

TÉCNICAS DE SEGMENTACIÓN EN IMÁGENES SLAR PARA LA DETECCIÓN DE VERTIDOS DE HIDROCARBUROS

Damián Mira¹, Beatriz Alacid¹, Pablo Gil², Fernando Torres²

⁽¹⁾Instituto Universitario de Investigación Informática,

⁽²⁾Dpto. Física, Ingeniería de Sistemas y Teoría de la Señal,
Universidad de Alicante

{damian.mira, bea.alacid, pablo.gil, fernando.torres}@ua.es

Resumen

En este artículo se presentan dos métodos de segmentación para la detección de vertidos de hidrocarburos en la superficie marítima a partir de imágenes obtenidas por un sensor SLAR embarcado en una aeronave. Para ello, se describen y comparan dos aproximaciones de segmentación, basadas en grafo e imagen-J, respectivamente. Finalmente, se muestra el resultado de aplicar ambas aproximaciones a imágenes SLAR, buscando como objetivo detectar la mayor área de vertido en la superficie marina al tiempo que se minimiza la falsa detección de ésta.

Palabras Clave: SLAR, sensores activos, vigilancia marítima, detección.

1 INTRODUCCIÓN

Dada la constante proliferación de embarcaciones y que cada año aumenta el tráfico de éstas, debido al transporte de personas y mercancías [29], los trabajos de vigilancia marítima se extienden cada vez más para hacer frente a los percances que puedan ocurrir, de forma rápida y eficaz. Además, es necesario realizar un control para evitar malas prácticas que lleven a la contaminación de las aguas, como la limpieza de tanques de embarcaciones.

Uno de los trabajos que se realizan para mejorar los sistemas de búsqueda y rescate, mejorar la seguridad y reducir la contaminación marítima es llevado a cabo por la Unión Europea con un sistema de vigilancia marítimo integrado [11]. Para la realización de estas tareas es indispensable el uso de información proveniente de sensores de diferente naturaleza y diferentes ubicaciones. Estos sensores pueden estar ubicados en satélites, como los SAR (*Synthetic Aperture Radar*), meteorológicos, etc.; o estar embarcados, como los SLAR (*Side Looking Airborne Radar*), sensores térmicos o transpondedores. Además, es común emplear sensores ubicados en

tierra como por ejemplo radares de posicionamiento o alta frecuencia para el control de mareas.

Una de las mayores problemáticas en la contaminación marítima son los vertidos de hidrocarburos. Casos como los del Prestige [13] y la base petrolífera del golfo de México [23], pusieron en manifiesto la problemática de estos desastres a gran escala. Pero, no es necesario un vertido a gran escala para que su impacto pueda suponer un peligro para los diferentes ecosistemas. Un ejemplo de vertidos de menor magnitud que presentan dicho tipo de peligro, es el ocurrido por el hundimiento del buque Oleg Naydenov 15 millas al sur de Punta Maspalomas (Gran Canaria) [20].

Dada la necesidad de controlar los vertidos de hidrocarburos, se han llevado a cabo numerosos estudios para la detección, seguimiento y control de dichos vertidos sobre la superficie marítima. La gran mayoría de los estudios realizados para llevar a cabo estas tareas de forma autónoma, se basan en el uso de información proveniente de sensores SAR. La extensión en el uso de estos radares se basa en las características que aportan, como la invariancia a diferentes condiciones climáticas, nubes, día/noche, etc. Por el contrario, estos radares presentan problemáticas en la detección de vertidos de hidrocarburos sobre la superficie marítima, en los que se puede destacar la velocidad del viento en dicha superficie [6], presencia de acumulaciones de plancton marino que provoca detecciones erróneas [4] o la presencia de capas de hielo flotante [5] entre otros. Por otra parte, dado el diseño, características y modo de funcionamiento, estos sensores se encuentran integrados en satélites a gran altura [27]. Por este motivo tienen como inconveniente que el satélite debe estar en la órbita adecuada para poder escanear una zona en concreto, con lo que se limita la respuesta y tiempo de acción de la emergencia.

Debido a la escasez de estudios de técnicas de segmentación en sensores SLAR, a continuación se presentan algunos trabajos realizados con sensores SAR cuyo objetivo es la detección de vertidos. Así, Anne Solberg et al. en [26] presentaron algoritmos de

detección de vertidos, basados en una segmentación por umbrales adaptativos y pirámides gaussianas, y la extracción de características de éstas para su clasificación. La tasa de acierto mostrada se situaba entre un 72 y 77% de acierto en la detección de manchas de hidrocarburos.

