

Multipixel Optical Detection of the Weak Floating Objects on an Agitated Sea Surface

D. Kantún, V. Golikov, *Member, IEEE*, and H. Alazki

Abstract—In this work, a new detection algorithm is proposed to improve the well-known Matched Subspace Detector (MSD) in a new scenario where the object is weak and with a priori unknown parameters. Detection algorithms using statistical parameters MSD are designed in base of the General Likelihood Ratio Test (GLRT), because they can provide a universal solution to detection problems where object parameters are partially or totally unknown. However, many works and papers to today were proposed minimum changes to this detector in order to adapt it to specific environments and improve the performance of the same detector. Both algorithms are implemented in simulated environments and real video cases in order to verify the improvement of the new algorithm.

Index Terms—Multipixel optical detection, Sea surface, Gaussian white noise.

I. INTRODUCCIÓN

LA DETECCIÓN de objetos utilizando secuencias de imágenes, como las que se pueden encontrar en video, han sido objeto de gran interés en aplicaciones tanto de vigilancia como de monitoreo e incluso para la Inteligencia Artificial ([4]-[8] [10]-[12], [14]-[16]).

Siendo esta una rama de interés para diferentes disciplinas, uno de los problemas a los que se enfrenta es a un escenario donde tanto el objeto de interés como el fondo que lo rodea son fluctuantes, de la misma forma que el tamaño, forma y posición del objeto son desconocidos. Algunos trabajos han utilizado y mejorado la sustracción de fondo [1] o la detección de bordes [9] para la detección de objetos. Sin embargo, estas técnicas en lo general asumen que, tanto la forma del objeto, como el contorno de los objetos que lo rodean y el fondo no son cambiantes, y suelen fallar en condiciones en las que tanto el fondo como el objeto de interés están en constante movimiento.

Diferentes trabajos han atacado el problema utilizando métodos estadísticos, los cuales tienen un mejor desempeño ante otros métodos de detección bajo ciertas condiciones de señal y ruido.

El detector subespacial acoplado (“Matched Subspace Detector” o MSD) diseñado a través de la prueba de verosimilitud [17], o la prueba de verosimilitud generalizada (“General Likelihood Ratio Test” o GLRT) ([3], [7],[8],[10]) ha sido un detector de interés al atacar este problema, ya que permite la detección de objetos incluso cuando el mismo es de parámetros desconocidos. Es por ese motivo que suele ser una especie de detector universal para los problemas de detección. A pesar de esto, muchos investigadores han intentado mejorar dicho algoritmo para tratar de llevar al máximo su desempeño, poniéndolo a prueba en diferentes escenarios de objetos y fondos ([2], [3], [14], [15], [18]), y así adaptarlo a necesidades específicas.

En el año 2016, Golikov, Lebedeva y Rodríguez ([11]-[13]) propusieron una serie de algoritmos basados en una aproximación de la GLRT para resolver problemas relacionados a la detección de objetos multipíxeles utilizando únicamente un conjunto de píxeles (o sub-imagen) en una secuencia consecutiva de imágenes. A pesar de mostrar una mejora con respecto al algoritmo MSD clásico, su desventaja es que asume que el objeto no cubre por completo la sub-imagen, por lo que existe una componente de energía de los píxeles que no contienen al objeto.

En este trabajo se presenta una modificación al algoritmo MSD, asumiendo un escenario donde el objeto cubre toda la sub-imagen, lo cual hace suponer que el objeto es de un tamaño igual o mayor al de la sub-imagen, o por lo menos cubrir la mayor parte de la misma. El nuevo detector será llamado “Detector Subespacial Acoplado Modificado 2” (“Modified Matched Subspace Detector 2” o MMSD₂). Este nuevo algoritmo se pondrá a prueba bajo las mismas condiciones tanto simuladas como en video real con el algoritmo MSD para mostrar su mejora en desempeño y detección de la señal del objeto.

