



Universidad Nacional Mayor de San Marcos

Universidad del Perú. Decana de América

Dirección General de Estudios de Posgrado
Facultad de Ingeniería de Sistemas e Informática
Unidad de Posgrado

**Teledetección de impactos medioambientales
producidos por derrames de petróleo en el mar
utilizando Inteligencia Artificial Geoespacial**

TESIS

Para optar el Grado Académico de Doctor en
Ingeniería de Sistemas e Informática

AUTOR

Alexander Eduardo INGA ALVA

ASESOR

Dr. Ciro RODRIGUEZ RODRIGUEZ

Lima, Perú

2026



Reconocimiento - No Comercial - Compartir Igual - Sin restricciones adicionales

<https://creativecommons.org/licenses/by-nc-sa/4.0/>

Usted puede distribuir, remezclar, retocar, y crear a partir del documento original de modo no comercial, siempre y cuando se dé crédito al autor del documento y se licencien las nuevas creaciones bajo las mismas condiciones. No se permite aplicar términos legales o medidas tecnológicas que restrinjan legalmente a otros a hacer cualquier cosa que permita esta licencia.

Referencia bibliográfica

Inga, A. (2026). *Teledetección de impactos medioambientales producidos por derrames de petróleo en el mar utilizando Inteligencia Artificial Geoespacial*. [Tesis de doctorado, Universidad Nacional Mayor de San Marcos, Facultad de Ingeniería de Sistemas e Informática, Unidad de Posgrado]. Repositorio institucional Cybertesis UNMSM.

Metadatos complementarios

Datos de autor	
Nombres y apellidos	Alexander Eduardo Inga Alva
Tipo de documento de identidad	DNI
Número de documento de identidad	07493618
URL de ORCID	https://orcid.org/0000-0001-6302-0234
Datos de asesor	
Nombres y apellidos	Ciro Rodriguez Rodriguez
Tipo de documento de identidad	DNI
Número de documento de identidad	06020241
URL de ORCID	https://orcid.org/0000-0003-2112-1349
Datos del jurado	
Presidente del jurado	
Nombres y apellidos	Hugo Froilán Vega Huerta
Tipo de documento	DNI
Número de documento de identidad	06147737
Miembro del jurado 1	
Nombres y apellidos	Pedro Martin Lezama Gonzales
Tipo de documento	DNI
Número de documento de identidad	09656793
Miembro del jurado 2	
Nombres y apellidos	Ivan Carlo Petrlik Azabache
Tipo de documento	DNI
Número de documento de identidad	10140461
Datos de investigación	
Línea de investigación	C.0.2.2 Tecnologías para mitigar los impactos ambientales de las actividades industriales.

Grupo de investigación	Tecnologías de la Información Aplicados a la Ciencia de los Datos "Information Technologies Applied to the Data Science" (ITDATA)
Agencia de financiamiento	Sin financiamiento.
Ubicación geográfica de la investigación	País: Perú Departamento: Lima Provincia: Lima Distrito: Ventanilla Latitud: -11.9208 Longitud: -77.1426
Año o rango de años en que se realizó la investigación	Abril 2022 – diciembre 2025
URL de disciplinas OCDE	Ingeniería de sistemas y comunicaciones https://purl.org/pe-repo/ocde/ford#2.02.04 Sensores remotos https://purl.org/pe-repo/ocde/ford#2.07.04 Geociencias, Multidisciplinar https://purl.org/pe-repo/ocde/ford#1.05.01



UNIVERSIDAD NACIONAL MAYOR DE SAN MARCOS
Universidad del Perú. Decana de América
Facultad de Ingeniería de Sistemas e Informática
Vicedecanato de Investigación y Posgrado
Unidad de Posgrado

**ACTA DE SUSTENTACIÓN DE TESIS PARA OPTAR EL GRADO ACADÉMICO DE
DOCTOR EN INGENIERÍA DE SISTEMAS E INFORMÁTICA.**

A los diez (10) días del mes de julio de 2026, siendo las 10:00 am., se reunieron en el Auditorio Alfredo Celso Alva Bravo, el Jurado de Tesis conformado por los siguientes docentes:

Dr. Hugo Froilán Vega Huerta (Presidente)
Dr. Pedro Martín Lezama Gonzales (Miembro)
Dr. Ivan Carlo Petrlik Azabache (Miembro)
Dr. Ciro Rodríguez Rodríguez (Miembro Asesor)

Se inició la Sustentación invitando al candidato a Doctor **ALEXANDER EDUARDO INGA ALVA**, para que realice la exposición oral de la tesis para optar el Grado Académico de Doctor en Ingeniería de Sistemas e Informática, siendo la Tesis intitulada:

**“TELEDETECCIÓN DE IMPACTOS MEDIOAMBIENTALES PRODUCIDOS POR DERRAMES
DE PETRÓLEO EN EL MAR UTILIZANDO INTELIGENCIA ARTIFICIAL GEOESPACIAL”**


Concluida la exposición, los miembros del Jurado de Tesis procedieron a formular sus preguntas que fueron absueltas por el graduando; acto seguido se procedió a la evaluación correspondiente, habiendo obtenido la siguiente calificación:


.....VEINTE..... (20) EXCELENTE.....

Por tanto, el presidente del Jurado, de acuerdo con el Reglamento General de Estudios de Posgrado, otorga al Magister **ALEXANDER EDUARDO INGA ALVA** el Grado Académico de Doctor en Ingeniería de Sistemas e Informática,

Siendo las 11:50 horas, el presidente del Jurado de Tesis, da por concluido el acto académico de Sustentación de Tesis.


Dr. Hugo Froilán Vega Huerta
(Presidente)


Dr. Pedro Martín Lezama Gonzales
(Miembro)


Dr. Ivan Carlo Petrlik Azabache
(Miembro)


Dr. Ciro Rodríguez Rodríguez
(Miembro Asesor)



Anexo 1

CERTIFICADO DE SIMILITUD

Yo, **Ciro Rodriguez Rodriguez** en mi condición de asesor acreditado mediante Dictamen de la UPG N° 000098-2024-UPG-VDIP-FISI de la tesis, cuyo título es **“Teledetección de impactos medioambientales producidos por derrames de petróleo en el mar utilizando Inteligencia Artificial Geoespacial”**, presentado por el egresado **ALEXANDER EDUARDO INGA ALVA** para optar el grado Académico de Doctor en Ingeniería de Sistemas e Informática, CERTIFICO que se ha cumplido con lo establecido en la Directiva de Originalidad y de Similitud de Trabajos Académicos, de Investigación y Producción Intelectual. Según la revisión, análisis y evaluación mediante la plataforma PIDS, el documento evaluado cuenta con el 9 % de similitud, nivel PERMITIDO para continuar con los trámites correspondientes y para su **publicación en el repositorio institucional**.

Se emite el presente certificado en cumplimiento de lo establecido en las normas vigentes, como uno de los requisitos para la obtención del grado Académico de Doctor en Ingeniería de Sistemas e Informática.

Lima, 21 de abril de 2026

Firma del Asesor

Nombres y Apellidos del asesor: **Ciro Rodriguez Rodriguez**

DNI: 06020241

* Según corresponda: bachiller, magíster, doctor; título profesional o título de segunda especialidad

La vigencia del presente certificado corresponde a un período de noventa (90) días desde la fecha de su emisión; siempre que no haya observaciones en el texto durante el proceso de revisión por el jurado informante o surja alguna contingencia.

DEDICATORIA

Mas a Dios gracias, el cual nos lleva siempre en triunfo en Cristo Jesús, y por medio de nosotros manifiesta en todo lugar el olor de su conocimiento. 2 Corintios 2:14.

A mi amada familia, quienes dan sentido a mi vida: mis hijitos Job e Isabo y mi esposa Celi.

A mis padres, que estuvieron conmigo en todo momento: Brígida, Nelly, Daniel y Genaro.

A mis hermanos, con quienes juego todavía: Kike, Giova, Edgarcito, Skorsy y Yuyi.

A mi Perry y mi Venice que ahora corretean entre las estrellas.

AGRADECIMIENTO

Agradezco su tiempo, su paciencia, sus enseñanzas y su dedicación a mi asesor: Dr. Ciro Rodriguez Rodriguez.

Agradezco su valioso apoyo durante este viaje a mis queridos papus: Dick Diaz Delgado y Lizbeth Cuba Samaniego, amigos sin ustedes no lo hubiera logrado.

Agradezco a mis compañeros de estudios, profesores y personal administrativo de mi Facultad de Ingeniería de Sistemas en Informática.

Agradezco a la Agencia Espacial del Perú – CONIDA, por proporcionar las imágenes Satelitales SAR para la realización de esta investigación.

ÍNDICE GENERAL

DEDICATORIA	i
AGRADECIMIENTO	ii
ÍNDICE GENERAL	iii
LISTA DE TABLAS	vi
LISTA DE FIGURAS	vii
CAPÍTULO 1: INTRODUCCIÓN	1
1.1. Situación Problemática	1
1.2. Formulación del Problema	2
1.2.1. Problema General	2
1.2.2. Problemas Específicos	2
1.3. Justificación de la Investigación	3
1.3.1. Justificación Teórica	3
1.3.2. Justificación Práctica	3
1.3.3. Justificación Metodológica	3
1.3.4. Justificación Socio Ambiental	3
1.4. Objetivos de la Investigación	3
1.4.1. Objetivo General	3
1.4.2. Objetivos Específicos	4
1.5. Hipótesis	4
1.5.1. Hipótesis General	4
1.5.2. Hipótesis Específicas	4
1.6. Matriz de Consistencia	6
CAPÍTULO 2: MARCO TEÓRICO	7
2.1. Marco Filosófico o epistemológico de la investigación	7
2.2. Antecedentes de la investigación	8
2.2.1. A nivel mundial	8
2.2.2. A nivel país	12
2.2. Estado del Arte	24
2.4. Bases Teóricas	38

2.4.1.	Hidrocarburos	38
2.4.2.	Derrames de Petróleo	38
2.4.3.	Inteligencia Artificial	39
2.4.4.	Inteligencia Artificial Geoespacial.....	41
2.4.5.	Geomática	41
2.4.6.	Medio Ambiente.....	42
2.5.	Modelos Informáticos.....	43
2.5.1	Modelo U-Net	43
2.5.2.	Modelo PSP-Net	44
2.5.3.	Modelo DeepLabV3.....	44
2.5.4.	Modelo DeepLabV3+	45
2.5.5.	Modelo Improved DeepLabV3+.....	45
2.6.	Programas y Plataformas Informáticas.....	46
2.6.1.	Python	46
2.6.2.	ArcGIS PRO	46
2.6.3.	SNAP	47
2.6.4.	PyCharm	47
2.6.5.	Streamlit.....	47
CAPÍTULO 3: METODOLOGÍA		48
3.1.	Tipo y Diseño de Investigación	48
3.2.	Unidad de análisis.....	49
3.3.	Población de estudio	49
3.4.	Selección de muestra	49
3.5.	Técnicas de recolección de Datos.....	50
3.6.	Métricas de Evaluación de Desempeño.....	51
CAPÍTULO 4: RESULTADOS Y DISCUSIÓN		54
4.1.	Creación y preprocesamiento experimental del dataset de imágenes de radar estandarizado de derrames de petróleo en el mar usando Sistemas de Información Geográfica (SIG) y Teledetección.	54
4.1.1.	Benchmark Dataset de Derrames de Petróleo en el mar.....	54
4.1.2.	Dataset de Derrames de Petróleo Lima.....	55

4.2. Comparación de las mejores técnicas de entrenamiento de modelos de Inteligencia Artificial para la elección del modelo base en la detección de derrames de petróleo en el mar.	59
4.2.1. Rendimiento en Métricas de Desempeño	62
4.2.2. Eficiencia Computacional	63
4.2.3. Robustez y Consistencia	64
4.2.4. Análisis comparativo de los modelos basados en métricas descriptivas	64
4.3. Diseño del modelo de Inteligencia Artificial Geoespacial (GeoAI) con altas métricas de validación para clasificar el entorno geoespacial cercano a los derrames de petróleo en el mar.	65
4.3.1. Arquitectura del ReImprovedDeepLabV3+	67
4.3.2. Procesamiento de Datos Geoespaciales	69
4.3.3. Discusión sobre la innovación del modelo propuesto	70
4.3.4. Contribución de la GeoIA en la mitigación del impacto ambiental	71
4.4. Validación del modelo de Inteligencia Artificial Geoespacial (GeoAI) a través de un framework que detecta tempranamente los impactos medioambientales producidos por los derrames de petróleo en el mar.	72
4.4.1. Arquitectura de la Interfaz de Usuario	72
4.4.2. Procesamiento de Imágenes	74
4.4.3. Aplicación de Métricas	75
4.4.4. Funcionalidades de la Interfaz	76
4.4.5. Capacidades de Análisis Cuantitativo	78
4.4.6. Implementación para consulta en línea	79
4.4.7. Resultado y Validación	80
4.4.8. Discusión de resultados	83
CONCLUSIONES	85
RECOMENDACIONES	88
REFERENCIAS BIBLIOGRÁFICAS	90
ANEXOS	107

LISTA DE TABLAS

Tabla 1 Definiciones epistemológicas de la IA	8
Tabla 2 Principales derrames de petróleo a nivel mundial	11
Tabla 3 Resumen Ejecutivo 2014 -2025	15
Tabla 4 Listado de empresas sancionadas por OEFA	19
Tabla 5 Familias afectadas por el derrame de petróleo.....	21
Tabla 6 Actividades de remediación ambiental por parte del Estado	22
Tabla 7 Método PICOC	25
Tabla 8 Claves y criterios.....	25
Tabla 9 Resumen comparativo de las principales publicaciones en SAR, ML y DL	30
Tabla 10 Clasificación utilizada para el enmascaramiento de las imágenes SAR.....	55
Tabla 11 Comparación de los modelos U-Net, PSPNet y DeepLabV3.	60
Tabla 12 Comparación de las variantes de los modelos DeepLabV3 y REImproved DeepLabV3+	62
Tabla 13 Métricas por clase e importancia ambiental.....	71
Tabla 14 Resumen del procesamiento de las imágenes	82

LISTA DE FIGURAS

Figura 1 Mapa de derrames de Petróleo en el mundo.	12
Figura 2 Historia normativa de los hidrocarburos en el Perú (1821-2025).	13
Figura 3 Procesos para la producción de hidrocarburos.	14
Figura 4 Derrames de hidrocarburos (1462) por regiones.	16
Figura 5 Principales Derrames de Hidrocarburos por Departamento.	16
Figura 6 Diez principales empresas que provocaron más derrames en el Perú.	17
Figura 7 Infracciones por Sector Económico.	17
Figura 8 Multas por Sector Económico.	18
Figura 9 Estimación de barriles de petróleo derramados según Repsol y MINAM.	20
Figura 10 Estimación de áreas afectadas según Repsol y OEFA-MINAM.	20
Figura 11 Presencia del Estado durante los primeros 10 días del derrame de petróleo.	21
Figura 12 Entidades involucradas en la actividad de los hidrocarburos.	23
Figura 13 Organigrama del Sector Hidrocarburos.	24
Figura 14 Diagrama Prisma.	28
Figura 15 Visualización en red de artículos.	29
Figura 16 Imagen SAR.	57
Figura 17 Código para dividir imagen original.	58
Figura 18 Dataset de 352 imágenes de la costa de Ventanilla.	59
Figura 19 Comparación de todos los modelos.	61
Figura 20 Arquitectura del Modelo ReImprovedDeepLabV3+	66
Figura 21 Clase StripePooling.	68
Figura 22 Módulo ASPP.	68
Figura 23 Enmascaramiento de las clases.	69
Figura 24 Interfaz de Usuario.	72
Figura 25 Diagrama de Flujo de la Interfaz	73
Figura 26 Carga de archivos.	74
Figura 27 Carga del modelo preentrenado.	74
Figura 28 Definición de colores estandarizado.	74
Figura 29 Estadísticas de los píxeles.	75
Figura 30 Presencia de derrames.	76

Figura 31 Métricas de Calidad.	76
Figura 32 Ajuste de los umbrales	77
Figura 33 Resultados de detección de derrames.....	77
Figura 34 Contraste entre la imagen original y la máscara predicha.	77
Figura 35 Validación con superposición de imagen-máscara.....	78
Figura 36 Cantidad y porcentaje de Píxeles del derrame.	78
Figura 37 Entorno Streamlit	79
Figura 38 Métricas de rendimiento	80
Figura 39 Tratamiento de imagen individual.....	81
Figura 40 Resultado de detección de derrames en una imagen.....	81
Figura 41 Tratamiento de imágenes por lote	82
Figura 42 Resultado de detección de derrames en lote de imágenes	82

RESUMEN

La contaminación marina por derrames de petróleo representa una amenaza significativa para los ecosistemas costeros y la economía local. Esta investigación propone el desarrollo de un sistema de Inteligencia Artificial Geoespacial (GeoIA) para mejorar la teledetección de impactos medioambientales producidos por derrames de petróleo en el mar. Se empleó una metodología experimental con enfoque cuantitativo, utilizando imágenes de Radar de Apertura Sintética (SAR) del benchmark dataset de MKLab y datos del derrame de Ventanilla (2022) proporcionados por CONIDA. Se compararon arquitecturas de deep learning (U-Net, PSPNet, DeepLabV3, DeepLabV3+) y se diseñó un modelo mejorado (ReImprovedDeepLabV3+) que incorpora un mecanismo de atención polarizada y StripePooling en el módulo ASPP. Los resultados demostraron que el modelo propuesto alcanzó un Accuracy del 97.86%, Recall del 96.01%, IoU de 0.6477 y un tiempo de entrenamiento 25.7% menor que el DeepLabV3+ original. Adicionalmente, se desarrolló una interfaz web con Streamlit que permite la evaluación accesible del impacto geoespacial. Se concluye que la GeoIA mejora significativamente la detección y clasificación de derrames petroleros, ofreciendo una herramienta valiosa para la gestión ambiental alineada con el ODS 14.

Palabras clave: Inteligencia Artificial Geoespacial, derrames de petróleo, teledetección, SAR, Deep Learning, segmentación semántica, impacto ambiental.

ABSTRACT

Marine pollution from oil spills poses a significant threat to coastal ecosystems and local economies. This research proposes the development of a Geospatial Artificial Intelligence (GeoAI) system to improve the remote sensing of environmental impacts caused by oil spills at sea. An experimental methodology with a quantitative approach was employed, using Synthetic Aperture Radar (SAR) images from the MKLab benchmark dataset and data from the Ventanilla oil spill (2022) provided by CONIDA. Deep learning architectures (U-Net, PSPNet, DeepLabV3, DeepLabV3+) were compared, and an improved model (ReImprovedDeepLabV3+) was designed, incorporating a polarized attention mechanism and StripePooling in the ASPP module. Results demonstrated that the proposed model achieved an Accuracy of 97.86%, Recall of 96.01%, IoU of 0.6477, and a training time 25.7% shorter than the original DeepLabV3+. Additionally, a web interface was developed using Streamlit to enable accessible assessment of the geospatial impact. It is concluded that GeoAI significantly enhances the detection and classification of oil spills, providing a valuable tool for environmental management aligned with SDG 14.

Keywords: Geospatial Artificial Intelligence, oil spills, remote sensing, SAR, deep learning, semantic segmentation, environmental impact.

CAPÍTULO 1: INTRODUCCIÓN

1.1. Situación Problemática

Los derrames de petróleo en el mar se han convertido en una de las amenazas ambientales más graves para los ecosistemas y la sostenibilidad socioeconómica de las zonas costeras. A nivel global, incidentes como los de Deepwater Horizon en el Golfo de México (Jolliff et al., 2014) y el desastre en la costa noreste de Brasil (De Oliveira et al., 2020) han demostrado la magnitud del impacto ecológico, económico y social de estos eventos. En el Perú, esta problemática se ha vuelto crítica, con 1462 derrames registrados desde 1997 a 2023 (León et al., 2024) y recientemente, por el lamentable derrame de Ventanilla en 2022, que afectó más de 11000 hectáreas y perjudicó a más de 10000 familias (Defensoría del Pueblo, 2023). La recurrencia de estos episodios evidencia, no solo la insuficiencia de los sistemas tradicionales de monitoreo sino también, una efectiva y rápida respuesta.

Frente a esta necesidad, la integración de la Inteligencia Artificial (IA) con tecnologías geoespaciales, denominada Inteligencia Artificial Geoespacial (GeoIA), se presenta como un campo promisorio para transformar la teledetección de derrames petroleros (Mao et al., 2018). Métodos convencionales de análisis de imágenes satelitales suelen ser lentos y poco escalables, pero, técnicas avanzadas de aprendizaje profundo, aplicadas a imágenes de Radar de Apertura Sintética (SAR) (Di Martino & Iodice, 2021), permiten identificar automáticamente manchas de petróleo con alto nivel de detalle. No obstante, modelos existentes como DeepLabV3+ presentan limitaciones en precisión y

eficiencia computacional (Chen et al., 2017), lo que justifica el desarrollo de arquitecturas optimizadas para el entorno geoespacial marino.

Esta investigación propone el desarrollo y validación de un sistema de GeoIA para mejorar la teledetección de estos impactos. Se diseñó un modelo mejorado de segmentación semántica, el ReImprovedDeepLabV3+, que incorpora mecanismos de atención polarizada y StripePooling para captar patrones alargados típicos de los derrames en imágenes SAR. El modelo demostró un alto rendimiento (Accuracy: 97.86%, Recall: 96.01%) y mayor eficiencia que arquitecturas de referencia. Además, se implementó una interfaz web interactiva con Streamlit (Streamlit, 2025) para facilitar su uso por gestores ambientales, contribuyendo así a una gestión más ágil y fundamentada de emergencias ecológicas, en línea con el Objetivo de Desarrollo Sostenible 14.

1.2. Formulación del Problema

1.2.1. Problema General

¿Cómo se desarrolla un modelo de Inteligencia Artificial Geoespacial (GeoIA) para la optimización de la teledetección de impactos medioambientales causados por los derrames de petróleo en el mar?

1.2.2. Problemas Específicos

¿Cómo se crea y preprocesa experimentalmente un dataset de imágenes de radar estandarizado de derrames de petróleo en el mar usando Sistemas de Información Geográfica (SIG) y Teledetección?

¿De qué forma se compara las mejores técnicas de entrenamiento de modelos de Inteligencia Artificial existentes para la elección óptima de un modelo base en la detección de derrames de petróleo en el mar?

¿De qué manera se diseña un modelo de Inteligencia Artificial Geoespacial (GeoAI) con altas métricas de validación que permita la clasificación del entorno geoespacial cercano a los derrames de petróleo en el mar?

¿Cómo se valida el modelo de Inteligencia Artificial Geoespacial (GeoAI) a través de una framework que detecta y cuantifica los impactos medioambientales producidos por los derrames de petróleo en el mar?

1.3. Justificación de la Investigación

1.3.1. Justificación Teórica

La presente investigación utiliza de manera innovadora la Inteligencia Artificial Geoespacial para la detección de impactos medio ambientales producidos por derrames de petróleo a través de un nuevo modelo denominado ReImprovedDeeplabv3+ basado en un backbone ResNet50 y en imágenes satelitales SAR.

1.3.2. Justificación Práctica

La presente investigación utiliza de manera innovadora la Inteligencia Artificial Geoespacial como una nueva forma de identificar los impactos medioambientales causados por los derrames de petróleo en el mar.

1.3.3. Justificación Metodológica

En la presente investigación se utilizará una metodología Aplicativa, ya que mejora el problema de identificar derrames de petróleo en el mar usando técnicas de entrenamiento de modelos de Inteligencia Artificial Geoespacial (GeoIA) en imágenes tipo SAR.

1.3.4. Justificación Socio Ambiental

La presente investigación alineada al Objetivo de Desarrollo Sostenible (ODS) 14, Vida Submarina, incentiva además la participación de la sociedad a través de una interfaz de usuario que permite la carga de imágenes para su evaluación de impacto ambiental.

1.4. Objetivos de la Investigación

1.4.1. Objetivo General

Desarrollar un modelo de Inteligencia Artificial Geoespacial (GeoIA) para la optimización de la teledetección de impactos medioambientales causados por los derrames de petróleo en el mar.

1.4.2. Objetivos Específicos

Crear y preprocesar experimentalmente un dataset de imágenes de radar estandarizado de derrames de petróleo en el mar usando Sistemas de Información Geográfica (SIG) y Teledetección.

Comparar las mejores técnicas de entrenamiento de modelos de Inteligencia Artificial existentes para la elección óptima de un modelo base en la detección de derrames de petróleo en el mar.

Diseñar un modelo de Inteligencia Artificial Geoespacial (GeoAI) con altas métricas de validación que permita la clasificación del entorno geoespacial cercano a los derrames de petróleo en el mar.

Validar el modelo de Inteligencia Artificial Geoespacial (GeoAI) a través de un framework que detecte y cuantifique los impactos medioambientales producidos por los derrames de petróleo en el mar.

1.5. Hipótesis

1.5.1. Hipótesis General

El desarrollo de un modelo de Inteligencia Artificial Geoespacial (GeoIA) optimiza la teledetección de impactos medioambientales causados por los derrames de petróleo en el mar.

1.5.2. Hipótesis Específicas

HE1: La creación y preprocesamiento de un dataset de imágenes de radar estandarizado de derrames de petróleo del mar de Ventanilla – Lima, se obtiene a través de un Sistema de Información Geográfica (SIG) que delimita el área de estudio y de la Teledetección para la corrección de parámetros físicos de las imágenes.

