

UNIVERSIDAD NACIONAL AMAZÓNICA DE MADRE DE DIOS
FACULTAD DE INGENIERÍA
ESCUELA ACADÉMICO PROFESIONAL DE INGENIERÍA
FORESTAL Y MEDIO AMBIENTE



TESIS

**“ANÁLISIS DE LA VARIACIÓN ESPACIAL-ESTACIONAL DEL USO DEL
SUELO POR MINERÍA DE ORO MEDIANTE EL SENSOR SAR
SENTINEL-1 EN LOS SECTORES DE LA PAMPA Y GUACAMAYO –
MADRE DE DIOS, PERIODO 2021”**

**PARA OPTAR EL TÍTULO PROFESIONAL DE: INGENIERO
FORESTAL Y MEDIO AMBIENTE**

AUTORES:

Bachiller:

APAZA CHOQUE, Javier Fritsch

ASESOR:

Dr. Alarcón Aguirre. Gabriel

CO-ASESOR:

M.Sc. Garate Quispe Jorge S.

Puerto Maldonado, setiembre de 2023

UNIVERSIDAD NACIONAL AMAZÓNICA DE MADRE DE DIOS

FACULTAD DE INGENIERÍA

**ESCUELA ACADÉMICO PROFESIONAL DE INGENIERÍA
FORESTAL Y MEDIO AMBIENTE**



TESIS

**“ANÁLISIS DE LA VARIACIÓN ESPACIAL-ESTACIONAL DEL USO DEL
SUELO POR MINERÍA DE ORO MEDIANTE EL SENSOR SAR
SENTINEL-1 EN LOS SECTORES DE LA PAMPA Y GUACAMAYO –
MADRE DE DIOS, PERIODO 2021”**

**PARA OPTAR EL TÍTULO PROFESIONAL DE: INGENIERO
FORESTAL Y MEDIO AMBIENTE**

AUTORES:

Bachiller:

APAZA CHOQUE, Javier Fritsch

ASESOR:

Dr. Alarcón Aguirre. Gabriel

CO-ASESOR:

M.Sc. Garate Quispe Jorge S.

Puerto Maldonado, setiembre de 2023

DEDICATORIA

Quiero dedicar mi tesis a DIOS, por todas las bendiciones que me brinda día a día, se que sin su guía y su amor incondicional no habría podido llegar hasta aquí, por darme la fuerza y sabidura para enfrentar los retos para concluir este proyecto de tesis, y la oportunidad de aprender y crecer a través de este proceso de investigación.

Esta tesis es un homenaje a mis padres, aunque ya no esten físicamente conmigo, se que siempre han estado guiándome y apoyándome desde donde esten. Quiero dedicarles esta tesis a su memoria, como un acto de gratitud y reconocimiento por todo lo que han hecho por mi.

A mis hermanos Noidy, Julio, Marleny, Luis, Luz Marina, en especial a mi hermano Fredy, que ha estado a mi lado desde el principio brindándome sus animos, sus consejos, se que sin su presencia no habría podido llegar hasta aquí. Quiero dedicarte este logro.

AGRADECIMIENTOS

Agradecer a Dios, por darme salud, sabidura, y cuidar de mi y de mi familia, muy agradecido, quiero expresar mi mas sincero agradecimiento a la Universidad Nacional Amazonica de Madre de Dios, por darme la oportunidad de llevar este proceso académico y brindarme un espacio donde pude desarrollar mi potencial y adquirir conocimientos.

Agradezco a los profesores que me han guidado y asesorado en esta vida universitaria, gracias por compartir sus conocimientos, al Dr. Emer Rosales, por apoyo constante durante mi carrera universitaria, al Dr. Gabriel Alarcon por su apoyo constante y su guía durante este proceso de investigación.

Agradecer a mis padres, Domingo Erasmo, Cirila, por haber sido modelos a seguir, por enseñarme los valores y principios, que con orgullo llevo en mi vida diaria, siempre llevare su amor y su legado en mi corazón y en mi mente, los extraño mucho y se que siguen siendo mi guía y mi inspiración.

A mis hermanos quiero darles las gracias por haberme escuchado en mis momentos de incertidumbre y motivarme a seguir adelante, a mi hermano Fredy Gracias por ser mi hermano y por ser mi amigo en todo momento, a Maritza por su apoyo incondicional en este proceso.

TURNITIN_JAVIER APAZA CHOQUE

INFORME DE ORIGINALIDAD

18%

INDICE DE SIMILITUD

17%

FUENTES DE INTERNET

5%

PUBLICACIONES

5%

TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	repositorio.unamad.edu.pe Fuente de Internet	10%
2	bella-programme.redclara.net Fuente de Internet	1%
3	Submitted to Universidad Nacional Amazonica de Madre de Dios Trabajo del estudiante	1%
4	Submitted to Universidad Catolica de Manizales Trabajo del estudiante	<1%
5	idoc.pub Fuente de Internet	<1%
6	hdl.handle.net Fuente de Internet	<1%
7	savoirs.usherbrooke.ca Fuente de Internet	<1%
8	Jiayong Liang, Desheng Liu. "A local thresholding approach to flood water delineation using Sentinel-1 SAR imagery",	<1%

Resumen

El monitoreo de áreas expuestas a inundaciones o alta presencia de humedad requiere información oportuna sobre la extensión del agua, que puede generarse mediante sensores remotos basados en satélites. Dado que el radar de apertura sintética (SAR) puede emitir y recibir señales durante la noche o en condiciones de nubosidad, es especialmente adecuado para delinear la extensión del agua o humedad en zonas que requiera detectarse, como lo es la minería de oro. Sin embargo, la mayoría de los métodos de umbralización se basan en un solo umbral para separar el agua y la tierra sin tener en cuenta la complejidad y la variabilidad de los diferentes tipos de superficie terrestre en una imagen. Para tener en cuenta las características heterogéneas de la superficie, esta investigación propone un método de umbralización mediante la adaptación del Índice de Degradación Forestal por Radar (aRDFI). Para detectar el uso y cambio de cobertura. El método implica aplicar la aRDFI del sensor Sentinel-1 banda C con polarizaciones VV y VH en tres periodos estacionales; marzo-abril, agosto-septiembre, y noviembre-diciembre de 2021, con la finalidad de evaluar la cobertura de minería de oro y sus cambios. Los valores de la aRDFI para la minería de oro se cuantifico para el 29 de marzo de 8 250,42 ha, 12 223,39 ha para el 20 de agosto y 9 143,96 ha para el 18 de diciembre. En cuanto a la precisión, se cuantifico un modelo general de 64,80% y una concordancia de kappa de 0,585 (Moderada) para el primer periodo, 67,60% y de 0,619 (Considerable) para el segundo, y 66,10% y una concordancia de 0,600 (Moderada) para el tercer periodo. En relación a los cambios de la minería de oro de los tres periodos estacionales, reporta un incremento de superficie del primer al segundo periodo de 3 972,97 ha, mientras que del segundo al tercer periodo existe un decremento de 3 079,43 ha. Los resultados marcan una mayor área en la época de menor precipitación que no necesariamente contrasta con la activación de área mineras con aguas de disposición residual, que podría suponer una mayor cuantificación.

Palabras clave: Sensor activo, banda-c, polarización, retrodispersión, aRDFI.

Abstract

Monitoring areas exposed to flooding or high humidity requires timely information on water extent, which can be generated by satellite-based remote sensors. Since synthetic aperture radar (SAR) can emit and receive signals at night or in cloudy conditions, it is particularly suitable for delineating the extent of water or moisture in areas requiring detection, such as gold mining. However, most thresholding methods rely on a single threshold to separate water and land without taking into account the complexity and variability of the different types of land surface in an image. To account for heterogeneous surface characteristics, this research proposes a thresholding method by adapting the Radar-based Forest Degradation Index (aRDFI). To detect land use and cover change. The method involves applying the aRDFI to the Sentinel-1 C-band Sentinel-1 sensor with VV and VH polarizations in three seasonal periods; March-April, August-September, and November-December 2021, in order to evaluate the gold mining coverage and its changes. The aRDFI values for gold mining were quantified for March 29 as 8 250.42 ha, 12 223.39 ha for August 20 and 9 143.96 ha for December 18. In terms of accuracy, a general model of 64.80% and a kappa co-match of 0.585 (Moderate) was quantified for the first period, 67.60% and 0.619 (Considerable) for the second period, and 66.10% and a match of 0.600 (Moderate) for the third period. In relation to the changes in gold mining in the three seasonal periods, it reports an increase in area from the first to the second period of 3,972.97 ha, while from the second to the third period there is a decrease of 3,079.43 ha. The results show a greater area in the period of lower precipitation that does not necessarily contrast with the activation of mining areas with residual disposal water, which could imply a greater quantification.

Key words: Active sensor, band-c, polarization, backscatter, aRDFI.