II. PLANTEAMIENTO DEL PROBLEMA Y DISEÑO DEL SISTEMA

Consideramos el problema de detección como una secuencia de K imágenes digitales modeladas con ruido gaussiano homogéneo. Se considera que el objeto de tamaño N se encuentra en todos los píxeles de la sub-imagen de tamaño L , lo que implicaría que el objeto es de igual o mayor tamaño que la sub-imagen ($N \geq L$) y que la contribución de la energía de los píxeles que no contienen al objeto, al no existir estos, se puede eliminar del planteamiento.

Además, se considera una matriz de covarianza muy cercana a una matriz identidad después de sustraer la variable de la media de las imágenes [16].

D. E. Kantún, Universidad Autónoma del Carmen, Ciudad del Carmen, Campeche, México, dkantun@gmail.com.

V. Golikov, Universidad Autónoma del Carmen, Ciudad del Carmen, Campeche, México, vgolikov@pampano.unacar.mx.

H. Alazki, Universidad Autónoma del Carmen, Ciudad del Carmen, Campeche, México, halazki@pampano.unacar.mx.

Definimos Ω_T como un subconjunto de enteros que indexan los píxeles que contienen al objeto bajo la hipótesis alternativa H_1

$$\Omega_T \equiv \{1, \dots, N\} \subset \Omega (N > L) \quad (1)$$

Los vectores homogéneos del fondo \mathbf{c}_i y del ruido del canal \mathbf{n}_i se pueden modelar como vectores normales aleatorios independientes de dimensión K , es decir

$$\mathbf{c}_i \sim (0, \sigma_c^2 \mathbf{I}), \quad (2)$$

$$\mathbf{n}_i \sim (0, \sigma_n^2 \mathbf{I}) \quad (3)$$

respectivamente.

La señal útil se puede presentar como

$$\mathbf{s}_i = \mathbf{H}\theta_i \text{ para cada } i \in \Omega_T \quad (4)$$

donde θ_i es un parámetro desconocido con un vector de amplitud $p \times 1$ que ubica la señal determinística del objeto en un sub-espacio del objeto de bajas dimensiones, es decir, la oscilación del objeto.

Este modelo es equivalente a uno ya conocido ([6], [10], [17]). Mientras tanto \mathbf{H} ([6], [17]) es una matriz de Vandermonde con componentes discretos complejos y exponenciales, esto es, una transformada de Fourier discreta.

Consideramos la señal discreta recibida \mathbf{x}_i desde el punto i del sub-espacio analizado como un vector $K \times 1$ para K imágenes recibidas. La prueba de hipótesis puede escribirse con dos hipótesis: una nula (H_0) y una alternativa (H_1), las cuales se pueden expresar de la siguiente forma:

$$\begin{cases} H_0 : \mathbf{x}_i = \mathbf{c}_i + \mathbf{n}_i, & i \in \Omega \\ H_1 : \mathbf{x}_i = \mathbf{s}_i + \mathbf{n}_i, & i \in \Omega_T \end{cases} \quad (5)$$

Si la forma, ubicación y tamaño del objeto son desconocidos a priori, según el criterio de Neyman-Pearson, la solución óptima es la LRT (Likelihood Ratio Test) para parámetros conocidos [15], o la GLRT para parámetros desconocidos ([2]-[4], [7], [8], [10], [11], [14], [15], [18]). El objetivo principal es obtener el algoritmo de detección T desde el vector recibido \mathbf{x}_i usando método GLRT. El método GLRT requiere tener la densidad de probabilidad $L(\cdot)$ para las ambas hipótesis estadísticas, L_1 respecto a conjunto de vectores que están en sub-espacio analizado cuando el objeto de interés está presente, L_0 respecto a conjunto de vectores que están en subespacio analizado cuando el objeto no está presente.

Sabiendo que los parámetros son desconocidos, para este caso la GLRT requiere una maximización de la función de verosimilitud respecto a θ_i del objeto desconocido, y una varianza $\sigma_{1,i}^2$ correspondiente a la suma del fondo más el ruido para cada vector de píxeles i bajo H_1 .