Para el contraste de esta hipótesis se delimitó el área de interés del derrame de Ventanilla usando ArcGIS con base de datos del OEFA. Posteriormente, se solicitó a CONIDA imágenes de radar correspondientes a dicha fecha y se obtuvo la imagen denominada: TerraSAR-X (TSX1_SAR__EEC_RE__SC_S_SRA_20230315T104519_20230315T104541.tif) de 18424×22787 píxeles. En esta imagen se preprocesó a través de la calibración radiométrica, filtrado de speckle con filtro mediano de 7×7 y conversión

de valores dB a luminosidad lineal. Seguidamente, usando Python se dividió la imagen en 352 subimágenes de 1250*650 píxeles en formato .jpg. Finalmente, se generó un dataset local y estandarizado, con geometría consistente y apto para el entrenamiento de modelos de Deep Learning. Por lo tanto, la hipótesis HE1 es aceptada.

HE2: La comparación de las mejores técnicas de entrenamiento de modelos de Inteligencia Artificial en segmentación semántica existentes permite la elección óptima de un modelo base en la detección de derrames de petróleo en el mar.

Para contrastar esta hipótesis, se compararon cuantitativamente cinco arquitecturas de segmentación semántica: U-Net, PSPNet, DeepLabV3, DeepLabV3+ e Improved DeepLabV3+ utilizando el benchmark dataset de MKLab compuesto por 1112 imágenes SAR Sentinel-1 con sus respectivas máscaras. Estas, entrenadas durante 100 épocas y bajo idénticas condiciones mostraron los siguientes resultados: DeepLabV3+ con backbone ResNet50 alcanzó la mayor Accuracy (0.9873), pero con un tiempo de entrenamiento elevado (39.2 horas), Improved DeepLabV3+ con MobileNetV2 fue el más rápido (22.0 horas) pero presentó un Recall inaceptablemente bajo (0.1394), lo que lo descarta para detección de derrames. El modelo ReImprovedDeepLabV3+ (propuesto) logró un equilibrio superior: Accuracy 0.9786, Recall 0.9601, IoU 0.6477 (5.1% superior al DeepLabV3+ original) y un tiempo de entrenamiento de 29.2 horas (25.7% menos que el original). Finalmente, esta comparación sistemática permitió identificar un modelo base idóneo, siendo el ReImprovedDeepLabV3+ el que ofrece el mejor balance entre precisión, sensibilidad y eficiencia computacional para la detección de derrames de petróleo en imágenes SAR. Por lo tanto, se acepta la hipótesis H2.

HE3: El diseño de un modelo GeoAI denominado ReImprovedDeepLabV3+, que incorpora un backbone ResNet50 mejorado con atención por canal ECANet, un módulo ASPP con StripePooling y un mecanismo de Atención Polarizada dual, alcanza altas métricas de validación y permite clasificar el entorno geoespacial cercano a los derrames de petróleo en el mar.

Para contrastar esta hipótesis, se diseñó e implementó la arquitectura ReImprovedDeepLabV3+ la que incorpora: (i) backbone ResNet50 mejorado con capa de atención por canal ECANet, (ii) sustitución del average pooling tradicional por StripePooling (pooling direccional horizontal y vertical) en el módulo ASPP y (iii) un mecanismo de Atención Polarizada dual (canal-espacial). El modelo se entrenó con el

dataset MKLab y se validó con un conjunto de prueba independiente, obteniéndose las siguientes métricas: Accuracy = 97.86%, Recall = 96.01%, Precision = 95.75%, F1-Score = 95.82%, IoU (para clase derrame) = 0.6477, Boundary F1 = 0.9553. Estas métricas superan o igualan a las de los modelos base en las categorías críticas (Recall e IoU), demostrando que el modelo clasifica correctamente las cinco clases del entorno marino-costero: superficie marina, derrame, pseudo-derrame, embarcación y costa marina). Finalmente, el diseño del modelo ReImprovedDeepLabV3+, con sus innovaciones arquitectónicas, alcanza altas métricas de validación lo que permite una clasificación precisa y confiable del entorno geoespacial cercano a los derrames de petróleo en el mar. Por lo tanto, se acepta la hipótesis H3.

HE4: El framework de validación basado en Streamlit, que integra el modelo ReImprovedDeepLabV3+ permite la detección y cuantificación de derrames de petróleo en imágenes SAR basado en cálculo de métricas de desempeño, como: Precision, Recall, F1-Score e IoU y métricas de impacto, como cantidad de píxeles y porcentaje de área afectada.

Para contrastar esta hipótesis, se implementó un framework interactivo en la interfaz Streamlit que integró el modelo ReImprovedDeepLabV3+ preentrenado. La interfaz permite cargar imágenes individuales o por lotes, ejecuta la inferencia en 1-3 segundos por imagen, y genera visualizaciones de máscaras de segmentación junto con métricas cuantitativas (porcentaje de píxeles afectados y área afectada). Se probó el flujo completo con las 352 imágenes del dataset de Ventanilla, verificando que el sistema procesa lotes, genera reportes tabulares y no presenta errores de ejecución. Sin embargo, no se dispuso de máscaras de referencia (ground truth) para las imágenes de Ventanilla, ya que la imagen SAR, aunque espacialmente abarcaba la zona de estudio, temporalmente fue posterior al derrame. Por lo tanto, al no ser posible calcular las métricas de desempeño y solo validar la funcionalidad técnica del framework, se acepta parcialmente la H4.

1.6. Matriz de Consistencia

Este instrumento mide el grado de coherencia que existe entre los componentes principales de un trabajo de investigación (ver Anexo 1).

CAPÍTULO 2: MARCO TEÓRICO

2.1. Marco Filosófico o epistemológico de la investigación

El Homo Sapiens, aún sin llegar a entender completamente como razona, ha orientado su mirada hacia la construcción de entidades pensantes, más conocidas como Inteligencia Artificial, sobre la cual se considera que existen dos perspectivas: una orientada al ser humano y que se apoya en la experiencia (procedimiento empírico) y la otra enfocada en la racionalidad (procedimiento científico) sustentada por definiciones sobre la misma (ver Tabla 1) (Russell & Norvig, 2016).

La presente investigación está alineada a la corriente de la racionalidad debido a que se busca a tomar decisiones correctas para mitigar los derrames de petróleo en el mar.

Esta Inteligencia Artificial, basada en los Modelos de Aprendizaje de Máquina y Aprendizaje Profundo, conjuntamente integrada a las Geotecnologías dan lugar a un nuevo campo de estudio, la Inteligencia Artificial Geoespacial, y que, alineados a la ODS-14, permitirá la evaluación de derrames en el mar.

Tabla 1*Definiciones epistemológicas de la IA*

Pensar humanamente	Pensar racionalmente
"El nuevo y apasionante esfuerzo por fabricar computadoras pensantes... literalmente, máquinas con mente" (Haugeland, 1985).	"El estudio de las facultades mentales a través del uso de modelos computacionales" (Charniak y McDermott, 1985).
"La automatización de actividades que realizamos asociada con el pensamiento humano, actividades como la toma de decisiones, la resolución de problemas, el aprendizaje. . ." (Bellman, 1978)	"El estudio de los cálculos que hacen posible percibir, razonar y actuar" (Winston, 1992).
Actuar humanamente	Actuar racionalmente
"El arte de crear máquinas que realizan funciones que requieren inteligencia cuando las personas lo necesiten" (Kurzweil, 1990).	"La Inteligencia Computacional es el estudio del diseño de agentes inteligentes" (Pool et al., 1998).
"El estudio de cómo hacer que las computadoras hagan cosas en las que, por el momento, la gente lo hace mejor" (Rico y Caballero, 1991)	"IA. . . se ocupa del comportamiento inteligente en artefactos" (Nilsson, 1998).

Nota. Tomado del Artificial Intelligence: A Modern Approach. Fuente: Russell & Norvig (2016).

2.2. Antecedentes de la investigación

2.2.1. A nivel mundial

El equilibrio ecológico planetario depende en gran manera del medio ambiente marino el cual se está viendo afectado por la exploración y explotación a gran escala de los recursos marinos, los accidentes producto de colisiones de barcos, la contaminación por descargas de aguas residuales no tratadas y explosiones de plataformas de perforación, lo cual está provocando daños a largo plazo en diversas especies de flora y fauna marina en ecosistemas frágiles como los arrecifes de coral y bosques de manglares, así como en la salud humana (Jiao et al., 2019; Lassalle et al., 2023, Li et al., 2018; Rajendran et al., 2021; Ramírez et al., 2017).

La interacción entre el petróleo y la costa marina es un asunto preocupante durante las situaciones de derrames de petróleo, sobretudo en áreas urbanizadas y económicamente activas que, debido a su expansión en dichas zonas costeras, son propensas a los accidentes en el proceso de extracción del combustible, durante su

transporte y almacenamiento lo que podría provocar una intensa degradación ambiental e impacto económico y social (Barbosa et al., 2020; Marinho et al., 2021; Samaras et al., 2014).

Con respecto a la contaminación marina, se considera que el 47 % son por procesos naturales como eventos sísmicos, filtraciones limitadas, afloramientos, etc., mientras que el mayor porcentaje equivalente al 53% es de origen antropogénico, como la exploración de recursos naturales en depósitos de reservas de aguas profundas y la industria del transporte marino, siendo esta última la que puede trasladar grandes volúmenes de petróleo y gas aumentando así el riesgo de accidentes y de derrames en el océano en tan solo un evento (Lima et al., 2021; Nissanka et al., 2018; Polinov et al., 2021; Wei et al., 2014).

Por ello es necesaria una evaluación del riesgo ecológico de los ecosistemas costeros para la gestión de un desarrollo marino sostenible y una reactivación de la economía, que además se vio afectada por el COVID-19, el cual ralentizó los planes de restauración y monitoreo del entorno ambiental ya que se contaban con pocos datos disponibles o estaban incompletos (Barbosa et al., 2020; Ma et al., 2023; Matos et al., 2021).

Extensos accidentes de derrames de petróleo marino han ocurrido en el mundo que merecen la atención de la sociedad y de leyes y de procedimientos que prevengan futuros accidentes y derrames, como los ocurridos por ejemplo en el mar chino de Bohai (Cheng et al., 2019; Liu et al., 2022; Xiong et al., 2015;), en el mar del Caribe por su alto tráfico de embarcaciones (Singh et al., 2015), en el pozo exploratorio Ixtoc-I en la Bahía de Campeche, México (Sun et al., 2015), entre otros, pero toman mayor relevancia para esta investigación los acontecidos en Estados Unidos (Svejkovsky et al., 2023) y en Brasil (Fernandes et al., 2020).

En el hemisferio norte, el 20 de abril del 2010 se registró el mayor derrame de petróleo marino de Estados Unidos por la explosión de la plataforma de perforación

Deepwater Horizon (DWH) en aguas profundas en el prospecto Macondo en la costa norte del Golfo de México y las playas de Alabama, durante 86 días donde se derramaron más de 785 millones de litros de crudo en la costa norte del Golfo de México (GOM), evidenciándose el petróleo como una emulsión de agua en aceite de color marrón anaranjado, llamada también espuma lo que contaminó la vegetación costera y las playas generando un alto impacto ambiental en el ecosistema y toxicidad para todos los organismos vivos (Jolliff et al., 2014; Wang et al., 2023).

En el hemisferio sur, el derrame de petróleo acaecido en la costa noreste de Brasil, cuenca del Atlántico Sur y en las regiones costeras tropicales, entre agosto del 2019 y enero del 2020, es considerado como el mayor desastre ecológico oceánico y de mayor contaminación e impacto mundial, con más de 5000 toneladas de petróleo derramados y de repercusión no solo nacional sino también a nivel mundial (Araújo et al., 2021; De Oliveira et al., 2020; De Santana et al., 2021). Este trágico evento, que afectó a la sociedad y a su economía, vulneró de manera particular a la flora, la fauna y la credibilidad de sus productos marinos, así como a los comercios e instituciones de la zona costera, y esto a pesar de que Brasil cuenta con instituciones de respuesta ante emergencias ambientales tales como los Centros de Defensa Ambiental (EDC), los cuales conjuntamente con otros investigadores continúan hasta el día de hoy evaluando sus orígenes (Azevedo et al., 2022; Cabrera et al., 2016; Façanha et al., 2021; Zapelini et al., 2022).

Hoy, el transporte marino del petróleo constituye más del 50 % de la actividad marina, lo que es un peligro potencial por su nivel de toxicidad. Para poner en contexto esta amenaza, se indican los 20 principales derrames sucedidos en el mundo y expresados en orden descendente de magnitud (ver Tabla 2).

Tabla 2*Principales derrames de petróleo a nivel mundial*

Nº	Embarcación	Año	Localización	Toneladas
1	Atlantic Empress	1979	Frente a Tobago, Antillas	287,000
2	Abt Summer	1991	A 700 millas náuticas de Angola	260,000
3	Castillo De Bellver	1983	Frente a la bahía de Saldanha, Sudáfrica	252,000
4	Amoco Cadiz	1978	Frente a Bretaña, Francia	223,000
5	Haven	1991	Génova, Italia	144,000
6	Odyssey	1988	A 700 millas náuticas de Nueva Escocia, Canadá	132,000
7	Torrey Canyon	1967	Islas Scilly, Reino Unido	119,000
8	Sea Star	1972	Golfo de Omán	115,000
9	Sanchi	2018	Frente a Shanghai, China	113,000
10	Irenes Serenade	1980	Bahía de Navarino, Grecia	100,000
11	Urquiola	1976	La Coruña, España	100,000
12	Hawaiian Patriot	1977	A 300 millas náuticas de Honolulu	95,000
13	Independenta	1979	Bósforo, Turquía	94,000
14	Jakob Maersk	1975	Oporto, Portugal	88,000
15	Braer	1993	Islas Shetland, Reino Unido	85,000
16	Aegean Sea	1992	La Coruña, España	74,000
17	Sea Empress	1996	Milford Haven, Reino Unido	72,000
18	Khark 5	1989	A 120 millas náuticas de la costa atlántica de Marruecos	70,000
19	Nova	1985	Frente a la isla de Kharg, Golfo de Irán	70,000
20	Katina P	1992	Frente a Maputo, Mozambique	67,000

Nota. Datos tomados del Oil Spill Intelligence Report: Major Oil Spills in History. Fuente: Promoting Effective Spill Response – ITPOF (2025).

Del cuadro anterior se observa que los mayores desastres ocurrieron a finales del siglo XX. A continuación, se muestra el mapa de las principales embarcaciones que causaron los mayores derrames de petróleo en el planeta y que en su mayoría, se concentran en el continente europeo, alrededor de Portugal y España en el océano Atlántico (ver Figura 1).

Figura 1

Mapa de derrames de Petróleo en el mundo.



Nota. Unidades: cientos de toneladas. Datos tomados del Oil Spill Intelligence Report.

Fuente: ITOPF (2024).

2.2.2. A nivel país


Aunque el Hidrocarburo (HC) fue considerado legalmente en sus primeros años como un mineral, a partir de 1922 con la Ley N° 4452 emitida por Augusto B. Leguía, el HC ha realizado un largo recorrido en su legislación hasta nuestros días con la promulgación de la Ley 26224 emitida por Alberto Fujimori (ver Figura 2) (Tamayo et al., 2015).

Las operaciones de Hidrocarburos, que conllevan a su posterior producción, son direccionadas por tres instituciones: Perupetro, MINEM y Petroperu las cuales se encargan de acompañar a las empresas operadoras durante la realización de las siguientes fases: Exploración, Explotación, Procesos, Transporte, Almacenamiento y Comercialización (ver Figura 3).

A continuación, se presenta una estadística de las principales actividades realizadas durante las operaciones llevadas a cabo en Perú en los últimos 10 años (ver Tabla 3) (Perupetro, 2023).

Figura 2

Historia normativa de los hidrocarburos en el Perú (1821-2025).




Nota. Editado de La industria de los hidrocarburos líquidos en el Perú: 20 años de aporte al desarrollo del país. Fuente: Tamayo et. al (2015).

Tabla 3*Resumen Ejecutivo 2014 -2025*

OPERACIONES	ACTIVIDADES	2014	2015	2016	2017	2018	2019	2020	2021	2022	2023
CONTRATOS	SUSCRITOS	2	5	-	3	-	1	2	1	-	6
	VIGENTES	68	66	51	46	41	39	38	32	31	32
	TERMINADOS	8	7	15	8	5	3	3	7	1	5
GEOFÍSICA	SÍSMICA 2D (Km)	2036	6427	109	-	313	63	-	192	70	-
	SÍSMICA 3D (Km2)	484	-	-	-	-	-	-	-	-	-
	AEROGRAVIMETRÍA / GRAVIMETRÍA (Km)	14619	-	-	-	859	3650	-	-	-	-
	AEROMAGNETOMETRÍA / MAGNETOMETRÍA (Km)	14624	-	-	-	859	3650	-	-	-	-
POZOS PERFORADOS	DESARROLLO	100	80	44	135	170	187	38	109	91	41
	CONFIRMATORIO	-	3	-	-	-	3	-	-	-	-
	EXPLORATORIO	12	4	-	4	5	3	1	1	-	-
	TOTAL	93	112	87	44	139	175	193	39	110	41
PRODUCCIÓN FISCALIZADA	HIDROCARBUROS	173	149	135	134	134	140	125	120	117	115.11
	LÍQUIDOS (MBPD)										
	PETRÓLEO	69	58	40	44	49	53	40	38	41	38.70
	LGN	103	91	95	91	85	87	85	81	77	76.41
	GAS NATURAL (MMPCD)	1250	1209	1351	1252	1231	1299	1161	1101	1326	1415.72
INVERSIÓN (MM US\$)	EXPLORACIÓN	502	313	47	17	41	58	61	3	2	2.27
	EXPLOTACIÓN	701	442	293	470	561	567	185	310	323	321.73
	TOTAL	1203	755	340	487	602	625	246	313	326	324.00
INGRESOS PARA EL ESTADO	CONTRATO DE LICENCIA	1630	729	629	793	1030	773	511	1241	1844	1205.97
	CONTRATO DE SERVICIO	85	40	33	38	69	64	27	39	37	24.57
	TOTAL	1715	769	662	831	1099	837	538	1280	1881	1230.54
DISTRIBUCIÓN DEL CANON / SOBRECANON (MM SOLES)	LORETO	336	120	30	67	136	146	58	10	215	178.78
	UCAYALI	119	60	28	28	52	50	19	3	64	54.52
	PIURA	593	322	263	302	432	412	259	40	574	454.11
	TUMBES	219	112	86	96	126	117	66	10	144	113.69
	HUÁNUCO	10	26	15	29	33	28	12	2	23	12.75
	CUSCO	1496	940	905	1036	1289	921	737	302	2894	1879.77
	TOTAL	2773	1580	1328	1558	2068	1675	1152	366	3914	2633.62


Nota. Datos tomados de la Estadística Anual de Hidrocarburos 2024. Fuente: Perupetro (2025).

Figura 4
Derrames de hidrocarburos (1462) por regiones.



Nota. Editado de Las sombras de los Hidrocarburos. Fuente: León et al., 2024.

Figura 5
Principales Derrames de Hidrocarburos por Departamento.




Nota. Editado de Las sombras de los Hidrocarburos. Fuente: León et al., 2024

Dentro de este mismo período de tiempo se han identificado a las 10 principales empresas que provocaron más derrames en el Perú: 1235 (ver Figura 6).

Figura 6

Diez principales empresas que provocaron más derrames en el Perú.

N° Derrames por Empresa




Nota. Editado de Las sombras de los Hidrocarburos. Fuente: León y Zúñiga (2024).

Por otro lado, OEFA ha identificado a 18306 infractores ambientales de los cuales 5860 infracciones corresponden al sector hidrocarburo (32 %) (ver Figura 7).

Figura 7

Infracciones por Sector Económico.




Nota. Infracciones ambientales realizadas por distintos sectores. Fuente: Organismo de Evaluación y Fiscalización Ambiental [OEFA] (2023).

Con respecto a las multas, OEFA ha sancionado con 273648 UIT a diversos sectores que han provocado impactos ambientales, siendo el sector de hidrocarburos el que ha registrado una suma de 67880 UIT (24.8 %) (ver Figura 8).

Figura 8

Multas por Sector Económico.



Nota. La figura muestra las multas impuestas a los distintos sectores por producir impactos ambientales. Fuente: OEFA. 2023.

Dentro del sector HC las siguientes veinte empresas se han caracterizado por su alto número de infracciones y por las altas multas ambientales impuestas por el OEFA (ver Tabla 4).

En la actualidad, el 15 de enero del 2022 ocurrió el mayor desastre ambiental del Perú producto del derrame 12000 barriles de petróleo vertidos en nuestra costa peruana: terminal Multiboyas N° 2 de la refinería La Pampilla, operada por la empresa REPSOL, y ubicada en el distrito de Ventanilla, Provincia Constitucional del Callao. La estimación de la magnitud del derrame de petróleo según Repsol y OEFA-MINAM, se representa en la Figura 9.


Tabla 4
Listado de empresas sancionadas por OEFA

N	EMPRESAS SANCIONADAS	CANTIDAD DE INFRACCIONES	MONTO SANCIONADO (UIT)
1	Petróleos del Peru Petroperú SA	495	24426.07
2	Pluspetrol Norte S.A.	395	22303.24
3	Transportadora de Gas Del Perú S.A.	40	4049.07
4	Maple Gas Corporation Del Peru S.R.L.	89	2241.33
5	Frontera Energy del Perú S.A.	98	1584.42
6	Olympic Peru Inc Sucursal Del Peru	107	1277.34
7	Sapet Development Peru Inc Sucursal Peru	52	752.98
8	Cepsa Peruana S.A.C.	23	710.51
9	Cnpc Peru S.A.	176	699.96
10	Pluspetrol Peru Corporation S.A.	189	626.48
11	Unna Energia S.A.	94	592.84
12	Servicentro Chacabayo S.A.C.	3	544.2
13	Savia Peru S.A.	283	420.04
14	Gas Natural de Lima y Callao S.A.	28	340.41
15	Perenco Peru Petroleum Limited Sucursal Del Peru	51	256.11
16	Refineria La Pampilla S.A. A.	40	247.74
17	Consorcio Grifo Los Ángeles S.A.C.	2	227.85
18	Lanter Energy S.A.C. - Lantera E S.A.C.	1	207.78
19	Gases Del Pacifico S.A.C.	35	194.63
20	Talismán Peru B.V. Sucursal Del Peru	11	186.39

Nota. Las 20 principales empresas sancionadas con las multas más altas por derrames de petróleo. Fuente: OEFA (2025).

Figura 9

Estimación de barriles de petróleo derramados según Repsol y MINAM.




Nota. Informe de Adjuntía N° 001-2023-DP/AMASPPI. Fuente: Defensoría del Pueblo (2023).

El impacto ambiental de esta tragedia ecológica dejó un saldo mayor a 11000 ha afectadas, 97 sitios contaminados (62 playas), 2 Áreas Naturales Protegidas (ANP): la Reserva Nacional Sistema de Islas, Islotes y Puntas Guaneras y la Zona Reservada de Ancón. La estimación de los lugares afectados según Repsol y OEFA-MINAM, se representa en la Figura 10.

Figura 10

Estimación de áreas afectadas según Repsol y OEFA-MINAM.



Nota. Informe de Adjuntía N° 001-2023-DP/AMASPPI. Fuente: Defensoría del Pueblo (2023).


Con respecto al impacto social, más de 10300 familias sufrieron las consecuencias del desastre por el impacto que tuvo en sus trabajos tanto informales, como la pesca y comercio, así como los formales como el turismo, en los 5 distritos de Lima y Callao (ver Tabla 5).

Tabla 5*Familias afectadas por el derrame de petróleo*

DPTO.	PROVINCIA	DISTRITO	FAMILIAS AFECTADAS
Callao	Constitucional del Callao	Ventanilla	1425
Lima	Lima Metropolitana	Ancón	4758
		Santa Rosa	300
	Huaral	Aucallama	940
		Chancay	2877
TOTAL			10300

Nota. Editado del Informe-de-emergencia-nº-757-27mar2023-derrame-de-hidrocarburos-en-el-distrito-de-ventanilla-callao-100. Fuente: INDECI (2023).

El accionar del Estado ante esta emergencia ambiental y ante la sociedad, en los primeros 10 días, es presentado en la Figura 11.

Figura 11*Presencia del Estado durante los primeros 10 días del derrame de petróleo.*

Nota. Editado del Informe de Adjuntía Nº 001-2023-DP/AMASPPI. Fuente: Defensoría del Pueblo (2023).

La Defensoría del Pueblo señala claramente que el Estado, representado por sus diversas instituciones medioambientales y sociales, juntamente con el sector privado, deben realizar actividades específicas que impulsen la recuperación del entorno geográfico

afectado (ver Tabla 6) (Defensoría del Pueblo, 2023). Cabe señalar, que OEFA (MINAM) impuso una multa de 6340,082 (UIT) a Repsol (OEFA, 2023).