Índice de contenidos

	Pág.
Dedicatoria	i
Agradecimientos	ii
Resumen	iii
Abstract	iv
Introducción	1
CAPÍTULO I: PROBLEMA DE INVESTIGACIÓN	17
1.1 Descripción del problema	17
1.2 Formulación del problema	18
1.2.1 Problema general.....	18
1.2.2 Problemas específicos	18
1.3 Objetivos de la investigación	19
1.3.1 Objetivo general.....	19
1.3.2 Objetivos específicos	19
1.4 Variables de la investigación.....	19
1.4.1 Identificación de variables.....	19
1.5 Operacionalización de variables	20
1.6 Hipótesis	21
1.7 Justificación e importancia	21
1.8 Consideraciones éticas.....	22
CAPÍTULO II: MARCO TEÓRICO	23
2.1 Antecedentes de la investigación.....	23
2.2 Base teórica	28
2.2.1 Minería de oro en Madre de Dios	28

2.2.2 Deforestación.....	29
2.2.3 Bosque	30
2.2.4 Sistemas de Información Geográfica (SIG).....	30
2.2.5 Sensoramiento remoto	30
2.2.6 Energía electromagnética	31
2.2.7 Teledetección activa y pasiva	34
2.2.8 Plataforma y sensores	35
Sensores	35
Plataformas	36
2.2.9 Escáneres multiespectrales	36
2.2.10 RADAR	37
Geometría de visualización de radar	38
Resolución espacial.....	40
Distorsiones en imágenes de radar	41
Clasificación de imágenes digitales	42
Proceso de clasificación de imágenes	42
Algoritmos de clasificación.....	43
2.2.11 Softwares de procesamiento de imágenes	43
SNAP ESA.....	43
Google Earth Engine	44
ENVI.....	44
ArcMap.....	44
ArcGIS Pro	44
2.2.12 Programa Copérnico.....	44
Sentinel-1	45
2.3 Definición de términos	47

CAPÍTULO III: METODOLOGÍA DE INVESTIGACIÓN.....	49
3.1 Tipo de estudio	49
3.2 Diseño del estudio	49
3.3 Delimitación espacial y temporal.....	49
3.3.1 Clima e hidrografía	50
3.4 Población y muestra	51
3.5 Método y técnicas	53
3.6 Tratamiento de datos	55
3.6.1 Procesamiento de datos	55
□ Tratamiento y análisis de la imagen SAR	56
3.6.2 Precisión de datos	59
3.6.4 Análisis estadístico	62
CAPÍTULO IV: RESULTADOS Y DISCUSIÓN	63
4.1 Retrodispersión del SAR Sentinel-1 en el sector de la Pampa y Guacamayo en periodos estacionales	63
4.1.1 Adaptación del Índice de degradación forestal por radar (aRFDI)	68
4.2 Evaluación de precisión de índice.....	75
4.3 Cambios de uso de suelo	78
CONCLUSIONES.....	84
SUGERENCIAS	85
REFERENCIAS BIBLIOGRÁFICAS.....	86
ANEXOS	106

Índice de Tablas

	Pág.
Tabla 1. Operacionalización de variables	20
Tabla 2. Características de la imagen de satélite Sentinel-1	46
Tabla 3. Información de adquisición de imágenes Sentinel-1	55
Tabla 4. Características de la imagen de satélite Sentinel-1	55
Tabla 5. Árbol de decisión para la clasificación del uso de suelo y cambio de cobertura por minería de oro mediante el SAR Sentinel-1	58
Tabla 6. Valores del coeficiente kappa	59
Tabla 7. Cuantificación de la aRFDI para los periodos estacionales 2021 ...	72
Tabla 8. Superficie de minería de oro respecto al área total de estudio	74
Tabla 9. Matriz de confusión e Índice de kappa de datos de campo e imágenes frente a datos de la aRFDI de Sentinel-1 29/03/2021	75
Tabla 10. Matriz de confusión e Índice de kappa de datos de campo e imágenes frente a datos de la aRFDI de Sentinel-1 20/08/2021	76
Tabla 11. Matriz de confusión e Índice de kappa de datos de campo e imágenes frente a datos de la aRFDI de Sentinel-1 18/12/2021	77
Tabla 12. Cambio de cobertura de periodo estacional (1) y (2).....	81
Tabla 13. Cambio de cobertura de periodo estacional (2) y (3).....	82
Tabla 14. Tasa y cambio de cobertura de minería de oro por periodo estacional	82

Índice de Figuras

	Pág.
Figura 1. Un sensor de detección remota mide la energía reflejada o emitida. Un sensor activo tiene su propia fuente de energía.	32
Figura 2. Vectores eléctricos (E) y magnéticos (M) de una onda electromagnética.	33
Figura 3. Relación entre longitud de onda, frecuencia y energía.	33
Figura 4. El espectro electromagnético.	34
Figura 5. Descripción general de los sensores.	36
Figura 6. Ángulo de incidencia del radar y ángulo de incidencia local.	39
Figura 7. Distorsiones geométricas en RADAR.	40
Figura 8. El proceso de clasificación; El componente más importante es el entrenamiento en combinación con la selección del algoritmo.	43
Figura 9. Distribución de muestras distribuidas al azar por estratos en el área de estudio.	52
Figura 10. Validación de bosque (a, f, g), minería (b, f, g), agua (c, f, g), pastos (d, f, g), vegetación secundaria (e, f, g), agricultura (f, g) y urbano (f, g) con imágenes de Drone de 0,03 m x 0,03 m (a, b, c, d), WorldView de 0,38 m x 0,38 m de resolución espacial (f) e imágenes PlanetScope de 3 m x 3 m de resolución espacial (g).	61
Figura 11. Polarización VV de banda C de SAR Sentinel-1 de marzo-abril de 2021.	64
Figura 12. Polarización VV de banda C de SAR Sentinel-1 de agosto-septiembre de 2021.	65
Figura 13. Polarización VH de banda C de SAR Sentinel-1 de marzo-abril de 2021.	65
Figura 14. Polarización VH de banda C de SAR Sentinel-1 de agosto-septiembre de 2021.	65

Figura 15. Polarizacion VH de banda C de SAR Sentinel-1 de noviembre-diciembre de 2021.	66
Figura 16. Polarizacion VV de banda C de SAR Sentinel-1 de noviembre-diciembre de 2021.	66
Figura 17. Adaptación del Índice de degradación forestal por radar (aRFDI) del Satélite Sentinel-1 (20/08/2021), con polarizaciones VV y VH; a. Urbano, b. Bosques, c. Vegetacion secundaria, d. Agricultura y pasto, e. Minería, y f. Agua.....	67
Figura 18. Adaptación del Índice de degradación forestal por radar (aRFDI) del Satélite Sentinel-1 (29/03/2021).....	71
Figura 19. Adaptación del Índice de degradación forestal por radar (aRFDI) del Satélite Sentinel-1 (20/08/2021).....	71
Figura 20. Adaptación del Índice de degradación forestal por radar (aRFDI) del Satélite Sentinel-1 (18/12/2021).....	72
Figura 21. Cuantificación de la aRFDI para los peiorodos estacionales 2021	73
Figura 22. Cambio de cobertura de periodo estacional (1), (2), y (3).	79
Figura 23. Cambios de cobertura en la polacion VV en el periodo estacional 2021.	80
Figura 24. Cambios de cobertura en la polacion VH en el periodo estacional 2021.	81

Índice de anexos

	Pág.
Anexo 1. Matriz de consistencia.	107
Anexo 2. Puntos de muestreo distribuidos al azar por estratos en los sectores de La Pampa y Guacamayo, 2021.....	108
Anexo 3. Panel fotográfico.....	117

Introducción

La deforestación en la Amazonia y degradación del suelo como producto de la pérdida de bosques destinados a otros usos generan una preocupación global, debido a que los bosques de la Amazonia representan un bastión fundamental para atenuar el cambio climático (Alarcón et al. 2016; Puzzi et al. 2020; Alarcon et al. 2021; Puzzi et al. 2021) y albergan la mayor biodiversidad del planeta (Reynolds et al. 2007; Coelho et al. 2016; Cabral et al. 2018). La mayor selva tropical del mundo se encuentra en la Amazonia y los peligros que afrontan han sido documentadas por la comunidad científica (Perz et al. 2013; Perz et al. 2016; Alarcon et al. 2020; Puzzi et al. 2020; Garate-Quispe et al. 2021; Puzzi et al. 2021). Para enfrentar estos peligros los países Amazónicos, tales como Brasil, Colombia, Bolivia y Perú vienen monitoreando a través de información satelital óptica y RADAR la pérdida de bosque, así como su alerta temprana (IDEAM 2010; INPE 2020a; INPE 2020b; MINAM 2020; RAISG 2020a; RAISG 2020b).