Las estimaciones de verosimilitud máxima ("Maximum Likelihood Estimates" o MLE) de θ_i y de $\sigma_{1,i}^2$ se utilizan

para realizar una aproximación GLR, la cual puede expresarse de la siguiente forma:

$$\begin{aligned} \text{GLR}(\mathbf{x}) &= \frac{L_1(\mathbf{x}_1, \dots, \mathbf{x}_L; | H_1)}{L_0(\mathbf{x}_1, \dots, \mathbf{x}_L; | H_0)} \\ &= \frac{\max_{\theta_i, \sigma_{1,i}^2} p_1(\mathbf{x}_1, \dots, \mathbf{x}_L; \sigma_{1,i}^2, \theta_i | H_1)}{p_0(\mathbf{x}_1, \dots, \mathbf{x}_L; | H_0)} \end{aligned} \quad (6)$$

Se toma una de las MLE de $\sigma_{1,i}^2$ para la estimación del subconjunto Ω_T cuando el objeto está presente, y esta MLE tiene la siguiente solución [13]:

$$\hat{\sigma}_{1,i}^2 = \frac{\mathbf{x}_i^T \mathbf{x}_i}{K} \text{ para } i \in \Omega_T \quad (7)$$

La MLE del vector θ_i tiene la siguiente solución explícita [11]:

$$\hat{\theta}_i = (\mathbf{H}^H \mathbf{H})^{-1} \mathbf{H}^H \mathbf{x}_i \quad (8)$$

Se asume que el fondo homogéneo tiene una varianza conocida $\sigma_{c+n}^2 = \sigma_c^2 + \sigma_n^2$ [13] bajo H_0 , y una varianza desconocida $\hat{\sigma}_{1,i}^2$ bajo H_1 , lo que implica que la función de distribución de probabilidad (PDF) conjunta para ambas hipótesis se puede escribir como:

$$L_1(\mathbf{x}_1, \dots, \mathbf{x}_L; \hat{\sigma}_{1,i}^2, \hat{\theta}_i | H_1) = \frac{c}{\left(\prod_{i=1}^L |\hat{\sigma}_{1,i}^2 \mathbf{I}| \right)^{1/2}} \quad (9)$$

$$\prod_{i \in \Omega_T} \exp \left[-\frac{1}{2} (\mathbf{x}_i - \mathbf{s}_i)^T (\hat{\sigma}_{1,i}^2 \mathbf{I})^{-1} (\mathbf{x}_i - \mathbf{s}_i) \right]$$

y

$$L_0(\mathbf{x}_1, \dots, \mathbf{x}_L; | H_0) = \frac{c}{|\sigma_{c+n}^2 \mathbf{I}|^{L/2}} \quad (10)$$

$$\exp \left[-\frac{1}{2} \sum_{i=1}^L \mathbf{x}_i^T (\sigma_{c+n}^2 \mathbf{I})^{-1} \mathbf{x}_i \right]$$

Al sustituir (7) y (8) en (9), se obtiene:

$$\begin{aligned} \text{GLR}(\mathbf{x}) &= \frac{(\sigma_{c+n}^2)^{\frac{KL}{2}} \exp \left[\sum_{i=1}^L \frac{\mathbf{x}_i^T \mathbf{x}_i}{2\sigma_{c+n}^2} - \sum_{i=1}^L \frac{K \mathbf{x}_i^T \hat{\theta}_i}{2\mathbf{x}_i^T \mathbf{x}_i} \right]}{\left(\prod_{i=1}^L \frac{\mathbf{x}_i^T \mathbf{x}_i}{K} \right)^{\frac{K}{2}}} \\ &= \frac{(\sigma_{c+n}^2)^{\frac{KL}{2}} \exp \left[\sum_{i=1}^L \frac{\mathbf{x}_i^T \mathbf{x}_i}{2\sigma_{c+n}^2} \right]}{\left(\prod_{i=1}^L \frac{\mathbf{x}_i^T \mathbf{x}_i}{K} \right)^{\frac{K}{2}}} \end{aligned} \quad (11)$$