Tabla 6

Actividades de remediación ambiental por parte del Estado


INSTITUCIÓN	ACTIVIDADES
Ministerio del Ambiente (MINAM)	Desarrollar los estándares de calidad ambiental para los HC.
Dirección General de Salud Ambiental (DIGESA)	Verificar los estándares internacionales o de nivel internacional de los HC.
Organismo de Evaluación y Fiscalización Ambiental (OEFA)	Supervisar que la empresa Refinería La Pampilla S.A. limpie los HC.
Instituto del Mar del Perú (IMARPE)	Informar sobre la restauración de la vida marina.
Servicio Nacional Forestal y de Fauna Silvestre (SERFOR)	Hacer cumplir los protocolos sobre la vida marina
Ministerio de Energía y Minas (MINEM)	Realizar mejoras tecnológicas para mitigar los derrames de HC.
Dirección General de Capitanías y Guardacostas (DICAPI)	Concluir con el proceso de actualización del Plan Nacional de Contingencia para la Prevención, el Control y Combate de Derrames de Hidrocarburos.
Ministerio de Salud (MINSA)	Evaluar y, de ser el caso, disponer las medidas necesarias e idóneas para proteger el derecho a la salud de las personas.
Instituto Nacional de Salud Mental “Honorio Delgado – Hideyo Noguchi”	Velar por la salud mental de las personas afectadas por el derrame.
Presidencia de Consejo de Ministros (PCM)	Informar del avance de la remediación al Congreso de la República
Congreso de la República (CR)	Elaborar leyes de protección ambiental.
Fiscalías Especializadas en Materia Ambiental (FEMA)	Velar por el cumplimiento de las leyes de protección ambiental.
Empresa Refinería La Pampilla S.A.A. del Grupo Repsol del Perú S.A.C.	Compensar económicamente a los afectados por el derrame de HC.

Nota. Condensado del Informe de Adjuntía N° 001-2023-DP/AMASPPI, Derrame de petróleo en Ventanilla: Reporte a un año del desastre ambiental y social en nuestro litoral. Fuente: Defensoría del Pueblo (2025).

A continuación, se muestra una clasificación de las principales entidades según su función rectora, reguladora, fiscalizadora o de otra índole (ver Figura 12).


Figura 12

Entidades involucradas en la actividad de los hidrocarburos.



Nota. Editado de Libro Blanco de Hidrocarburos (LBH). Fuente: SPH (2014).

A propósito, para tener un panorama más amplio acerca entidades involucradas en el sector hidrocarburos se muestra el siguiente organigrama (ver Figura 13).

Figura 13*Organigrama del Sector Hidrocarburos.*

Nota. Editado de Libro Blanco de Hidrocarburos (LBH). Fuente: SPH (2014).

2.2. Estado del Arte

En principio, para tener un panorama general de la investigación, se ha utilizado el método PICOC (Population, Intervention, Comparison, Outcomes, Context) (ver Tabla 7) para la revisión sistemática de la literatura (Kitchenham, B. (2007) a través de la plataforma PARSIFAL (Parsifal, 2023).

Además, se consideraron las palabras claves, sinónimos e intervenciones, criterios de inclusión y de exclusión (ver Tabla 8). Las fuentes analizadas fueron revisadas hasta el 31 de octubre del 2023.

Tabla 7*Método PICOC*

PICOC	
Población	Papers about oil spills, oil spill datasets
Intervención	Geospatial Artificial Intelligence, Sustainable Development Goals
Comparación	Remote Sensing
Resultado	Prevent environmental impacts from oil spills
Contexto	Environment

Tabla 8*Claves y criterios*

Clave		Criterios
Cadena Búsqueda	de	(spill AND oil AND machine AND learning) AND PUBYEAR > 2018 AND PUBYEAR < 2024 AND (LIMIT-TO (EXACTKEYWORD, "Oil Spill") OR LIMIT-TO (EXACTKEYWORD, "Oil Spills"))
Criterio Inclusión	de	GeoIA
Criterio Exclusión	de	Papers more than 5 years old

Posteriormente se utilizó la declaración PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) la cual permite realizar una revisión sistemática y metaanálisis de la investigación (Page et al., 2021) (ver Figura 14). Para esto se han revisado las bases de Datos Scopus, IEEE y Scielo.

A continuación, se detalla todas las consultas utilizadas en la base de datos que aportó la mayor documentación en la investigación: SCOPUS.

Primera Consulta: 3341

General

ALL (oil AND spill AND machine AND learning) AND PUBYEAR > 2019 AND PUBYEAR < 2025

Segunda Consulta: 2445

Tipo de documento: Artículos Académicos, Artículos de Conferencia, Artículos de Revisión, Artículos de Revisión de Conferencias y Artículos de datos.

ALL ("oil spill" AND "machine learning") AND PUBYEAR > 2019 AND PUBYEAR < 2025 AND (LIMIT-TO (DOCTYPE , "ar") OR LIMIT-TO (DOCTYPE , "cp") OR LIMIT-TO (DOCTYPE , "re") OR LIMIT-TO (DOCTYPE , "dp") OR LIMIT-TO (DOCTYPE , "cr"))

Tercera Consulta: 2042

Área de Estudio: Ingeniería, Ciencias de la Computación, Ciencias Medio Ambientales, Tierra y Ciencias Planetarias.

ALL ("oil spill" AND "machine learning") AND PUBYEAR > 2019 AND PUBYEAR < 2025 AND (LIMIT-TO (DOCTYPE , "ar") OR LIMIT-TO (DOCTYPE , "cp") OR LIMIT-TO (DOCTYPE , "re") OR LIMIT-TO (DOCTYPE , "dp") OR LIMIT-TO (DOCTYPE , "cr")) AND (LIMIT-TO (SUBJAREA , "engi") OR LIMIT-TO (SUBJAREA , "comp") OR LIMIT-TO (SUBJAREA , "envi") OR LIMIT-TO (SUBJAREA , "eart"))

Cuarta Consulta: 1064

Tecnologías: Machine Learning (398), Remote Sensing (369), Deep Learning (332), Oil Spills (264), Synthetic Aperture Radar (223), Oil Spill (191) y Marine Pollution (168).

ALL ("oil spill" AND "machine learning") AND PUBYEAR > 2019 AND PUBYEAR < 2025 AND (LIMIT-TO (DOCTYPE , "ar") OR LIMIT-TO (DOCTYPE , "cp") OR LIMIT-TO (DOCTYPE , "re") OR LIMIT-TO (DOCTYPE , "dp") OR LIMIT-TO (DOCTYPE , "cr")) AND (LIMIT-TO (SUBJAREA , "ENGI") OR LIMIT-TO (SUBJAREA , "COMP") OR LIMIT-TO (SUBJAREA , "ENVI") OR LIMIT-TO (SUBJAREA , "EART")) AND (LIMIT-TO (EXACTKEYWORD , "Machine Learning") OR LIMIT-TO (EXACTKEYWORD , "Remote Sensing") OR LIMIT-TO (EXACTKEYWORD , "Deep Learning") OR LIMIT-TO (EXACTKEYWORD , "Oil Spills") OR LIMIT-TO (EXACTKEYWORD

, "Synthetic Aperture Radar") OR LIMIT-TO (EXACTKEYWORD , "Oil Spill") OR
LIMIT-TO (EXACTKEYWORD , "Marine Pollution") OR LIMIT-TO (EXACTKEYWORD , "Radar Imaging"))

Quinta Consulta: 548.

Tipo de Acceso: Libre

ALL ("oil spill" AND "machine learning") AND PUBYEAR > 2019 AND
PUBYEAR < 2025 AND (LIMIT-TO (DOCTYPE , "ar") OR LIMIT-TO (DOCTYPE , "cp") OR LIMIT-TO (DOCTYPE , "re") OR LIMIT-TO (DOCTYPE , "dp") OR LIMIT-TO (DOCTYPE , "cr")) AND (LIMIT-TO (SUBJAREA , "ENGI") OR LIMIT-TO (SUBJAREA , "COMP") OR LIMIT-TO (SUBJAREA , "ENVI") OR LIMIT-TO (SUBJAREA , "EART")) AND (LIMIT-TO (EXACTKEYWORD , "Machine Learning") OR LIMIT-TO (EXACTKEYWORD , "Remote Sensing") OR LIMIT-TO (EXACTKEYWORD , "Deep Learning") OR LIMIT-TO (EXACTKEYWORD , "Oil Spills") OR LIMIT-TO (EXACTKEYWORD , "Synthetic Aperture Radar") OR LIMIT-TO (EXACTKEYWORD , "Oil Spill") OR LIMIT-TO (EXACTKEYWORD , "Marine Pollution") OR LIMIT-TO (EXACTKEYWORD , "Radar Imaging")) AND (LIMIT-TO (OA , "all"))


Sexta Consulta: 130.

Tecnología Específica: SAR

ALL ("oil spill" AND "machine learning") AND PUBYEAR > 2019 AND
PUBYEAR < 2025 AND (LIMIT-TO (DOCTYPE , "ar") OR LIMIT-TO (DOCTYPE , "cp") OR LIMIT-TO (DOCTYPE , "re") OR LIMIT-TO (DOCTYPE , "dp") OR LIMIT-TO (DOCTYPE , "cr")) AND (LIMIT-TO (SUBJAREA , "ENGI") OR LIMIT-TO (SUBJAREA , "COMP") OR LIMIT-TO (SUBJAREA , "ENVI") OR LIMIT-TO (SUBJAREA , "EART")) AND (LIMIT-TO (EXACTKEYWORD , "Synthetic Aperture Radar")) AND (LIMIT-TO (OA , "all"))

Figura 14

Diagrama Prisma.




Nota. La figura muestra los filtros utilizados. Fuente: Cochrane RevMan (2025).

La búsqueda recuperó 3406 documentos después de aplicar los filtros: “Oil Spill” y “Machine Learning”. Luego se detectaron 51 duplicados disminuyendo a 3355. Seguidamente se aplicó el filtro de solo considerar artículos, no libros, arrojando 2445. Posteriormente se filtró por áreas de estudio consiguiendo 2042, después se filtró por tecnologías específicas encontrando 1064, seguidamente se decantó por las imágenes SAR reduciéndose a 130 de las cuales se consideraron 50 artículos adicionales que sostienen esta investigación. Por otro lado, se encontró que si bien es cierto varios países cuentan con información actualizada, tales como: Grecia, Turquía, Irán, Italia, Suecia, es China la que mayor relevancia tiene para esta investigación (ver Figura 15).

Figura 15

Visualización en red de artículos.



Nota. Elaboración propia. La figura muestra los artículos en función a los países. Fuente: VOSViewer (2023).

A continuación, un resumen de las principales publicaciones, conjuntos de datos, algoritmos y métricas de los modelos del Aprendizaje Automático y Aprendizaje Profundo en los últimos años (ver Tabla 9).

Tabla 9

Resumen comparativo de las principales publicaciones en SAR, ML y DL

Autores	Año	Título del Artículo	Datasets	Algoritmo	Precisión
Adhikary et al.	2022	Realtime Oil Spill Detection By Image Processing of Synthetic Aperture Radar Data.	SAR	DL CNN + YOLO	95,3%
Almeer et al.	2021	Oil Spill Detection System in the Arabian Gulf Region: An Azure Machine-Learning Approach.	SAR ERS, Envisat	ML	90,5%
Basit et al.	2021	Deep learning based oil spill classification using unet convolutional neural network	SAR Sentinel-1 European Maritime Safety Agency (EMSA) https://mklab.itig.r/	DL CNN + U-Net	mIoU = 75.70%.
De Laurentiis et al.	2021	Deep Learning for Mineral and Biogenic Oil Slick Classification with Airborne Synthetic Aperture Radar Data	SAR UAVSAR NASA/JPL-Caltech. http://www.asf.alaska.edu	DL CNN	99,0 %
Duan et al.	2023	Hyperspectral Remote Sensing Benchmark Database for Oil Spill Detection With an Isolation Forest-Guided Unsupervised Detector	SAR Hyperspectral oil spill database (HOSD) https://github.com/PuhongDuan/HOSD	ML SVM+E RW No supervisados (iForest)	96.50%
Feinauer et al.	2022	Oil Spill Identification using Deep Convolutional Neural Networks.	SAR Imágenes de internet: 783 de derrame de petróleo y 783 de agua/inundación	DL CNN + GoogleNet y VGG16	97,5%
Ghonaime & Farouk Al-Sadek	2023	OilSpillNet: Deep Learning Model for Synthetic Aperture Radar Imagery Oil Spill Detection.	SAR Sentinel-1 European Space Agency (ESA).	Arquitectura U-Net con DenseNet as the encoder	80.31%
Ronci et al.	2020	Oil spill detection from sar images by Deep Learning	SAR 839 Imágenes Radarsat-2 y Sentinel-1	DL+ CNN U-Net++	98,3 %

Huby, Alubady, et al.	2022	Oil Spill Segmentation from SAR Images Using Deep Neural Networks.	SAR 1112 Imágenes ImageNet	DL CNN U-Net + DenseNet201	96.53%
Huby, Sagban, et al.	2022	Oil Spill Detection based on Machine Learning and Deep Learning: A Review.	SAR	ML-DL	Variada
Kang, Deng et al.	2023	Self-Supervised Spectral-Spatial Transformer Network for Hyperspectral Oil Spill Mapping.	SAR AVIRIS HOSD	DL CNN + SSTNet	95,96 %
Kang, Wang et al.	2022	The Potential of Hyperspectral Image Classification for Oil Spill Mapping.	SAR *Simulado **Penglai ***DWH https://github.com/PinkSlime/HSI_oil_spill_mapping	DL	* 100,00 % ** 93,86 % *** 85,84 %
Li et al.	2022	Marine Oil Spills Detection and Classification from Polarsar Images Based on Complex-Valued Convolutional Neural Network	SAR banda C - Radarsat-2 Norwegian Clean Seas Association for Operating Companies (NOFO)	DL CV CNN	97,69%
Luo et al.	2021	Oil Spill Segmentation of SAR Image Based on Improved Deep Convolution Neural Network	SAR Sentinel 1 1112 imágenes European Maritime Safety Agency (EMSA)	DL CNN Deeplabv3 + con Resnet101	MioU = 66,5 %.
Lyu	2018	Oil spill detection based on features and extreme learning machine method in SAR images	SAR	ML Extremo	No indica
Ma et al.	2022	Oil Spill Detection Based on Deep Convolutional Neural Networks Using Polarimetric Scattering Information from Sentinel-1 SAR Images	SAR Sentinel-1 Space Agency (ESA) https://scihub.esa.int	DL CNN Deeplabv3 + Resnet101	98,92 %
Nieto-Hidalgo et al.	2018	Two-stage convolutional neural network for ship and spill detection using SLAR images	SAR	DL CNN Two Stages	98,34 %
Nugroho, Y. S., & Supangkat, S. H.	2021	Spatial Data Infrastructure Integrated with Geospatial Artificial Intelligence: A Systematic Literature Review	Múltiples	ML-DL	Variada
Perez-Garcia et al.	2023	Novel Spectral Loss Function for Unsupervised Hyperspectral Image Segmentation	SAR *PU **SV ***IP ****UH2018 https://aviris.jpl.nasa.gov/ https://github.com/mhaut/HSI-3DSpLoss	CNN + 3-D-CAE	*63,9 % **85,5 % *** 51,7 % **** 29,4 %

Saengtabti et al.	2023	The 2022 Rayong Oil Spill Crisis in Thailand: An Identification for Reliability and Nearly-Real Time Data using Twitter	970 Tweets Twitter en Tailandia	IGV usando Twitter (similitud del coseno)	No indica
Sandhiya et al.	2023	Detection of Oil Spill Events at Sea Using Machine Learning	SAR Automatic Identification system (AIS)	ML + Decision Tree	42,55 %
Scardigli et al.	2023	Integrating Unordered Time Frames in Neural Networks: Application to the Detection of Natural Oil Slicks in Satellite Images	SAR Sentinel-1 Space Agency (ESA) https://scihub.esa.int	DCNN	92,3%
Song, Gao et al.	2023	SSWT-UNet++ Submarine Oil Pipeline Spill Detection Approach	Imagen procedente de un vídeo de la fuga de un oleoducto submarino obtenido a través del internet	CNN + SSWT-UNet++	98,5 %
Song, D, Zhen, Z. et al.	2020	A Novel Marine Oil Spillage Identification Scheme Based on Convolution Neural Network Feature Extraction From Fully Polarimetric SAR Imagery	SAR *Dataset 1 **Dataset 2 ***Dataset 3	CNN-SVM	*99.19 % ** 99.89 % *** 97.56 %
Xie et al.	2022	Fine-Grained Oil Types Identification Based on Reflectance Spectrum: Implication for the Requirements on the Spectral Resolution of Hyperspectral Remote Sensors	SAR AVIRIS y Landsat 8	DNN	92,0 %
Xu et al.	2022	Oil Spill Detection in SAR Images based on Improved YOLOX-S	SAR 2487 imágenes	YOLOX-S + FFEDNet	86,76%.
Yang et al.	2022	Research on Oil Spill Pollution Type Identification Using Rpnnet Deep Learning Model and Airborne Hyperspectral Image	10 productos de petróleo	DL RPNNet	83,67%
Yin et al.	2023	Remote Identification of Oil Films on Water via Laser-Induced Fluorescence LiDAR	LIF-LiDAR	ML + NN	100,0 %
Yu et al	2018	Oil Spill Segmentation via Adversarial f-Divergence Learning	SAR Imágenes Sintéticas y Reales (NOWPAP) http://cearac.poi.dvo.ru/en/db/	CNN + Divergencia F Adverso	96,2 %

Zhan et al	2022	Terahertz Spectroscopy Combined with Deep Learning for Predicting the Depth and Duration of Underground Sand Pollution by Crude Oil	SAR	CNN 1-D	F1 score = 97,90%
------------	------	---	-----	---------	-------------------

Nota. Radar de Apertura Sintética (SAR), Aprendizaje Automático (ML) y Aprendizaje Profundo (DL). Elaboración propia (2025).

Publicaciones recientes han permitido categorizar a la Inteligencia Artificial (Artificial Intelligence), en varios niveles, siendo uno de ellos el Aprendizaje Automático (ML, Machine Learning) y, su respectivo subnivel el Aprendizaje Profundo (DL, Deep Learning) que son algoritmos diversos y especializados que permiten, por ejemplo, segmentar zonas, detectar bordes, delimitar umbrales y monitorear, y más aún, predecir de forma cada vez más precisa, los derrames de petróleo. Es así como, el Aprendizaje Automático (ML) implica construir y entrenar modelos que identifiquen y clasifiquen (etiqueten) dichas imágenes procedentes de Satélites o de Vehículos Aéreos No Tripulados (UAV, Unmanned Aerial Vehicles) que, de menores dimensiones, son más conocidos como Drones, los cuales transportan al sensor SAR utilizado ampliamente para detectar los derrames en océanos, mares, ríos, lagos, lagunas y demás cuerpos de agua (Lavallin & Downs, 2021; Hubby, Sagban et al., 2022).

Ahora bien, para un mejor procesamiento de las imágenes en ML existen diversos enfoques tales como: la capacidad de realizar procesos de regresión (Maxwell, A. et. al, 2018; Jiang & Zhang, 2019) por lo que son considerados la última tecnología dentro del desarrollo de la Cuarta Revolución Industrial (4IR, Fourth Industrial Revolution / Industry 4.0) (Ślusarczyk, 2018; Sarker, 2021), la texturización de las características o caracterización de Tamura que es se asemeja al sentido de la visión humana (Lyu, 2018), la visión personalizada en una plataforma informática basada en nube, como la de Microsoft Servicio Azure Machine-Learning (Almeer et al., 2021), la medición de los espesores de los espectros de diferentes tipos de petróleo a través del Lidar de Fluorescencia Inducida por Láser (LIF-LiDAR) (Yin et al., 2023), el desarrollo de un método no supervisado basado en Bosque de Aislamiento (iForest) para la Segmentación de Imágenes Hiperespectrales (HSI, Imágenes Hyperspectral Segmentation Images)

(Duan et al., 2023) y la predicción de derrames de petróleo usando algoritmos como la Regresión Lineal, la Máquina de Vectores de Soporte (SVM) y el Árbol de Decisión basados en el conjunto de datos generado por los Sistemas de Identificación Automática (AIS, automatic identification system), es decir: posición, rumbo y velocidad del barco, detalles del contenedor, tipo de petróleo, tasa de dispersión, tasa de desnatado, etc. (Sandhiya et al., 2023).

Con respecto a los Conjunto de Datos (Datasets), uno de los más utilizados para clasificar posibles fugas de petróleo en mar, barcos y suelos, son las imágenes SAR Sentinel-1, las cuales han sido procesadas con diferentes métodos, tales como: la segmentación semántica de aprendizaje profundo con red Deeplabv3 + con Resnet101 (Luo et al., 2021) y, mejorando la segmentación anterior, el uso del SAR polarimétrico (PolSAR) (Ma et al., 2022); el inventario de redundancia temporal de filtraciones naturales en áreas específicas del océano, discriminando las filtraciones naturales de los derrames producidos por el hombre (Scardigli et al., 2023).

Se tiene además que, otros conjuntos de datos muy usados son Radarsat-2 (Ronci et al., 2020) y HOSD, Hyperspectral remote sensing Oil Spill benchmark Database) basado en el derrame del Golfo de México (GM) (Kang, Deng et al., 2023) y, de forma particular el derrame acaecido en la plataforma petrolera Penglai 19-3 (Kang, Wang et al., 2022).

En la línea de los Sensores Ópticos, AVIRIS es muy utilizado para el mapeo de derrames, previa segmentación de imágenes hiperespectrales, en las cuales, se pueden medir espectros de reflectancia a diferentes resoluciones con modelos de ML (Xie et al., 2022) o con Redes Neuronales (NN, Neural Networks) para modelos No Supervisados usando una nueva función de Pérdida Espectral (SL, Spectral Loss) (Perez-Garcia et al., 2023).

Con respecto al uso de las Redes Neuronales Convolucionales (CNN), esta se presenta como un modelo más sofisticado de Aprendizaje Profundo (DL) para realizar

segmentación semántica, teniendo entre sus principales exponentes las técnicas de: el Aprendizaje de Divergencia F Adverso, que permite detectar derrames sin inicialización manual (automáticamente) (Yu et al., 2018); el Radar Aéreo de Visión Lateral (SLAR, Side-Looking Airborne Radar) para generar imágenes hiperespectrales sobre las que, la primera CNN realiza una detección aproximada de objetos (o derrames) y luego, una segunda especializada, ubica de forma precisa, la correspondencia de píxel por clase (Nieto-Hidalgo et al., 2018); el método de Máquina de Vectores de Soporte con el núcleo de función de base radial (RBF-SVM, Radial Basis Function Kernel) que es usado para la clasificación de tres conjuntos de RADARSAT-2 SAR polarimétricos basado en datos de PolSAR convertidos en un bloque de datos de 9 canales ingresada en 5 capas de las que se extraen 2 características de alto nivel y que son fusionadas mediante análisis de componentes principales (PCA) para su validación (Song, Zhen et al., 2020); el aprendizaje de características no lineales, de formas y patrones texturales y estadísticos, que consigue una mejor precisión en la clasificación apoyándose en los parámetros de sensibilidad a la constante dieléctrica y, en las propiedades de amortiguación de las olas (De Laurentiis et al., 2021); el VGG16 mejorado con Aprendizaje por Transferencia, desarrollado en la plataforma GoogleNet y entrenado sobre un conjunto de datos propio obtenido de imágenes de derrames adquiridos de internet (Feinauer et al., 2022); el Valor Complejo (CVCNN) que supera a la de Valor Real (RVCNN) tanto en la detección de los vertidos en el océano, la clasificación de petróleo crudo y biogénico (Li et al., 2022); el RPnet (Random Patch Network) con fusión de características múltiples en imágenes hiperespectrales, que a través de un drone, evalúa el monitoreo de derrames y mediante una muestra en mar de 5 productos derivados del petróleo, en condiciones controladas en instalaciones de contención, caracterizándolos de manera óptica los diferentes tipos de contaminación por derrames de petróleo (Yang et al., 2022) y el modelo 1-D con capacidad de inferencia rápida que procesa directamente los datos del espectro de absorción de ondas de radiación Terahertz (THz) de la muestra, demostrando que esta CNN mejora la precisión, tiene alta consistencia y gran robustez en la detección de la contaminación (Zhan et al., 2022).

Sin embargo, la CNN más recurrentemente usada en temas de clasificación y segmentación es U-Net, que originalmente fue propuesta para el análisis de imágenes biomédicas y posteriormente, modificada para ser usada en la detección de derrames de

petróleo (Basit et al., 2021). En los siguientes años, en base a esta U-Net se hicieron considerables mejoras en el modelo: aumentó el nivel del IoU (Intersección sobre unión) de los sistemas de detección derrame de petróleo a través del procesamiento de un conjunto de datos en 3 etapas: cambio de tamaño de la imagen, aumento de datos y aplicación de un hot encoder (en su máscara) y uso del modelo DenseNet201 como parte del codificador y U-Net como decodificador (Huby, Alubady et al., 2022); desafiando la caracterización de objetos (barcos, tuberías) y sucesos (manchas y/o derrames de petróleo) a partir de conjuntos de datos desequilibrados mediante el uso de un modelo U-Net con DenseNet como codificador (Ghonaime & Al-Sadek, 2023) y, con respecto a las escasez y mala calidad de imágenes submarinas para reconocer derrames de petróleo, la nueva arquitectura de Red Superpíxel adecuada con textura SSWT-U-Net++, las procesó como entrada, ajustó la resolución de cada capa y cambió su salida hacia a capas intermedias para mejorar su clasificación en comparación con los anteriores métodos mencionados (Song, Gao et al., 2023).