Comprender los procesos de cambio de uso de la tierra y cobertura terrestre (CUTCT) que generan la pérdida de bosques es primordial para encaminar programas y políticas de gestión del territorio (GOREMAD y IIAP 2009). Por lo tanto, identificar los motores de la pérdida de bosques es fundamental en el sensoramiento (Puzzi et al. 2020; Alarcon et al. 2021; Puzzi et al. 2021). En la actualidad, los datos disponibles para identificar y cuantificar la deforestación (Alarcon et al. 2021), se realiza mediante datos de satélite ópticos (Jiang et al. 2006; Chirif 2018; Dong et al. 2019; Elias et al. 2020; INPE 2020b) y enfocados a un alcance regional y global (RAISG 2020a; Puzzi et al. 2021), con información específica limitada (Puzzi et al. 2020; Alarcon et al. 2021; Puzzi et al. 2021). A nivel de la Amazonia existen varios proyectos con la misión de monitorear el suelo y mapear la pérdida de bosques; El proyecto TerraClass PRODES de Brasil (INPE 2020a; INPE 2020b; RAISG 2020a), el Ministerio del Ambiente de Perú mediante la plataforma GeoBosques (MINAM 2020), entre otros sistemas de otros países Amazónicos. Sin embargo, estos sistemas de monitoreo se basan en sensores ópticos que están fuertemente influenciados por los efectos del clima (McNairn et al. 2009), que en muchos

casos representan barreras en la alerta temprana (McNairn et al. 2009; Puzzi et al. 2020; Alarcon et al. 2021; Puzzi et al. 2021). La Amazonia de Madre de Dios presenta una condición de nubosidad persistente (60-100%) durante un período de 8-10 meses, lo que limita el uso de sensores ópticos en la detección y cuantificación del cambio de uso de la tierra y cobertura terrestre, como tipos de cultivo o tipos de pasturas (Caballero et al. 2018; Puzzi et al. 2020; Alarcon et al. 2021; Puzzi et al. 2021). En este contexto, los sensores de radar de apertura sintética (SAR) presenta una alternativa y una ventaja para cuantificar CUTCT en la Amazonia, ya que tienen capacidad para atenuar los fenómenos climáticos y cubren cualquier periodo del año, asimismo aportan información como textura, estructura y humedad mediante copolarizaciones (Vertical-V; Vertical-V, Horizontal-H; Horizontal-H) y polarizaciones cruzadas (Vertical-V; Horizontal-H, Horizontal-H; Vertical-V) (Ajadi et al. 2016; Ali et al. 2018; Bouvet et al. 2018; Martins et al. 2018; Zhou et al. 2018; Fikriyah et al. 2019; Nicolau et al. 2019; Liang y Liu 2020).

El uso de información satelital óptica y SAR se han usado ampliamente en CUTCT (Oppenheimer 1998; Jiang et al. 2006; Mariaca y Andrés 2007; McNairn et al. 2009; Chen et al. 2010; Häme et al. 2012; Ou et al. 2012; ESA 2013; Hansen et al. 2013; Potin 2013; Gharbia et al. 2014; Hong et al. 2014; Joshi et al. 2016; Nair y Bindhu 2016; Chatziantoniou et al. 2017; Chirif 2018; De Alban et al. 2018; Erinjery et al. 2018; Lennox et al. 2018; Lesiv et al. 2018; Melchiorri et al. 2018; Rajah et al. 2018; Dong et al. 2019; Mutanga y Kumar 2019; Zhu et al. 2019; Elias et al. 2020; FAO 2020; Huang et al. 2020; Booyesen et al. 2021; Huamani et al. 2021; Puzzi et al. 2021), sin embargo, hasta una década atrás los datos de SAR eran restringidos y focalizadas a ciertas regiones, hoy los datos de Sentinel-1 del Programa Copernicus de la Agencia Espacial Europea representan un potencial sin barreras para el uso de los SAR en el monitoreo de los bosques en todo el mundo desde el 2014 (Potin 2013).

El suroeste de la Amazonia de Madre de Dios está fuertemente afectada por la minería de oro, actividad fuertemente ligada en zonas con presencia de redes hídricas (Asner y Tupayachi 2017; Caballero et al. 2018; Alarcon et al.

2021; Garate-Quispe et al. 2021; Román-Dañobeytia et al. 2021; Velásquez et al. 2021), en ese sentido, el uso de copolarizaciones VV, HH y polarizaciones cruzadas VH, HV permiten una adecuada detección de la textura, estructura y humedad donde se desarrolla la minería aurífera, que a diferencia de los sensores ópticos presentan confusiones con otras categorías con presencia de humedad (Chen et al. 2010; Tanase et al. 2015b; Tanase et al. 2015a; Nicolau et al. 2021).

Por lo tanto, este estudio analiza la variación del uso del suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La Pampa y Guacamayo, mediante la toma de datos de tres periodos estacionales; marzo-abril, agosto-septiembre, y noviembre-diciembre de 2021, con la finalidad de detectar, cuantificar, y analizar la influencia de la variación estacional en la dinámica de uso de suelo por la minería de oro.

CAPÍTULO I: PROBLEMA DE INVESTIGACIÓN

1.1 Descripción del problema

La minería de oro es uno de los procesos más dinámicos en el cambio del uso de suelo y representa una fuerza importante en el cambio en el uso y la cobertura de la tierra (Garate-Quispe et al. 2021; Velásquez et al. 2021). El proceso acelerado de cambio del paisaje por la minería de oro trae consigo impactos negativos en la economía y el ambiente. Para evitar estas consecuencias negativas, es necesario una adecuada gestión del territorio (Caballero et al. 2018; Alarcon et al. 2021), para ello, es fundamental obtener información actualizada y confiable sobre la dinámica de la actividad minera (Puzzi et al. 2020; Puzzì et al. 2021). La tecnología de teledetección mediante sensores ópticos es útil, sin embargo, en actividades que se desarrollan en épocas de alta nubosidad o precipitación, como es la minería de oro, es muy limitado y es poco lo que se puede monitorear (Alarcón et al. 2016; Alarcon et al. 2021). El uso de data para todo clima, así como la penetración del dosel y capacidades de alta resolución, las imágenes del Radar de Apertura Sintética (SAR) superan efectivamente estas limitaciones en la clasificación de la cobertura terrestre.

Investigaciones recientes y pasadas mediante datos SAR proporcionaron informaciones valiosas y por consiguiente toma de decisiones adecuadas (Moran y Brondizio 1998; Lopez-Sanchez et al. 2014; Ajadi et al. 2016; Chen et al. 2016; Ali et al. 2018; Bouvet et al. 2018; Martins et al. 2018; Samat et al. 2018; Albuquerque et al. 2020). El empleo de polarizaciones simples y duales proporcionan información sobre la intensidad, estructura y coherencia de manera efectiva sobre la precisión de la clasificación.

En ese sentido, el estudio planteó el uso del SAR Sentinel-1, que, a diferencia de los sensores ópticos, es una tecnología que atraviesa nubes y humo, y

proporcionara información de la variación espacial y estacional del uso del suelo por la minería de oro en los sectores de La Pampa y Guacamayo. Esta técnica usa una antena de un sensor para proporcionar imágenes de alta resolución, mediante microondas para detectar y cuantificar entre los procesos ecológicos según la rugosidad de la superficie objetivo, y energía de recepción y proceso.

1.2 Formulación del problema

1.2.1 Problema general

¿Cuál es la variación espacial-estacional del uso del suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La pampa y Guacamayo – Madre de Dios en el año 2021?

1.2.2 Problemas específicos

P.E.1 ¿Cuánto es el uso de suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La pampa y Guacamayo en el periodo estacional de marzo-abril de 2021?

P.E.2. ¿Cuánto es el uso suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La pampa y Guacamayo en el periodo estacional de agosto-septiembre de 2021?

P.E.3 ¿Cuánto es el uso de suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La pampa y Guacamayo en el periodo estacional de noviembre-diciembre de 2021?

P.E.4 ¿Cuáles son los cambios de uso del suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La pampa y Guacamayo – Madre de Dios de los periodos estacionales en el año 2021?

1.3 Objetivos de la investigación

1.3.1 Objetivo general

Analizar variación espacial-estacional del uso del suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La pampa y Guacamayo – Madre de Dios en el año 2021.

1.3.2 Objetivos específicos

O.E.1 Cuantificar el uso de suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La pampa y Guacamayo en el periodo estacional de marzo-abril de 2021.

O.E.2. Cuantificar el uso de suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La pampa y Guacamayo en el periodo estacional de agosto-septiembre de 2021.

O.E.3 Cuantificar el uso de suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La pampa y Guacamayo en el periodo estacional de noviembre-diciembre de 2021.

O.E.4 Determinar los cambios de uso del suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La pampa y Guacamayo – Madre de Dios de los periodos estacionales en el año 2021.

1.4 Variables de la investigación

1.4.1 Identificación de variables

Variable Dependiente

- ✓ Comportamiento del suelo y la vegetación en la función de la unidad mínima de la imagen (píxel) y polarizaciones del SAR Sentinel-1 a través de la aRDFI.

Variable Independiente

- ✓ Uso de suelo por minería de oro por periodo estacional en el año 2021.
- ✓ Cambio de cobertura por uso de suelo por la minería de oro en el año 2021.

1.5 Operacionalización de variables

Las variables y su operacionalización de detallan en la Tabla 1.

Tabla 1. *Operacionalización de variables*

Definición conceptual	Definición operacional	Dimensión	Indicadores	Ítems
Variable independiente				
La cuantificación del uso de suelo mediante el sensor SAR Sentinel-1 en los sectores de La pampa y Guacamayo en el periodo estacional de marzo-abril, agosto-septiembre, y noviembre-diciembre de 2021 permite monitorear la superficie de minería de oro.	Cuantificar la cobertura de minería de oro en los sectores de La Pampa y Guacamayo por periodos estacionales en el año 2021.	Dinámica de la cobertura minera mediante aRDFI. Precisión de la aRDFI mediante modelo general y concordancia de Kappa.	Superficie de cobertura de minería de oro (ha).	1
			Matriz de confusión e índice de Kappa.	2
Los cambios de cobertura con la aRDFI permiten comprender los estados y cambios producidos en el medio ambiente y el ecosistema.	Dinámica de cambios de la superficie minera en el año 2021.	Dinámica de la vegetación según NDVI y RVI de sensores ópticos y de radar SAR.	Superficie de cambios de cobertura de minería de oro (ha).	3
Variable dependiente				
Comportamiento del suelo y la vegetación en la función de la unidad mínima de la imagen (píxel) y polarizaciones del SAR Sentinel-1 a través de la aRDFI.	Polarizaciones VV y VH analizadas en la aRDFI.	Rango espectral de índices de aRDFI.	Umbrales de índice.	4

1.6 Hipótesis

Hipótesis nula (H_0): La detección y cuantificación del cambio de cobertura y uso de suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La Pampa y Guacamayo no se produce en mayor proporción en la época estacional de lluvias.