Por otra parte, David Mera et al. propusieron el uso de un algoritmo con un umbralizado adaptativo, a partir de una calibración de las imágenes, para que cada píxel represente la reflexión del ‘backscatter’ del radar, y la estimación del viento en la superficie marina [21]. En otro de sus trabajos, los autores añaden al proceso anterior un algoritmo de caracterización orientado a la clasificación de las formas de contorno de la región etiquetada como vertido [22].

Lena Chang et al. [7] muestran técnicas de segmentación basadas en la preservación del momento comentado en [18,28]. El método consiste en dividir la imagen en regiones cuyos píxeles tengan un momento similar. Y a continuación, se unen las regiones vecinas a partir de la regla ‘*N-nearest-neighbor*’, según los datos de correlación espacial de las propias regiones. Con los resultados de la segmentación, se crea un modelo del vertido basado en un conjunto de regiones en imagen que representan manchas de fuel. Posteriormente, se emplea un test de cociente de probabilidades generalizadas (*Generalized Likelihood Ratio Test*, GLRT, en la literatura inglesa) [17], para identificar los vertidos de hidrocarburos en imágenes.

Otra metodología utilizada para la detección de vertidos de hidrocarburos, es la de Yuanming Shu et al. en la que se empleaba la densidad espacial [25], definida como la cantidad de píxeles de un área con un valor de intensidad que pudiera ser considerado como vertido. Para ello, primero se realizaba un filtrado por Gauss con una máscara de 3x3 y una desviación estándar de 0.5. A continuación, se realizaba una segmentación basada en una umbralización por intensidad con Otsu. Seguidamente, se empleaba una segunda segmentación en la que el umbral, es la densidad de los píxeles considerados como mancha. Finalmente, se aplicaba un filtrado en el que se determinaban regiones de píxeles significativas en función de su tamaño de área y contraste, para de este modo eliminar falsos positivos.

Jojene R. Santillan y Enrico C. Paringit propusieron un método de segmentación semiautomático [24], a partir de un análisis del histograma de la imagen y una umbralización con el “backscatter” del propio radar, el valor de umbral usado es $\beta_{\text{mean}} - 0.75\sigma$, basado en pruebas empíricas previas. Adicionalmente, se aplica un clasificador basado en una regresión logística para

clasificar los resultados obtenidos en la etapa de segmentación.

En otros trabajos como el presentado por Ziyi Chen et al. [8], se propuso un método basado en segmentación por superpíxeles, para subdividir la imagen SAR en diferentes zonas con escalas uniformes y similares, conservando los bordes. Además, se combinan las distancias espaciales, la desviación de intensidad y la información de tamaño para eliminar los falsos positivos.

2 SISTEMA SENSORIAL EMBARCADO

El sensor empleado es un radar aerotransportado de apertura lateral, SLAR, cuya tecnología es similar a los radares de apertura sintética SAR.

Algunas diferencias entre SAR y SLAR radican en la identificación de dos zonas de barrido: la zona ciega del sensor y la zona de datos hábiles para su tratamiento. En [1], los autores plantearon una primera aproximación para solventar el problema de la identificación de la zona ciega del sensor mediante métodos de procesamiento basado en imagen, sin considerar información de otros sensores de la aeronave que eran de acceso restringido, como el altímetro, inclinómetro, etc.

Adicionalmente, otra de las perturbaciones que pueden darse en las imágenes SLAR, es la perturbación en la imagen producida por los giros de la aeronave, que genera ruido en las zonas hábiles de barrido. La eliminación de las perturbaciones generadas por los giros de la aeronave se presenta en [2], en el que además se mejora la detección de la zona ciega del radar.

3 SEGMENTACIÓN DE VERTIDOS

La primera aproximación llevada a cabo, estaba basada en técnicas de umbralización adaptativa por métodos estadísticos que medían, la similitud o diferencia entre posibles regiones de píxeles, adecuando las técnicas aplicadas en [19], no siendo satisfactorios los resultados al no identificar correctamente la región de los vertidos. También, se analizaron otros conocidos métodos de segmentación de imágenes en espectro visible para ver cómo eran sus comportamientos [3, 9, 16], siendo previamente ajustados sus parámetros a imágenes cuantizadas de naturaleza SLAR. Así, se comprobó el funcionamiento de algoritmos tipo ‘*map saliency*’ como DRFI [15]. Dicho algoritmo, se basaba en segmentar a partir de un mapa de descriptores de textura, los píxeles que destacan en la imagen. El