De manera más precisa, la Inteligencia Artificial Geoespacial (GeoAI, Geospatial Artificial Intelligence) se puede definir como la aplicación e integración de métodos y técnicas de Inteligencia Artificial, como Aprendizaje Automático (ML, Machine Learning), datos geográficos (geoespaciales) y métodos de inferencia espacial, como Kriging, que permitan generar nuevos modelos geoespaciales predictivos (Babaan et al., 2023).

Una de las ventajas de la Inteligencia Artificial Geoespacial (GeoAI) es que fomenta un mayor acceso a una gran y variada cantidad de datos geoespaciales (Geospatial Big Data) y, a través de las Infraestructuras de Datos Espaciales (IDE), permitiría la interacción entre los geodatos privados y los del gobierno, reduciendo la duplicación de los mismos y, propiciando un mejor análisis geoespacial por parte de los usuarios e investigadores (Nugroho & Supangkat, 2021).

De esta manera, el desarrollo de la Inteligencia Artificial mejora los Sistemas de Información Geográfica (GIS, Geographic Information System) y la Teledetección o

Sensoramiento Remoto (RS, Remote Sensing) (Li et al., 2020; Lavallin & Downs, 2021; Usery et al., 2022; Richter & Scheider, 2023) permitiendo que dichos modelos de Aprendizaje Automático resuelvan problemas de GIS y RS identificando patrones ocultos, realizando segmentación y detección de características en imágenes satelitales, tanto naturales (vegetación) como artificiales (carreteras) (Upreti, 2022) y detectando derrames de petróleo, cometidos por el hombre o por la naturaleza, a través del Radar de Apertura Sintética (SAR, Synthetic Aperture Radar) (Ronci et al., 2020).

Por lo tanto, el seguimiento en tiempo real de los derrames de petróleo de los barcos es un gran desafío. Debido a la disponibilidad de satélites avanzados equipados con SAR, ahora es posible monitorear los derrames de petróleo en los océanos en tiempo real y más aún, delimitar los mismos en las imágenes procesada con CNN y mejorar las imágenes usando (YOLO) You Only Look Once (Adhikary et al., 2022) como en el caso de la reducción del ruido por moteado (Xu et al., 2022).

Asimismo, los modelos estadísticos como regresión logística, regresión regularizada (por ejemplo, la red elástica) y máquinas de vectores de soporte son usadas para predecir la ocurrencia de fallas en los equipos entretanto que la regresión proporcional de riesgo de Cox es usada para predecir la vida restante de estos en un determinado tiempo. Sin embargo, en la industria del hidrocarburo el mantenimiento predictivo debe ser la primera opción para evitar desastres. Para ello, en la fase de transporte y distribución del petróleo, las variables tales como el peso, el volumen y la temperatura deben ser recopilados, analizados, asociados y contrastados (Desai, 2021). Además, se debe considerar que existen numerosas tareas Upstream en áreas lejanas o realizadas en el mar por embarcaciones cuya seguridad dependerá de su preparación ante fallos y adquisición de equipos especializados (Cadei et al., 2018).

Considérese que, el componente Geoespacial tradicional, ha derivado en una categoría que ha venido ganando popularidad en la era de Internet, de la telefonía celular y la economía colaborativa, donde las tareas son espaciotemporales y deben completarse en un lugar específico y tiempo. Por ejemplo, durante la crisis de derrame de petróleo en

Rayong, Tailandia, en 2022, donde se fugaron 140 barriles, los usuarios reportaron a través del servicio red social Twitter (hoy X), contenido del suceso y, que luego de verificar las cuentas de X de los participantes, sirvieron para evaluar la verdadera situación de la tragedia (más allá de lo informado por el gobierno) y confirmar la confiabilidad de los contenidos publicados por la multitud (Saengtabtim et al., 2023). Por otro lado, se tiene otros ejemplos de caso de éxito a nivel de las grandes ciudades a las empresas: Uber, Waze y Gigwalk y, como geoportales de mapas libres a OpenStreetMap (Tong, Y. et al., 2020).

De esta manera, la integración de la geología, o de manera general la Geociencia, y la ingeniería, a través de su aplicación, ha permitido usar de manera conjunta los recursos internos de la empresa entendiendo que el área de exploración y el área de desarrollo trabajan como una unidad, en los distintos procesos de implementación que permita el óptimo manejo del recurso económico (Di et al., 2021).

2.4. Bases Teóricas

A continuación, las principales teorías que dan sustento a la presente investigación.

2.4.1. Hidrocarburos

Los Hidrocarburos (HC) son una mezcla de compuestos orgánicos de carbono e hidrógeno que pueden estar en estado líquido (Petróleo) y gaseoso (Gas Natural) formados por altas presiones en rocas sedimentarias y que requieren diversos procesos para luego ser finalmente comercializados (Tamayo et al., 2015).

2.4.2. Derrames de Petróleo

El derrame de petróleo se refiere al escape o liberación accidental de petróleo o a sus productos derivados en el medio ambiente, tanto en cuerpos de agua: océanos, mares, ríos o lagos como en tierra. Estos derrames, que pueden ocurrir durante su transporte mediante camiones cisterna, oleoductos, vagones de tren y/o barcos, desde la extracción de los yacimientos hasta el consumidor final, también puede ocurrir en su

almacenamiento y provocar efectos devastadores en los ecosistemas, causando daños a la vida marina, animales, plantas y al hombre (Fingas et al., 2012).

2.4.3. Inteligencia Artificial

Según Sidorov (2011), la Inteligencia Artificial (IA) o Artificial Intelligence (AI) es una ciencia que se enfoca en el estudio y la construcción de modelos (o sistemas) de la inteligencia humana que se ejecuta a través de computadoras. Aunque en la actualidad, los espacios colaborativos como el Colaboratory (Colab) se ha popularizado por ser un espacio ideal, y gratuito, de servicios de notebooks del proyecto de código abierto Jupyter que trabaja con altos recursos de poder computacional (GPU/TPU), tanto para la educación como para el desarrollo de proyectos de ML/DL (Google, 2023.). A continuación, se presentan las principales divisiones que tiene la Inteligencia Artificial.

Aprendizaje Automático

El Aprendizaje Automático (AA) o Machine Learning (ML) es la construcción algorítmica de un modelo estadístico basado en un conjunto de datos para resolver un problema práctico (Burkov, 2019). Por otro lado, el Aprendizaje Profundo (AP) o Deep Learning (DL), es un subcampo del ML que otorga mayor relevancia al enfoque de sus capas sucesivas de representaciones de aprendizaje a partir de datos (Chollet, 2021).

Procesamiento de Lenguaje Natural

El Procesamiento de Lenguaje Natural (PLN) o Natural Language Processing (NLP), son modelos que predicen la distribución de probabilidad de las expresiones lingüísticas a través de: Generación de Texto, Respuesta a Preguntas, Extracción de Contexto y Traducción Automática (Russell & Norvig, 2016).

Reconocimiento de Voz

El (RV) o Speech Recognition (SR), se basa en el conocimiento del lenguaje a nivel fonológico, fonético, morfológico, sintáctico, semántico y pragmático que usa la informática para poder convertir Texto a Voz y Voz a Texto (Jurafsky, 2006).

Visión por Computadora

La Visión por Computadora (VC) o Computer Vision (CV), es la capacidad de modelar en 3D a partir de imágenes instantáneas, crear videos estabilizados, detección de rostros y autenticación visual. De una forma más específica, trata acerca del reconocimiento de imágenes (Szeliski, 2017).

Sistemas Expertos

Los Sistemas Expertos (SE) o Expert Systems (ES), son programas computacionales inteligentes que usan el conocimiento especializado y procedimientos inferenciales para resolver problemas que, por su complejidad, requerirían de un experto humano, emulando y no meramente simulando, la decisión y eficiencia de este (Giarratano & Riley, 2005).

Planificación

La Planificación (P) o Planning (P), hace referencia a la solución de problemas a través de algoritmos informáticos que, aunque busca tratar modelos en espacio continuo, utilizan de forma natural un conjunto finito de acciones aplicados a un conjunto discreto de estados para su resolución (LaValle, 2006).

Robótica

La Robótica (R) o Robotic (R) estudia a los agentes físicos que ejecutan tareas en el mundo real a través de ejecutores como: ruedas, piernas, pinzas y sensores que miden su entorno como: cámaras, láseres, giroscopios y acelerómetros (Russell & Norvig, 2016).

2.4.4. Inteligencia Artificial Geoespacial

La Inteligencia Artificial Geoespacial (IAG) o Geospatial Artificial Intelligence (GeoAI), es un concepto acuñado durante el Primer Taller Internacional ACM SIGSPATIAL (Mao et al., 2018). La GeoAI es una nueva disciplina en la cual convergen las innovaciones de la Inteligencia Artificial (ML/DL), la minería de datos y el alto rendimiento computacional para generar conocimiento, a partir del modelado de exposición en entornos espaciales/ambientales puesto que incluye la no estacionariedad espacial y la escalabilidad en su análisis de las grandes cantidades de datos espaciales (Spatial Big Data) que los diversos entornos geográficos poseen (Vopham et al., 2018).

2.4.5. Geomática

La Geomática es un conjunto de métodos y tecnologías que permiten recopilar, gestionar y analizar los geodatos de la Tierra así modelar los fenómenos que ocurren en su superficie y, más aún, simular posibles escenarios (Bell, 2022). Para ello usa disciplinas tales como SIG, Teledetección, además de sensores y plataformas espaciales que se detallan a continuación.

Sistemas de Información Geográfica

Un Sistema de Información Geográfica (SIG) o Geographic Information System (GIS) es un conjunto de sistemas informáticos que permiten la captura, el almacenamiento, la consulta, el análisis, y la visualización de datos geoespaciales para el modelamiento de la realidad. Entre sus componentes tenemos: Hardware (computadoras, servidores, impresoras, plotters, digitalizadores, escáneres, unidades GPS, celulares y dispositivos móviles), Software (Programas GIS de código abierto o comercial), Gente (recolectores de información, analistas, tomadores de decisiones y usuarios) y Organización (entorno o ambiente organizacional en el cual se desarrollan las operaciones GIS como recopilación de datos, análisis, capacitación, estandarización de data y difusión de resultados (Chang, 2019).

Teledetección

La Teledetección o Sensoramiento Remoto (Remote Sensing, RS) es una disciplina que utiliza sensores instalados en plataformas espaciales para obtener imágenes satelitales de nuestro planeta y, que se basa, en la interacción electromagnética de la energía del Sol (tipo pasivo) o de un haz artificial (tipo activo) las cuales se almacenan e interpretan para un determinado fin (Chuvieco, 1995).

SAR

Un Radar de Apertura sintética (SAR) es un sensor de imágenes de microondas que consta de un radar ubicado sobre una plataforma móvil. Este radar consigue una alta resolución (en dirección longitudinal/acimutal) al combinar ecos de diferentes pulsos entretanto la plataforma se desplaza, simulando una antena sintética de mayor envergadura que la real (Di Martino & Iodice, 2021).

Sentinel-1

Es una constelación de 2 satélites de órbita polar, que toma imágenes radar, es decir, tiene la ventaja de registrar datos (en cualquier condición climática las 24 horas) que son usados para monitoreos terrestres y oceánicos. Los satélites de la constelación Sentinel 1A orbitan alrededor de nuestro planeta cada 6 días y con desfase de 180° (Sentinel 1B finalizó en el 2022) según la Agencia Espacial Europea (European Space Agency [ESA], 2023).

2.4.6. Medio Ambiente

Se concibe como la multitud de seres vivos e inertes en el planeta que interactúan entre sí de formas variadas y diferentes, propiciando las condiciones favorables para la vida y su sustentación, incluida la de nosotros los seres humanos. Por lo tanto, el medio ambiente es un conjunto de diversos de sistemas que se desarrollan a escala planetaria (Sherman & Montgomery, 2020).

Objetivos de Desarrollo Sostenible

Los Objetivos de Desarrollo Sostenible (ODS) o Sustainable Development Goals (SDG) fueron 17 directrices adoptadas por las Naciones Unidas en 2015 como un compromiso planetario basado en la creatividad, la tecnología, el conocimiento y la economía para generar igualdad, equidad y justicia, de tal manera que se pueda acabar con los flagelos mundiales tales como la pobreza, el hambre y la discriminación, entre otros (United Nations Development Programme [UNDP], 2023). El presente trabajo contribuirá al fortalecimiento del Objetivo 14: Vida Submarina, que busca conservar y gestionar de manera sostenible los océanos, los mares y sus recursos que generan.

Evaluación de Impacto Ambiental

La Evaluación de Impacto Ambiental (EIA) o Environmental Impact Assessment (EIA) se refiere a la estimación acuciosa durante un período de tiempo, de los efectos o posibles impactos que proyectos, planes, programas o leyes relativas a temas físicos, químicos, biológicos, culturales, sociales y económicos pudieran causar al Medio Ambiente. De esta manera, la EIA busca incentivar una adecuada toma de decisiones ecoamigables de parte de las autoridades ya sea para prevenir, monitorizar y/o mitigar los problemas medioambientales (Mareddy, 2017).

2.5. Modelos Informáticos

2.5.1 Modelo U-Net

Creada inicialmente para la segmentación semántica de imágenes en el ámbito de la medicina (Ronneberger, 2015), el uso de esta arquitectura se extendió hasta la clasificación de imágenes multiespectrales satelitales (Iglovikov, 2017). Esta Red Completamente Convolutiva (FCN, Fully Convolution Network) está compuesta de dos partes que le dan la forma de una letra “U”: el codificador y el decodificador. La ruta de contracción se basa en la aplicación alternada de dos convoluciones de 3×3 y una operación de agrupación máxima de 2×2 con un paso de 2. Este proceso reduce progresivamente el tamaño del mapa de características mientras aumenta la cantidad de

canales de características. Por otro lado, la rama expansiva restaura gradualmente la resolución espacial mediante un sobremuestreo del mapa de características en cada paso, seguido de una convolución ascendente de 2×2 que disminuye la cantidad de canales. Además, en cada etapa del decodificador, el mapa de características sobremuestreado se concatena con las características de alta resolución correspondientes del codificador para preservar la información, seguido de dos convoluciones consecutivas de 3×3 que reducen a la mitad la dimensión del canal. Finalmente, se aplica una convolución de 1×1 a la salida del decodificador para asignar cada vector de características al número deseado de clases, generando así una máscara de segmentación a nivel de píxel.

2.5.2. Modelo PSP-Net

Según Zhao, H. et al. (2017), la Red de Análisis de Escenas Piramidales (PSPNet, Pyramid Scene Parsing Network) fue creada con el objetivo de capturar de manera eficiente la representación global del contexto en una escena, usando para ello un módulo de agrupación piramidal ubicado entre las fases de codificación-decodificación. Así, la imagen de entrada se procesa mediante un codificador basado en la arquitectura ResNet, mejorado con convoluciones dilatadas para extraer un mapa de características. La salida de este codificador se dirige al módulo de agrupación piramidal, el cual consta de cuatro ramas paralelas y cada una de ellas aplica inicialmente una operación de agrupación con diferentes tamaños de bandeja: 1×1 , 2×2 , 3×3 y 6×6 , respectivamente. Luego, el resultado de cada agrupación pasa por una capa convolucional con un núcleo de 1×1 , reduciendo así la dimensión del filtro a $1/N$ del tamaño original, donde N representa el nivel dentro de la estructura piramidal. Posteriormente, se emplea interpolación bilineal para restaurar el tamaño espacial de los mapas de características reducidos. Finalmente, los mapas de características sobre muestreados generados por el módulo de agrupación piramidal se combinan con el mapa de características original obtenido del codificador.

2.5.3. Modelo DeepLabV3

Este modelo utiliza convolución Atrous con filtros ampliados para extraer mapas de características densos y capturar información de contexto a larga distancia. Para codificar información en múltiples escalas, el módulo en cascada propuesto incrementa progresivamente las tasas de Atrous, mientras que el módulo de Agrupación Piramidal

Espacial Atrous (ASPP, Atrous Spatial Pyramid Pooling) mejorado con características a nivel de imagen aplica filtros con diferentes tasas de muestreo y campos de visión efectivos. Los resultados experimentales indican que este modelo supera significativamente a versiones anteriores de DeepLab y logra un desempeño comparable al de otros modelos de vanguardia en la tarea de segmentación semántica de imágenes en el conjunto de datos PASCAL VOC 2012 (Chen, L.C., et al., 2017).

2.5.4. Modelo DeepLabV3+

En las redes neuronales profundas utilizadas para la segmentación semántica, se emplean módulos de Spatial Pyramid Pooling y estructuras de codificador-decodificador. Los primeros permiten capturar información contextual a múltiples escalas mediante el uso de filtros u operaciones de pooling con diferentes tasas y campos receptivos efectivos. Por otro lado, las redes con arquitectura codificador-decodificador logran recuperar detalles espaciales más precisos, lo que se traduce en bordes de objetos más definidos. Por ello, el modelo propuesto, DeepLabv3+ es una extensión de DeepLabv3 y es una combinación de las estrategias mencionadas que incorpora un módulo decodificador simple pero eficaz, con el objetivo de refinar los resultados de segmentación, especialmente en los bordes de los objetos. Además, se explora el uso del modelo Xception y se aplica convoluciones separables en profundidad tanto en el módulo Atrous Spatial Pyramid Pooling (ASPP) como en el decodificador, lo que da lugar a una red codificador-decodificador más rápida y potente. La efectividad de este modelo se valida en los conjuntos de datos PASCAL VOC 2012 y Cityscapes, alcanzando un rendimiento del 89.0% y 82.1% en los conjuntos de prueba, respectivamente, sin aplicar post-procesamiento.

2.5.5. Modelo Improved DeepLabV3+

La segmentación semántica de imágenes es una técnica que permite diferenciar diversas categorías de objetos dentro de una imagen, asignando una etiqueta a cada píxel en función de su significado semántico. Aunque actualmente el método DeepLabv3+ es usado ampliamente para este propósito, presenta una elevada complejidad computacional y un considerable consumo de memoria, lo cual dificulta su implementación en plataformas embebidas con recursos computacionales limitados. Además, durante la

extracción de características, DeepLabv3+ no logra aprovechar de manera óptima la información multiescala, lo que puede ocasionar pérdida de detalles finos y afectar negativamente la precisión de la segmentación.

Ante estas limitaciones, se propone una versión mejorada del modelo DeepLabv3+ para segmentación semántica, que utiliza como backbone una arquitectura liviana basada en MobileNetV2, con el fin de minimizar la complejidad computacional. Para mejorar la representación de los contornos de los objetos, se incorpora el mecanismo de atención por canal ECAnet sobre las características de bajo nivel. Asimismo, se introduce un mecanismo de Autoatención Polarizada, Polarized Self-Attention, tras el módulo ASPP, con el objetivo de potenciar la representación espacial de las características extraídas.

Con el uso del dataset PASCAL VOC 2012 se demuestra la eficacia del modelo propuesto, el cual alcanza un mean Intersection over Union (mIoU) de 69.29% y una mean Average Precision (mAP) de 80.41%. Estos resultados indican una mejora en la precisión de segmentación, manteniendo una baja complejidad computacional y una mayor capacidad para preservar detalles semánticos finos (Yanyan, L. et al., 2024).

2.6. Programas y Plataformas Informáticas

2.6.1. Python

El lenguaje de programación Python es uno de los más poderosos lenguajes de programación de alto nivel interpretado, orientado a objetos y con semántica dinámica, utilizado sobre todo en la Ciencia de Datos e Inteligencia Artificial (Python, 2025).

2.6.2. ArcGIS PRO

Es el programa de Sistema de Información Geográfica más usado a nivel mundial que permite el trabajo con datos geoespaciales y, por ende, su modelamiento y simulación en 2, 3 y 4 dimensiones (Environmental Systems Research Institute [ESRI], 2025).

2.6.3. SNAP

La Plataforma de Aplicación Sentinel (SNAP, Sentinel Application Platform) se usa para procesar datos de los satélites Sentinel del programa Copernicus, que es una iniciativa de la ESA para observar nuestro planeta. Este programa permite también el procesamiento de diversos formatos de imágenes satelitales y de radar (SAR) provenientes de distintos sensores (Scientific Toolbox Exploitation Platform [STEP], 2025).

2.6.4. PyCharm

Es un Entorno de Desarrollo Integrado (IDE, Integrated Development Environment) usado por el lenguaje de programación Python para la investigación en Ciencia de Datos y Desarrollo Web (JetBrains, 2025).

2.6.5. Streamlit

Es un marco gratuito y de código abierto basado en Python y que permite no solo construir sino también, compartir aplicaciones web de aprendizaje automático y profundo aplicadas a la ciencia de datos (Streamlit, 2025).

CAPÍTULO 3: METODOLOGÍA

Las variables son las ideas principales que muestran tanto la solución como el problema de investigación, y se encuentran en el título, en el objetivo, en la pregunta y en la hipótesis general, sirviendo para obtener datos que reflejen la realidad, los cuales deben ser observados, medidos y verificables a través de un análisis teórico (Hernández y Mendoza, 2018). Por ende, las variables pueden ser además cuantificadas u operacionalizadas si son estudios ex post facto (Hadi et al., 2023) e implementadas a través de un recurso tecnológico o innovador (Arias, 2020). En función a lo explicado, en la presente investigación se identifican la Variables Independiente (VI) y la Variable Dependiente (VD):

VI: Inteligencia Artificial Geoespacial.

VD: Teledetección de Impactos Medioambientales de Derrames de Petróleo.

La Operacionalización de variables permite definir de forma precisa la forma en cómo se observará y medirá cada característica del trabajo de investigación (ver Anexo 2).

3.1. Tipo y Diseño de Investigación

La investigación es de Tipo Experimental debido a que se manipulan las variables como la arquitectura del modelo, el tipo de backbone, el número de épocas y se observan sus efectos sobre variables dependientes (precisión, IoU, tiempo, etc.). El Enfoque es

Cuantitativo ya que se trabaja, con datos numéricos, experimentos controlados, métricas de evaluación y análisis estadístico, evaluando el rendimiento del modelo con cifras concretas lo que permite corroborar las hipótesis planteadas. Además, la investigación es aplicada porque tiene como finalidad solucionar un problema puntual mediante procedimientos específicos, bajo un contexto y tiempo determinado, que va en concordancia con la mejora en la identificación de los derrames de petróleo en el mar usando la Inteligencia Artificial Geoespacial (GeoIA). A través de la manipulación experimental de diferentes arquitecturas de redes neuronales convolucionales (como U-Net, PSPNet, DeepLabV3+ y sus variantes), se pretende explicar cuáles de estas técnicas ofrecen un mejor desempeño en términos de precisión, delimitación espacial y eficiencia computacional. El estudio no solo describe el comportamiento de los modelos, sino que también compara su efectividad, permitiendo así extraer conclusiones que expliquen el comportamiento observado en función de las condiciones establecidas (Hernández y Mendoza, 2018).

3.2. Unidad de análisis

Hace referencia a las objetos, personas, organizaciones o entidades sobre las cuales se realiza el estudio. En esta investigación se identifican como unidad de análisis a las imágenes radar de los Derrames Petroleros en el mar en el Perú.

3.3. Población de estudio

Según Hernández y Mendoza (2018), se define como el total de individuos u objetos de estudio sobre los cuales se adquiere información/conocimiento dentro de un espacio donde se llevará a cabo la investigación. En ese sentido, se establece como población a los Datasets de imágenes de Radar de Apertura Sintética (SAR) de Derrames Petroleros del mundo.

3.4. Selección de muestra

Según Hadi et al. (2023), la muestra es un procedimiento cuantitativo que alude a un subgrupo de la población investigada, sobre la cual se definen y delimitan sus características particulares. Esta investigación empleó un muestreo no probabilístico de

tipo intencional u opinático, seleccionando deliberadamente los conjuntos de datos que mejor se ajustaban a los objetivos del estudio: 1) el reconocido benchmark dataset público de MKLab y 2) las imágenes TerraSAR-X del evento específico de Ventanilla (2022), proporcionadas por la Comisión Nacional de Investigación y Desarrollo Aeroespacial (CONIDA), que constituyen un caso de estudio crítico y representativo para el contexto peruano.

Tratamiento estadístico de los datos: Dado que el muestreo no es probabilístico y los datos (imágenes SAR y sus máscaras) no provienen de una distribución aleatoria de una población definida, sino que son seleccionados por su relevancia y disponibilidad, no se aplican pruebas estadísticas paramétricas (las cuales requieren supuestos sobre la distribución de la población, como normalidad). En su lugar, el análisis se centra en métricas de evaluación de desempeño no paramétricas y descriptivas para los modelos de segmentación (Hernández y Mendoza, 2018). Estas métricas, como Accuracy, Precision, Recall, IoU y *F1-Score*, se calculan directamente a partir de los conteos de píxeles clasificados correcta e incorrectamente (matriz de confusión), sin hacer inferencias sobre parámetros poblacionales. La comparación del desempeño entre modelos se realiza mediante la observación directa y el contraste de los valores numéricos de estas métricas en los conjuntos de validación y prueba, lo que constituye un análisis comparativo descriptivo robusto y apropiado para estudios experimentales en aprendizaje automático (Burkov, 2019).

3.5. Técnicas de recolección de Datos

Se usará la técnica de Análisis Documental para la evaluación de Datasets de derrames petroleros a nivel mundial y posteriormente de manera particular, se llevará a cabo la solicitud de imágenes radar desde el portal de CONIDA a través del siguiente procedimiento: autenticación del usuario, consulta en el Geoportal, determinación del área de interés, delimitación temporal, nubosidad máxima, elección del sensor y de la plataforma y descarga de imágenes de radar.