Hipótesis alterna (H_1): La detección y cuantificación del cambio de cobertura y uso de suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La Pampa y Guacamayo se produce en mayor proporción en la época estacional de lluvias.

1.7 Justificación e importancia

La aplicación del sensoramiento remoto es proporcionar información útil en casi tiempo real, minimizando tiempo y costo. Sin embargo, los sensores con tecnología óptica presentan dificultades en épocas con presencia de eventos climáticos; como nubosidad, precipitación, vientos, entre otros fenómenos. El uso de los SAR “no es nuevo, pero tampoco es de amplio conocimiento”, en este contexto, la investigación mediante el empleo de los SAR, generara información en cualquier periodo del año, minimizando los eventos ambientales que pudieran interferir, y brindando una clasificación adecuada del uso del suelo y la cobertura terrestre. En nuestro estudio, la variación espacial estacional producto de la minería de oro, y en base a ello aplicar políticas y medidas de control en cualquier periodo del año.

El objetivo de la investigación fue clasificar el uso del suelo en los sectores de La Pampa y Guacamayo para la minería de oro utilizando el método de árbol de decisión de imágenes de RADAR de Apertura Sintética (SAR). Los expertos del Centro de Teledetección para el Estudio y Gestión de los Recursos Naturales (CETEGERN) brindaron asesoramiento para su ejecución.

1.8 Consideraciones éticas

El estudio emplea métodos de procesamiento de imágenes de apertura sintética RADAR (SAR), incluido software de análisis y procesamiento utilizando la plataforma abierta “SNAP ESA y Google Earth Engine, así como licencias comerciales de ENVI 5.3®, ArcGisPro 2,1® y ArcGIS 10,5® proporcionadas por CETEGERN”. Todo ello se basará en la política interna de la UNAMAD y nacional de la Comisión Nacional de Investigación y Desarrollo Aeroespacial (CONIDA).

CAPÍTULO II: MARCO TEÓRICO

2.1 Antecedentes de la investigación

Janse van Rensburg y Kemp (2022) usaron el SAR de banda C y banda X con aprendizaje automático para detectar minería a pequeña escala. El objetivo de este estudio fue determinar si la clasificación de las imágenes del radar de apertura sintética (SAR) podría detectar y mapear la minería a pequeña escala en Ghana mediante el análisis del filtrado multitemporal aplicado a tres conjuntos de datos SAR y la prueba de cinco clasificadores de aprendizaje automático. Usando un enfoque de análisis de imágenes basado en objetos, logramos clasificar los cuerpos de agua asociados con la minería a pequeña escala. El conjunto de datos Sentinel-1 filtrado multitemporalmente fue el más confiable, con coeficientes kappa de 0,65 y 0,82 para el esquema de clasificación de clases múltiples y el esquema de clasificación de agua binaria, respectivamente. El conjunto de datos Sentinel-1 de fecha única tiene la precisión general más alta, con un 90,93 % para el esquema de clasificación binaria del agua. Por lo tanto, el uso de SAR puede ayudar a los gobiernos locales a regular las actividades de minería a pequeña escala al proporcionar información espacial específica sobre el paradero de las ubicaciones de minería a pequeña escala. Los resultados experimentales demostraron que es posible clasificar el agua como un proxy para identificar actividades de minería ilegal y que SAR es una solución potencialmente precisa y confiable para la detección de SSM en regiones tropicales como Ghana.

Puzzi et al. (2021) evaluaron análisis históricos de SAR desde 2017 hasta 2019, obteniendo una fiabilidad baja (52%). Pero, con resultados satisfactorios para las categorías de bosques y aguas, y mucha imprecisión para la agricultura, la vegetación secundaria y los bosques.

Doblas et al. (2020) optimizaron la detección casi en tiempo real de la deforestación en las selvas tropicales utilizando datos de Sentinel-1. Para ello, establecieron un riguroso experimento de validación en todo el Amazonas utilizando la plataforma Google Earth Engine para muestrear y procesar datos Sentinel-1A de casi 6000 ubicaciones en toda la cuenca amazónica brasileña, generando más de 8 millones de muestras procesadas. La mitad de esas ubicaciones corresponden a áreas forestales no degradadas, mientras que la otra mitad corresponde a áreas deforestadas en 2019. Los resultados de la detección mostraron que el algoritmo de estabilización espacial mejoró los resultados del enfoque MLC, alcanzando una precisión global del 94,36%. El algoritmo de detección de ALT funcionó mejor, alcanzando una precisión global del 95,91%, independientemente del uso de cualquier método de estabilización. Los resultados de este experimento se están utilizando para desarrollar un SAT operativo en la Amazonía brasileña. La mitad de esas ubicaciones corresponden a áreas forestales no degradadas, mientras que la otra mitad corresponde a áreas deforestadas en 2019. Los resultados de la detección mostraron que el algoritmo de estabilización espacial mejoró los resultados del enfoque MLC, alcanzando una precisión global del 94,36%. El algoritmo de detección de ALT funcionó mejor, alcanzando una precisión global del 95,91%, independientemente del uso de cualquier método de estabilización. Los resultados de este experimento se están utilizando para desarrollar un SAT operativo en la Amazonía brasileña. La mitad de esas ubicaciones corresponden a áreas forestales no degradadas, mientras que la otra mitad corresponde a áreas deforestadas en 2019. Los resultados de la detección mostraron que el algoritmo de estabilización espacial mejoró los resultados del enfoque MLC, alcanzando una precisión global del 94,36%. El algoritmo de detección de ALT funcionó mejor, alcanzando una precisión global del 95,91%, independientemente del uso de cualquier método de estabilización. Los resultados de este experimento se están utilizando para desarrollar un SAT operativo en la Amazonía brasileña.

Liang y Liu (2020) desarrollaron un enfoque de umbral local para la delimitación de aguas de inundación utilizando imágenes SAR de Sentinel-1.

La mayoría de los métodos de umbralización se basan en un solo umbral para separar el agua y la tierra sin tener en cuenta la complejidad y la variabilidad de los diferentes tipos de superficie terrestre en una imagen. Para tener en cuenta las características heterogéneas de la superficie, este artículo propone un nuevo método de umbralización local para la delineación del agua con imágenes SAR, específicamente, el método sigue cuatro pasos principales. Primero, se aplica un umbral global a las imágenes SAR para delinear los píxeles de agua iniciales, a partir de los cuales los píxeles que no son de agua se agrupan en varios tipos de superficie terrestre. Esto divide las imágenes SAR en un grupo de agua y varios grupos de tierra. En segundo lugar, los umbrales locales se estiman en cada subconjunto de conglomerados terrestres emparejados con conglomerados de agua ajustando las distribuciones Gamma a la retrodispersión de intensidades de los píxeles combinados de agua/tierra en cada subconjunto. En tercer lugar, las extensiones de agua locales se delimitan a partir de cada subconjunto y luego se fusionan como la unión de todos los subconjuntos. Los resultados se combinan en múltiples polarizaciones al realizar una operación de intersección para generar la extensión global de la inundación. Finalmente, la extensión del agua de inundación se mejora aún más al imponer restricciones hidrológicas básicas. Este enfoque es rápido y totalmente automatizado para la detección de inundaciones. Nuestros experimentos con imágenes SAR de Sentinel-1 muestran que el enfoque de umbral local propuesto podría distinguir el agua de lo que no es agua con una precisión significativamente mayor (4–13 % de mejora en la media armónica de la precisión del agua del usuario y del productor) que los métodos convencionales de umbral global.

Vargas et al. (2019) plantearon una metodología de detección automática de deforestación usando Sentinel-1. El área de estudio se ubica dentro de los bosques húmedos tropicales del Perú y comprende tres áreas piloto de 6717 km², 9,643 km² y 11,251 km², las cuales se ubican en las regiones de San Martín, Ucayali y Madre de Dios respectivamente. La metodología propone una detección automática de la deforestación a partir de los datos de Sentinel-1, adquiridos en modo interferométrico Wide Swath (IW) y utilizando una

polarización VH. La metodología incluye la aplicación del filtro Gamma-Map, el cálculo de imágenes promedio, la aplicación de un algoritmo de detección de deforestación, y la unidad mínima de mapeo fue 1 ha. La metodología fue probada en tres áreas piloto dentro de los bosques húmedos tropicales de Perú, y obtuvo una precisión del usuario superior al 95%. Durante la estación húmeda, también fue posible detectar la deforestación, por lo que esta metodología puede ser utilizada para complementar el vacío de información existente que tienen las metodologías de alerta temprana de deforestación utilizando datos ópticos, especialmente en las zonas donde hay deforestación frecuente asociada a la actividad minera o al cultivo de arrozales.