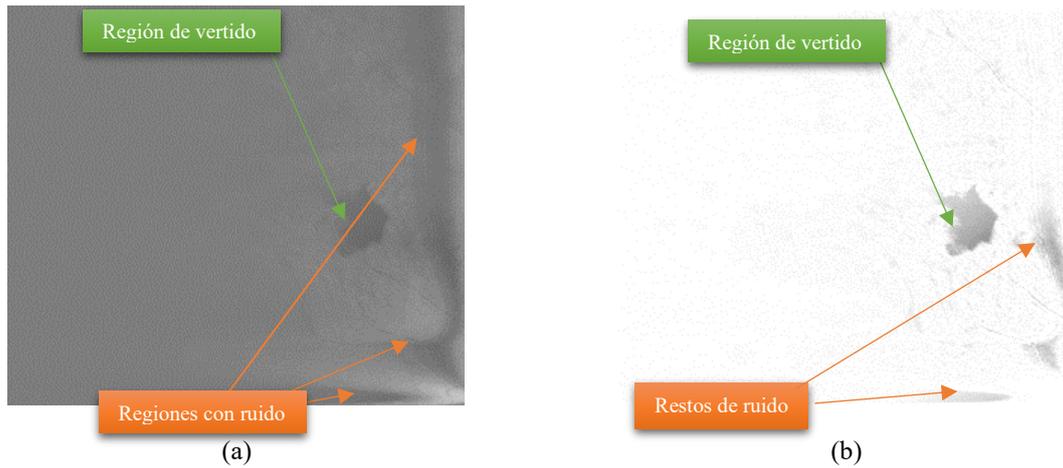


Figura 1: a) Imagen SLAR. b) Imagen SLAR preprocesada

resultado de este algoritmo es una imagen en escala de grises, donde los píxeles con mayor intensidad son las zonas que más destacan de la imagen y menos redundancia presentan. Este algoritmo como inconvenientes presenta un alto coste computacional y sobreesegmentación en la región de la mancha cuando hay cierta variación de homogeneidad en la distribución de los valores de intensidad de sus píxeles. Esto ocurre por los cambios de densidad del vertido como consecuencia de la degradación y disolución del hidrocarburo con el paso del tiempo.

3.1 FILTRADO PREVIO DE LA IMAGEN

Para solventar los problemas presentados en los métodos de segmentación comentados anteriormente, se han implementado dos nuevas aproximaciones, una primera basada en segmentación por grafo y otra, basada en segmentación a partir de imagen J .

En ambos métodos se realiza una etapa de preprocesado previo, posterior al proceso de identificación de la zona ciega del sensor y giros de la aeronave. Este preprocesado se realiza para eliminar ruido en la zona de la imagen seleccionada y destacar las zonas que pueden ser candidatas a representar zonas de vertido de hidrocarburo (Figura 1a). Para ello, se hace uso de un filtro Gaussiano y seguidamente un análisis de forma y valores del histograma para realizar un ecualizado, que permita realzar el contraste para posteriormente, eliminar los valores atípicos de alta y baja intensidad, entorno al 2%. Posteriormente, se realiza un proceso para suprimir fronteras de ciertas zonas en la imagen que pudieran detectarse como regiones de vertido sin serlo. De esta forma, se homogenizan los píxeles de estas zonas no representativas o en cualquier caso, se reducen o desgajan dichas regiones para hacerlas menos representativas, dando lugar a una mejor

detección de las regiones que sí que contienen vertidos de hidrocarburos (Figura 1b).

3.2 MATRIZ DE COOCURRENCIA

Los métodos de segmentación propuestos hacen uso de la matriz de coocurrencia, para mejorar el procesamiento de la imagen y de esta forma mejorar también el proceso de detección. La matriz de coocurrencia de niveles de grises (*Gray Level Cooccurrence Matrix*, GLCM) es comúnmente usada para medir matemáticamente texturas en la imagen [14]. Esta matriz aproxima la probabilidad de distribución conjunta de un par de píxeles. De esta forma, describe la frecuencia con la que un nivel de gris aparece en una relación espacial específica con otro valor de gris dentro de la ventana determinada.