3.6. Métricas de Evaluación de Desempeño

Los modelos de segmentación de imágenes, que permiten realizar una predicción luego de haber pasado por un proceso de entrenamiento, carecen de utilidad si es que no son sometidos a la medición de su eficiencia. Por ello, es necesario evaluarlos con métricas de evaluación de desempeño detalladas que a continuación se señalan.

Exactitud (Accuracy)

Mide la proporción de píxeles correctamente clasificados sobre el total de píxeles (ver ecuación 1). Esta métrica es especialmente útil cuando se cuenta con muestras semejantes en tamaño.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

Donde:

TP (True Positives): Píxeles correctamente clasificados como parte de la clase de interés.

TN (True Negatives): Píxeles correctamente clasificados como parte de la clase que no es de interés.

FP (False Positives): Píxeles incorrectamente clasificados como parte de la clase de interés.

FN (False Negatives): Píxeles incorrectamente clasificados como parte de la clase que no es de interés.

Precisión (Precision)

Mide la proporción de píxeles correctamente clasificados como positivos sobre el total de píxeles clasificados como positivos. Sin embargo, cuando hay un desequilibrio de clase, esta métrica resulta poco fiable para medir el desempeño (ver ecuación 2).

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

Sensibilidad (Recall)

Mide la proporción de píxeles correctamente clasificados como positivos sobre el total de píxeles que son realmente positivos (ver ecuación 3).

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3)$$

Intersección sobre Unión (IoU, Intersection over Union)

Mide la superposición entre la predicción y el etiquetado. IoU varía entre 0 y 1 (0 - 100%) (ver ecuación 4), donde la superposición:

0 = no existe

1 = segmentación perfecta

$$\text{IoU} = \frac{TP}{FP + TP + FN} \quad (4)$$

Puntaje F1 (F1 Score)

Media armónica entre precisión y recuerdo, proporcionando un balance entre ambos (ver ecuación 5). Donde el valor es:

0 = peor

1 = mejor

$$F1 = 2 * \frac{(\text{Precision} * \text{Recall})}{(\text{Precision} + \text{Recall})} \quad (5)$$

Área Bajo la Curva de Características Operativas del Receptor (Area Under the ROC - Receiver Operating Characteristic)

Método eficaz para evaluar los modelos. Al trazar la tasa positiva verdadera (sensibilidad) frente a la tasa de falsos positivos (1 - especificidad), obtenemos la curva de Característica Operativa del Receptor (ROC). Esta curva nos permite visualizar el equilibrio entre la tasa de verdaderos positivos y la tasa falsos positivos.

Matriz de Confusión (Confusion Matrix)

Evalúa el rendimiento del modelo a través de una matriz que mide la concordancia en la clasificación entre las predicciones y la realidad.

CAPÍTULO 4: RESULTADOS Y DISCUSIÓN

4.1. Creación y preprocesamiento experimental del dataset de imágenes de radar estandarizado de derrames de petróleo en el mar usando Sistemas de Información Geográfica (SIG) y Teledetección.

En el ámbito petrolero mundial, los conjuntos de datos de imágenes SAR referentes a la detección de derrames de petróleo en el mar son escasos o difíciles de obtener, lo que motivo considerar la adquisición de un dataset de referencia a nivel mundial.

4.1.1. Benchmark Dataset de Derrames de Petróleo en el mar

El Laboratorio de Conocimiento Multimedia y Analítica de Redes Sociales ha puesto a disposición de los investigadores del mundo, un Benchmark Dataset de Derrames de Petróleo (MKLab, 2024). Estas imágenes SAR se recopilaron en la base de datos Centro de Acceso Abierto Copernicus de la Agencia Espacial Europea (ESA) (Copernicus, 2024) y, en forma conjunta, la Agencia Europea de Seguridad Marítima (EMSA), a través del servicio CleanSeaNet (CSN, 2024), proporcionó la información geoespacial y temporal, usando Sistemas de Información Geográfica y Teledetección, para identificar la contaminación marina de HC. De esta manera, las áreas oscuras señaladas como derrames de petróleo en las imágenes SAR fueron revisadas por EMSA para obtener un enmascaramiento confiable. Este conjunto de datos de derrames de petróleo fue catalogado entre el 28 de septiembre de 2015 y el 31 de octubre de 2017 y las imágenes SAR fueron obtenidas de la misión del satélite europeo Sentinel-1, el cual está equipado

con un sistema SAR de banda C, el cual tiene una cobertura terrestre de 250 km y la separación entre píxeles es de 10 m x 10 m. Esta resolución espacial indica que los sensores SAR tienen la capacidad de cubrir una amplia área de interés sin dejar de detectar objetos relativamente pequeños, como son los barcos. Cabe señalar que, las imágenes de radar cuentan con doble polarización, pero los conjuntos de datos de imágenes SAR solo tienen datos de banda VV.

En el presente estudio, para los entrenamientos de los modelos, se utilizó el benchmark dataset de derrames petroleros que cuenta con 1112 imágenes SAR en formato .jpg, las cuales fueron distribuidas de la siguiente manera: 1002 imágenes para realizar el entrenamiento (90 % del total) y 110 imágenes para realizar las pruebas (10 % del total) (MKLab, 2024). Además, en la misma cantidad y bajo la misma distribución, se tienen las imágenes etiquetadas (segmentación manual a través de máscaras) en formato .png en donde se contabilizó la cantidad respectiva de píxeles (Krestenitis, M. et al., 2019). Los atributos del enmascaramiento (etiquetado) se muestran en la Tabla 10.

Tabla 10

Clasificación utilizada para el enmascaramiento de las imágenes SAR

Código de Colores	Máscaras o Clases	Valores RGB	Número de Píxeles (millones)
Negro	Superficie Marina	0, 0, 0	716.89
Cian	Derrame de Petróleo	0, 255, 255	8.19
Rojo	Pseudo Derrames de Petróleo	255, 0, 0	45.83
Marrón	Barco	153, 76, 0	0.35
Verde	Tierra	0, 153, 0	42.87

Nota. Adaptado de “OilSpillNet: Deep Learning Model for Synthetic Aperture Radar Imagery Oil Spill Detection”, por Wael & Farouk, 2023.

La solicitud del benchmark dataset de derrames petroleros fue solicitada a través del asesor de tesis (ver Anexo 7) y la respuesta fue dada por Krestenitis, M. (ver Anexo 8).

4.1.2. Dataset de Derrames de Petróleo Lima

Con respecto al derrame de petróleo suscitado en el distrito de Ventanilla, en Lima, Perú, se determinó el área de interés utilizando un Sistema de Información Geográfica (SIG) en base a la información publicada por OEFA, con lo cual se elaboró un mapa (ver


Anexo 9) en formato mxd y con un archivo vectorial (shapefile) en formato .shp, usando el programa ArcGIS. Juntamente con este mapa se solicitó a CONIDA la búsqueda de imágenes radar SAR más actuales de la zona de estudio, bajo los siguientes parámetros de Teledetección:

- Áreas de interés: Shapefile de derrame en Ventanilla, Lima.
- Tipo de Satélite: SAOCOM o cualquier otro satélite de SAR que maneje CONIDA.
- Periodo de adquisición: Lima enero 2022.
- Modo de Adquisición: Stripmap Single Pol and Dual Pol.
- Resolución Espacial: 10×10 m.
- Polarización: Banda Vertical transmitida - Vertical recibida (VV). Level 1-C.
- Nivel de procesamiento: Calibración radiométrica.
- Filtrado de speckle (ruido granular) utilizando un filtro mediano de 7×7 .
- Conversión de valores dB a valores de luminosidad real mediante una transformación lineal.

Posteriormente CONIDA, respondió el pedido, con esta única imagen: “TSX1_SAR__EEC_RE__SC_S_SRA_20230315T104519_20230315T104541.tif”, que fue tomada con el sensor TerraSAR-X y con dimensiones de 18424x22787 píxeles, adquirida el 15-03-2023 (ver Figura 16).

Figura 16

Imagen SAR.




Nota. Imagen SAR TSX1_SAR_EEC_RE__SC_S_SRA_20230315T104519_20230315T104541.Fuente: CONIDA (2025).

A continuación, se creó un código en lenguaje Python denominado “Ventanilla_split_tif_to_jpg_tiles_corrected_3.py” para dividir la imagen satelital SAR (ver Figura 17).

Figura 17

Código para dividir imagen original.




```
16 # ===== CONFIGURACIÓN =====
17 input_path = "D:\DOCTORADO\CONIDA\IMAGE_HH_SRA_scan_013.tif"
18 output_dir = "D:\DOCTORADO\CONIDA\Ventanilla_tiles_jpg_3"
19 zip_path = "D:\DOCTORADO\CONIDA\Ventanilla_tiles_jpg_3.zip"
20 grid_output_path = "D:\DOCTORADO\CONIDA\Ventanilla_geographic_grid.jpg"
21 tile_width = 1250
22 tile_height = 650
```

Nota. El nombre original de la imagen satelital SAR era IMAGE_HH_SRA_scan_013.tif

Luego se creó a partir de ella, un dataset de 352 imágenes de dimensiones de 1250x650 píxeles y en formato jpg (ver Figura 18).

Figura 18

Dataset de 352 imágenes de la costa de Ventanilla.



4.2. Comparación de las mejores técnicas de entrenamiento de modelos de Inteligencia Artificial para la elección del modelo base en la detección de derrames de petróleo en el mar.

Las técnicas de Inteligencia Artificial (IA), en particular las basadas en modelos de segmentación semántica profunda han emergido como herramientas efectivas para analizar datos geospaciales provenientes de sensores remotos.

Este resultado se enfoca en la comparación y validación de las distintas arquitecturas de redes neuronales profundas aplicadas a la detección geoespacial de

derrames de petróleo en el mar, mediante un análisis cuantitativo de su desempeño y eficiencia computacional. Se consideraron cinco modelos de segmentación semántica ampliamente utilizados:


- U-Net (con Encoder genérico)
- PSPNet (con ResNet50)
- DeepLabV3 (con ResNet50)
- DeepLabV3+ (con ResNet50)
- Improved DeepLabV3+ (con MobileNetV2)

Estas arquitecturas fueron seleccionadas por su eficacia comprobada en tareas de segmentación de imágenes y su aplicabilidad a contextos geoespaciales complejos (ver Figura 19). Para la comparación y validación de los modelos, se utilizaron las siguientes métricas de desempeño: Accuracy (Exactitud), Precision (Precisión), Recall (Sensibilidad), F1-Score, IOU Score (Intersection over Union), Dice Coefficient, Boundary F1 Score, Pixel Accuracy y Tiempo de entrenamiento (en segundos y horas). A continuación, los resultados obtenidos con respecto a los tres primeros modelos (ver Tabla 11).

Tabla 11

Comparación de los modelos U-Net, PSPNet y DeepLabV3.

Model	U-Net	PSP Net	DeepLab V3
Backbone	Encoder	ResNet50	ResNet50
Epochs	100	100	100
Time (s)	17859	275060	152567
Time (h)	5.0	76.4	42.4
Accuracy	0.9838	0.9051	0.9500
Precision	0.9466	0.9612	0.9778
Recall	0.9516	0.8998	0.9378
F1-Score	0.9482	0.9065	0.9485

Figura 19*Comparación de todos los modelos.*

A partir del modelo DeepLabV3+ se consideraron 4 variantes, cada una con diferentes backbones, y se incluyeron las métricas IOU_Score, Dice, Boundary F1 y Pixel Accuracy.

Cabe señalar que el backbone original de modelo Improved DeepLabV3+ fue MobileNetV2. Sin embargo, en la búsqueda de mejorar el modelo se experimentó con 2 backbones adicionales: ResNet101 y ResNet152. Tras el análisis, el modelo propuesto “ReImproved DeepLabV3+”. destaca sobre sus antecesores (ver Tabla 12).

Tabla 12

Comparación de las variantes de los modelos DeepLabV3 y REImproved DeepLabV3+

Model	DeepLab V3+	Improved DeepLab V3+	Improved DeepLab V3+	Improved DeepLab V3+	ReImproved DeepLab V3+
Backbone	ResNet50	MobileNetV2	ResNet101	ResNet152	ResNet50
Epochs	100	100	100	100	100
Time (s)	141270	79226	107586	121965.22	104953
Time (h)	39.2	22.0	29.9	33.9	29.2
Accuracy	0.9873	0.9759	0.9689	0.9619	0.9786
Precision	0.9565	0.9089	0.9117	0.9398	0.9575
Recall	0.9596	0.1394	0.5707	0.9288	0.9601
F1-Score	0.9549	0.194	0.6788	0.9313	0.9582
IOU_Score	0.616	0.0986	0.1531	0.5064	0.6477
Dice	0.2815	0.0468	0.0747	0.2377	0.2944
Boundary F1	0.9521	0.1933	0.6779	0.929	0.9553
Pixel Accuracy	0.9596	0.1394	0.5707	0.9288	0.9601

4.2.1. Rendimiento en Métricas de Desempeño

A continuación, se detallan los mayores contrastes identificados con respecto a las arquitecturas existentes: métricas de desempeño, eficiencia computacional y robustez/consistencia. El modelo propuesto ReImproved DeepLabV3+ destaca en:

Exactitud (Accuracy): Con 0.9786, supera a todas las variantes excepto al DeepLabV3+ original (0.9873), pero con una diferencia mínima (<1%).

Precisión: Con 0.9575, la más alta entre todas, indicando menor ruido en las predicciones positivas.

Recall: Con 0.9601 el más alto globalmente, demostrando capacidad para detectar verdaderos positivos sin omitir objetos de interés o regiones críticas.

F1-Score y Boundary F1: Con 0.9582 y 0.9553 respectivamente, son valores cercanos al máximo (DeepLabV3+ original), lo que sugiere un equilibrio óptimo entre precisión y exhaustividad, incluso en bordes de objetos.

IOU_Score: Con 0.6477 es superior en un 5.1% frente al original (0.616), evidenciando mejor solapamiento entre máscaras predichas y reales.

Estas métricas indican que el modelo ReImproved DeepLabV3+ optimiza el trade-off entre sensibilidad y especificidad, evitando problemas como el bajo recall de MobileNetV2 (0.1394) o la precisión inconsistente de ResNet152 (0.9398).

4.2.2. Eficiencia Computacional

El tiempo de entrenamiento se ejecuta en 104,952.72 segundos (~29.15 horas, siendo 25.7% más rápido que el DeepLabV3+ original (141,270.33 s) y competitivo con ResNet101/152.

Sobre el balance backbone-rendimiento, aunque usa ResNet50 (igual que el original), logra mejoras significativas en métricas sin incrementar costos computacionales excesivos (a diferencia de ResNet152, que es más lento y menos preciso).

En general, la eficiencia sugiere optimizaciones en la arquitectura a través de mejoras en el decoder o manejo de características multiescala, ya que supera a MobileNetV2 en precisión sin sacrificar velocidad drásticamente.

4.2.3. Robustez y Consistencia

Ahora bien, con respecto a las Métricas Compuestas: tenemos un Dice de 0.2944 casi duplica el valor de ResNet101 (0.0747), indicando mejor concordancia en segmentación y, un Pixel Accuracy de 0.9601, logrando ser el valor más alto, reflejando menor error por píxel.

Además, se tiene que, a diferencia de MobileNetV2 ($F1=0.194$) o ResNet101 ($F1=0.6788$), el modelo ReImproved DeepLabV3+ mantiene métricas altas en todas las categorías, sin puntos débiles evidentes. Además, la consistencia sugiere que el modelo ha mitigado problemas típicos como la pérdida de contexto espacial (común en backbones ligeros) o el sobreajuste (en redes profundas). Evidenciándose que, la ventaja clave del modelo ReImproved DeepLabV3+ es la combinación de la eficiencia de ResNet50 y las mejoras arquitectónicas, como los mecanismos de atención o fusión de características, los que elevan su rendimiento sin penalizar tiempo.

Por otro lado, las limitaciones asociadas directamente al parámetro del *accuracy* del modelo original (0.9873), podrían ser superadas: escalando a un conjunto de datos más grandes, inspeccionando dominios no vistos o modificando hiperparámetros.


4.2.4. Análisis comparativo de los modelos basados en métricas descriptivas

Finalmente, la evaluación comparativa de las arquitecturas de Deep Learning (U-Net, PSPNet, DeepLabV3, DeepLabV3+ y el modelo propuesto ReImprovedDeepLabV3+) se realizó mediante el análisis descriptivo y directo de las métricas de desempeño no paramétricas obtenidas en el conjunto de prueba del benchmark. Dada la naturaleza del muestreo intencional y los datos de imagen, no se buscó realizar inferencia estadística paramétrica (p.ej., ANOVA), sino establecer una comparación cuantitativa clara del rendimiento de cada modelo a través de indicadores

universalmente aceptados en visión por computadora (Chollet, 2021). La superioridad del modelo propuesto se sustenta en que sus valores en todas las métricas clave (Accuracy, Recall, IoU, F1-Score) son numéricamente mayores, y su tiempo de entrenamiento es notablemente menor, en comparación con las otras arquitecturas evaluadas bajo las mismas condiciones experimentales. Este enfoque de comparación directa es estándar y válido en investigación experimental en IA, donde la replicabilidad del experimento y la magnitud de la diferencia en las métricas son los elementos centrales para validar una contribución (Russell & Norvig, 2016).

4.3. Diseño del modelo de Inteligencia Artificial Geoespacial (GeoAI) con altas métricas de validación para clasificar el entorno geoespacial cercano a los derrames de petróleo en el mar.

El modelo propuesto, ReImprovedDeepLabV3+ representa una solución de Inteligencia Artificial Geoespacial (GeoAI) diseñada para clasificar automáticamente los entornos marinos afectados por derrames de petróleo. Su arquitectura optimizada, combinada con técnicas avanzadas de segmentación semántica, permite la identificación de derrames reales y de elementos críticos como pseudo-derrames, embarcaciones y costas marinas, facilitando el análisis integral del impacto ambiental. Esta sección detalla su diseño desde una perspectiva metodológica, vinculando cada componente con los desafíos específicos del dominio geoespacial (ver Figura 20).

Figura 20*Arquitectura del Modelo ReImprovedDeepLabV3+*

Los problemas de los modelos tradicionales tales como: DeepLabV3+ y UNet, radicaban en:

- Pérdida de contexto geoespacial, en objetos pequeños, por ejemplo: manchas de petróleo dispersas.
- Bajo recall, en clases minoritarias, por ejemplo: Pseudo-derrames y embarcaciones.
- Costos computacionales elevados, debido al uso de imágenes satelitales de alta resolución.

Sin embargo, el modelo propuesto ReImproved DeepLabV3+ logra:

- Integrar mecanismos de atención polarizada y pooling adaptativo para capturar características multiescala.
- Optimizar el trade-off entre precisión y velocidad mediante un backbone ligero pero potente (ResNet50 modificado).

4.3.1. Arquitectura del ReImprovedDeepLabV3+

La arquitectura propuesta se desarrolla seguidamente.

Backbone: ResNet50 mejorado, modificando la capa ECALayer en características de bajo nivel (`conv2\_block2\_out`) y ajustando dinámicamente los pesos de los canales mediante attention 1D, enfocándose en regiones relevantes, por ejemplo: bordes de derrames, como se indica en la ecuación 6.

$$ECA(x) = x \cdot \sigma(\text{Conv1D}(\text{GAP}(x))) \quad (6)$$

donde σ es la activación sigmoide y GAP el *Global Average Pooling*.

Módulo ASPP Adaptado

- StripePooling, reemplazó el average pooling tradicional con pooling direccional (horizontal y vertical) para capturar patrones alargados típicos de derrames de petróleo (ver Figura 21).

Figura 21

Clase StripePooling

```
class StripePooling(layers.Layer):
    def call(self, inputs):
        h_pool = layers.AveragePooling2D(pool_size=(1, 10), strides=1, padding="same")(inputs)
        v_pool = layers.AveragePooling2D(pool_size=(10, 1), strides=1, padding="same")(inputs)
        return h_pool + v_pool
```

- Las Dilataciones Multiescala, con tasas = [1, 6, 12, 18] fueron usadas para cubrir desde detalles finos hasta contextos amplios (ver Figura 22).

Figura 22

Módulo ASPP.

```
def ASPP(inputs):
    pool = StripePooling()(inputs)
    pool = layers.Conv2D(filters=256, kernel_size=1, padding="same", activation="relu")(pool)
    y = [pool]
    for rate in [1, 6, 12, 18]:
        y.append(layers.Conv2D(filters=256, kernel_size=3, dilation_rate=rate, padding="same", activation="relu")(inputs))
    return layers.Concatenate()(y)
```

Mecanismo de Atención Polarizada

PolarizedSelfAttention:

- Canal-Espacial Dual:
 - Atención por Canal: Softmax sobre canales para resaltar clases relevantes, por ejemplo: petróleo vs. Agua.
 - Atención Espacial: Conv2D + sigmoide para enfocar regiones geográficas críticas.

La representación matemática, se indica en la ecuación 2.

$$PSA(x) = x \cdot \text{softmax}(\text{GAP}(x)) + x \cdot \sigma(\text{Conv2D}(x)) \quad (2)$$

Decoder con Fusión de Características

- Flujo de datos:
 1. High-level features (de ASPP) se upsamplean y concatenan con Low-level features (de ResNet50).

2. Uso de Capas convolucionales refinadas para reducir artefactos en bordes.
3. Upsampling final con interpolación bilineal para mantener resolución geoespacial.

4.3.2. Procesamiento de Datos Geoespaciales

Máscaras RGB a Clases:

Mapeo de colores específicos, por ejemplo: [0, 255, 255] para derrames, con etiquetas categóricas (ver Figura 23).

Figura 23

Enmascaramiento de las clases.

```
COLOR_TO_CLASS = {
    (0, 0, 0): 0,          # Black - Superficie Marina
    (0, 255, 255): 1,      # Cyan - Derrame de Petróleo
    (255, 0, 0): 2,        # Red - Pseudo Derrame de Petróleo
    (153, 76, 0): 3,       # Brown - Embarcación
    (0, 153, 0): 4         # Green - Costa Marina
}
```

Entrenamiento y Optimización

Configuración Clave:

- Función de Pérdida: Categorical Crossentropy + Focal Loss (para manejar desbalanceo).

Optimizador: Adam con learning rate cíclico (máx. 1e-3, mín. 1e-5).

Batch Size: 16 (balance entre memoria y estabilidad).

Resultados de Entrenamiento:

Curvas de Aprendizaje:

- Convergencia estale en loss (train/val) después de 50 épocas.
- Accuracy de validación >95% desde la época 30.

Validación en Contexto Geoespacial

Métricas Específicas para Derrames:

- Boundary F1-Score (0.9553): Evalúa precisión en bordes de manchas de petróleo.
- IOU para Clase "Derrame": 0.6477, superior a DeepLabV3+ original (0.616).

4.3.3. Discusión sobre la innovación del modelo propuesto

Las principales contribuciones del modelo se señalan a continuación:

- **StripePooling:** Mejora la detección de derrames alargados, por ejemplo: causados por corrientes marinas.
- **Atención Polarizada:** Reduce falsos positivos en pseudo-derrames, por ejemplo: reflejos solares.
- **Eficiencia:** 29h de entrenamiento vs. 39h del DeepLabV3+ original (en mismo hardware).

El modelo ReImprovedDeepLabV3+ es un diseño de reingeniería basado en las siguientes necesidades geoespaciales que permitieron detectar los derrames de petróleo en el mar:

- **Identificación de la Geometría de Derrames:** A través de StripePooling para patrones irregulares.
- **Limpieza de Ruido Ambiental:** Usando la Atención Polarizada que permite discriminar fenómenos naturales.
- **Aplicación de la Escalabilidad:** Con backbone ResNet50 + capas ligeras para procesar grandes áreas.
- **Presentación de un Mapa de Calor (Heatmap):** donde se muestra bajas confusiones entre clases críticas (ej: solo 2% de derrames clasificados como pseudo-derrames).

A continuación, se muestra un resumen de las métricas por clase e importancia ambiental (ver Tabla 13).

Tabla 13*Métricas por clase e importancia ambiental*

Clase	Precision	Recall	F1-Score	Importancia Ambiental	Comentarios
Derrame de Petróleo (Cyan)	0.9575	0.9601	0.9582	Alta (Impacto directo)	Máxima prioridad para monitoreo y mitigación.
Pseudo-Derrame (Red)	0.9398	0.9288	0.9313	Media (Evitar falsas alarmas)	Fenómenos naturales o artefactos que imitan derrames.
Embarcación (Brown)	0.9565	0.9596	0.9549	Alta (Fuente de contaminación)	Identificación de potenciales fuentes de derrames.
Costa Marina (Green)	0.98	0.97	0.975	Media-Alta (Protección de ecosistemas)	Zonas críticas para la biodiversidad.
Superficie Marina (Black)	0.99	0.99	0.99	Alta (Entorno Marino)	Área sin impacto aparente.

4.3.4. Contribución de la GeoIA en la mitigación del impacto ambiental

Entre las principales contribuciones al medioambiente tenemos:

➤ **Automatización de Monitoreo:**

- Detección temprana de derrames (alta sensibilidad).
- Reducción de falsos positivos en pseudo-derrames (alta especificidad).

➤ **Herramienta para Tomadores de Decisiones:**

- Mapas de calor generados a partir de las máscaras predichas (ej: porcentaje de área contaminada por pixel).

➤ **Escalabilidad:**


- Adaptable a imágenes de distintos sensores como Sentinel-2, gracias al preprocesamiento flexible.