Li y Bijker (2019) clasificaron los vegetales en Indonesia utilizando la deformación temporal dinámica de la serie temporal SAR de polarización dual Sentinel-1A. Este estudio investiga el potencial de los datos de series de tiempo SAR de polarización dual Sentinel-1A (S1A) para la clasificación de los vegetales en Indonesia. Los vegetales se caracterizan por los cambios temporales de observables extraídos de series temporales de datos S1A. Extrajeron datos observables con respecto a los coeficientes de retrodispersión (VH y VV) y las características de descomposición (es decir, entropía, ángulo y anisotropía). La clasificación de los vegetales se basa en una medida de disimilitud de deformación de tiempo dinámico ponderada en el tiempo que se calcula con la estrategia SPRING para la búsqueda de subsecuencias, denominada twDTWS. Este estudio se enfoca en tres tipos principales de vegetales ampliamente plantados en Indonesia, a saber, chile, tomate y pepino. Realizamos una clasificación de vegetales en dos áreas, Malang y Lampung, utilizando series temporales de datos S1A que cubren la estación seca en 2017. Nuestros resultados muestran que el método twDTWS proporciona un medio prometedor para clasificar vegetales utilizando series temporales de datos S1A para la estación seca, mientras que las características descompuestas a partir de datos S1A de polarización dual tienen poca influencia en la precisión de la clasificación. Además, el método twDTWS con secuencias de consulta (a saber, perfiles temporales de referencia) definidas en el conjunto de datos de Malang produjo una precisión

general de 0,80 para la clasificación de chile y pepino del conjunto de datos de Lampung cuando las secuencias de consulta corresponden a los ciclos de crecimiento de las verduras. La variación en la longitud (es decir, el número de observaciones) de las secuencias de consulta puede afectar la precisión de la clasificación. Concluimos que el método twDTWS tiene un alto potencial para clasificar vegetales en diferentes áreas al construir las secuencias de consulta en función de sus ciclos de crecimiento.

Clement et al. (2018) mapearon la inundación con datos de radar de apertura sintética multitemporal usando detección de cambios, para ello, se adaptó una metodología de umbral y detección de cambios a partir de estudios anteriores para determinar el alcance de las inundaciones para 13 imágenes de radar de apertura sintética Sentinel-1 capturadas durante las inundaciones del invierno de 2015–2016 en Yorkshire, Reino Unido. Ambas polarizaciones disponibles, VH y VV, se han procesado para permitir una comparación de su precisión respectiva para delimitar aguas superficiales. Las extensiones máximas de inundación se encuentran el 29 de diciembre de 2015 durante las secuelas de las tormentas Eva y Frank. Los resultados han sido validados contra una imagen óptica Sentinel-2, con ambas polarizaciones produciendo una precisión total del 97%. De las dos polarizaciones, VV produce menos clasificaciones erróneas, lo que refleja los resultados similares informados en investigaciones anteriores. Los resultados mapeados se comparan con los mapas de inundación para la planificación de la Agencia de Medio Ambiente (EA FMP), con una buena correlación observada para la inundación en las llanuras aluviales. Las diferencias ocurren lejos de las llanuras aluviales, con los datos satelitales que identifican las inundaciones pluviales no destacadas por el EA FMP.

Ajadi et al. (2016) evaluaron la detección de cambios en imágenes de radar de apertura sintética utilizando un enfoque basado en escalas múltiples, hasta la actualidad, la clasificación y detección automática de cambios a partir de imágenes de radar de apertura sintética (SAR) sigue siendo una tarea difícil. Esto se debe, en gran parte, a (a) el alto nivel de ruido moteado que es inherente a los datos SAR; (b) la compleja respuesta de dispersión del SAR

incluso para objetivos bastante homogéneos; (c) el bajo muestreo temporal que suele lograrse con los sistemas SAR, ya que las imágenes secuenciales no siempre tienen la misma geometría radar (ángulo de incidencia, trayectoria orbital, etc.); y (d) el desempeño típicamente limitado de SAR en la delimitación del límite exacto de las regiones modificadas. Con este documento, presentamos un método de detección de cambios prometedor que utiliza imágenes SAR y proporciona soluciones para estas dificultades mencionadas anteriormente. Mostraremos que el enfoque presentado permite la detección de cambios automática y de alto rendimiento en una amplia gama de escalas espaciales (niveles de resolución). El método desarrollado sigue un enfoque de tres pasos de (i) preprocesamiento inicial; (ii) mejora/filtrado de datos; y (iii) detección de cambios multiescala basada en ondículas. La propiedad independiente de nuestro enfoque es la alta flexibilidad en la aplicación del enfoque de detección de cambios a una amplia gama de problemas de detección de cambios.

2.2 Base teórica

2.2.1 Minería de oro en Madre de Dios

Madre de Dios es un departamento Amazónico conocido en el mundo por su alta biodiversidad, localizado en el sureste de Perú. Abarca unos 85 000 kilómetros cuadrados y limita con Bolivia y Brasil. Sin embargo, Madre de Dios también es conocido por sus operaciones mineras, el 80% del oro de Perú se extrae de esta región. Perú es el sexto productor de oro de todos los países del mundo, además de ser el mayor productor de oro de América Latina. Teniendo en cuenta el estatus de Perú, está claro que las operaciones mineras de Madre de Dios son extensas, ¿Cuál es el problema? La gran mayoría de estas operaciones son ilegales, si bien estas prácticas pueden ser buenas para la economía de Madre de Dios y de Perú en general, no se puede decir lo mismo de los habitantes de la zona ni del medio ambiente. En la actualidad, esta región no se gestiona de forma sostenible (Martinez et al. 2018; Cortés-McPherson 2019).

Las operaciones mineras están provocando la deforestación en las secciones de la selva amazónica situadas en Madre de Dios. El aumento de la deforestación es especialmente notable desde principios de 2000 y se está extendiendo a zonas protegidas como los parques nacionales. En esta época, la demanda de oro se disparó, aumentando el potencial de beneficios. Esto es problemático por una multitud de razones. La Amazonia es conocida por su increíble biodiversidad y las secciones de Madre de Dios no son diferentes. Una cantidad inimaginable de especies llaman a esta región su hogar, pero ahora están siendo sometidas a la pérdida de su hábitat. Esta pérdida de biodiversidad es alarmante y puede tener consecuencias indirectas imprevistas (Martinez et al. 2018; Cortés-McPherson 2019).

2.2.2 Deforestación

La remoción permanente de árboles para hacer espacio para algo más que un bosque se conoce como deforestación. La deforestación puede referirse a la limpieza de la tierra para fines agrícolas, ganadísticos, mineros o para el uso de la madera como combustible, construcción o fabricación. Según el Fondo Mundial para la Naturaleza (WWF), más del 30% de la superficie terrestre de la Tierra está cubierta por bosques. Aproximadamente el 80% de las especies terrestres de la Tierra vive en estas áreas boscosas, que también producen oxígeno y absorben dióxido de carbono (CO₂). Más de mil millones de personas dependen de los bosques como fuente de alimentos, medicamentos y combustible. 13,4 millones de personas en todo el mundo tienen empleos en el sector forestal y otros 41 millones tienen trabajos relacionados con los bosques (FAO 2016; Leite-Filho et al. 2020).

La mayoría de la deforestación ocurre en las regiones tropicales. A medida que las personas construyen nuevos caminos a través de los densos bosques, ahora se pueden acceder a áreas que antes eran inaccesibles. Desde 2000, el mundo ha perdido aproximadamente el 10% de su cubierta de árboles tropicales, y solo en 2019 se destruyeron casi 47 000 millas cuadradas, o 121 000 kilómetros cuadrados (FAO 2016; Leite-Filho et al. 2020).

2.2.3 Bosque

Los árboles deben madurar in situ en tierras con una cobertura de copas (o nivel de población equivalente) superior al 10% y una superficie superior a 0,5 hectáreas (ha) (FAO 2016). La tierra destinada principalmente a uso agrícola o urbano no está incluida (FAO 2016).

2.2.4 Sistemas de Información Geográfica (SIG)

Un SIG es un sistema informático que analiza y muestra información geográficamente referenciada. utiliza los datos adjuntos a una ubicación específica. La mayor parte de la información que tenemos sobre nuestro mundo tiene una referencia de ubicación: ¿dónde se encuentran los medidores de flujo del USGS? ¿En qué lugar se tomó una muestra de piedra? ¿En qué lugar de una ciudad se encuentran todas las fuentes de incendio? Por ejemplo, si se observa una planta rara en tres lugares diferentes, el análisis GIS podría mostrar que todas las plantas están en laderas orientadas al norte que están por encima de 1,000 pies y reciben más de diez pulgadas de lluvia por año. Para que los investigadores sepan dónde buscar más plantas raras, los mapas GIS pueden mostrar todas las ubicaciones en el área que tienen condiciones similares. El análisis GIS de las ubicaciones geográficas de las granjas, las ubicaciones de los arroyos, las elevaciones y las precipitaciones mostrará qué arroyos es probable que lleven ese fertilizante río abajo. Estos solo son algunos ejemplos de los muchos usos de SIG en ciencias de la tierra, biología, gestión de recursos y muchos otros campos (Jiang 2020).

