

Desarrollo e implementación de un método para detección automática de manaderos naturales de petróleo (*oil slicks*) en exploración *off-shore*

Por *Alejandro Iriarte, Ofelia Silio, Gustavo Garbati, Valentina Ciut Villar, Juan Pablo Lovecchio, Sebastián Arismendi y Gabriel Horowitz* (YPF)

Un método innovador basado en imágenes SAR y algoritmos de aprendizaje automático permite detectar automáticamente manchas de petróleo en aguas profundas, optimizando el análisis y reduciendo el esfuerzo humano. La implementación de mapas de calor aporta mayor precisión en la identificación de surgencias naturales, marcando un avance significativo en la exploración *off-shore*.

Este trabajo fue seleccionado en las 3^o Jornadas de Revolución Digital para Petróleo y Gas.



de la superficie del mar: la presencia de olas genera planos inclinados en los que las ondas electromagnéticas emitidas por el radar rebotan hacia al detector del satélite. Esta señal que regresa al satélite es, por lo tanto, un indicador de la presencia de olas.

Para la identificación de oil slicks en imágenes SAR, se saca provecho del fenómeno físico por el cual la presencia de hidrocarburo amortigua las olas, lo que genera zonas en la que el satélite no recibe una señal reflejada. Esto se traduce como regiones oscuras en las imágenes satelitales (Figura 1). Es importante resaltar que, al fundamentarse en la presencia de olas, este método solo resulta válido cuando existen condiciones climáticas que las generen. La velocidad de viento mínima para poder emplear esta técnica suele ser de 3 m/s.




Figura 1. Oil slick interpretada por especialistas.

Planteo del problema

La presencia de oil slicks en la superficie del mar puede estar relacionada con la surgencia de hidrocarburo procedente de un sistema petrolero en el fondo marino. Por lo tanto, su detección constituye una importante herramienta de prospección durante la exploración de hidrocarburos en cuencas fronterizas. YPF está participando de un proyecto de exploración off-shore en el Mar Argentino y esta es una de las técnicas que se están utilizando en el marco de dicho proyecto.

Una forma muy eficiente para detectar oil slicks es el uso de imágenes satelitales de radar de apertura sintética (SAR). Estas se pueden emplear para medir la rugosidad

de la superficie del mar. Uno de los principales retos en la implementación de este método es el esfuerzo y el tiempo que se requiere por parte de los especialistas para analizar imágenes correspondientes a miles de kilómetros cuadrados de mar. Eso lleva a que, incluso manchas que un especialista puede identificar claramente como posibles oil slicks al principio de un análisis, puedan pasar desapercibidas luego de varias horas de trabajo.

La detección automática de oil slicks es una solución posible a este problema. Sheta et al (2012) y Keramitsoglou et al (2006) probaron con éxito técnicas de detección automática basadas en machine learning. En estos trabajos, el objetivo era la detección de derrames provocados por barcos y, por lo tanto, su aplicación estaba centrada en aguas someras cercanas a la costa. En el presente trabajo, el objetivo fue detectar oil slicks en aguas profundas. Eso agregó un desafío adicional, debido a la mayor dispersión de las manchas de petróleo, que deben transitar una columna de agua de mayor longitud hasta llegar a la superficie.

En los trabajos de Krestenitis et al (2019) y Sornam (2017) se propusieron métodos alternativos basados en redes neuronales convolucionales. Este enfoque requiere contar con una mayor cantidad de manchas previa-

mente clasificadas para poder entrenar un algoritmo que resulte en una performance aceptable. Al no contar con una cantidad significativa de oil slicks interpretadas por especialistas, en el presente desarrollo se optó por recurrir a algoritmos de clasificación más simples, como los descritos en el párrafo anterior.

La automatización de la tarea mediante un algoritmo de machine learning estandariza los criterios y evita diferencias de resultados entre analistas.

Desarrollo técnico del trabajo

El presente trabajo describe un método de análisis y detección automática de manchas de petróleo en imágenes satelitales SAR, basado en aprendizaje automático. El objetivo del desarrollo es acelerar y facilitar el análisis de imágenes SAR para la detección de oil slicks provenientes de surgencias naturales. Para ello, el sistema identifica posibles manchas candidatas, lo cual reduce la cantidad de objetos que deben ser analizadas por los especialistas, reduce la cantidad de horas hombre requeridas, evita que la demanda de concentración afecte la calidad de las interpretaciones y acelera la obtención de resultados. La herramienta fue entrenada y aplicada a la exploración de oil slicks en el Mar Argentino en las zonas concesionadas por YPF.