Al tomar el logaritmo de la raíz $K/2$ de $\text{GLR}(\mathbf{x})$, el nuevo detector basado en GLRT, al que llamaremos MMSD_2 , se obtiene por el siguiente estadístico:

$$T = \sum_{i=1}^L \left(\frac{\mathbf{x}_i^T \mathbf{x}_i}{K \sigma_{c+n}^2} - \ln \frac{\mathbf{x}_i^T \mathbf{x}_i}{K \sigma_{c+n}^2} \right) \quad (12)$$

Al observar el nuevo algoritmo MMSD_2 en (12) se aprecia que tiene una estructura muy similar al algoritmo MMMSD mostrado en [13], con la diferencia de que este nuevo algoritmo no considera la energía de los píxeles que no contienen al objeto. De (12) se infiere que la calidad de la detección depende de la contribución de la energía de los píxeles del objeto y el logaritmo de esos mismos píxeles, lo cual restringe este modelo a un caso particular, es decir, el caso donde el objeto no puede ser más pequeño que la ventana de análisis.

De la misma forma que con MMMSD , MMSD_2 se puede reescribir de la siguiente forma:

$$T = T_{\text{MSD}} + m T_{\text{ad}} \quad (13)$$

donde

$$T_{\text{MSD}} = \mathring{\mathbf{a}} \sum_{i=1}^L \frac{\mathbf{x}_i^T \mathbf{x}_i}{K S_{c+n}^2} \quad (14)$$

$$T_{\text{ad}} = - \mathring{\mathbf{a}} \sum_{i=1}^L \ln \frac{\mathbf{x}_i^T \mathbf{x}_i}{K S_{c+n}^2} \quad (15)$$

y m es el factor de sensibilidad del estadístico.

III. PRUEBAS DE DESEMPEÑO

Para las pruebas de desempeño, se realizan las comparaciones entre MMSD_2 y MSD simulando las mismas condiciones de mar y objeto, de la misma forma se realizan pruebas con muestras de video real. Estas pruebas fueron realizadas implementando los algoritmos en MATLAB® R2017a.

Utilizando dicho software, se generaron 1000 matrices aleatorias de tamaño $K \times L$ con L columnas gaussianas independientes que describen el comportamiento del fondo más el ruido en la dimensión temporal.

La señal útil sintética es generada como 1000 matrices aleatorias de tamaño $K \times N$, donde cada columna $\mathbf{s}_i = \mathbf{H} \boldsymbol{\theta}_i$ son diferentes píxeles del objeto descritos en la dimensión temporal, y \mathbf{H} con las componentes de Fourier que se pueden considerar en el espectro de la señal, la cual puede ser modelada como una matriz de Vandermonde con elementos exponenciales complejos discretos [17]:

$$\mathbf{H} = \begin{bmatrix} 1 & 1 & \cdots & 1 \\ h_1 & h_2 & \cdots & h_p \\ \vdots & \vdots & \ddots & \vdots \\ h_1^{K-1} & h_2^{K-1} & \cdots & h_p^{K-1} \end{bmatrix} \quad (16)$$

donde

$$h_t = \exp\left(\frac{j2\pi t}{K}\right), \quad (17)$$

$$t \in (1, p), \quad (18)$$

$$j = \sqrt{-1} \quad (19)$$

y donde $\boldsymbol{\theta}_i$ es un vector de amplitud desconocida.

La variable p se puede obtener ya sea de una biblioteca digital o a través de mediciones experimentales. En este caso, dicha variable nos permitirá modificar la oscilación del objeto modelado. A pesar de que este parámetro es necesario para modelar dicho objeto, al no formar parte de los estadísticos a comparar, este parámetro no interferirá en el proceso de detección.

Para el proceso de simulación se requerirá de técnicas de conteo de Monte Carlo. Ambos algoritmos son evaluados utilizando curvas Características de Operación del detector ("Receiver Operating Characteristic" o ROC).