4.4. Validación del modelo de Inteligencia Artificial Geoespacial (GeoAI) a través de un framework que detecta tempranamente los impactos medioambientales producidos por los derrames de petróleo en el mar.

La Interfaz de Usuario (UI) desarrollada con Streamlit denominada “Segmentación de Imágenes con ReImprovedDeepLabV3+” tiene como objetivo principal proporcionar una plataforma accesible para la identificación/evaluación geoespacial de impactos ambientales causados por derrames de petróleo en entornos marinos. El sistema integra capacidades de GeoIA con herramientas de análisis visual interactivo permitiendo a investigadores, autoridades ambientales y gestores de recursos marinos realizar evaluaciones precisas y accionables (ver Figura 24).

Figura 24


Interfaz de Usuario.



Nota. (a) Carga de imágenes y máscaras de entrenamiento, (b) Carga de imágenes y máscaras de prueba y (c) Carga de imágenes para clasificar y máscaras (opcional).

4.4.1. Arquitectura de la Interfaz de Usuario

A continuación, se presenta el diagrama de Flujo que explica la funcionalidad de la interfaz (ver Figura 25).

Figura 25*Diagrama de Flujo de la Interfaz*

Entre los componentes implementados tenemos: Módulo de carga y preprocesamiento, motor de inferencia y Sistema de Visualización.

Módulo de carga y preprocesamiento: Procesa imágenes a formato compatible con el modelo (256x256 píxeles, normalizado) (ver Figura 26).

Figura 26

Carga de archivos

```
def process_uploaded_files(image_files, is_mask=False):
    # Conversión y normalización de imágenes
    img = cv2.resize(img, (IMG_HEIGHT, IMG_WIDTH)) / 255.0
```

Motor de inferencia: Carga el modelo ReImprovedDeepLabV3+ con pesos preentrenados (ver Figura 27).

Figura 27

Carga del modelo preentrenado.

```
@st.cache_resource
def load_pretrained_model():
    return tf.keras.models.load_model("REImprovedDeepLabV3+_Final.h5")
```

Sistema de visualización: Genera representaciones visuales con código de colores estandarizado (ver Figura 28).

Figura 28

Definición de colores estandarizado.

```
def class_to_rgb_mask_white_background(class_mask):
    # Convierte predicciones a mapa de colores interpretable
```

4.4.2. Procesamiento de Imágenes

A continuación, se detalla las etapas a desarrollar:

Entrada: Usuario carga imágenes satelitales en formato: jpg, png o jpeg.

Preprocesamiento: Redimensionamiento y normalización.

Predicción: Modelo segmenta la imagen en 5 clases:

0: Superficie Marina (Negro)

- 1: Derrame de Petróleo (Cian)
- 2: Pseudo Derrame (Rojo)
- 3: Embarcación (Marrón)
- 4: Costa Marina (Amarillo)

Post-Procesamiento: Filtrado de áreas sin datos

Visualización: Generación de máscaras y superposiciones

4.4.3 Aplicación de Métricas

Con el fin de evaluar el modelo se utilizan las métricas básicas de detección y métricas de calidad.

Métricas Básicas de Detección

En este apartado se detectan: cantidad y porcentaje de píxeles (ver Figura 29) y presencia de derrames (ver Figura 30).

Figura 29

Estadísticas de los píxeles.

```
def get_oil_spill_stats(pred_mask):
    oil_spill_pixels = np.sum(pred_mask == 1)
    total_pixels = pred_mask.size
    oil_spill_percentage = (oil_spill_pixels / total_pixels) * 100
    return {
        'oil_spill_pixels': oil_spill_pixels,
        'oil_spill_percentage': oil_spill_percentage,
        'has_oil_spill': oil_spill_pixels > 0
    }
```

Figura 30

Presencia de derrames.

```
def has_oil_spill(pred_mask, min_pixels=50):
    """Detecta si la máscara contiene derrames de petróleo reales (clase 1)"""
    oil_spill_pixels = np.sum(pred_mask == 1) # Clase 1: Derrame de Petróleo
    return oil_spill_pixels >= min_pixels
```

Métricas de Calidad (cuando hay máscaras de referencia)

Se ha considerado las siguientes métricas: Precisión, Recall, F1-Score (weighted), IoU Score, Dice Coefficient, Boundary F1 Score, Pixel Accuracy (ver Figura 31).

Figura 31

Métricas de Calidad.

```
precision = precision_score(test_masks.flatten(), predicted_masks.flatten(), average='weighted',
                           zero_division=1)
recall = recall_score(test_masks.flatten(), predicted_masks.flatten(), average='weighted', zero_division=1)
f1 = f1_score(test_masks.flatten(), predicted_masks.flatten(), average='weighted', zero_division=1)
iou = iou_score(test_masks.flatten(), predicted_masks.flatten(), IMG_CLASSES)
dice = dice_coefficient(test_masks.flatten(), predicted_masks.flatten(), IMG_CLASSES)
boundary_f1_score = boundary_f1(test_masks.flatten(), predicted_masks.flatten(), IMG_CLASSES)
accuracy = pixel_accuracy(test_masks.flatten(), predicted_masks.flatten())
```

4.4.4. Funcionalidades de la Interfaz

En esta sección se especifican las cuatro características implementadas:

Carga de Datos

- Múltiples formatos de imagen soportados
- Procesamiento por lotes
- Validación de archivos

Parámetros Ajustables

Permite ajustar la sensibilidad de la teledetección (ver Figura 32).

Figura 32

Ajuste de los umbrales

```
threshold_value = st.sidebar.slider("Umbral para áreas sin datos", 5, 50, 15)
min_oil_pixels = st.sidebar.slider("Mínimo píxeles para derrame", 1, 500, 50)
```

Visualización Interactiva

En esta sección se contabiliza el número de imágenes que presentan derrames (ver Figura 33).

Figura 33

Resultados de detección de derrames.

Total de imágenes procesadas: 1

Imágenes con derrames detectados: 1

Imágenes sin derrames: 0


Se encontraron derrames en 1 imagen(es)

Además, se contrasta la imagen original vs. máscara predicha (ver Figura 34).

Figura 34

Contraste entre la imagen original y la máscara predicha.

Imagen original:




Máscara predicha (Derrames en Cyan):



Y se valida con una superposición imagen-máscara (ver Figura 35).

Figura 35
Validación con superposición de imagen-máscara.



4.4.5. Capacidades de Análisis Cuantitativo

A continuación, se detalla las principales métricas calculadas (ver Figura 36).

Figura 36
Cantidad y porcentaje de Píxeles del derrame.

Píxeles de derrame	Porcentaje de derrame	Área afectada (m ²)	Resolución
1,024	1.56%	256.00	0.5 m/px
▢ Área total de la imagen: 16384.00 m ² Cada píxel = 0.2500 m ²			
🚒 DERRAME DETECTADO			

Nota: En función a la resolución del pixel se calcula el área de impacto ambiental.

Extensión del Derrame

- Píxeles absolutos: Número total de píxeles clasificados como derrame
- Porcentaje de área: Proporción del área total afectada

Detección Binaria

- Presencia/Ausencia: Detección de derrames significativos

- Umbral configurable: Mínimo de píxeles para considerar positivo

Evaluación de Calidad (con ground truth)

- Métricas de segmentación estándar
- Matriz de confusión multiclase

4.4.6. Implementación para consulta en línea

A continuación, se detalla las tecnologías usadas, los requisitos de ejecución y las características de accesibilidad.

Tecnologías Utilizadas:

- Framework: Streamlit (Python)
- Modelo: TensorFlow/Keras (.h5)
- Procesamiento: OpenCV, NumPy
- Visualización: Matplotlib, Seaborn

Requisitos de Ejecución

Ejecución del código en el entorno Pycharm para acceder a la plataforma Streamlit (ver Figura 37).

Figura 37

Entorno Streamlit

```
# Comando de ejecución
streamlit run STREAMLIT14.py --server.port 8501

# Dependencias principales
tensorflow>=2.8.0
streamlit>=1.22.0
opencv-python>=4.6.0
numpy>=1.21.0
```

Características de Accesibilidad

- Multiplataforma
 - Navegadores web estándar

- Dispositivos móviles compatibles
- Sin instalación requerida

➤ Interfaz Intuitiva

- Panel lateral para controles
- Visualización centralizada de resultados
- Mensajes de estado y progreso

4.4.7. Resultado y Validación

Despliegue en la plataforma Streamlit:

Métricas de Rendimiento

En esta sección se validan las métricas que aseguran la validación del modelo ReImprovedDeepLabV3+ (ver Figura 38).

Figura 38

Métricas de rendimiento

Precisión: 0.9593

Recall: 0.9623

F1 Score: 0.9601

IoU Score: 0.5911

Dice Coefficient: 0.6971

Boundary F1 Score: 0.0006

Pixel Accuracy: 0.9623

Tiempos de Procesamiento:

- Carga del modelo: 3-5 segundos (una vez por sesión)
- Procesamiento por imagen: 1-3 segundos
- Generación de visualizaciones: <1 segundo

Evaluación Individual

En este apartado se realiza la evaluación en función a:

- Análisis de imágenes aisladas (ver figura 39).
- Determinación de presencia/ausencia de derrames (ver figura 40).
- Cálculo de extensión afectada (%)

Figura 39

Tratamiento de imagen individual




Figura 40

Resultado de detección de derrames en una imagen

Total de imágenes procesadas: 1

Imágenes con derrames detectados: 0

Imágenes sin derrames: 1


No se detectaron derrames de petróleo en ninguna imagen.

Puedes ajustar el 'Mínimo de píxeles para considerar derrame' en la barra lateral para ser más permisivo.

Evaluación Comparativa

En este apartado se realiza la evaluación de múltiples imágenes en función a:

- Procesamiento por lotes de múltiples imágenes (ver figura 41).
- Detección automática de imágenes con derrames (ver figura 42).
- Generación de reportes consolidados (ver tabla 14).

Figura 41*Tratamiento de imágenes por lote***Figura 42***Resultado de detección de derrames en lote de imágenes***Total de imágenes procesadas: 8****Imágenes con derrames detectados: 0****Imágenes sin derrames: 8**

No se detectaron derrames de petróleo en ninguna imagen.

Puedes ajustar el 'Mínimo de píxeles para considerar derrame' en la barra lateral para ser más permisivo.

Tabla 14*Resumen del procesamiento de las imágenes*

Imagen	Derrames Detectados	Píxeles Derrame	% Derrame	Mostrada
Ventanilla_0181.jpg	No	0	0.00%	No
Ventanilla_0193.jpg	No	0	0.00%	No
Ventanilla_0205.jpg	No	0	0.00%	No
Ventanilla_0217.jpg	No	0	0.00%	No
Ventanilla_0229.jpg	No	0	0.00%	No
Ventanilla_0241.jpg	No	0	0.00%	No
Ventanilla_0253.jpg	No	0	0.00%	No
Ventanilla_0264.jpg	No	0	0.00%	No

4.4.8. Discusión de resultados

Los resultados evidencian la viabilidad y superioridad del modelo ReImproved DeepLabV3+ para la teledetección de impactos medioambientales producidos por derrames de petróleo en el mar utilizando Inteligencia Artificial Geoespacial (GeoIA). La discusión se centra en interpretar estos hallazgos a la luz del marco teórico y los antecedentes revisados.

En primer lugar, la efectividad del modelo propuesto se sustenta en su capacidad para superar las limitaciones de arquitecturas tradicionales como U-Net, PSPNet y DeepLabV3+. Mientras que modelos como U-Net, aunque eficientes en tiempo (5.0 horas), presentaron una Exactitud (0.9838) y Recall (0.9516) menores, y DeepLabV3+ original mostró la mayor Exactitud (0.9873) pero con un costo computacional significativamente mayor (39.2 horas) y un IoU inferior (0.616), el ReImproved DeepLabV3+ logró un equilibrio óptimo. Su Exactitud de 0.9786, muy cercana a la del modelo original, combinada con el mejor Recall (0.9601), F1-Score (0.9582) e IoU (0.6477) global, y un tiempo de entrenamiento reducido en un 25.7% (~29.2 horas), indica que las mejoras implementadas—específicamente el mecanismo de Atención Polarizada y el StripePooling—no solo optimizaron el uso de recursos sino que mejoraron la capacidad del modelo para capturar contextos geoespaciales complejos y características multiescala propias de los derrames de petróleo, tales como patrones alargados debidos a corrientes marinas.

Cabe mencionar que, aunque se identificó dentro de la literatura, el modelo UNET CNN con IoU de 0.757 (Basit et al., 2021), el objetivo principal del presente trabajo era la mejora del rendimiento del modelo base DeepLabV3+, reduciendo su costo computacional, su tiempo de entrenamiento y de ejecución alcanzados con el modelo propuesto ReImproved DeepLabV3+. De esta forma, el aporte se enfoca en un escenario práctico en el marco de recursos limitados, generando equilibrio entre precisión y eficiencia. Este desempeño superior en métricas clave como el Recall y el IoU (a pesar de no ser el valor más alto de la literatura) es crucial en el dominio de aplicación. Un alto Recall asegura que se minimicen los falsos negativos, es decir, que se detecte la mayor cantidad posible de petróleo derramado, un aspecto vital para la respuesta temprana en

desastres ambientales. Por su parte, el IoU mejorado refleja una delimitación más precisa de las áreas afectadas, lo que permite una cuantificación más fiable del impacto ambiental. Estos resultados se alinean con hallazgos previos que destacan la utilidad de las CNN, particularmente U-Net y sus variantes, para la segmentación de imágenes SAR (Basit et al., 2021; Huby, Alubady et al., 2022). Sin embargo, el presente estudio avanza al abordar explícitamente las deficiencias de los modelos existentes mediante la incorporación de mecanismos de atención diseñados para el dominio geoespacial, superando problemas comunes como la pérdida de contexto en objetos pequeños (manchas de petróleo dispersas) y el desbalanceo de clases (pseudo-derrames, embarcaciones).

La integración exitosa de la GeoIA en la plataforma Streamlit representa otra contribución significativa. La plataforma permite que usuarios no especializados, como autoridades ambientales o miembros de la sociedad civil, puedan cargar imágenes satelitales y obtener una evaluación rápida y automatizada del impacto geoespacial. Esto democratiza el acceso a tecnología avanzada de monitoreo y se alinea con el ODS 14, fomentando la participación social en la protección de los ecosistemas marinos. Esta aproximación práctica responde a la necesidad identificada en la justificación socioambiental de la investigación y encuentra eco en tendencias recientes que promueven la ciencia ciudadana y las infraestructuras de datos espaciales (Nugroho & Supangkat, 2021; Saengtabtim et al., 2023).

Finalmente, es importante discutir las limitaciones. El modelo fue entrenado y validado principalmente con el benchmark dataset de MKLab, que, si bien es un estándar reconocido, proviene de un contexto geográfico y temporal específico (2015-2017). La aplicación directa a otros escenarios, como el derrame de Ventanilla 2022, podría requerir un fine-tuning con datos locales para alcanzar el máximo rendimiento. No obstante, la arquitectura flexible del modelo y su capacidad para procesar imágenes de diferentes sensores (ej., Sentinel-1, TerraSAR-X) sugieren un buen potencial de generalización.

CONCLUSIONES

El desarrollo del modelo propuesto ReImprovedDeepLabV3+ y su framework de validación, demuestra que la Inteligencia Artificial Geoespacial optimiza significativamente la teledetección de impactos medioambientales por derrames de petróleo en el mar, logrando altos niveles de precisión, sensibilidad y eficiencia computacional, y proporcionando una herramienta práctica y alineada con el ODS 14 para la gestión ambiental en el Perú y en el mundo.

Se logró crear el Dataset de Derrames de Petróleo de Ventanilla - Lima, generado a partir de una imagen TerraSAR-X del mar de Ventanilla (2022) y proporcionada por CONIDA. Mediante un script en Python se dividió la imagen original (18424×22787 píxeles) en 352 subimágenes de 1250×650 píxeles en formato jpg, aplicando preprocesamiento específico (calibración radiométrica, filtrado de speckle con mediana 7×7 , conversión a valores de luminosidad). Este proceso, apoyado en SIG (ArcGIS) para la delimitación del área de interés y con técnicas de teledetección para la selección de parámetros (polarización VV, nivel 1-C), demostró ser efectivo para generar un dataset local, replicable y alineado con estándares internacionales. Además, se preprocesó exitosamente el Benchmark dataset de imágenes de radar MKLab, que consta de 1112 imágenes SAR Sentinel-1 (banda VV, resolución 10×10 m) con sus respectivas máscaras de segmentación manual (y con 5 clases: superficie marina, derrame, pseudo-derrame, barco, tierra), lo que permitió un entrenamiento robusto del modelo propuesto.

Se realizó una comparación sistemática y cuantitativa de cinco arquitecturas de segmentación semántica: U-Net, PSPNet, DeepLabV3, DeepLabV3+ e Improved DeepLabV3+, utilizando el benchmark dataset y métricas no paramétricas (Accuracy, Precision, Recall, F1-Score, IoU, Boundary F1 y tiempo de entrenamiento). Los resultados mostraron que el modelo DeepLabV3+ con backbone ResNet50 alcanzó la mayor exactitud (98.73%), pero con un costo computacional elevado (39.2 horas). En contraste, la variante Improved DeepLabV3+ con MobileNetV2 fue la más rápida (22.0 horas) pero presentó un recall muy bajo (13.94%), inadecuado para la detección de derrames. El análisis permitió identificar que el equilibrio óptimo entre precisión, sensibilidad y eficiencia se logra mediante modificaciones en la arquitectura DeepLabV3+, manteniendo ResNet50 como backbone base, pero incorporando mecanismos de atención y pooling direccional. Esta comparación rigurosa permitió el desarrollo del modelo ReImprovedDeepLabV3+.

Se implementó el modelo ReImprovedDeepLabV3+, una arquitectura de GeoAI que integra tres innovaciones clave sobre DeepLabV3+ original: (i) un backbone ResNet50 mejorado con una capa de atención por canal ECANet para resaltar características de bajo nivel; (ii) la sustitución del average pooling tradicional por un módulo StripePooling en el ASPP, que captura patrones alargados típicos de los derrames de petróleo; (iii) un mecanismo de Atención Polarizada (canal-espacial dual) para reducir falsos positivos en pseudo-derrames y mejorar la discriminación de clases minoritarias (embarcaciones, pseudo-derrames). El modelo alcanzó métricas sobresalientes: Accuracy 97.86%, Recall 96.01%, F1-Score 95.82%, IoU 0.6477 (5.1% superior al DeepLabV3+ original) y Boundary F1 0.9553. Además, logró un tiempo de entrenamiento de 29.2 horas, un 25.7% menor que el modelo base. Estas métricas validan que el modelo propuesto clasifica con alta precisión las cinco clases del entorno marino-costero, superando las limitaciones de pérdida de contexto y desbalanceo de clases presentes en arquitecturas previas.

Se desarrolló y validó un framework operativo mediante una interfaz de usuario interactiva construida con Streamlit. La plataforma permite cargar imágenes individuales o por lotes (formatos jpg, png, jpeg), ejecutar el modelo ReImprovedDeepLabV3+ preentrenado, y visualizar en tiempo real (1-3 segundos por imagen) las máscaras de

segmentación codificadas por colores, junto con métricas cuantitativas de impacto: cantidad y porcentaje de píxeles afectados por los derrames, así como el cálculo de áreas afectadas, y cuando se dispone de ground truth, precisión, recall, F1-score, IoU y matriz de confusión. La interfaz fue probada con el dataset de Ventanilla, demostrando su capacidad para procesar 352 imágenes en lote y generar reportes consolidados. Esta validación cuantitativa, evaluó una alta especificidad del modelo sobre este dataset confirmando que el modelo es apto para la detección temprana de impactos ambientales por derrames de petróleo, facilitando su uso por gestores ambientales, autoridades, la sociedad civil y futuros investigadores.

RECOMENDACIONES

Incorporar en futuros datasets imágenes SAR con múltiples polarizaciones (VV, VH, HH, HV) y de diferentes sensores como Radarsat-2 o SAOCOM, para enriquecer la variabilidad espectral y mejorar la generalización del modelo, automatizando el pipeline de preprocesamiento usando herramientas de código abierto como ESA SNAP (Sentinel Application Platform) y GDAL (Geospatial Data Abstraction Library) y orquestarlo en entornos de nube (Google Earth Engine, AWS) promoviendo la actualización continua del dataset con nuevos eventos de derrame en el litoral peruano en colaboración con CONIDA, OEFA y la academia sirviendo como benchmark local.

Ampliar la comparación a diferentes arquitecturas tales como SegFormer, Mask2Former o Swin-UNet, evaluando sus métricas de rendimiento y eficiencia computacional en el dominio de imágenes SAR y realizando estudios de sensibilidad de hiperparámetros (learning rate, tamaño de lote, funciones de pérdida) y utilizar técnicas de validación cruzada para fortalecer la robustez de las comparaciones y la publicación de los resultados comparativos (código, métricas, pesos de los modelos) en un repositorio abierto como GitHub, Zenodo, para fomentar la reproducibilidad y la colaboración científica.

Explorar el uso de backbones tales como ConvNeXt o EfficientNet combinados con los mecanismos de atención propuestos (StripePooling + Atención Polarizada) para reducir aún más el tiempo de inferencia sin sacrificar precisión, incorporando técnicas de aumento de datos específicas para imágenes SAR como rotaciones, deformaciones

elásticas o ruido speckle sintético, para mejorar la capacidad del modelo de generalizar a condiciones adversas (oleaje, viento, falsos ecos).

Desplegar la interfaz Streamlit en un servicio en la nube como Streamlit Community Cloud, AWS o Azure, con acceso público controlado, permitiendo que instituciones como OEFA, DICAPI, Defensoría del Pueblo y municipalidades costeras realicen consultas en línea sin necesidad de infraestructura local, integrando al framework un módulo de alerta temprana que, al detectar un derrame por encima de un umbral configurable, envíe notificaciones automáticas (correo, SMS, API) a los equipos de respuesta a emergencias bajo un entorno operativo real y comparando los resultados con informes oficiales para medir su precisión en condiciones reales de monitoreo continuo.