Dentro de los valores que se pueden obtener a través de GLCM, se ha hecho uso de los valores de homogeneidad, energía, contraste y correlación. Los valores usados se definen de la siguiente forma:

Homogeneidad:

$$\sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1 + (i - j)^2} \quad (1)$$

Contraste

$$\sum_{i,j=0}^{N-1} P_{i,j}(i - j)^2 \quad (2)$$

Energía

$$\sum_{i,j=0}^{N-1} P_{i,j}^2 \quad (3)$$

Correlación

$$\sum_{i,j=0}^{N-1} P_{i,j} \left[\frac{(i - \mu_i)(j - \mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \quad (4)$$

donde $P_{i,j}$ es la probabilidad de coocurrencia de los valores de gris para i, j , donde i es la posición en filas y j la posición en columna. N representa el tamaño de la ventana, μ la media para i y j , y σ la varianza para i y j .

El resultado de aplicar dichos valores a la imagen preprocesada se pueden observar en la Figura 2.

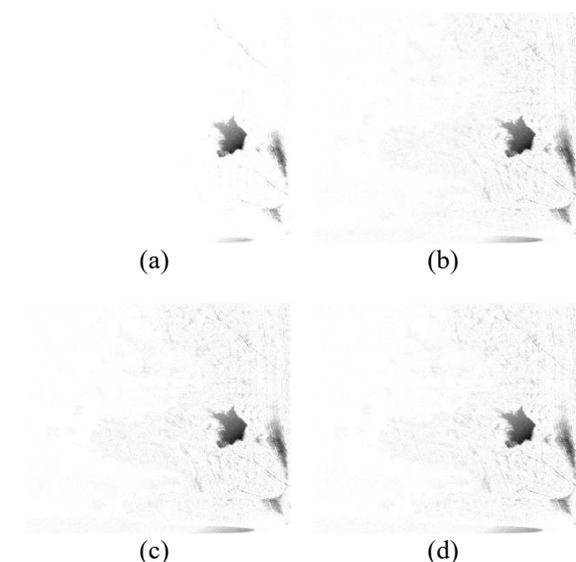


Figura 2. Procesos aplicados sobre Figura 1b. a) Homogeneidad. b) Contraste. c) Correlación. d) Energía.

3.3 TÉCNICAS DE SEGMENTACIÓN

3.3.1 Segmentación por grafo

Dada la necesidad de obtener un segmentado robusto en el que la falta de homogeneidad se tenga en cuenta para la correcta segmentación, se implementó un método basado en segmentación por grafos [12], el cual, permite mejorar el proceso de detección de regiones que representan manchas cuyos píxeles mantienen una distribución de intensidad variable sobre imágenes SLAR, con degradados progresivos de intensidad. Los degradados progresivos de intensidad en la imagen, suelen ser generalmente como consecuencia de la pérdida de la sensibilidad del sensor, dependiente de la resolución de rango dada por la ecuación (5).

$$R_r = \frac{c_0 t_p}{2 \sin \gamma} \quad (5)$$

donde γ es el ángulo de incidencia del radar sobre la porción escaneada, c_0 es la velocidad de la luz y t_p es la duración del pulso del radar. Datos que están restringidos para los autores, ya que no se tiene acceso a los datos de calibración del sensor SLAR. La resolución de rango viene determinada por el valor del ángulo de incidencia del sensor. De forma que las zonas alejadas, a nivel de píxel representan una mayor porción de terreno escaneado.

Además, estos degradados se ven acentuados por el problema de disolución del vertido, por condiciones meteorológicas y por el paso del tiempo. Algunas de las pruebas ejecutadas, han consistido en aplicar modificaciones a este algoritmo para adaptarlo a esta problemática, modificando la ordenación interna de los vectores que almacenan las características de valores de intensidad de los píxeles de las regiones.

El funcionamiento de este método consta de 4 pasos principales. Primero, se recorre la imagen en la que por cada píxel (i, j) , se guardan en un vector los valores de diferencia de intensidad con sus 4 píxeles vecinos $(i+1, j)$, $(i, j+1)$, $(i+1, j+1)$ y $(i+1, j-1)$. Seguidamente, este vector es ordenado por el valor de diferencia de menor a mayor. En el segundo paso, se realiza un recorrido por el vector y se van añadiendo los diferentes píxeles a un *disjoint-set*, en función de si la diferencia entre los píxeles es menor al umbral definido al inicio. De esta forma, se consigue un conjunto denominado *disjoint-set* que se caracteriza en que los píxeles están agrupados según la diferencia entre sus 4 vecinos comentados anteriormente. Esta característica, es la que proporciona al algoritmo, la capacidad de poder segmentar zonas con degradaciones de intensidad como una sola. El tercer paso del método, se basa en la eliminación de los grupos de píxeles con un tamaño menor al determinado al inicio. Para finalizar, se realiza un etiquetado de los píxeles de los sets del árbol generado, obteniendo de esta forma la matriz binaria con la segmentación realizada.