La tabla I muestra los parámetros de operación que se utilizaron para esta etapa de simulaciones. El tamaño del fondo es de $K \times L$ píxeles de ruido blanco. El Factor de Llenado ("Fill Factor" o FF) es una relación de qué tanto el objeto cubre la sub-imagen L , en este caso dos objetos de tamaño N y N_1 .

Este factor de llenado puede expresarse en decimales o en porcentaje. Se tienen dos valores de factor de llenado para mostrar mejor cómo se comporta este algoritmo ante dos casos extremos: uno donde el objeto cubre casi toda la sub-imagen L , y otro donde apenas lo cubre.

TABLA I
PARÁMETROS DE OPERACIÓN PARA LAS CURVAS ROC

Parámetro	Rango de valores
Número de imágenes digitales (K)	10 imágenes
Tamaño de la sub-imagen (L)	12 píxeles
Tamaño del objeto 1 ($N = L - 10$)	2 píxeles
Tamaño del objeto 2 ($N_1 = L - 1$)	11 píxeles
Factor de llenado 1 (N / L)	≈ 0.1667
Factor de llenado 2 (N_1 / L)	≈ 0.9167
Factor de sensibilidad (m)	1
Probabilidad de falsa alarma (P_{FA})	$0.05 \leq P_{FA} \leq 0.09$

Observación: $k=10$ imágenes tienen el mismo tamaño $L=3 \times 4=12$ píxeles.

En la Figura 1 se muestra el desempeño de detección cuando se tiene un FF similar a 0.1667 y un ruido de variación del canal de 0.2. Una probabilidad de falsa alarma (P_{FA}) igual o por debajo de 0.05 suele ser aceptable. Sin embargo, para dicho rango, ambos algoritmos tienden a fallar y las probabilidades de detección (P_D) suelen ser de valores por debajo de 0.4.

A pesar de ello, se puede notar un patrón entre las curvas de $MMSD_2$ y MSD , donde $MMSD_2$ suele tener un mejor desempeño sobre MSD . De la misma figura, se puede apreciar que cuando se incrementa el FF, $MMSD_2$ suele tener una mejor respuesta que el algoritmo MSD , y que para una P_{FA} menor a 0.01, $MMSD_2$ tiene una P_D de 0.9, lo cual se considera aceptable para una aplicación de detección.




Fig. 1. Desempeño de detección de un objeto simulado sobre fondo con ruido blanco más ruido del canal con un tamaño diferente de región observada N y N_1 con una variación de ruido del canal de 0.2.

La Figura 2 es graficada cambiando la variación de ruido del canal a 0.35, lo que en una aplicación real se puede considerar algo ruidoso. Se observa que, para valores pequeños de FF, ambos algoritmos fallan en tener una P_D por arriba de 0.9, lo que es esperable bajo este entorno. A pesar de ello, $MMSD_2$ suele tener un mejor desempeño que MSD considerando que se utilizan los mismos parámetros para su evaluación. En general, las Figuras 1 y 2 muestran que $MMSD_2$ tiene un mejor desempeño MSD incluso para valores pequeños de FF.

Un problema se aprecia en la Figura 3, puesto que al ir aumentando el ruido del canal a 0.5, el desempeño de $MMSD_2$ decae más rápido que el de MSD . En efecto, la desventaja en este caso para $MMSD_2$ es que depende mucho de la energía de los píxeles donde se encuentra el objeto, tal como se aprecia en (8), y por lo tanto es sensible a perturbaciones como el ruido del canal. Análisis realizados con valores de ruido más altos suelen dar peores resultados.

Para los análisis con video real se requirió del toolbox Image Processing para obtener un video el cual presenta un objeto (contenedor de plástico) tan pequeño y débil que es

apenas distinguible a simple vista flotando en la superficie del mar (ver Figura 4).