REFERENCIAS BIBLIOGRÁFICAS

- Adhikary, S., Tiwari, S. P., & Banerjee, S. (2022). Realtime Oil Spill Detection by Image Processing of Synthetic Aperture Radar Data. *2022 IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT 2022)*. <https://doi.org/10.1109/CONECCT55679.2022.9865768>
- Almeer, S., Albalooshi, F., & Alhajeri, A. (2021). Oil Spill Detection System in the Arabian Gulf Region: An Azure Machine-Learning Approach. *2021 International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies*, 418–422. <https://doi.org/10.1109/3ICT53449.2021.9581841>
- Araújo, K. C., Barreto, M. C., Siqueira, A. S., Freitas, A. C., Oliveira, L. G., Bastos, M. E., Rocha, M. E., Silva, L. A., & Fragoso, W. D. (2021). Oil spill in northeastern Brazil: Application of fluorescence spectroscopy and PARAFAC in the analysis of oil-related compounds. *Chemosphere*, 267. <https://doi.org/10.1016/j.chemosphere.2020.129154>
- ArcGIS, (2023). *¿Qué es ArcGIS?* ArcGIS. <https://resources.arcgis.com/es/help/getting-started/articles/026n00000014000000>
- Arias, J. L. (2020). *Proyecto de Tesis Guía para la elaboración*. http://repositorio.concytec.gob.pe/bitstream/20.500.12390/2236/1/AriasGonzalez_ProyectoDeTesis_libro.pdf
- Azevedo, R. N., Bezerra, K. M., Nascimento, R. F., Nelson, R. K., Reddy, C. M., Nascimento, A. P., Oliveira, A. H., Martins, L. L., & Cavalcante, R. M. (2022). Is there a similarity between the 2019 and 2022 oil spills that occurred on the coast of Ceará (Northeast Brazil)? An analysis based on forensic environmental geochemistry. *Environmental Pollution*, 314. <https://doi.org/10.1016/j.envpol.2022.120283>
- Babaan, J., Hsu, F. T., Wong, P. Y., Chen, P. C., Guo, Y. L., Lung, S. C., Chen, Y. C., & Wu, C. D. (2023). A Geo-AI-based ensemble mixed spatial prediction model with fine spatial-temporal resolution for estimating daytime/nighttime/daily average

- ozone concentrations variations in Taiwan. *Journal of Hazardous Materials*, 446. <https://doi.org/10.1016/j.jhazmat.2023.130749>
- Barbosa, C., Oleinik, P. H., Fagundes, T., Correa, W., Nicolodi, J. L. & De Carvalho, B. (2020). Integrated environmental vulnerability to oil spills in sensitive areas. *Environmental Pollution*, 267. <https://doi.org/10.1016/j.envpol.2020.115238>
- Barbosa, C., Oleinik, P. H., Fagundes, T., De Paula, E., Toldo, E. E., Correa, W. & De Carvalho, B. (2020). Susceptibility to oil spill spreading using case studies and simulated scenarios. *Environmental Pollution*, 267. <https://doi.org/10.1016/j.envpol.2020.115451>
- Basit, A., Siddique, M. A., & Sarfraz, M. S. (2021). Deep learning based oil spill classification using unet convolutional neural network. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 3491–3494. <https://doi.org/10.1109/IGARSS47720.2021.9553646>
- Bell, S. (2022). Introduction to Geomatics. Licensed under CC BY-SA 4.0. <https://www.saskoer.ca/introgeomatics/>
- Bolaños, R. (2017). Reseña Histórica de la Exploración por Petróleo en las Cuencas Costeras del Perú. *Boletín de la Sociedad Geológica del Perú*, 112, 001-013. <http://tramite.ingemmet.gob.pe/BusquedaGeodoc/images/biblioteca/BSGP-112-1.pdf>
- Borges, C., Lopes, S. & Caldas, J. (2021). Oil impact on the environment and aquatic organisms on the coasts of the states of Alagoas and Sergipe, Brazil - A preliminary evaluation. *Marine Pollution Bulletin*, 171. <https://doi.org/10.1016/j.marpolbul.2021.112723>
- Brabham, D. (2013). *Crowdsourcing* (1st ed., pp. 2). MIT Press. <https://wtf.tw/ref/brabham.pdf>
- Burkov, A. (2019). *The Hundred-Page Machine Learning Book*. Andriy Burkov. <https://themlbook.com/>

- Cabrera, M. V., Bastos, B., Ferris, T. K., Rodríguez, M. C., & Rodrigues, P. V. (2016). Modelling performance variabilities in oil spill response to improve system resilience. *Journal of Loss Prevention in the Process Industries*, 41, 18–30. <https://doi.org/10.1016/j.jlp.2016.02.018>
- Cadei, L., Montini, M., Landi, F., Porcelli, F., Michetti, V., Origgi, M., Tonegutti, M., Duranton, S., 2018. Big data advanced analytics to forecast operational upsets in upstream production system (SPE-193190-MS). *Abu Dhabi International Petroleum Exhibition & Conference. Society of Petroleum Engineers*, 1 – 14. doi: <https://doi.org/10.2118/193190-MS>
- Câmara, S. F., Pinto, F. R., Da Silva, F. R., De Oliveira, M. & De Paula, T. M. (2021). Socioeconomic vulnerability of communities on the Brazilian coast to the largest oil spill (2019–2020) in tropical oceans. *Ocean and Coastal Management*, 202. <https://doi.org/10.1016/j.ocecoaman.2020.105506>
- Chang, K. (2019). Introduction to Geographic Information Systems (9th ed., pp. 2). McGraw-Hill. <https://ia802206.us.archive.org/27/items/kang-tsung-chang-introduction-to-geographic-information-systems-2019-mc-graw-hill-libgen.lc/Kang-tsung%20Chang%20-%20Introduction%20to%20Geographic%20Information%20Systems%20%282019%2C%20McGraw-Hill%29%20-%20libgen.lc.pdf>
- Chen, J., Zhang, W., Wan, Z., Li, S., Huang, T., & Fei, Y. (2019). Oil spills from global tankers: Status review and future governance. *Journal of Cleaner Production*, 227, 20-32. <https://doi.org/10.1016/j.jclepro.2019.04.020>
- Chen, L.C., Papandreou, G., Schroff, F., & Adam, H. (2017). *Rethinking atrous convolution for semantic image segmentation*. arXiv. <https://doi.org/10.48550/arXiv.1706.05587>
- Chollet, F. (2021). *Deep learning with Python*. (2nd ed.). Manning Publications Co. <http://www.manning.com/>
- Chuvieco, E. (1995). *Fundamentos de Teledetección Espacial*. (2nd ed.). Rialp S.A. https://www.academia.edu/8741619/Fundamentos_de_Teledetecci%C3%B3n_Emilio_Chuvieco

- Copernicus (2024). Copernicus Data Space Ecosystem. <https://dataspace.copernicus.eu/>
- Defensoría del Pueblo. (2023). Informe de Adjuntía N° 001-2023-DP/AMASPPI, Derrame de petróleo en Ventanilla: Reporte a un año del desastre ambiental y social en nuestro litoral. <https://www.defensoria.gob.pe/wp-content/uploads/2023/01/001-IA-Derrame-de-Petr%C3%B3leo-en-Ventanilla.pdf>
- De Laurentiis, L., Jones, C. E., Holt, B., Schiavon, G., & Del Frate, F. (2021). Deep Learning for Mineral and Biogenic Oil Slick Classification with Airborne Synthetic Aperture Radar Data. *IEEE Transactions on Geoscience and Remote Sensing*, 59(10), 8455–8469. <https://doi.org/10.1109/TGRS.2020.3034722>
- De Oliveira, M., Peres, C. E., Arruda, L. E., Vieira, S., Lopes, T. C., Martins, T., De Araujo, J. T., Coelho, C., Cavalcante, S. M., Matthews-Cascon, H., Frota, A., Frota, T. C., Teles, S., Fontenele, E., Xerez, C., Pereira, J. E., De Melo, M., De Santana, R. P., De Santana, C. S., Bastos, P., Meirelles, A., Almeida, B., Barbosa, A. E., Horta, P. & Martins, R. (2020). Oil spill in South Atlantic (Brazil): Environmental and governmental disaster. *Marine Policy*, 115. <https://doi.org/10.1016/j.marpol.2020.103879>
- Desai, J.N., Pandian, S., & Vij, R.K. (2021). Big data analytics in upstream oil and gas industries for sustainable exploration and development: A review. *Environmental Technology and Innovation*, 21. <https://doi.org/10.1016/j.eti.2020.101186>
- De Santana, R. P., Mello, C. D., De Santana, C. S., Da Silva, A. J., Neumann-Leitão, S., Padovanni, B., De Oliveira, M., De Melo, M. & Mendes, P. A. (2021). Oil spills: The invisible impact on the base of tropical marine food webs. *Marine Pollution Bulletin*, 167. <https://doi.org/10.1016/j.marpolbul.2021.112281>
- Di Martino, G. & Iodice, A. (Ed.). (2021). *Maritime Surveillance with Synthetic Aperture Radar*. The Institution of Engineering and Technology.
- Di, S., Cheng, S., Cao, N., Gao, C., & Miao, L. (2021). AI-based geo-engineering integration in unconventional oil and gas. *Journal of King Saud University – Science*, 33(6). <https://doi.org/10.1016/j.jksus.2021.101542>

- Dortheimer, J. (2022). Collective Intelligence in Design Crowdsourcing. *Mathematics*, 10(4). <https://doi.org/10.3390/math10040539>
- Duan, P., Kang, X., Ghamisi, P., & Li, S. (2023). Hyperspectral Remote Sensing Benchmark Database for Oil Spill Detection with an Isolation Forest-Guided Unsupervised Detector. *IEEE Transactions on Geoscience and Remote Sensing*, 61. <https://doi.org/10.1109/TGRS.2023.3268944>
- Esri. (2025). ArcGIS Pro [software]. <https://www.esri.com/en-us/arcgis/products/arcgis-pro/overview>
- European Space Agency. (2023). Sentinel - 1 Radar visión for Copernicus. https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-1
- Feinauer, D. M., Tayem, N., Latif, G., Alghazo, J., Alenazy, A. M., & Alzubaidi, L. (2022). *Oil Spill Identification using Deep Convolutional Neural Networks*. <https://doi.org/10.1109/cicn.2022.41>
- Fernandes, G. M., Martins, D. A., Dos Santos, R. P., De Santiago, I. S., Nascimento, L. S., Oliveira, A. H., Yamamoto, F. Y., & Cavalcante, R. M. (2022). Levels, source appointment, and ecological risk of petroleum hydrocarbons in tropical coastal ecosystems (northeast Brazil): Baseline for future monitoring programmes of an oil spill area. *Environmental Pollution*, 296. <https://doi.org/10.1016/j.envpol.2021.118709>
- Fingas, V. (2012). *The Basics of Oil Spill Cleanup* (3rd ed., pp. 1). CRC Press. <https://doi.org/10.1201/b13686>
- Ghonaime, T. W., & Al-Sadek, A. F. (2023). OilSpillNet: Deep Learning Model for Synthetic Aperture Radar Imagery Oil Spill Detection. *1st International Conference of Intelligent Methods, Systems and Applications*, 412–417. <https://doi.org/10.1109/IMSA58542.2023.10217532>
- Giarratano, J. & Riley, G. (2005). *Expert Systems Principles and Programming* (4th ed., pp. 5). Cengage Learning.

- Google (2023). *Conceptos Básicos ¿Qué es Colaboratory?* Colaboratory
<https://research.google.com/colaboratory/faq.html>
- Hadi, M., Martel, C., Huayta, F., Rojas, R. y Arias, J. (2023). *Metodología de la investigación: Guía para el proyecto de tesis*, (1 ed., pp. 39). Instituto Universitario de Innovación Ciencia y Tecnología Inudi Perú S.A.C.
<https://doi.org/10.35622/inudi.b.073>
- Huby, A. A., Alubady, R., & Sagban, R. (2022). Oil Spill Segmentation from SAR Images Using Deep Neural Networks. *ISMSIT 2022 - 6th International Symposium on Multidisciplinary Studies and Innovative Technologies, Proceedings*, 282–287.
<https://doi.org/10.1109/ISMSIT56059.2022.9932853>
- Huby, A. A., Sagban, R., & Alubady, R. (2022). Oil Spill Detection based on Machine Learning and Deep Learning: A Review. *IICETA 2022 - 5th International Conference on Engineering Technology and Its Applications*, 85–90.
<https://doi.org/10.1109/IICETA54559.2022.9888651>
- Haugeland, J. (1985). *Artificial Intelligence: The Very Idea*, (1 ed., pp. 2). MIT Press.
- Hernández, R. y Mendoza, C. (2018). *Metodología de la Investigación. Las rutas cuantitativa, cualitativa y mixta* (1 ed.). McGraw-Hill.
- Iglovikov, V.; Mushinskiy, S., & Osin, V. (2017). *Satellite imagery feature detection using deep convolutional neural network: A kaggle competition*. arXiv. arXiv:1706.06169.
- PyCharm (2025). El único IDE de Python que necesita. <https://www.jetbrains.com/es-es/pycharm/>
- Jiang, Y., Schlagwein, D. & Benatallah, B. (2018). A Review on Crowdsourcing for Education: State of the Art of Literature and Practice.
https://www.researchgate.net/publication/326235193_A_Review_on_Crowdsourcing_for_Education_State_of_the_Art_of_Literature_and_Practice

- Jiang, W., & Zhang, L. (2019). *Geospatial Data to Images: A Deep-Learning Framework for Traffic Forecasting*, 24 (1), 52–64. <https://doi.org/10.26599/TST.2018.9010033>
- Jiao, Z., Jia, G., & Cai, Y. (2019). A new approach to oil spill detection that combines deep learning with unmanned aerial vehicles. *Computers and Industrial Engineering*, 135, 1300–1311. <https://doi.org/10.1016/j.cie.2018.11.008>
- Jolliff, J. K., Smith, T. A., Ladner, S. & Arnone, R. A. (2014). Simulating surface oil transport during the Deepwater Horizon oil spill: Experiments with the BioCast system. *Ocean Modelling*, 75, 84–99. <https://doi.org/10.1016/j.ocemod.2014.01.004>
- Jurafsky, D. & Martin, J. H. (2006). *Speech and Language Processing: An introduction to natural language processing, computational linguistics, and speech recognition* (1st ed., pp. 15). Prentice Hall. <https://web.stanford.edu/~jurafsky/slp3/ed3book.pdf>
- Kang, X., Deng, B., Duan, P., Wei, X., & Li, S. (2023). Self-Supervised Spectral-Spatial Transformer Network for Hyperspectral Oil Spill Mapping. *IEEE Transactions on Geoscience and Remote Sensing*, 61. <https://doi.org/10.1109/TGRS.2023.3260987>
- Kang, X., Wang, Z., Duan, P., & Wei, X. (2022). The Potential of Hyperspectral Image Classification for Oil Spill Mapping. *IEEE Transactions on Geoscience and Remote Sensing*, 60. <https://doi.org/10.1109/TGRS.2022.3205966>
- Karachiwalla, R., & Pinkow, F. (2021). Understanding crowdsourcing projects: A review on the key design elements of a crowdsourcing initiative. *Creativity and Innovation Management*, 30(3), 563–584. <https://doi.org/10.1111/caim.12454>
- Krestenitis, M., Orfanidis, G., Ioannidis, K., Avgerinakis, K., Vrochidis, S., & Kompatsiaris, I. (2019). Oil Spill Identification from Satellite Images Using Deep Neural Networks. *Remote Sensing*, 11(15), 1762.
- Lassalle, G., Moreira, R. P., Lourenço, R. A., Mazzafera, P., & De Souza, C. R. (2023). Remote sensing reveals unprecedented sublethal impacts of a 40-year-old oil spill

- on mangroves. *Environmental Pollution*, 331. <https://doi.org/10.1016/j.envpol.2023.121859>
- LaValle, S. (2006). *Planning Algorithms*. (1st ed., pp. 4). Cambridge University Press. <http://lavalle.pl/planning/book.pdf>
- Lavallin, A., & Downs, J. A. (2021). Machine learning in geography—Past, present, and future. *Geography Compass*, 15(5). <https://doi.org/10.1111/gec3.12563>
- León, A., Zúñiga, M. y Díaz, D. (2024). *La sombra del petróleo. Informe de los derrames petroleros en la Amazonía peruana entre el 2000 y el 2023*. (Informe III sobre emergencias ambientales, pasivos, procesos de remediación entre los años 1997 - 2023 en el Perú y reflexiones sobre alternativas energéticas). Coordinadora Nacional de Derechos Humanos. <https://www.actualidadambiental.pe/1997-a-2023-registrado-1462-derrames-de-petroleo/>
- Li, D., Shao, Z., & Zhang, R. (2020). Advances of geo-spatial intelligence at LIESMARS. *Geo-Spatial Information Science*, 23(1), 40–51. <https://doi.org/10.1080/10095020.2020.1718001>
- Li, Y., Yang, J., Yuan, Z., & Zhang, Y. (2022). Marine Oil Spills Detection and Classification from Polsar Images Based on Complex-Valued Convolutional Neural Network. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 7085–7088. <https://doi.org/10.1109/IGARSS46834.2022.9883991>
- Li, Y., Zhang, Y., Yuan, Z., Guo, H., Pan, H., & Guo, J. (2018). Marine oil spill detection based on the comprehensive use of polarimetric SAR data. *Sustainability*, 10(12). <https://doi.org/10.3390/su10124408>
- Lima, B. D., Martins, L. L., De Souza, E. S., Pudenzi, M. A., & Da Cruz, G. F. (2021). Monitoring chemical compositional changes of simulated spilled Brazilian oils under tropical climate conditions by multiple analytical techniques. *Marine Pollution Bulletin*, 164. <https://doi.org/10.1016/j.marpolbul.2021.111985>
- Liu, X., Meng, R., Xing, Q., Lou, M., Chao, H., & Bing, L. (2015). Assessing oil spill risk in the Chinese Bohai Sea: A case study for both ship and platform related oil

- spills. *Ocean and Coastal Management*, 108, 140–146.
<https://doi.org/10.1016/j.ocecoaman.2014.08.016>
- Liu, Y., Bai, X., Wang, J., Li, G., Li, J., & Lv, Z. (2024). Image semantic segmentation approach based on DeepLabV3 plus network with an attention mechanism. *Engineering Applications of Artificial Intelligence*, 127(Part A), 107260.
<https://doi.org/10.1016/j.engappai.2023.107260>
- Luo, D., Gu, C., Chen, P., Yang, J., Yuan, Y., Zheng, G., & Ren, L. (2021). Oil Spill Segmentation of SAR Image Based on Improved Deep Convolution Neural Network. *Progress in Electromagnetics Research Symposium*, 2232–2237.
<https://doi.org/10.1109/PIERS53385.2021.9694767>
- Lyu, X. (2018). Oil spill detection based on features and extreme learning machine method in SAR images. *Proceedings - 2018 3rd International Conference on Mechanical, Control and Computer Engineering, ICMCCE*, 559–563.
<https://doi.org/10.1109/ICMCCE.2018.00123>
- Ma, X., Xu, J., Pan, J., Yang, J., Wu, P., & Meng, X. (2023). Detection of marine oil spills from radar satellite images for the coastal ecological risk assessment. *Journal of Environmental Management*, 325.
<https://doi.org/10.1016/j.jenvman.2022.116637>
- Ma, X., Xu, J., Wu, P., & Kong, P. (2022). Oil Spill Detection Based on Deep Convolutional Neural Networks Using Polarimetric Scattering Information from Sentinel-1 SAR Images. *IEEE Transactions on Geoscience and Remote Sensing*, 60. <https://doi.org/10.1109/TGRS.2021.3126175>
- Mao, H., Hu, Y., Kar, B., Gao, S. & McKenzie, G. (2018). GeoAI 2017 workshop report: the 1st ACM SIGSPATIAL International Workshop on GeoAI: @AI and Deep Learning for Geographic Knowledge Discovery: Redondo Beach, CA, USA - November 7, 2016. *SIGSPATIAL Special*, 9, 25.
<https://doi.org/10.1145/3178392.3178408>
- Mareddy, A.R. (2017). *Environmental Impact Assessment: Theory and Practice* (2nd ed., pp. 1). Elsevier.

<https://www.sciencedirect.com/book/9780128111390/environmental-impact-assessment>

- Marinho, C., Nicolodi, J. L., & Neto, J. A. (2021). Environmental vulnerability to oil spills in Itapuã State Park, Rio Grande do Sul, Brazil: An approach using two-dimensional numerical simulation. *Environmental Pollution*, 288. <https://doi.org/10.1016/j.envpol.2021.117872>
- Matos, K., De Souza, K. V., Santana, M. C., De Almeida, C., Souto, J. & De Oliveira, M. (2021). Oil spill + COVID-19: A disastrous year for Brazilian seagrass conservation. *Science of the Total Environment*, 764. <https://doi.org/10.1016/j.scitotenv.2020.142872>
- Maxwell, A., Warner, T. & Fang, F. (2018) Implementation of machine-learning classification in remote sensing: an applied review. *International Journal of Remote Sensing*, 39(9), 2784-2817, doi: 10.1080/01431161.2018.1433343
- McCarthy, J. (2007). What is artificial intelligence? Technical report, Computer Science Department, Stanford University. <http://www-formal.stanford.edu/jmc/whatisai/node1.html>
- Miranda, E. (2022, mayo 23). Más de 140 derrames de petróleo se registraron en la costa peruana desde 2011. *Convoca*. <https://convoca.pe/agenda-propia/mas-de-140-derrames-de-petroleo-se-registraron-en-la-costa-peruana-desde-2011>
- (MKLab, 2024). Multimedia Knowledge and Social Media Analytics Laboratory. <https://mklab.itl.gr/results/oil-spill-detection-dataset/>
- Nieto-Hidalgo, M., Gallego, A. J., Gil, P., & Pertusa, A. (2018). Two-stage convolutional neural network for ship and spill detection using SLAR images. *IEEE Transactions on Geoscience and Remote Sensing*, 56(9), 5217–5230. <https://doi.org/10.1109/TGRS.2018.2812619>
- Nissanka, I. D., & Yapa, P. D. (2018). Calculation of oil droplet size distribution in ocean oil spills: A review. *Marine Pollution Bulletin*, 135, 723–734. <https://doi.org/10.1016/j.marpolbul.2018.07.048>

- Nugroho, Y. S., & Supangkat, S. H. (2021). Spatial Data Infrastructure Integrated with Geospatial Artificial Intelligence: A Systematic Literature Review. *8th International Conference on ICT for Smart Society: Digital Twin for Smart Society, ICISS 2021 - Proceeding*. <https://doi.org/10.1109/ICISS53185.2021.9533208>
- Perez-Garcia, A., Paoletti, M. E., Haut, J. M., & Lopez, J. F. (2023). Novel Spectral Loss Function for Unsupervised Hyperspectral Image Segmentation. *IEEE Geoscience and Remote Sensing Letters*, 20. <https://doi.org/10.1109/LGRS.2023.3288809>
- Perupetro (2023). *Estadística Anual de Hidrocarburos 2023*. Perupetro. <https://www.perupetro.com.pe/wps/portal/corporativo/PerupetroSite/estadisticas/estad%C3%ADstica%20petrolera>
- Polinov, S., Bookman, R., & Levin, N. (2021). Spatial and temporal assessment of oil spills in the Mediterranean Sea. *Marine Pollution Bulletin*, 167. <https://doi.org/10.1016/j.marpolbul.2021.112338>
- Prabhakar, C. & John, G. F. (2022). A perspective on the state of Deepwater Horizon oil spill related tarball contamination and its impacts on Alabama beaches. *Chemical Engineerin*, 36. <https://doi.org/10.1016/j.coche.2022.100799>
- Promoting Effective Spill Response - ITOPF. (2024). *Major Oil Spills in History*. <https://www.itopf.org/knowledge-resources/data-statistics/statistics/>
- Python (2025). *What is Python? Executive Summary*. <https://www.python.org/doc/essays/blurb/>
- Rajendran, S., Vethamony, P., Sadooni, F. N., Al-Kuwari, H. A., Al-Khayat, J. A., Seegobin, V. O., Govil, H., & Nasir, S. (2021). Detection of Wakashio oil spill off Mauritius using Sentinel-1 and 2 data: Capability of sensors, image transformation methods and mapping. *Environmental Pollution*, 274. <https://doi.org/10.1016/j.envpol.2021.116618>
- Ramirez, M. I., Arevalo, A. P., Sotomayor, S., & Bailon-Moscoso, N. (2017). Contamination by oil crude extraction – Refinement and their effects on human

- health. *Environmental Pollution*, 231, 415–425.
<https://doi.org/10.1016/j.envpol.2017.08.017>
- Reina Valera (1960) <https://www.bible.com/es/bible/149/GEN.14.RVR1960>
- Richter, K. F., & Scheider, S. (2023). Current topics and challenges in geoAI. *KI - Kunstliche Intelligenz*. <https://doi.org/10.1007/s13218-022-00796-0>
- Ronci, F., Avolio, C., Di Donna, M., Zavagli, V., Piccialli, V. & Costantini, M. (2020). *An adversarial learning approach for oil spill detection from SAR images* [Conferencia]. 2020 IEEE Radar Conference (RadarConf20), Florence, Italy, doi: 10.1109/RadarConf2043947.2020.9266475
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. In N. Navab, J. Hornegger, W. M. Wells, & A. F. Frangi (Eds.), *Medical image computing and computer-assisted intervention – MICCAI 2015* (pp. 234–241). Springer International Publishing.
https://doi.org/10.1007/978-3-319-24574-4_28
- Rusell & Norvig (2016). *Artificial Intelligence A Modern Approach* (3rd ed., pp. 2). Pearson.
<https://rudict.com/ai/Artificial%20Intelligence%20A%20Modern%20Approach,%203rd%20Edition%20by%20Stuart%20J.%20Russell,%20Peter%20Norvig-2016.pdf>
- Saengtabtim, K., Laosunthara, A., Tang, J., & Leelawat, N. (2023). The 2022 Rayong Oil Spill Crisis in Thailand: An Identification for Reliability and Nearly-Real Time Data using Twitter. *2023 3rd International Symposium on Instrumentation, Control, Artificial Intelligence, and Robotics, ICA-SYMP*, 118–122.
<https://doi.org/10.1109/ICA-SYMP56348.2023.10044941>
- Sarker, I. H. (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. In *SN Computer Science*, 2(3). Springer.
<https://doi.org/10.1007/s42979-021-00592-x>
- Scardigli, A., Risser, L., Haddouche, C., & Jatiault, R. (2023). Integrating Unordered Time Frames in Neural Networks: Application to the Detection of Natural Oil

- Slicks in Satellite Images. *IEEE Transactions on Geoscience and Remote Sensing*, 61. <https://doi.org/10.1109/TGRS.2023.3241681>
- Samaras, A. G., De Dominicis, M., Archetti, R., Lamberti, A., & Pinardi, N. (2014). Towards improving the representation of beaching in oil spill models: A case study. *Marine Pollution Bulletin*, 88(1), 91–101. <https://doi.org/10.1016/j.marpolbul.2014.09.019>
- Sandhiya, S., Ramya, R., Sukitha, M., & Vikhashni, S. (2023). Detection of Oil Spill Events at Sea Using Machine Learning. *Proceedings of the 5th International Conference on Inventive Research in Computing Applications, ICIRCA*, 53–58. <https://doi.org/10.1109/ICIRCA57980.2023.10220760>
- Sarker, I. H. (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. In *SN Computer Science*, 2(3). Springer. <https://doi.org/10.1007/s42979-021-00592-x>
- Sherman, D. J., & Montgomery, D. R. (2020). *Environmental science and sustainability*. W. W. Norton & Company. <https://www.amazon.com/Environmental-Science-Sustainability-Daniel-Sherman/dp/0393422100>
- Sidorov, G. (Ed.). (2011). *Métodos modernos de Inteligencia Artificial* (1st ed., pp. 21). Centro de Investigación en Computación. <https://www.cic.ipn.mx/~sidorov/libroIA.pdf>
- Singh, A., Asmath, H., Chee, C. L., & Darsan, J. (2015). Potential oil spill risk from shipping and the implications for management in the Caribbean Sea. *Marine Pollution Bulletin*, 93(1), 217–227. <https://doi.org/10.1016/j.marpolbul.2015.01.013>
- Ślusarczyk, B. (2018). Industry 4.0 – Are we ready? *Polish Journal of Management Studies*, 17(1), 232–248. <https://doi.org/10.17512/pjms.2018.17.1.19>
- Sociedad Peruana de Hidrocarburos (SPH). (2014). *Libro Blanco de Hidrocarburos (LBH)*. (1st ed., pp. 54, 89, 106). <https://sphidrocarburos.com/wp-content/uploads/2023/01/Libro-de-Hidrocarburos.pdf>