Un ejemplo del resultado de aplicar dicho algoritmo se puede apreciar en la Figura 3a-b.

3.3.2 Segmentación por imagen J

Una imagen J [10], es aquella en la que cada elemento de la imagen viene definido, por un lado, por su intensidad obtenida como el promedio de las diferencias de varianzas de todas las tonalidades de intensidad dentro de un entorno de vecindad o ventana, y por otro lado, por la posición relativa de dichas tonalidades con respecto al píxel central de la ventana. Para realizar esta segmentación, primero se debe realizar un proceso de normalización de la imagen, en la que se reducen los niveles de escala de

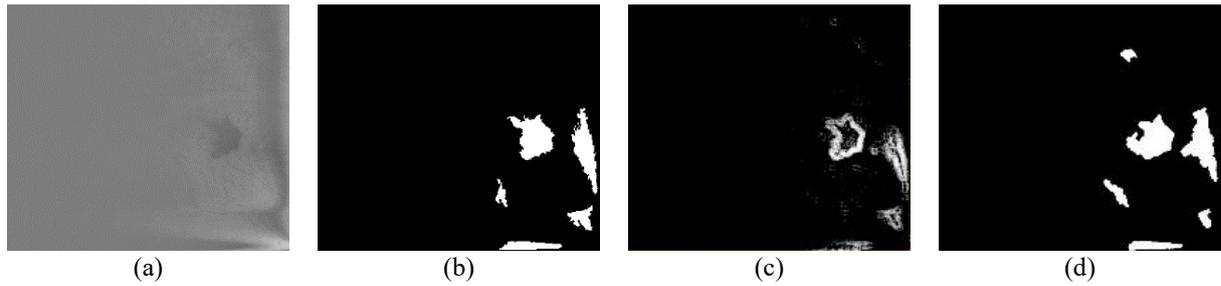


Figura 3: a) Imagen original SLAR. b) Imagen segmentada por grafo. c) Imagen J resultante. d) Imagen segmentada por Imagen J.

gris a usar, al igual que se realiza con la matriz de coocurrencia anteriormente mencionada.

La imagen J (Figura 3c) se obtiene de la siguiente forma:

$$J = (S_T - S_W)/S_W \quad (6)$$

Para ello, primero se realiza una transformación de la imagen a N escalas de gris, tomando cada escala de gris como una clase.

Con estos valores se calcula la varianza total como:

$$S_T = \sum_{z \in Z} \|z - \bar{z}\|^2 \quad (7)$$

Donde Z son todos los píxeles de la imagen normalizada, por lo que $z=(i, j)$ en el que $z \in Z$, \bar{z} es el promedio de coordenadas de los elementos de Z. Seguidamente, se calcula la media de varianza de cada clase como:

$$S_W = \sum_{i=1}^C S_i = \sum_{i=1}^C \sum_{z \in Z_i} \|z - \bar{z}_i\|^2 \quad (8)$$

Donde \bar{z}_i es el promedio de coordenadas de la clase Z_i . C es el número de niveles de gris usados en la normalización. Una vez obtenida la imagen J (Figura 3c) se realiza la segmentación tomando como semillas los píxeles con el valor de J menor al umbral seleccionado, obteniendo de esta forma el resultado final que se muestra en la Figura 3d.

4 RESULTADOS Y ANÁLISIS

Para analizar la tasa de éxito de los métodos desarrollados para la segmentación, se ha generado un 'ground truth' que consiste en el área real (número de píxeles) de la mancha, extraída directamente y de forma manual de cada imagen SLAR.

A continuación, para cada método, se compara el resultado de segmentar la imagen obtenida después de

aplicar el preprocesado comentado en el apartado 3.1, así como los valores de homogeneidad, energía, contraste y correlación resultantes de aplicar el método presentado en el apartado 3.2.

El objetivo es maximizar la tasa de acierto de la zona 1, que corresponde a los píxeles segmentados que forman parte de un vertido de hidrocarburo, y reducir tanto la zona 2 (píxeles detectados de forma errónea conectados a píxeles detectados correctamente), como la zona 3 (píxeles no detectados del vertido). Un ejemplo de estas zonas se pueden ver en la Figura 4, donde el vertido está representado por la unión de las zonas 1 y 3, y las regiones detectadas por la unión de las zonas 1 y 2 y adicionalmente, la zona 4 corresponde a zonas detectadas, pero que no contienen vertido y no son tratadas en este trabajo.