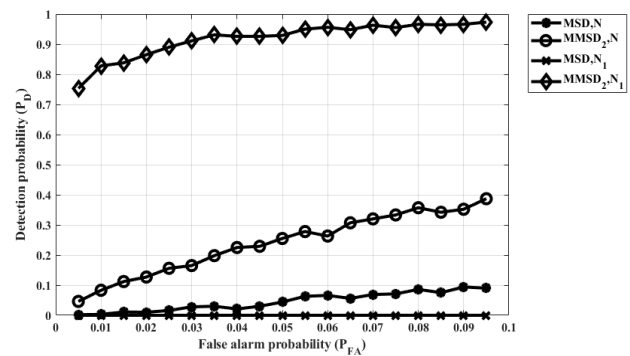


Fig. 2. Desempeño de detección de un objeto simulado sobre fondo con ruido blanco más ruido del canal con un tamaño diferente de región observada N y N_1 con una variación de ruido del canal de 0.35.




Fig. 3. Desempeño de detección de un objeto simulado sobre fondo con ruido blanco más ruido del canal con un tamaño diferente de región observada N y N_1 con una variación de ruido del canal de 0.5.



Fig. 4. Muestra de video real donde se señala en un rectángulo negro el objeto a detectar.

El análisis con video real difiere de una simulación principalmente por el hecho de que los parámetros del video no pueden ser controlados. No se puede variar el ruido del canal o el fondo, se está restringido a la información que el video nos puede proporcionar y por ese motivo la forma de analizar el entorno real debe cambiar. Según método de Monte-Carlo elegimos número de pruebas es igual a 1000 para la probabilidad de falsa alarma $F=0.01$. La prueba se realizó tomando $K \times 1000$ cuadros de video, los cuales $K = 10, 20, 30$, cada píxel es representado en escala de grises a 8 bits (256 niveles de gris), y en vista de que el objeto no puede cambiar de tamaño a voluntad, será la ventana de

análisis la que cambiará de tamaño para que el objeto cubra toda o una parte de la misma. En este caso, 5×5 pixeles es el caso donde el objeto tiene un FF de 0.3 aproximadamente. Se añade que el objeto grabado se encuentra aproximadamente a 100 metros de la cámara.

Para entender las Figuras 5, 6 y 7 se debe hacer énfasis que los resultados obtenidos por H_1 , mientras más se alejan de H_0 , significa que dicho algoritmo tiene un buen desempeño de detección.

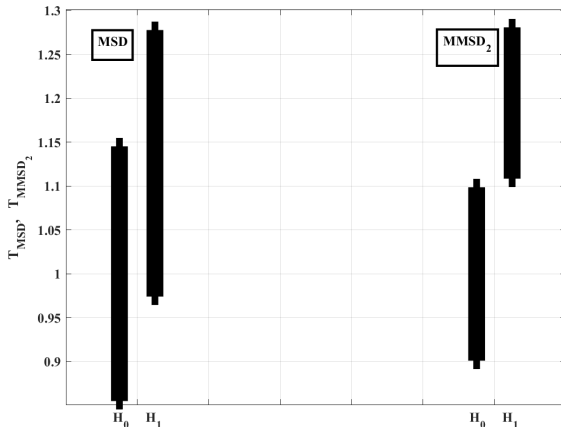


Fig. 5. Salida del detector de H_0 y H_1 para MSD y $MMSD_2$ con un $K = 10$.

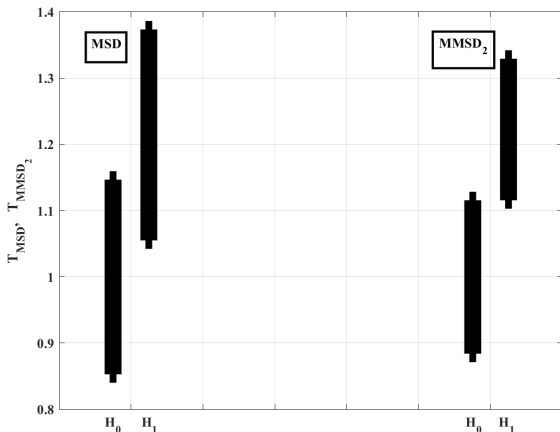


Fig. 6. Salida del detector de H_0 y H_1 para MSD y $MMSD_2$ con un $K = 20$.

