Distribution: An Experimental Analysis. *IEEE Transactions on Aerospace and Electronic Systems*. 2015, 51(1): pp. 142-153.
5. Schoenecker S, Willett P, Bar Shalom Y. The Effect of K-Distributed Clutter on Trackability. *IEEE Transactions on Signal Processing*. 2016, 64 (2):475-484. doi: 10.1109/TSP.2015.2478745.
6. Rosenberg L, Bocquet S. Application of the Pareto Plus Noise Distribution to Medium Grazing Angle Sea-Clutter. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2015, 8(1):255-261. doi: 10.1109/JSTARS.2014.2347957.
7. Sayama S, Sekine M. Weibull, Log-Weibull and K-Distributed Ground Clutter Modelling Analyzed by AIC. *IEEE Transactions on Aerospace and Electronic Systems*. 2001, 37(3):1108-1113. doi: 10.1109/7.953262.
8. Sayama S, Ishii S. Amplitude Statistics of Ground Clutter from Town and Hill Observed by S-band Radar. *IEEJ Transactions Fundamentals and Materials*. 2011, 131(11):916-923. doi: 10.1541/ieejfms.131.916.
9. Sayama S, Sekine M. Amplitude Statistics of Ground Clutter after MTI Processing. *IEEJ Transactions on Fundamentals and Materials*. 2004, 124(12):1171-1176. doi: 10.1541/ieejfms.124.1171.
10. Sayama S, Ishii S. Amplitude Statistics of Sea Clutter by MDL Principle. *IEEJ Transactions Fundamentals and Materials*. 2012, 132(10):886-892. doi: 10.1541/ieejfms.132.886.
11. Sayama S, Ishii S, Sekine Matsuo. Amplitude Statistics of Sea Clutter Observed by a Millimeter Wave Radar Analyzed by Minimum Description Length (MDL) Principle. *International Journal of Infrared and Millimeter Waves*. 2005, 26(11):1639-1649.
12. Sayama S, Ishii S, Sekine M. Amplitude Statistics of Sea Clutter Observed by L-band Radar. *IEEE Transactions on Fundamentals and Material*. 2006, 126(6):438-442. doi: 10.1541/ieejfms.126.426.
13. Sekine M, et al. Log-Weibull Distributed Sea Clutter. *IEE Proceedings*. 1980, 127(3): 225-228. doi: 10.1049/ip-f-1:19800033.
14. Sayama S, Ishii S. Suppression of Weather Clutter by Means of Log-normal/CFAR Circuit Modified CA LOG/CFAR Circuit. *Electrical Engineering in Japan*. 2014, 187(4): 1-9. doi: 10.1002/eej.22514
15. De Maio A, Greco MS, Orlando D. Capítulo 1: Introduction to Radar Detection, en *Modern Radar Detection Theory*. 2016, Scitech: New Jersey, USA. ISBN: 1613531990
16. Rohling H. Radar CFAR Thresholding in Clutter and Multiple Target Situations. *IEEE Transactions on Aerospace and Electronic Systems*. 1983, 19(4):608-621. doi: 10.1109/TAES.1983.309350
17. Machado Fernández JR, Bacallao Vidal, JC. MATE-CFAR: Ambiente de Pruebas para Detectores CFAR en MATLAB. *Telem@tica*. 2014, 13(3):86-98.
18. Ishii S, Sayama S, Mizutani K. Effect of Changes in Sea-Surface State on Statistical Characteristics of Sea Clutter with X-band Radar. *Wireless Engineering and Technology*. 2011, 2(3):175-183. doi: 10.4236/wet.2011.23025.
19. Sayama S, Ishii S. Suppression of Log-Normal Distributed Weather Clutter Observed by an S-Band Radar. *Wireless Engineering and Technology*. 2013, 4(3):125-133. doi: 10.4236/wet.2013.43019.
20. Barkat M. *Signal Detection and Estimation*. 2da edición. 2005, Artech House, New York, USA. ISBN: 1-58053-070-2.
21. Gentle JE. *Random number generation and Monte Carlo Methods*. 2da edición. 2003, Springer, New York, USA. ISBN: 0-387-00178-6.