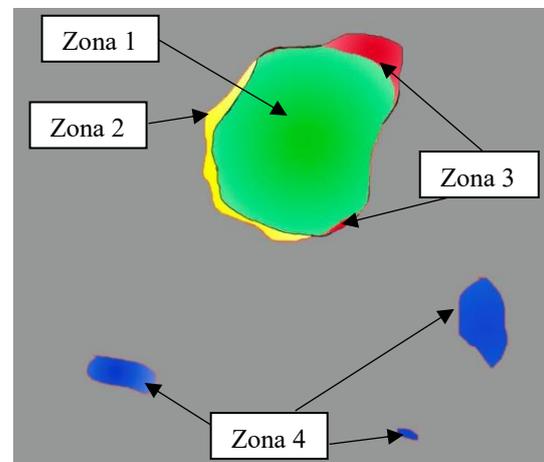


Figura 4: Ejemplo de representación de las zonas usadas para su análisis.

Para calcular los porcentajes de las diferentes zonas se utilizan las siguientes formulas:

$$\%Zona 1 = \frac{\text{Píxeles segmentados que están presentes en el ground truth}}{\text{Píxeles totales del ground truth}} \times 100 \quad (9)$$

$$\%Zona 2 = \frac{\text{Píxeles segmentados que no están presentes en el ground truth}}{\text{Píxeles totales del ground truth}} \times 100 \quad (10)$$

$$\%Zona 3 = \frac{\text{Píxeles del ground truth no segmentados}}{\text{Píxeles totales del ground truth}} \times 100 \quad (11)$$

En la Tabla 1, se puede observar los resultados obtenidos con el uso de la segmentación basada en grafo, apartado 3.3.1. Como se puede apreciar en todos los casos, el porcentaje de acierto de la zona 1 supera el 95%, excepto, en el caso de usar el valor de contraste de la matriz de coocurrencia. Otro dato a destacar, es la tasa de falsa detección obtenida en la región que contiene información sobre el vertido, zona 2. En todos los casos, el valor de falsa detección es superior al 36%, exceptuando otra vez, el resultado con el valor de homogeneidad en el que se obtiene un valor más aceptable, 16.61%.

Tabla 1: Resultados obtenidos por el uso del método de segmentación basado en grafo.

Tipo de imagen de entrada	%Zona 1	%Zona 2	%Zona 3
ROI original SLAR	99.82	48.51	0.18
ROI + preprocesado 3.1	99.86	42.18	0.14
ROI + preprocesado 3.1 y 3.2 (homogeneidad)	95.93	68.42	4.07
ROI + preprocesado 3.1 y 3.2 (energía)	98.35	38.81	1.65
ROI + preprocesado 3.1 y 3.2 (contraste)	82.96	16.61	7.04
ROI + preprocesado 3.1 y 3.2 (correlación)	97.26	36.81	2.74

Por otra parte, en la Tabla 2 se presentan los resultados obtenidos con el uso de la segmentación por imagen-

J. Un aspecto a tener en cuenta, es el resultado de dicho método con la imagen original, en el que se obtienen dos regiones, pero ninguna de dichas regiones contiene parte del vertido. Otro aspecto, es el resultado con la imagen preprocesada, en el que se obtiene un 100% de acierto en la mancha pero debido a su elevada tasa de falsa detección, 4514%. Finalmente, aplicando los valores obtenidos con la matriz de coocurrencia se obtienen mejores resultados que los obtenidos con el uso de la segmentación basada en grafo. En el peor de los casos, se obtiene un acierto del 98.38%, pero a su vez una tasa de falsos positivos de un 11,1%. En el resto de casos, pese a que el porcentaje de acierto es mayor, se obtiene una media cercana al 99.5%, los falsos positivos superan el 15% llegando a valores cercanos al 38%.

Tabla 2: Resultados obtenidos por el uso del método de segmentación por imagen-J.

Tipo de imagen de entrada	%Zona 1	%Zona 2	%Zona 3
ROI original SLAR	0	0	100
ROI + preprocesado 3.1	100	4514	0
ROI + preprocesado 3.1 y 3.2 (homogeneidad)	98.38	11.1	1.62
ROI + preprocesado 3.1 y 3.2 (energía)	99.51	17.46	0.49
ROI + preprocesado 3.1 y 3.2 (contraste)	99.44	15.95	0.56
ROI + preprocesado 3.1 y 3.2 (correlación)	99.65	37.72	0.35

Conviene resaltar que el objetivo es detectar la presencia de manchas en la imagen, maximizando la tasa de detección correcta de los píxeles de esta, independientemente de que se hayan detectado píxeles de zonas no conectadas a zonas de píxeles de detección correctas. Además, cabe destacar que se busca minimizar la tasa de detección errónea de píxeles conectados con la región que contiene mancha. Como se demuestra, estos objetivos se alcanzan con la aproximación de segmentación por imagen-J con el valor de homogeneidad de la GLCM, donde se detecta el 98.38% del área del vertido y adicionalmente, un

11.1% de área conectada al vertido que o no es vertido o el nivel de densidad del vertido ha decrecido considerablemente.