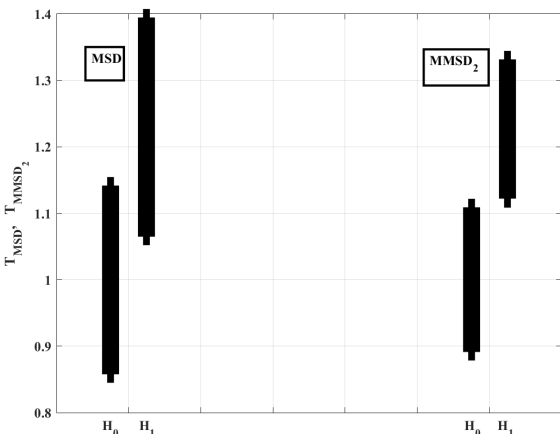


Fig. 7. Salida del detector de H_0 y H_1 para MSD y $MMSD_2$ con un $K = 30$.

Dichas figuras muestran que tanto la detección de $MMSD_2$ como de MSD mejoran conforme se aumenta K . Las figuras también muestran que, para valores bajos de K , $MMSD_2$ tiene un desempeño significativamente mejor que MSD, lo que significa que no se requieren muchos cuadros de video para obtener un buen resultado de detección utilizando el nuevo algoritmo.

IV. CONCLUSIÓN

Los estadísticos mostrados anteriormente parten de una premisa similar a una mostrada anteriormente con algunas modificaciones. Al partir de los parámetros estadísticos necesarios del entorno propuesto, se logró diseñar un nuevo algoritmo al que se le llamó $MMSD_2$. Este nuevo algoritmo de detección, es puesto a prueba con el MSD para una comparación entre ambos tanto en un entorno simulado como en video real. Bajo un entorno con fondo y objeto simulados, se muestra que el nuevo algoritmo tiene un mejor desempeño ante valores bajos de número de cuadros y de factor de llenado que el clásico, mostrando también que ante condiciones extremas de ruido su principal fortaleza, el cual reside en la energía de los pixeles donde se encuentra el objeto, termina siendo a la vez una de sus debilidades. Al utilizar un fondo y objeto reales grabados en video, se observa que el nuevo algoritmo $MMSD_2$ ofrece mejores resultados de detección que MSD. También se puede observar que $MMSD_2$ no requiere una cantidad alta de cuadros de video para ofrecer resultados aceptables. Bajo ambos entornos, se prueba que el nuevo algoritmo de detección suele funcionar mejor para la aplicación para la que fue diseñado.

REFERENCIAS

- [1] J. L. Aching Samatelo and E. Ottoni Teatini Salles, "A New Change Detection Algorithm for Visual Surveillance System," IEEE Latin America Transactions, vol. 10, no. 1, pp. 1221-1226, 2012.
- [2] A. Aubry, A. D. Maio, D. Orlando, and M. Piezzo, "Adaptive detection of point-like targets in the presence of homogeneous clutter and subspace interference," IEEE Signal Processing Letters, vol. 21, no. 7, pp. 848-852, July 2014.
- [3] F. Bandiera, O. Besson, D. Orlando, G. Ricci, and L. L. Scharf, "GLRT-based direction detectors in homogeneous noise and subspace interference," IEEE Transactions on Signal Processing, vol. 55, no. 6, pp. 2386-2394, jun 2007.
- [4] F. Bandiera, D. Orlando, and G. Ricci, "CFAR detection of extended and multiple point-like targets without assignment of secondary data," IEEE Signal Processing Letters, vol. 13, no. 4, pp. 240-243, apr 2006.
- [5] S. Blostein and T. Huang, "Detecting small, moving objects in image sequences using sequential hypothesis testing," IEEE Transactions on Signal Processing, vol. 39, no. 7, pp. 1611-1629, jul 1991.
- [6] N. Bon, A. Khenchaf, and R. Garello, "GLRT subspace detection for range and Doppler distributed targets," IEEE Transactions on Aerospace and Electronic Systems, vol. 44, no. 2, pp. 678-696, apr 2008.
- [7] J. Chen and I. Reed, "A detection algorithm for optical targets in clutter," IEEE Transactions on Aerospace and Electronic Systems, vol. AES-23, no. 1, pp. 46-59, jan 1987.
- [8] E. Conte, A. D. Maio, and G. Ricci, "GLRT-based adaptive detection algorithms for range-spread targets," IEEE Transactions on Signal Processing, vol. 49, no. 7, pp. 1336-1348, jul 2001.
- [9] A. Cruz Bernal, D. L. Almanza Ojeda and M. A. Ibarra Manzano, "Object Detection from a Range Image Using Sparse Keypoint Detector Technique," IEEE Latin America Transactions, vol. 16, no. 5, pp. 1532-1538, 2018.