2.2.5 Sensoramiento remoto

Al detectar la energía que se refleja desde la Tierra, los sensores remotos recopilan datos. Estos sensores se pueden encontrar en aviones o en satélites. Los sensores remotos pueden funcionar de manera pasiva o activa. Los sensores pasivos reciben estímulos externos y responden. Registran y registran la energía natural emitida o reflejada desde la superficie de la Tierra.

La luz solar reflejada es la fuente de radiación más común detectada por sensores pasivos (Kerle et al. 2004; Jensen 2009).

Sin embargo, los sensores activos recopilan información sobre la Tierra mediante estímulos internos. Por ejemplo, un sistema de detección remota de rayos láser proyecta un láser sobre la superficie de la Tierra y mide el tiempo que tarda el láser en reflejarse de regreso a su sensor. La teledetección se utiliza en una variedad de campos:

- ✓ Aplicaciones costeras: Mapee las características costeras, monitoree el transporte de sedimentos y supervise los cambios en la línea de costa. Los datos se pueden utilizar para la prevención de la erosión y el mapeo costero.
- ✓ Aplicaciones oceánicas: controle la circulación oceánica y los sistemas de corrientes, mida la temperatura oceánica y la altura de las olas, y rastree el hielo marino. Los datos se pueden utilizar para comprender mejor los océanos y cómo gestionar mejor los recursos oceánicos.
- ✓ Evaluación de peligros: monitorear huracanes, terremotos, erosión y inundaciones. Los datos se pueden utilizar para evaluar los efectos de un desastre natural y crear planes para usar antes y después de un evento peligroso.
- ✓ Gestión de recursos naturales: observa el uso de la tierra, mapee los humedales y dibuje los hábitats de vida silvestre. Los datos se pueden utilizar para reducir el daño ambiental causado por el crecimiento urbano y ayudar en la toma de decisiones sobre cómo proteger mejor los recursos naturales. (Kerle et al. 2004; Jensen 2009).

2.2.6 Energía electromagnética

La radiación electromagnética, o radiación EM, es una forma fundamental de energía que nos rodea en todas partes, desde las microondas que calientan nuestra comida hasta las ondas de radio que nos traen música y noticias. En este artículo, exploraremos la radiación electromagnética, su naturaleza,

teoría, propiedades y la amplia gama de formas que toma (Kerle et al. 2004; Jensen 2009).

La radiación electromagnética se puede definir como una forma de energía que se genera cuando las partículas cargadas eléctricamente se mueven a través de la materia o el vacío. Alternativamente, también puede ser producido por perturbaciones magnéticas y eléctricas oscilantes (Kerle et al. 2004; Jensen 2009).

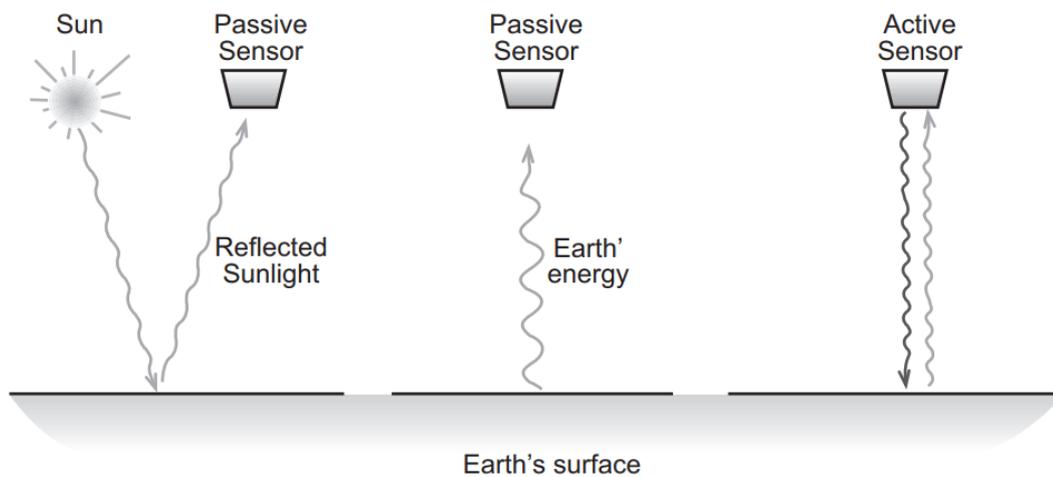


Figura 1. Un sensor de detección remota mide la energía reflejada o emitida. Un sensor activo tiene su propia fuente de energía.

Fuente: Kerle et al. (2004).

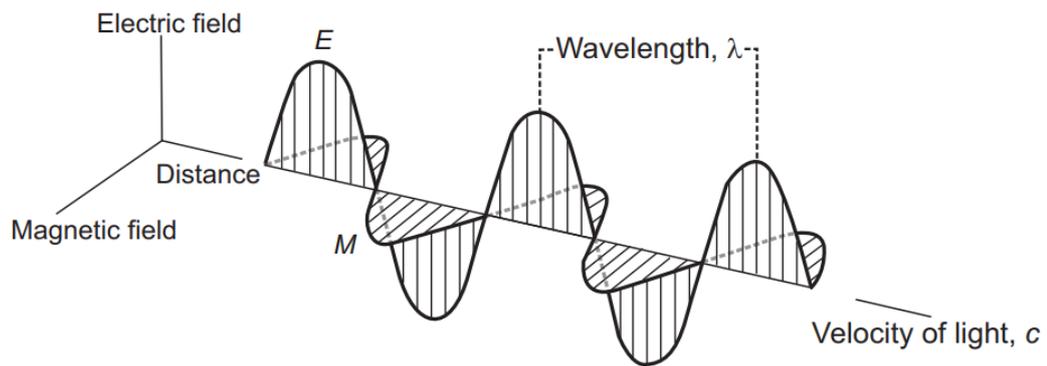


Figura 2. Vectores eléctricos (E) y magnéticos (M) de una onda electromagnética.

Fuente: Kerle et al. (2004)

La radiación electromagnética exhibe propiedades tales como longitud de onda, amplitud y frecuencia. La longitud de onda (λ) representa la distancia entre dos puntos adyacentes en fase, mientras que la frecuencia determina el número de ciclos de onda por segundo. La amplitud se refiere al desplazamiento máximo de la onda desde su posición de equilibrio (Kerle et al. 2004; Jensen 2009).

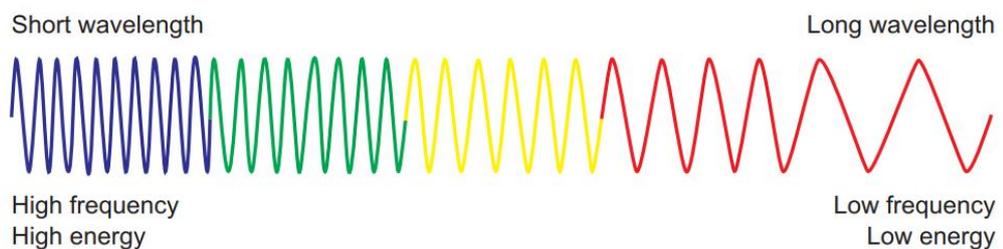


Figura 3. Relación entre longitud de onda, frecuencia y energía.

Fuente: Kerle et al. (2004).

“Toda materia con cierta temperatura irradia ondas electromagnéticas de varias longitudes de onda”. “El rango total de longitudes de onda se conoce comúnmente como espectro electromagnético (Figura 4), y se extiende desde los rayos gamma hasta las ondas de radio” (Kerle et al. 2004; Jensen 2009).

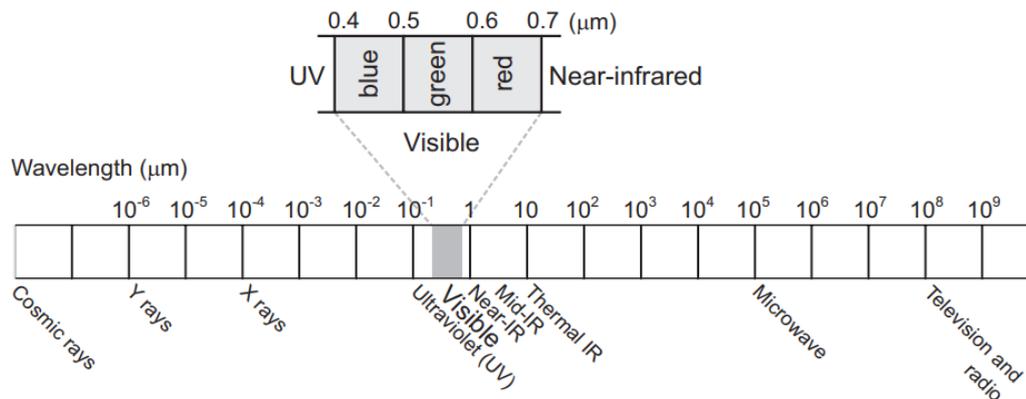


Figura 4. El espectro electromagnético.

Fuente: Kerle et al. (2004).