El primer paso de la metodología propuesta consiste en identificar posibles manchas de petróleo mediante una simple segmentación de áreas oscuras en las imágenes SAR. Luego, cada una de las manchas segmentadas es caracterizada según un conjunto de propiedades (features) de forma y/o contraste. Las propiedades mencionadas se emplean para poder distinguir entre manchas

potencialmente generadas por oil slicks y otras que por su forma y/o contraste serían zonas oscuras no asignables a una oil slick, utilizando un modelo de clasificación binaria basado en árboles de decisión. Para obtener estas propiedades se relevaron las propuestas en los trabajos de Topouzelis (2008), Sheta et al (2012) y Keramitsoglou et al (2006), en algunos casos con modificaciones planteadas por el equipo de trabajo.

Como se mencionó previamente, en las imágenes SAR existen varias zonas con potencial de albergar oil slicks que, luego de una inspección cuidadosa, son descartadas por los especialistas por corresponder a ruido en la detección por parte del satélite o a otro tipo de fenómenos, tales como la presencia de cúmulos de algas. Estas mismas zonas son segmentadas por el algoritmo y deben ser diferenciadas de las verdaderas oil slicks por un algoritmo de aprendizaje automático. En la Figura 2 se muestran ejemplos de estos tipos de casos: en la Figura (2.a) pueden verse regiones oscuras interpretadas como ruido mientras que la Figura (2.b) corresponde a regiones oscuras interpretadas como algas.

El algoritmo de aprendizaje automático fue entrenado empleando datos de características de manchas previamente clasificadas por especialistas. Uno de los desafíos para este entrenamiento fue la baja proporción de manchas positivas (clasificadas como posibles oil slicks) frente a las negativas (clasificadas como ruido).

Una de las ventajas de utilizar un método de clasificación basado en características en lugar de un método basado en redes neuronales convolucionales, que utiliza imágenes como entrada de la función de clasificación, es la facilidad para generar en forma simple y eficiente casos positivos sintéticos para balancear las clases positiva y negativa dentro del conjunto de datos previo a




Figura 2. (a) regiones oscuras interpretadas como ruido. (b) regiones oscuras interpretadas como algas.

entrenar el algoritmo de clasificación y aumentar así su eficiencia.

Se utilizaron 46 imágenes para el entrenamiento, con 35 manchas clasificadas como positivas por los especialistas. A partir de la segmentación inicial, se detectaron más de 120.000 objetos candidatos para analizar. Luego de aplicar el algoritmo de generación sintética de casos positivos y una estrategia de downsample para la clase negativa, se logró una proporción de 10% de casos positivos sobre el total de la muestra que conformó el conjunto de datos para el entrenamiento del modelo de clasificación.

El algoritmo fue ajustado mediante la implementación de una validación cruzada anidada (Konasani, 2021). Eso permitió utilizar una serie de casos para el ajuste del modelo y dejar un último subconjunto para la estimación del error de clasificación. La métrica elegida para el ajuste de parámetros fue el recall, con el fin de priorizar la minimización de falsos negativos.

Para la fase final del análisis, se desarrolló una técnica que aprovecha una de las principales características de las manchas de petróleo asociadas a surgencias naturales: su persistencia en el tiempo dentro de una determinada región geográfica. Mientras que un derrame provocado por un barco o la presencia de algas son eventos puntuales en una zona determinada, una verdadera surgencia natural aflorará en diferentes días en una zona cercana a su origen. En cambio, otros fenómenos que podrían confundirse con oil slicks, como derrames, algas o el simple ruido de fondo del radar, son poco persistentes en el tiempo.

Tomando en consideración la característica descrita anteriormente, para minimizar el efecto de los falsos positivos se implementó una técnica que, si bien no reduce su número, disminuye su importancia. Esta consistió en fusionar los resultados del análisis de varias imágenes correspondientes a una misma zona geográfica, pero adquiridas en distintas fechas, en un único mapa de calor que da cuenta del número de ocurrencias de manchas clasificadas por el algoritmo como oil slicks en una misma región. La combinación de resultados obtenidos para varias imágenes adquiridas en distintos períodos de tiempo en un único mapa de calor permitió separar los falsos positivos de las verdaderas manchas de petróleo de origen natural.

Resultados obtenidos

En las corridas iniciales de la herramienta, se detectaron varias manchas que el algoritmo clasificó como positivas, pero que no habían sido detectadas por los especialistas. Consultados al respecto, estos evaluaron que 36 de ellas resultaban compatibles con oil slicks. A partir de ese resultado, estas nuevas manchas fueron agregadas al conjunto de datos de entrenamiento, mejorando los resultados posteriores.




Figura 3. imagen SAR analizada por el algoritmo de clasificación automática.

En la Figura 3, se muestra un resultado típico del análisis de clasificación de oil slicks utilizando el algoritmo de machine learning propuesto. Sobre la imagen original del satélite, se identifican con color rojo las manchas detectadas por la herramienta. En esta imagen se identificaron 15 potenciales oil slicks. Por otro lado, se recuadran en color celeste las manchas a la que los especialistas




Figura 4. Mapa de calor.

consideraron como verdaderas oil slicks.