- [10] B. Du, Y. Zhang, L. Zhang, and L. Zhang, "A hypothesis independent subpixel target detector for hyperspectral images," *Signal Processing*, vol. 110, pp. 244–249, may 2015.
- [11] V. Golikov, O. Lebedeva, and M. R. Blanco, "GLRT subspace detection of multi-pixel targets with known and unknown spatial parameters in presence of signal-dependent background power," *Computers & Electrical Engineering*, vol. 52, pp. 38–48, may 2016.
- [12] V. Golikov, O. Lebedeva and M. A. Rodriguez, "Detection of Barely Discernible Subpixel Objects Using a Modified Orthogonal Subspace Projection Method," *IEEE Latin America Transactions*, vol. 14, no. 2, pp. 899-906, Feb. 2016.
- [13] V. Golikov, M. Rodriguez-Blanco, and O. Lebedeva, "Robust multipixel matched subspace detection with signal-dependent background power," *Journal of Applied Remote Sensing*, vol. 10, no. 1, p. 015006, jan 2016.
- [14] S. Kraut and L. Scharf, "The CFAR adaptive subspace detector is a scale-invariant GLRT," *IEEE Transactions on Signal Processing*, vol. 47, no. 9, pp. 2538–2541, 1999.
- [15] D. Manolakis and G. Shaw, "Detection algorithms for hyperspectral imaging applications," *IEEE Signal Processing Magazine*, vol. 19, no. 1, pp. 29–43, 2002.
- [16] A. Margalit, I. Reed, and R. Gagliardi, "Adaptive optical target detection using correlated images," *IEEE Transactions on Aerospace and Electronic Systems*, vol. AES-21, no. 3, pp. 394–405, may 1985.
- [17] L. L. Scharf, *Statistical Signal Processing: Detection, Estimation, and Time Series Analysis*. Addison–Wesley, 1991.
- [18] L. Scharf and B. Friedlander, "Matched subspace detectors," *IEEE Transactions on Signal Processing*, vol. 42, no. 8, pp. 2146–2157, 1994.

His research interests include robust nonlinear control; identification and stochastic models.



David Emmanuel Kantún received his B.S. degree in electronic engineering in 2012, and his M.S. degree in mechatronic engineering in 2018, both from the Autonomous University of Carmen, Ciudad del Carmen, Mexico. His research interests include digital signal processing, image processing and computational vision.



Victor Golikov (M'03) received the M.S. degree in radio-physics from the National University of Kharkov, Kharkiv, Ukraine and the Ph.D. degree in radar systems from the National Radio-Electronic University of Kharkiv, Kharkiv, in 1970 and 1976, respectively.

He is a currently Professor at the Autonomous University of Carmen, Ciudad del Carmen, Mexico. He is the author of more than 60 journal papers. His current research interest includes remote optoelectronic systems.



Hussain Alazki received his Postdoc in University National Autonomous of Mexico (UNAM). His PhD degrees from Automatic Control in the Centre for Research and Advanced Studies of National Polytechnic Institute (CINVESTAV). Bachelor's degree in Electronic Engineering from the Tishreen University, 2001, a Diploma in Communication Engineering in 2002 and an MSc degree in Telecommunication Engineering in 2007 from Tishreen University, Faculty of Electrical and Mechanical Engineering.