2.2.7 Teledetección activa y pasiva

Los sistemas pasivos de detección remota registran la energía electromagnética que se refleja (p. ej., luz azul, verde, roja e infrarroja) o se emite (p. ej., radiación infrarroja térmica) desde la superficie de la Tierra. Por lo tanto, los sensores pasivos dependen de una fuente de energía externa (p. ej., iluminación solar, emisión de calor de la Tierra). A diferencia de los sensores pasivos, que detectan la radiación natural, los sensores activos emiten radiación y recopilan y analizan la señal que envía la superficie o la atmósfera de la Tierra. Los sistemas de teledetección activa producen, por tanto, su propia energía electromagnética. Transmiten y reciben la radiación que se refleja o se retrodispersa desde el objetivo iluminado. No necesitan una fuente externa de radiación (por ejemplo, el Sol o la Tierra). A diferencia de la mayoría de los sensores pasivos que están destinados a detectar la radiación solar reflejada o la radiación emitida por la superficie de la Tierra en rangos que van desde el ultravioleta hasta el infrarrojo térmico, los sensores activos pueden utilizar cualquier radiación del espectro electromagnético, con la única limitación de la transparencia de la atmósfera de la Tierra. A menudo utilizan longitudes de onda que el Sol no proporciona suficientemente, por ejemplo, las microondas. Los sistemas activos se pueden categorizar según

su capacidad de formación de imágenes, o según la longitud de onda emitida considerada, o también según la forma en que utilizan la señal devuelta. Para la última categoría, generalmente se distingue entre sistemas de medición de distancia, que utilizan como información principal el tiempo de retardo entre la transmisión y la recepción de la radiación electromagnética en el sensor, y los sistemas de dispersión, que consideran la fuerza (también llamada magnitud o intensidad) de la señal devuelta. Algunos sistemas también registran ambas informaciones. Como los sensores activos producen su propia radiación y no dependen, por ejemplo, de la radiación solar, son independientes del día y también pueden recuperar información sobre la superficie de la Tierra durante la noche. Además, dependiendo de la longitud de onda considerada, los sensores activos son independientes del clima. Para longitudes de onda más largas del dominio de microondas, las nubes son transparentes, ya que la longitud de onda transmitida es mayor que las partículas de agua que constituyen la nube y no interactúan con ellas (Kerle et al. 2004; Jensen 2009).

2.2.8 Plataforma y sensores

Las plataformas de teledetección son los vehículos que llevan sensores remotos, lo que les permite recopilar datos a distancia. Hay tres tipos principales de plataformas en teledetección, cada una con sus características y capacidades únicas. En este artículo, veremos más de cerca estos tres tipos de plataformas y sus aplicaciones. Las plataformas de teledetección incluyen plataformas terrestres (trípodes y torres), aéreas (aviones tripulados y vehículos aéreos no tripulados) y satelitales, que facilitan la recopilación de datos de la superficie, la atmósfera y los océanos de la Tierra (Kerle et al. 2004; Jensen 2009).

Sensores

Es un dispositivo que capta la radiación electromagnética y la convierte en una señal que puede almacenarse y presentarse como datos numéricos o una imagen (Kerle et al. 2004; Jensen 2009).

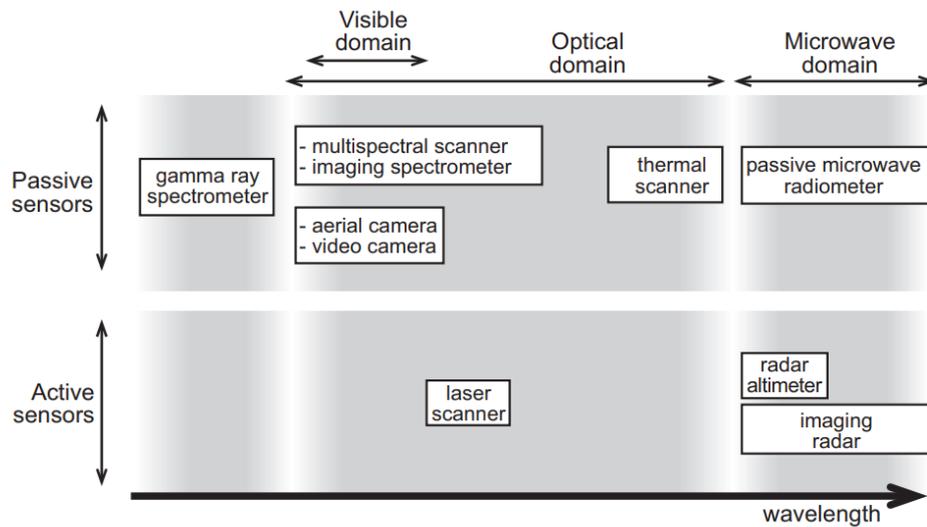


Figura 5. Descripción general de los sensores.

Fuente: Kerle et al. (2004).

Plataformas

La teledetección es una herramienta poderosa que se utiliza para adquirir información sobre la superficie, la atmósfera y los océanos de la Tierra sin contacto físico directo. Este proceso se basa en varios portadores, conocidos como plataformas, sensores para capturar y registrar datos a distancia. Cada plataforma tiene sus capacidades y características únicas, lo que la hace adecuada para aplicaciones específicas. Las plataformas aerotransportadas son ideales para capturar imágenes y datos de alta resolución en áreas pequeñas, las plataformas terrestres se utilizan para capturar datos desde las proximidades de la superficie de la Tierra y las plataformas espaciales se utilizan para capturar datos desde una perspectiva global. (Kerle et al. 2004; Jensen 2009).

2.2.9 Escáneres multispectrales

La energía electromagnética reflejada se mide escaneando la superficie de la Tierra con escáneres multispectrales. Esto produce datos de imagen digital, de los cuales el píxel es la unidad elemental de imagen. El nombre multispectral indica que las mediciones se realizan en una variedad de

rangos del espectro electromagnético (EM). Desde el lanzamiento del primer satélite Landsat en 1972, los escáneres multiespectrales se han utilizado en la teledetección. Es el sensor más utilizado, solo superado por la cámara aérea. El mapeo de la cobertura terrestre, la vegetación, la mineralogía superficial y el agua superficial son aplicaciones de los datos del escáner multiespectral (Kerle et al. 2004; Jensen 2009).

2.2.10 RADAR

“La teledetección por microondas utiliza ondas electromagnéticas con longitudes de onda entre 1 cm y 1 m”. “Estas longitudes de onda relativamente más largas tienen la ventaja de que pueden penetrar las nubes y son independientes de las condiciones atmosféricas, como la bruma”. “En la teledetección por microondas existen sensores activos y pasivos”. “Los sensores pasivos funcionan de manera similar a los sensores térmicos al detectar energía de microondas emitida naturalmente, y se utilizan en meteorología, hidrología y oceanografía”. “En los sistemas activos, la antena transmite señales de microondas desde una antena a la superficie de la Tierra donde se dispersan”. “La parte de la energía electromagnética que se dispersa en la dirección de la antena es detectada por el sensor. Se pueden obtener varias ventajas del uso de sensores activos, que tienen su propia fuente de energía” (Kerle et al. 2004; Jensen 2009):

- ✓ “Es posible adquirir datos en cualquier momento, incluso durante la noche (similar a la teledetección térmica)”.
- ✓ “Dado que las ondas se crean de forma activa, las características de la señal están totalmente controladas (por ejemplo, longitud de onda, polarización, ángulo de incidencia, etc.) y se pueden ajustar según la aplicación deseada”.

“Los sensores activos se dividen en dos grupos: sensores de imágenes y sensores sin imágenes”.

“Los sensores RADAR pertenecen al grupo de sensores de microondas de imágenes activas más utilizados”. “El término RADAR es un acrónimo de

Radio Detection and Ranging”. “Radio significa microondas y rango es otro término para distancia. Los sensores de radar fueron desarrollados y utilizados originalmente por los militares” (Kerle et al. 2004; Jensen 2009).

“Hoy en día, los sensores de radar también se utilizan ampliamente en aplicaciones civiles, como el monitoreo ambiental”. “Al grupo de instrumentos de microondas que no generan imágenes pertenecen los altímetros, que recopilan información sobre la distancia y los dispersómetros, que adquieren información sobre las propiedades del objeto (por ejemplo, la velocidad del viento)” (Kerle et al. 2004; Jensen 2009).

Geometría de visualización de radar

El sensor de radar de apertura sintética (SAR) generalmente se monta en un avión o satélite. La altitud del instrumento sobre una superficie de referencia permanece constante a lo largo del tiempo, una condición que es más fácil de lograr para los sensores satelitales que permanecen en la misma órbita que para las aeronaves que están sujetas a las condiciones atmosféricas. El sensor se mueve en una trayectoria de vuelo recta, que se denomina dirección azimutal. Corresponde a la dirección de vuelo. Los sistemas SAR adquieren información en vista oblicua, la antena apuntando hacia el suelo. La mayoría de los sistemas de satélite utilizan una antena que mira hacia el lado derecho del instrumento. El área de tierra iluminada por el haz del radar se denomina huella de antena. A medida que el sensor se mueve a lo largo de la dirección del acimut (a lo largo de la trayectoria), la franja continua del área terrestre representada por las sucesivas huellas de antena se denomina franja. La dirección de observación de la antena SAR se denomina dirección de alcance. Suele ser perpendicular a la dirección del acimut (es decir, a través de la trayectoria), pero también puede presentar ligeras diferencias según el modo de adquisición. El ángulo entre la vista del nadir y la dirección del rango se llama ángulo de incidencia. La imagen SAR original se muestra en lo que se denomina geometría de rango inclinado, es decir, se basa en la distancia real desde el radar hasta cada una de las características respectivas de la escena. En la dirección del rango oblicuo, la retrodispersión de cada objetivo

puntual se representa como una función del retraso de tiempo entre la transmisión del pulso electromagnético y su recepción en el sensor. Esta representación dependiente del rango induce distorsiones geométricas en la imagen SAR (Figura 7) (Kerle et al. 2004; Jensen 2009).