5 CONCLUSIÓN

De acuerdo con los resultados obtenidos en la sección 4, el uso de la segmentación por grafo es válida para obtener regiones que pueden contener vertidos de hidrocarburos, pero generando porcentajes altos de falsos positivos de detección en regiones no conectadas. Por otra parte, el uso del método de segmentación por imagen-J, sí que permite obtener información de características que describan la región que representa el vertido de hidrocarburo, tales como compactación, perímetro, elongación, etc.; ya que minimiza la detección de regiones no conectadas, y los falsos positivos.

Objetivos futuros consisten en estudiar métodos de clasificación para las regiones obtenidas y etiquetadas como posibles candidatas a ser vertido de hidrocarburo.

Agradecimientos

Este trabajo ha sido financiado por el proyecto (RTC-2014-1863-8) "ONTIME: Operación remota de Transmisión de Información en Misiones de Emergencia" de la Convocatoria Retos de Colaboración del MINECO. Agradecimientos al personal de INAER Helicópteros S.A.U.

Referencias

- [1] Alacid, B.; Mira, D.; Gil, P.; Torres, F., (2015) "Detección automática de la zona ciega de un SLAR" Actas de las XXXVI Jornadas de Automática, pp.40-47, 2 - 4 de septiembre de 2015. Bilbao ISBN 978-84-15914-12-9
- [2] Alacid B.; Gil, P., (2016) "An approach for SLAR images denoising based on removing regions with low visual quality for oil spill detection", SPIE Remote Sensing-Image and Signal Processing for Remote Sensing, 26 – 29 September 2016, Edinburgh, United Kingdom.
- [3] Arbelaez, P.; Maire, M.; Fowlkes, C.; Malik, J., (2011) "Contour Detection and Hierarchical Image Segmentation," Pattern Analysis and Machine Intelligence, IEEE Transactions on, vol.33, no.5, pp.898, 916,
- [4] Blondeau-Patissier, D.; Gower, J. F.; Dekker, A. G.; Phinn, S. R.; & Brando, V. E., (2014). A review of ocean color remote sensing methods and statistical techniques for the detection,

mapping and analysis of phytoplankton blooms in coastal and open oceans. Progress in oceanography, 123, 123-144.

- [5] Brekke, C.; Holt, B.; Jones, C.; & Skrunes, S., (2014). Discrimination of oil spills from newly formed sea ice by synthetic aperture radar. Remote Sensing of Environment, 145, 1-14.
- [6] Brekke, C.; & Solberg, A. H., (2005). Oil spill detection by satellite remote sensing. Remote sensing of environment, 95(1), 1-13.
- [7] Chang, L.; Tang, Z.S.; Chang, S.H.; Chang, Y., (2008). A region-based GLRT detection of oil spills in SAR images, Pattern Recognition Letters, Volume 29, Issue 14, 15 October 2008, Pages 1915-1923, ISSN 0167-8655.
- [8] Chen, Z.; Wang, C.; Teng, X.; Cao, L. and Li, J., (2014). "Oil spill detection based on a superpixel segmentation method for SAR image," 2014 IEEE Geoscience and Remote Sensing Symposium, Quebec City, QC, 2014, pp. 1725-1728
- [9] Comaniciu, D.; Meer, P., (2002) "Mean shift: a robust approach toward feature space analysis," Pattern Analysis and Machine Intelligence, IEEE Transactions on, vol.24, no.5, pp.603, 619, May 2002
- [10] Deng, Y. and Manjunath, B. S., (2001) "Unsupervised segmentation of color-texture regions in images and video," in IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 23, no. 8, pp. 800-810, Aug 2001.
- [11] European Integrated maritime surveillance, recurso on-line: http://ec.europa.eu/maritimeaffairs/policy/integrated_maritime_surveillance/index_en.htm (accedido 27/5/2016)
- [12] Felzenszwalb, P. F.; Huttenlocher, D. P., (2004) "Efficient graph-based image segmentation", International Journal of Computer Vision, vol. 59, no. 2, pp. 167-181.
- [13] García-Mira, R.; Real, J.E.; Uzzell, D.L.; San Juan, C.; Pol, E., (2006) Coping with a threat to quality of life: the case of the Prestige disaster, Revue Européenne de Psychologie Appliquée/European Review of Applied Psychology, Volume 56, Issue 1, March 2006, Pages 53-60, ISSN 1162-9088.