22. Machado Fernández JR, Torres Martínez S, Bacallao Vidal JC. CA-CFAR Adjustment Factor Correction with a priori Knowledge of the Clutter Distribution Shape Parameter. *International Journal of Artificial Intelligence and Interactive Multimedia*. 2016, 4(4):7-13.
23. Machado Fernández JR, Bacallao Vidal JC. Optimal Selection of the CA-CFAR Adjustment Factor for K Power Sea Clutter with Statistical Variations. *Ciencia e Ingeniería Neogranadina*. 2016, 27(1): 61-76. doi: 10.18359/rcin.1714.

24. Machado Fernández JR, Bacallao Vidal JC. Estimation of the Optimal CA-CFAR Threshold Multiplier in Pareto Clutter with Known Parameters (aceptado). *Entramado*, 2017.
25. Machado Fernández JR. Estimation of the Relation between Weibull Distributed Sea clutter and the CA-CFAR Scale Factor. *Journal of Tropical Engineering*. 2015, 25(2):19-28. doi: 10.15517/jte.v25i2.18209.
26. Machado Fernández JR, Bacallao Vidal JC. Estimation of the Optimal CA-CFAR Threshold Multiplier in Pareto Clutter with Known Parameters (aceptado). *Entramado*, 2017. LING, Dang; PINGJUN, Wang. A Method for Determining Scale Factor of CFAR Detector Based on BP Neural Networks. 2nd International Conference on Computer Application and System Modeling. 2012. doi: 10.2991/iccasm.2012.116. Disponible en Web: www.atlantis-press.com/php/download_paper.
27. Garzón Guerrero JA. Clasificación de Blancos de Radar en Ambientes de Ruido Arbitrario mediante Resonancias Naturales y Técnicas de Componentes Principales. Doctor en Ciencias, 2012, Universidad de Granada. doi: 10.1109/MIKON.2004. Disponible en Web: <https://hera.ugr.es/>
28. Gálvez Nick B, Cousseau James E. Improved Neural Network Based CFAR Detection for non Homogeneous Background and Multiple Target Situations. *Latin American Applied Research*. 2012, 42(1):343-350.
29. Alpaydin E. *introduction to machine learning*. 2nd edición. 2010, Edit. MIT Press, London, England. ISBN: 978-0-262-01243-0.
30. Kim Jeong H, BELL, Mike R. A computationally efficient CFAR algorithm based on a goodness-of-fit test for piecewise homogeneous environments. *IEEE Transactions on Aerospace and Electronic Systems*. 2013, 49(3):1519-1535.
31. Gandhi Paul P, Kassam Simon A. Two level CFAR detector (TL-CFAR) Analysis of CFAR processors in Homogeneous Background. *IEEE Transactions on Aerospace and Electronic Systems*. 1988, 24(4):427-445.
32. Wicks Michael C. Expert System Application to Constant False Alarm Rate (CFAR) Processor. Lecture Series on Knowledge-Based Radar Signal and Data Processing, Knowledge-Based Radar Signal and Data Processing Convention, Stockholm, Sweden, 3-4 November 2003. Disponible en Web: www.dtic.mil/dtic/tr/fulltext/u2/a472792.pdf.
33. Zhu D, Sun J. Empirical Distributions of Stock Returns and Applications in Value at Risk. 2014. Faculty of Business Administration, Faculty of Business Administration, Simon Fraser University: Canada. Disponible en Web: summit.sfu.ca/system/files/iritems1/14638/final_version_-_Difei_Zhu_%26.
34. Machado Fernández JR, Bacallao Vidal JC. Improved Shape Parameter Estimation in K Clutter with Neural Networks and Deep Learning. *International Journal of Interactive Multimedia and Artificial Intelligence*. 2016, 3(7): 96-103. doi: 10.9781/ijimai.2016.3714.
35. Machado Fernández JR, Bacallao Vidal, JC. Improved Shape Parameter Estimation in Pareto Distributed Clutter with Neural Networks. *International Journal of Artificial Intelligence and Interactive Multimedia*. 2016, 4(2):7-11. doi: 10.9781/ijimai.2016.421.
36. Machado Fernández JR, Bacallao Vidal JC, Chávez Ferry N. A Neural Network Approach to Weibull Distributed Sea Clutter Parameter's Estimation. *Inteligencia Artificial*. 2015, 18(56):3-13. doi: 10.4114/ia.v18i56.1090