El algoritmo logró un recall del 87,5% en la clasificación de imágenes correspondientes a una sola pasada del satélite. Como se explicó anteriormente, esto es sólo una primera aproximación, ya que existen varios fenómenos que pueden causar anomalías de baja retrodispersión en las imágenes satelitales, que no están asociados con la filtración natural de petróleo. Estos falsos positivos fueron gestionados en forma eficiente utilizando un mapa de calor.

En la Figura 4 puede verse el mapa de calor que resultó luego de varios pasos del satélite en una misma zona. El número de manchas compatibles con oil slicks en cada sector de la imagen se expresa con colores. El tamaño de la región en la cual se buscan manchas cercanas depende de la profundidad del mar en cada zona, debido a que la dispersión de las manchas en la superficie es mayor cuando la profundidad del mar es mayor.

Conclusiones

Se desarrolló un método de clasificación automática de potenciales oil slicks provenientes de surgencias naturales en imágenes satelitales de radar de apertura sintética (SAR) empleando técnicas de machine learning.

El método consiste en una segmentación de regiones oscuras acoplada a un algoritmo de clasificación binaria basado en árboles de decisión y la posterior generación de un mapa de calor a partir de la fusión de varios resultados correspondientes a una misma zona geográfica, que resultan de imágenes SAR adquiridas en distintos períodos de tiempo, en un único mapa de calor, lo cual indica la cantidad de ocurrencias de oil slicks en dicha zona.

El método propuesto resultó ser altamente confiable y muy simple de utilizar e interpretar.

Si bien se han publicado anteriormente otros métodos de machine learning para la detección automática de oil slicks, la mayoría se limitan principalmente a derrames de combustible de barcos en aguas poco profundas y no proponen la generación de un mapa de calor.

Bibliografía

- Brekke C., A. H. S. Solberg: "Feature extraction for oil spill detection based on SAR images", *Lecture Notes in Computer Science* 3540, pp. 75-84, 2005. DOI: 10.1007/11499145_9.
- Del Frate F., A. Petrocchi, J. Lichtenegger, G. Calabresi: "Neural networks for oil spill detection using ERS-SAR data", *IEEE Transactions on Geoscience and Remote Sensing*, 2000, Vol. 38, No. 5.
- Fischella B., A. Giancaspro, F. Nirchio, P. Pavese, P. Trivero: "Oil spill detection using marine SAR images", *International Journal of Remote Sensing*, 2000, Vol. 21, No. 18, 3561-3566.
- Karathanassi V., K. Topouzelis, P. Pavlakis, D. Rokos: "An object-oriented methodology to detect oil spills", *International Journal of Remote Sensing*, 2006, Vol. 27, No. 23, 5235-5251
- Keramitsoglou I., C. Cartalis, C. T. Kiranoudis: "Automatic identification of oil spills on satellite images", *Environmental Modelling & Software*, 2006, 21, 640-652.
- Konasani V. R., S. K., *Machine Learning and Deep Learning Using Python and TensorFlow*, Mc Graw Hill, 2021
- Krestenitis M., G. Orfanidis, K. Ioannidis, K. Avferinakis, S. Vrochidis, & I. Kompatsiaris: "Oil spill identification from satellite images using deep neural networks", *International Journal of Remote Sensing*, 2019, 11, 1762. DOI: 10.3390/rs11151762.
- Naz S., M. F. Iqbal, I. Mahmood, M. Allam: "Marine oil spill detection using Synthetic Aperture Radar over Indian Ocean", *Marine Pollution Bulletin*, 2021, Vol. 162. DOI: 10.1016/j.marpolbul.2020.111921.
- Nirchio F., M. Sorgente, A. Giancaspro, W. Biamino, E. Parisato, R. Raverta & P. Trivero: "Automatic detection of oil spills from SAR images", *International Journal of Remote Sensing*, 2005, 26, 6, 1157-1174. DOI: 10.1080/01431160512331326558.
- Schistad Solberg A. H.: "Automatic detection of oil spills in ERS SAR images", *IEEE Transactions on Geoscience and Remote Sensing*, 1999, Vol. 37, No. 4.
- Sheta A., M. Alkasassbeh, M. Braik, H. A. Ayyash: "Detection of oil spills in SAR images using threshold segmentation algorithms", *International Journal of Computer Applications*, 2012, Vol. 57, No. 7.
- Sornam M.: "Oilspill and look-alike spots from SAR imagery using OUTSU method and artificial neural network", *International Journal of Engineering Technologies and Management Research*, 2017, 4(11), 1-10. DOI: 10.5281/zenodo.1065293.
- Topouzelis K. N.: "Oil spill detection by SAR images: dark formation detection, feature extraction and classification algorithms", *Sensors*, 2008, 8, 6642-6659. DOI: 10.3390/s8106642.

Seguinos en nuestras redes



INSTITUTO ARGENTINO
DEL PETROLEO Y DEL GAS

www.iapg.org.ar