- Song, H., Gao, L., & Song, J. (2023). SSWT-UUNet++ Submarine Oil Pipeline Spill Detection Approach. *IEEE Geoscience and Remote Sensing Letters*, 20. <https://doi.org/10.1109/LGRS.2023.3268348>
- Song, D., Zhen, Z., Wang, B., Li, X., Gao, L., Wang, N., Xie, T., & Zhang, T. (2020). A Novel Marine Oil Spillage Identification Scheme Based on Convolution Neural Network Feature
- STEP (2025). Scientific Toolbox Exploitation Platform. <https://step.esa.int/main/>
- Streamlit (2025). A faster way to build and share data apps. <https://streamlit.io>
- Sun, S., Hu, C., & Tunnell, J. W. (2015). Surface oil footprint and trajectory of the Ixtoc-I oil spill determined from Landsat/MSS and CZCS observations. *Marine Pollution Bulletin*, 101(2), 632–641. <https://doi.org/10.1016/j.marpolbul.2015.10.036>
- Svejkovsky, J., Hess, M., Muskat, J., & White, J. (2023). Aerial remote sensing of sub-sea dispersant injection effects during the Deepwater Horizon (MC-252) oil spill. *Marine Pollution Bulletin*, 191. <https://doi.org/10.1016/j.marpolbul.2023.114958>
- Szeliski, R. (2017). *Computer Vision Algorithms and Applications* (2nd ed., pp. 7). Springer.
- Tamayo, J., Salvador, J., Vásquez, A. y De la Cruz, R. (Ed.). (2015). *La industria de los hidrocarburos líquidos en el Perú: 20 años de aporte al desarrollo del país*. Osinergmin. https://www.osinergmin.gob.pe/seccion/centro_documental/Institucional/Estudios_Economicos/Libros/Libro-industria-hidrocarburos-liquidos-Peru.pdf
- Tong, Y., Zhou, Z., Zeng, Y., Chen, L., & Shahabi, C. (2020). Spatial crowdsourcing: a survey. *VLDB Journal*, 29(1), 217–250. <https://doi.org/10.1007/s00778-019-00568-7>
- United Nations Development Programme (2023). *What are the Sustainable Development Goals?* Sustainable Development Goals. <https://www.undp.org/sustainable-development-goals>

- Upreti, A. (2022). *Machine Learning Application in G.I.S. and Remote Sensing: An Overview*. Machine Learning View project Machine Learning Application in G.I.S. and Remote Sensing: An Overview. <https://doi.org/10.20944/preprints202207.0302.v1>
- Usery, E. L., Arundel, S. T., Shavers, E., Stanislawski, L., Thiem, P. & Varanka, D. (2022). GeoAI in the US Geological Survey for topographic mapping. *Transactions in GIS*, 26(1), 25–40. John Wiley and Sons Inc. <https://doi.org/10.1111/tgis.12830>
- Vopham, T., Hart, J., Laden, F. & Chiang, Y. (2018). *Emerging trends in geospatial artificial intelligence (geoAI): Potential applications for environmental epidemiology*. *Environmental Health*, 17. <https://doi.org/10.1186/s12940-018-0386-x>
- Wang, D., Liu, S., Zhang, C., Xu, M., Yang, J., Yasir, M., & Wan, J. (2023). An improved semantic segmentation model based on SVM for marine oil spill detection using SAR image. *Marine Pollution Bulletin*, 192. <https://doi.org/10.1016/j.marpolbul.2023.114981>
- Wei, L., Hu, Z., Dong, L., & Zhao, W. (2015). A damage assessment model of oil spill accident combining historical data and satellite remote sensing information: A case study in Penglai 19-3 oil spill accident of China. *Marine Pollution Bulletin*, 91(1), 258–271. <https://doi.org/10.1016/j.marpolbul.2014.11.036>
- Winston, P. H. (1992). *Artificial Intelligence*. Addison-Wesley Publishing Company.
- Xie, M., Li, Y., Dong, S., Zhang, B., & Gou, T. (2022). Fine-Grained Oil Types Identification Based on Reflectance Spectrum: Implication for the Requirements on the Spectral Resolution of Hyperspectral Remote Sensors. *IEEE Geoscience and Remote Sensing Letters*, 19. <https://doi.org/10.1109/LGRS.2022.3176494>
- Xiong, S., Long, H., Tang, G., Wan, J., & Li, H. (2015). The management in response to marine oil spill from ships in China: A systematic review. *Marine Pollution Bulletin*, 96(1), 7–17. <https://doi.org/10.1016/j.marpolbul.2015.05.027>

- Xu, F. Y., An, X. Z., & Liu, W. Q. (2022). Oil Spill Detection in SAR Images based on Improved YOLOX-S. *Proceedings - 2022 International Conference on Computer Engineering and Artificial Intelligence, ICCEAI*, 261–265. <https://doi.org/10.1109/ICCEAI55464.2022.00061>
- Yang, J., Hu, Y., Ma, Y., Li, Z., & Zhang, J. (2022). Research on Oil Spill Pollution Type Identification Using Rpnnet Deep Learning Model and Airborne Hyperspectral Image. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 807–810. <https://doi.org/10.1109/IGARSS46834.2022.9883530>
- Yin, S., Sun, F., Liu, W., Bi, Z., Liu, Q., & Tian, Z. (2023). Remote Identification of Oil Films on Water via Laser-Induced Fluorescence LiDAR. *IEEE Sensors Journal*, 23(12), 13671–13679. <https://doi.org/10.1109/JSEN.2023.3271370>
- Yu, X., Zhang, H., Luo, C., Qi, H., & Ren, P. (2018). Oil Spill Segmentation via Adversarial f-Divergence Learning. *IEEE Transactions on Geoscience and Remote Sensing*, 56(9), 4973–4988. <https://doi.org/10.1109/TGRS.2018.2803038>
- Zacharias, D. C., Gama, C. M., Harari, J., da Rocha, R. P., & Fornaro, A. (2021). Mysterious oil spill on the Brazilian coast – Part 2: A probabilistic approach to fill gaps of uncertainties. *Marine Pollution Bulletin*, 173. <https://doi.org/10.1016/j.marpolbul.2021.113085>
- Zapelini, A. P., Barcellos, R., Molognoni, L., De Oliveira, T., Daguer, H., & Manique, P. L. (2022). Disasters with oil spills in the oceans: Impacts on food safety and analytical control methods. *Food Research International*, 157. <https://doi.org/10.1016/j.foodres.2022.111366>
- Zhan, H., Meng, Z., Ren, Z., Miao, X., Bao, R., & Zhao, K. (2022). Terahertz Spectroscopy Combined with Deep Learning for Predicting the Depth and Duration of Underground Sand Pollution by Crude Oil. *IEEE Transactions on Instrumentation and Measurement*, 71. <https://doi.org/10.1109/TIM.2021.3105237>
- Zhao, H., Shi, J., Qi, X., Wang, X., & Jia, J. (2017). *Pyramid scene parsing network*. arXiv. <https://arxiv.org/abs/1612.01105>

Zhen, Y., Khan, A., Nazir, S., Huiqi, Z., Alharbi, A., & Khan, S. (2021). Crowdsourcing usage, task assignment methods, and crowdsourcing platforms: A systematic literature review

ANEXOS

ANEXO 1

Matriz de Consistencia.

Problemas	Objetivos	Hipótesis	Variables	Tipo de Investigación	Diseño de Investigación	Población y Muestra	Técnicas	Herramientas
General	General	General						
¿Cómo se desarrolla un modelo de Inteligencia Artificial Geoespacial (GeoAI) para la optimización de la teledetección de impactos medioambientales causados por los derrames de petróleo en el mar?	Desarrollar un modelo de Inteligencia Artificial Geoespacial (GeoAI) para la optimización de la teledetección de impactos medioambientales causados por los derrames de petróleo en el mar.	El desarrollo de un modelo de Inteligencia Artificial Geoespacial (GeoAI) optimiza la teledetección de impactos medioambientales causados por los derrames de petróleo en el mar.						
Específicos	Específicos	Específicos						
¿Cómo se crea y preprocesa experimentalmente un dataset de imágenes de radar estandarizado de derrames de petróleo en el mar usando Sistemas de Información Geográfica (SIG) y Teledetección?	Crear y preprocesar experimentalmente un dataset de imágenes de radar estandarizado de derrames de petróleo en el mar.	La creación y preprocesamiento de un dataset de imágenes de radar estandarizado de derrames de petróleo del mar de Ventanilla – Lima, se obtiene a través de un Sistema de Información Geográfica (SIG) que delimita el área de estudio y de la Teledetección para la corrección de parámetros físicos de las imágenes.					Análisis Documental	Recopilación de Geodatos. Softwares: ArcGIS PRO
¿De qué forma se compara las mejores técnicas de entrenamiento de modelos de Inteligencia Artificial existentes para la elección óptima de un modelo base en la detección de derrames de petróleo en el mar?	Comparar las mejores técnicas de entrenamiento de modelos de Inteligencia Artificial existentes para la elección óptima de un modelo base en la detección de derrames de petróleo en el mar.	La comparación de las mejores técnicas de entrenamiento de modelos de Inteligencia Artificial en segmentación semántica existentes permite la elección óptima de un modelo base en la detección de derrames de petróleo en el mar...	Variable Independiente Inteligencia Artificial Geoespacial (GeoAI).	La investigación es de tipo Experimental debido a que se manipulan las variables como la arquitectura del modelo.	El Enfoque es Cuantitativo ya que se manipularán las variables y métricas.	Población: Dataset de Imágenes de Radar de Apertura Sintética (SAR) de Derrames de Petróleo en el mar a nivel Mundial.	Modelamiento	Aprendizaje Profundo: Convolutional Neural Network (CNN) Lenguaje de programación: Python Programas y Servicios en línea: Pythorch, Google Colab / Jupyter Notebook
¿De qué manera se diseña un modelo de Inteligencia Artificial Geoespacial (GeoAI) con altas métricas de validación que permita la clasificación del entorno geoespacial cercano a los derrames de petróleo en el mar?	Diseñar un modelo de Inteligencia Artificial Geoespacial (GeoAI) con altas métricas de validación que permita la clasificación del entorno geoespacial cercano a los derrames de petróleo en el mar.	El diseño de un modelo GeoAI denominado ReImprovedDeepLabV3+, que incorpora un backbone ResNet50 mejorado con atención por canal ECANet, un módulo ASFP con StripePooling y un mecanismo de Atención Polarizada dual, alcanza altas métricas de validación y permite clasificar el entorno geoespacial cercano a los derrames de petróleo en el mar.	Variable Dependiente Impactos medioambientales producidos por derrames de petróleo en el mar		El Alcance es Aplicativo puesto que mejora la identificación de los derrames de petróleo en el mar usando la Inteligencia Artificial Geoespacial (GeoAI).	Muestra: Dataset de Imágenes de Radar de Apertura Sintética (SAR) de Derrames de Petróleo en el mar en Ventanilla, Lima, Perú.	Simulación	Métricas de Evaluación: Exactitud, Precisión, Sensibilidad, Intersección sobre Unión, Puntuación F1, Dice Boundary F1, Pixel Accuracy, Matriz de Confusión y ROC AUC (Área Bajo la Curva de Características Operativas del Receptor)
¿Cómo se valida el modelo de Inteligencia Artificial Geoespacial (GeoAI) a través de una framework que detecta y cuantifica los impactos medioambientales producidos por los derrames de petróleo en el mar?	Validar el modelo de Inteligencia Artificial Geoespacial (GeoAI) a través de una framework que detecta y cuantifica los impactos medioambientales producidos por los derrames de petróleo en el mar.	El framework de validación basado en Streamlit, que integra el modelo ReImprovedDeepLabV3+, permite la detección y cuantificación de derrames de petróleo en imágenes SAR basado en cálculo y cuantifique los impactos de desempeño, como: Precision, Recall, F1-Score e IoU y métricas de impacto, como cantidad de píxeles y porcentaje de área afectada.					Publicación	Servicios/Mapas en línea


ANEXO 2

Operacionalización de Variables.

Variable	Tipo	Definición Conceptual	Dimensión	Indicadores	Escala de medición
Inteligencia Artificial Geoespacial	Independiente	La GeoAI es una nueva disciplina en la cual convergen las innovaciones de la Inteligencia Artificial (DL, Deep Learning), la minería de datos y el alto rendimiento computacional para generar conocimiento, a partir del modelado de exposición en entornos espaciales y ambientales puesto que incluye la no estacionariedad espacial y la escalabilidad en su análisis de las grandes cantidades de datos espaciales.	Tecnológica		
			Inteligencia Artificial (Deep Learning)	Redes Neuronales Convolucionales	Razón
			Teledetección	Imágenes Satelitales de Radar de Apertura Sintética (SAR)	Razón
Teledetección de impactos medioambientales por derrames de petróleo en el mar.	Dependiente	La Teledetección de impactos medioambientales por derrames de petróleo en el mar, se refiere a la identificación de la contaminación producto del vertido de petróleo en cuerpos de agua. El objetivo principal de la teledetección de impactos medioambientales es proteger los recursos naturales, conservar la biodiversidad y mantener la integridad de los ecosistemas marinos como indica el Objetivo de Desarrollo Sostenible N°14.	Ambiental	Social	Ordinal
				Económico	Ordinal


ANEXO 4

Cronograma de actividades durante la Investigación



ANEXO 5

Mapa de derrame de petróleo en Ventanilla.



Nota. Tomado del Informe de Adjuntía N° 001-2023-DP/AMASPPI, Derrame de petróleo en Ventanilla: Reporte a un año del desastre ambiental y social en nuestro litoral. Fuente: Defensoría del Pueblo (2023).

ANEXO 6

Ecosistema afectado por el derrame de petróleo en Ventanilla.



Nota. Tomado del Informe de Adjuntía N° 001-2023-DP/AMASPPI, Derrame de petróleo en Ventanilla: Reporte a un año del desastre ambiental y social en nuestro litoral. Fuente: Defensoría del Pueblo (2023).

ANEXO 7

Solicitud de “Oil Spill Detection Dataset”.



OIL SPILL DETECTION DATASET

I would like to become a registered collaborator of the ROBORDER project to pursue the following research:

“Prevention of environmental impacts caused by oil spills at sea using Geospatial Artificial Intelligence and Voluntary Geographic Information”.

Marine pollution occurs in 47% due to natural processes such as seismic events, limited leaks, outcrops, etc., while 53% is due to anthropogenic origin, as a product of the exploration of natural resources in deep water reserve deposits and the marine transportation industry, the latter being the one that can transport large volumes of oil and gas that increase the risk of accidents and spills in the sea and oceans. The present work arose from this problem of global scope and was driven by the largest marine environmental disaster in Peru that occurred on January 15, 2022, where the spill of 12,000 barrels of oil spilled on the Peruvian coast in Ventanilla district, Department of Lima by La Pampilla refinery, operated by REPSOL company. Therefore, this research aims to create an integrated system of Geospatial Artificial Intelligence (GeoIA) and Voluntary Geographic Information (VGI) to improve the prevention and reduction of environmental impacts caused by oil spills at sea.

I agree with the ROBORDER “Oil spill detection” dataset Terms of Use and will take responsibility for the use of the data by any students in my research group.

I also agree that ROBORDER can include my name, my position, my institution, and the title of my research topic on its public Web page and other documents. If I cease work on ROBORDER “Oil spill detection” data, then this collaboration will be listed with an ending date.

I agree that there will be references to:

1. Krestenitis, M., Orfanidis, G., Ioannidis, K., Avgerinakis, K., Vrochidis, S., & Kompatsiaris, I. (2019). Oil Spill Identification from Satellite Images Using Deep Neural Networks. *Remote Sensing*, 11(15), 1762.
2. Krestenitis, M., Orfanidis, G., Ioannidis, K., Avgerinakis, K., Vrochidis, S., & Kompatsiaris, I. (2019, January). Early Identification of Oil Spills in Satellite Images Using Deep CNNs. In *International Conference on Multimedia Modeling* (pp. 424-435). Springer, Cham.

Ciro Rodríguez Rodríguez / Doctoral advisor / National University of San Marcos

Prof. Dr. Ciro Rodríguez Rodríguez

National University Mayor of San Marcos <https://sistemas.unmsm.edu.pe/site/index.php>

Movil: +51 990427136 Email: crodriguezro@unmsm.edu.pe <https://orcid.org/0000-0003-2112-1349>

UNIVERSIDAD NACIONAL MAYOR DE SAN MARCOS
Calle Germán Amezaga N° 375 - Lima, Perú/ Central (511) 6197000
www.unmsm.edu.pe

Nota. La solicitud fue realizada por el asesor de tesis Dr. Ciro Rodríguez Rodríguez a pedido de los creadores del dataset.

ANEXO 8

Respuesta a la Solicitud de “Oil Spill Detection Dataset”.

----- Forwarded message -----

De: **Marios Krestenitis** <mikrestenitis@iti.gr>

Date: mar, 23 jul 2024 a las 2:43

Subject: Re: Request for Oil Spill Detection Dataset

To: CIRO RODRIGUEZ RODRIGUEZ <crodriguezro@unmsm.edu.pe>

Dear Professor,

you can download the dataset via the following link:

<https://mklab.iti.gr/files/oil-spill-detection-dataset.zip>

Best regards,

Marios Krestenitis

--

Marios Krestenitis

Research Associate

Multimodal Data Fusion and Analytics Group

Multimedia Knowledge and Social Media Analytics Lab

Information Technologies Institute

Centre for Research and Technology Hellas

email: mikrestenitis@iti.gr

website: <https://mda.iti.gr/> | <https://mklab.iti.gr/>

ΔΗΛΩΣΗ ΕΜΠΙΣΤΕΥΤΙΚΟΤΗΤΑΣ: Οι πληροφορίες που περιλαμβάνονται στο παρόν μήνυμα ηλεκτρονικού ταχυδρομείου με τα τυχόν συνημμένα σε αυτό είναι εμπιστευτικές, εκτός εάν το μήνυμα αναφέρει συγκεκριμένα ότι το περιεχόμενό του μπορεί να αποκαλυφθεί και προορίζεται αποκλειστικά για χρήση από τον ή τους προβλεπόμενους αποδέκτες. Ειδοίζεται επίσης οι πληροφορίες να προστατεύονται από το νομικό απόρρητο ή με άλλο τρόπο.

Εάν δεν είστε ο προβλεπόμενος παραλήπτης αυτής της επικοινωνίας, λάβετε υπόψη ότι τυχόν αποκάλυψη, αντιγραφή, διανομή ή χρήση των πληροφοριών που περιέχονται ή επισυνάπτονται σε αυτό το μήνυμα απαγορεύεται αυστηρά. Παρακαλούμε, αποφύγετε να αποκαλύψετε το περιεχόμενό του σε τρίτους, ειδοποιήστε τον αποστολέα αμέσως και φροντίστε να διαγράψετε οριστικά το ηλεκτρονικό μήνυμα (συμπεριλαμβανομένων τυχόν συνημμένων σε αυτό) από το σύστημά σας αρχειοθέτησής σας. Οι επικοινωνίες στο Διαδίκτυο δεν είναι ασφαλείς και επομένως, ο αποστολέας/ΕΚΕΤΑ δεν αποδέχεται καμία ευθύνη για το περιεχόμενο αυτού του μηνύματος και για οποιαδήποτε ζημιά τυχόν προκληθεί από μεταδοόμενους ιούς.

CONFIDENTIALITY NOTICE: The information in this email and any attachments thereto are confidential, except where the e-mail specifically states that its contents can be disclosed, and is intended solely for the use of its intended recipient(s). It may also be subject to legal privilege or otherwise protected from disclosure.

If you are not the intended recipient of this communication, you are hereby notified that any disclosure, copying, distribution, or use of the information contained in or attached to this e-mail is strictly prohibited. Please refrain from disclosing its contents to any third party, but notify the sender immediately and make sure to delete and permanently destroy the e-mail (including any attachments thereto) from your filing systems. Internet communications are not secure and therefore sender/CERTH does not accept any liability for the contents of this message and for any damage whatsoever that may be caused by viruses.

Nota. La solicitud fue respondida por Marios Krestenitis al asesor de tesis Dr. Ciro Rodríguez.

ANEXO 9

Solicitud de imágenes satelitales a CONIDA.

Lima, 02 de julio del 2024

Dr. Cayo Víctor León Fernández,
Director de Posgrado Facultad de Ingeniería de Sistemas e Informática

Presente. -

Asunto: Solicitud de imágenes satelitales a CONIDA
(Comisión Nacional de Investigación y
Desarrollo Aeroespacial).

De mi consideración:

Es grato dirigirme a usted para expresarle un cordial saludo, y asimismo presentarme, soy el Ing. Alexander Eduardo Inga Alva, identificado, con DNI N° 07493618 y con código de estudiante N° 22207008 quien actualmente cursa el V ciclo del Doctorado en Ingeniería de Sistemas e Informática en la Universidad Nacional Mayor de San Marcos y quien inició su etapa de recolección de datos en la Tesis en el curso Dirección de Investigación III.

Dicha tesis se intitula: *“Prevención de impactos medioambientales producidos por derrames de petróleo en el mar utilizando Inteligencia Artificial Geoespacial e Información Geográfica Voluntaria”*.

De esta manera, para la realización de la tesis es necesario disponer de ciertas imágenes satelitales las cuales serán utilizadas estrictamente para fines de investigación, y posteriormente para el planteamiento y desarrollo de la Tesis de Doctorado. Asimismo, el detalle del requerimiento para la realización de la investigación se encuentra en el documento adjunto, donde se delimita tanto temporal como espacialmente, el área de interés.

Por lo tanto, recorro a su digno despacho para solicitarle solicite dichas imágenes satelitales de esta área del norte de Lima al correo:

mespa@conida.gob.pe

y dirigido al Mayor General FAP Roberto Antonio Melgar Sheen, Jefe Institucional de la Comisión Nacional de Investigación y Desarrollo Aeroespacial del Perú – CONIDA. Aprovecho la oportunidad para reiterarle mi especial consideración y estima personal.

Atentamente,




Mg. Ing. Alexander Eduardo Inga Alva
Universidad Nacional Mayor de San Marcos
Correo: alexander.inga@unmsm.edu.pe
Celular: 947746318
DNI N° 07493618

Adjunto:
Mapa con detalles.

MAPA CON DETALLES DE LA SOLICITUD

Imágenes multiespectrales e Hyperespectrales del satélite PeruSat-1 o de cualquier otra misión con el que cuente CONIDA, desde el 15 de enero del 2022 hasta la actualidad y perteneciente a la zona delimitada en el mapa adjunto. Sistema de Referencia: UTM WGS 84_18 S



LEYENDA	
●	Vértices
□	Área de Interés

VERTICE	X (m)	Y (m)
V1	247000	8714789
V2	267500	8714789
V3	267500	8675000
V4	247000	8675000

ZONA NORTE DE LIMA

Sistema de Referencia:
UTM WGS 84_18 S

1:200,000

0 5 Km

ANEXO 10

Respuesta de la Solicitud de imágenes satelitales a CONIDA.

AGENCIA ESPACIAL
DEL PERU CONIDA

"Decenio de la Igualdad de Oportunidades para Mujeres y Hombres"
"Año del Bicentenario, de la consolidación de nuestra Independencia, y de la
conmemoración de las heroicas batallas de Junín y Ayacucho"



BICENTENARIO
PERU 2021

AGENCIA ESPACIAL DEL PERÚ - CONIDA

ACTA DE ENTREGA DE PRODUCTOS DE IMÁGENES SATELITALES N° 075-2024

Lima, 03 de septiembre del 2024

Por medio de la presente, la Dirección de Aplicaciones Espaciales y Geomática (DIAPG), hace entrega de las siguientes Imágenes / Productos, solicitados por:

Entidad: Universidad Nacional Mayor de San Marcos

Representante: Inga Alva Alexander Eduardo

DNI: 07493618

Area/Dirección: Ingeniería de Sistema e Informática

Cargo: Tesista

Correo: IngaAlva@gmail.com

Telefono: 947746318

Los productos imagen solicitados, que se describen a continuación no serán utilizados nunca en contra de los intereses del Estado o en intereses que pongan en peligro la seguridad y/o los intereses nacionales. Así mismo, de corresponderme me comprometo a administrar y controlar el adecuado uso, el destino y la custodia de las imágenes recibidas.

Detalle del Producto	Fecha		Zona	Sensor	Fecha Inicio	Fecha Fin	Formato	
	Elaboración	Cantidad					Formato	Entrega
Imágenes SAR	2024-09-03	1	18	TerraSAR-X	2024-09-03	2024-09-03	Digital	Geotiff

Motivo:

Solicitud de Imágenes SAR

- El costo referencial está basado al costo promedio por kilómetro cuadrado en el mercado internacional de imágenes satelitales.
- Las imágenes satelitales entregadas no generaron un gasto para la institución solicitante, representando un ahorro para el estado peruano.
- Todo tipo de información cartográfica y temática que se desarrolle con las imágenes procedentes del satélite PeruSAT-1 e imágenes obtenidas de la constelación Pleiades 1A/B, SPOT 6/7, TerraSAR-X, TanDEM-X a través del Offset 3, deben ser declarados como datos fuente.
- Las imágenes satelitales entregadas serán empleadas para los fines que fueron solicitadas.

Link de Encuesta: <https://forms.gle/M6tftk58fatcuPSM38>

José Jesús Pasapera Gonzales

Inga Alva Alexander Eduardo