- [14] Haralick, R. M., (1979) "Statistical and structural approaches to texture," in Proceedings of the IEEE, vol. 67, no. 5, pp. 786-804, May 1979.
- [15] Jiang, H.; Wang, J.; Yuan, Z.; Wu, Y.; Zheng, N.; Li, S., (2013) "Salient Object Detection: A Discriminative Regional Feature Integration Approach," Computer Vision and Pattern Recognition (CVPR), 2013 IEEE Conference on , vol., no., pp.2083,2090, 23-28 June 2013
- [16] Kanungo, T.; Mount, D.M.; Netanyahu, N.S.; Piatko, C.D.; Silverman, R.; Wu, A.Y., (2002) "An efficient k-means clustering algorithm: analysis and implementation," Pattern Analysis and Machine Intelligence, IEEE Transactions on , vol.24, no.7, pp.881,892, Jul 2002
- [17] Kay, S.M., (1998) Fundamentals of Statistical Signal Processing: Detection Theory. Prentice-Hall, Englewood Cliffs, NJ.
- [18] Lau, S., Zhang, Q., Luo, F., Wang, Y., Chen, Z., (2004) An improved moment preserving auto threshold image segmentation algorithm. In: Proc. ICIA'04, pp. 316–318.
- [19] Liu, P.; Li, X.; Qu, J.J.; Wang, W.; Zhao, C.; Pichel, W., (2011) Oil spill detection with fully polarimetric UAVSAR data, Marine Pollution Bulletin, Volume 62, Issue 12, December 2011, Pages 2611-2618, ISSN 0025-326X.
- [20] Manchas hidrocarburos buque Oleg Naydenov: <http://www.fomento.gob.es/MFOMBPrensa/Noticias/Los-medios-contra-la-contaminaci%C3%B3n-se-concentran-a/ccb64d7b-2337-4ebc-bad6-dbcafc2e33cd> (accedido 27/5/2016)
- [21] Mera, D.; Cotos, J.M.; Varela-Pet, J.; Garcia-Pineda, O., (2012) Adaptive thresholding algorithm based on SAR images and wind data to segment oil spills along the northwest coast of the Iberian Peninsula, Marine Pollution Bulletin, Volume 64, Issue 10, October 2012, Pages 2090-2096, ISSN 0025-326X.
- [22] Mera, D.; Cotos, J.M.; Varela-Pet, J.; Rodríguez, P.G.; Caro, A., (2014) Automatic decision support system based on SAR data for oil spill detection, Computers & Geosciences, Volume 72, November 2014, Pages 184-191, ISSN 0098-3004,
- [23] Ramseur, J. L. (2010, December). Deepwater Horizon oil spill: the fate of the oil. Washington, DC: Congressional Research Service, Library of Congress.
- [24] Santillan, J.R. and Paringit, E.C., (2011) Oil spill detection in Envisat ASAR images using radar backscatter thresholding and logistic regression analysis, 32nd Asian Conference on Remote Sensing 2011 (ACRS 2011) 1, 473-480
- [25] Shu, Y.; Li, J.; Yousif, H.; Gomes, G., (2010) Dark-spot detection from SAR intensity imagery with spatial density thresholding for oil-spill monitoring, Remote Sensing of Environment, Volume 114, Issue 9, 15 September 2010, Pages 2026-2035, ISSN 0034-4257
- [26] Solberg, A. H. S. ; Brekke, C. and Husoy, P. O., (2007) "Oil Spill Detection in Radarsat and Envisat SAR Images," in IEEE Transactions on Geoscience and Remote Sensing, vol. 45, no. 3, pp. 746-755, March 2007.
- [27] Topouzelis, K.N. (2008). Oil Spill Detection by SAR Images: Dark Formation Detection, Feature Extraction and Classification Algorithms. Sensors 2008, 8, 6642-6659.
- [28] Tsai, W.H., (1985). Moment-preserving thresholding: a new approach. Comput. Vision Graph. Image Process. 29, 377–393.
- [29] United Nations Conference on Trade and Development, UNCTAD (2016), Review of Maritime Transport 2015, ISBN 978-92-1-112892-5, ISSN 0566-7682