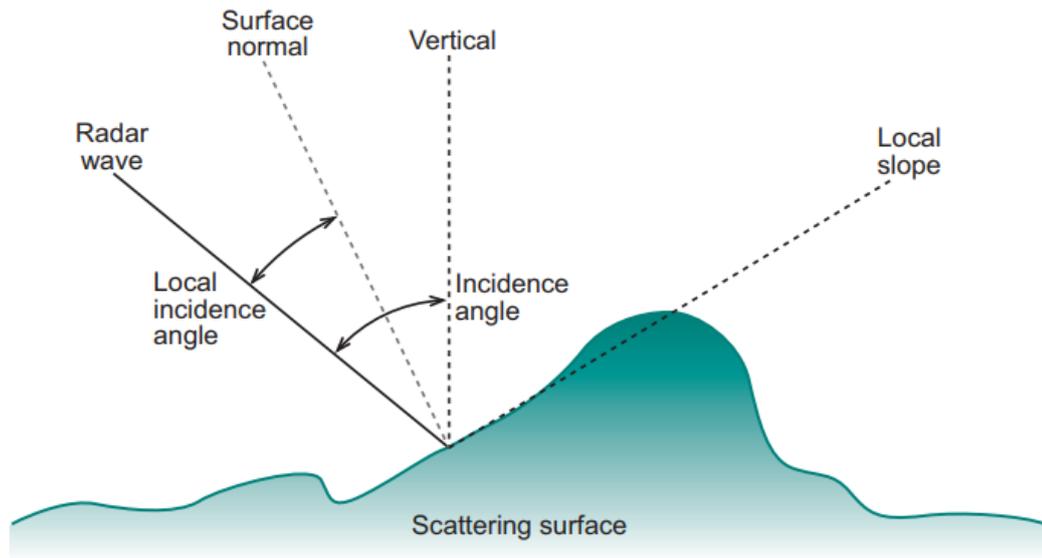


Figura 6. Ángulo de incidencia del radar y ángulo de incidencia local.

Fuente: Kerle et al. (2004).

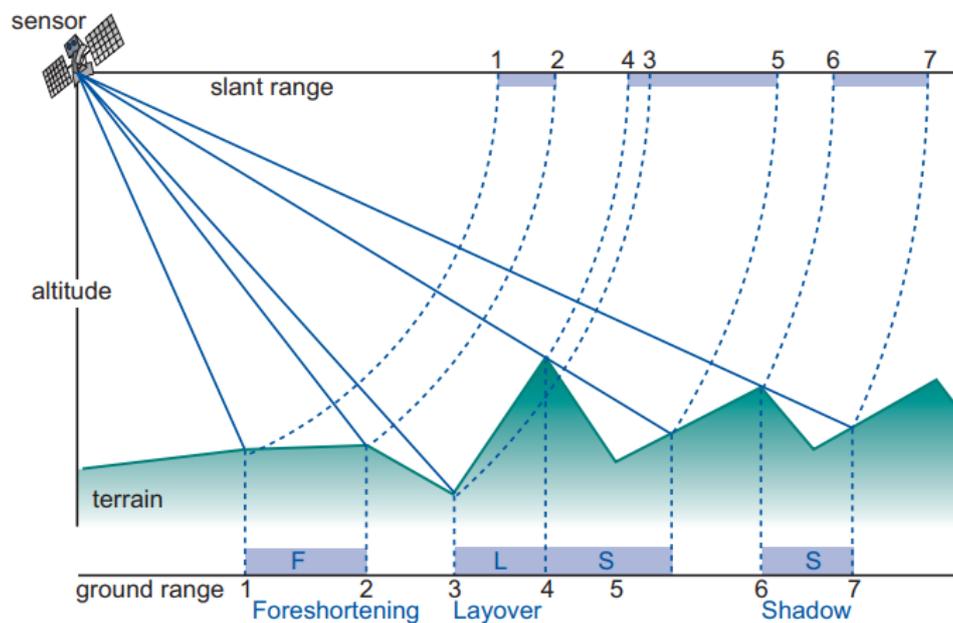


Figura 7. Distorsiones geométricas en RADAR.

Fuente: Kerle et al. (2004).

Resolución espacial

La resolución espacial (también conocida como GSD de distancia de muestra del suelo) se refiere al tamaño de un píxel en el suelo. Por ejemplo, una resolución espacial de 15 metros significa que un píxel de la imagen corresponde a un cuadrado de 15 por 15 metros en el suelo. Una resolución más fina indica un tamaño de píxel más bajo y significa que puede ver más detalles en las imágenes. Hoy en día, las imágenes satelitales se pueden clasificar generalmente en tres "cubos" de resolución espacial:

- ✓ Baja resolución: más de 30 m/píxel (p. ej., satélites NASA Terra y Aqua MODIS)
- ✓ Resolución media: 5-30 m/píxel (p. ej., USGS/NASA Landsat 8 Satellite)
- ✓ Alta resolución: 1-5 m/píxel (p. ej., Planet Labs Rapid Eye Satellite)
- ✓ Resolución muy alta: <1 m/píxel (p. ej., los satélites Worldview de Maxar)

La sección de resolución mínima requerida está duplicada; una debe eliminarse. Recomendamos eliminar el primero que viene directamente después de la lista con viñetas que muestra las resoluciones baja, media, alta y muy alta (Kerle et al. 2004; Jensen 2009).

Radar de Apertura Sintética (SAR)

Un radar de apertura sintética (SAR) es un sistema de radar lateral coherente, principalmente aerotransportado o espacial, que crea sensores remotos de alta resolución utilizando la trayectoria de vuelo de la plataforma para simular electrónicamente una antena o apertura extremadamente grande. imágenes. Los ciclos individuales de transmisión/recepción (PRT) se completan gradualmente y los datos de cada PRT se almacenan electrónicamente. La magnitud y la fase de las señales recibidas se aplican a pulsos sucesivos de elementos de una apertura sintética en el procesamiento de señales. Los datos almacenados se recombinan después de un cierto número de ciclos. Esto ocurre debido a los efectos Doppler asociados con las geometrías diferentes del transmisor (Kerle et al. 2004; Jensen 2009).

El SAR funciona de manera similar a una matriz en fase, pero usa una antena en múltiplex de tiempo en lugar de muchos elementos de antena paralelos en una matriz en fase. La plataforma en movimiento ha dado lugar a las distintas posiciones geométricas de los elementos de la antena. Durante el período de tiempo T desde la posición A hasta la D , el procesador SAR almacena todas las señales del radar, incluidas las amplitudes y las fases. La señal que una antena de longitud $v \cdot T$, donde v es la velocidad de la plataforma, habría obtenido anteriormente, ahora se puede reconstruir. A medida que cambia el rumbo de la línea de visión a lo largo de la trayectoria (Kerle et al. 2004; Jensen 2009).

Distorsiones en imágenes de radar

La distorsión del sistema es inevitable en el radar de imágenes de banda ancha, que debe compensarse con precisión. En el radar de imágenes de

banda ancha tradicional para vigilancia espacial, se transmite una señal de modulación de frecuencia lineal y la señal de eco se recibe con procesamiento de eliminación de chirridos. En este caso, la distorsión del sistema cambia con el rango objetivo, lo que dificulta compensar la distorsión. Sin embargo, la señal de muestreo de frecuencia intermedia directa (DIFS) mantiene la distorsión completa del sistema y evita la distorsión de la variante de rango en la señal eliminada (Kerle et al. 2004; Jensen 2009).

Clasificación de imágenes digitales

“En este proceso, la visión humana juega un papel crucial en la extracción de información de los datos de imágenes. Aunque las computadoras pueden usarse para visualización y digitalización, la interpretación en sí la realiza el operador”. “En este proceso, el operador (humano) indica a la computadora que realice una interpretación de acuerdo con ciertas condiciones”. “Estas condiciones las define el operador. La clasificación de imágenes es una de las técnicas en el dominio de la interpretación de imágenes digitales (IIS)”. “Otras técnicas incluyen el reconocimiento automático de objetos (por ejemplo, detección de carreteras) y la reconstrucción de escenas (por ejemplo, generación de modelos de objetos en 3D)”. La clasificación de imágenes, sin embargo, es la técnica más comúnmente aplicada en el contexto de las IIS.

“La clasificación de imágenes se basa en las diferentes características espectrales de diferentes materiales en la superficie de la Tierra, la clasificación de imágenes es un proceso que opera en el espacio de características”. El resultado de una clasificación de imágenes debe validarse para evaluar su precisión (Kerle et al. 2004; Jensen 2009).

Proceso de clasificación de imágenes

El proceso de clasificación de imágenes (Figura 8) generalmente implica cinco pasos:

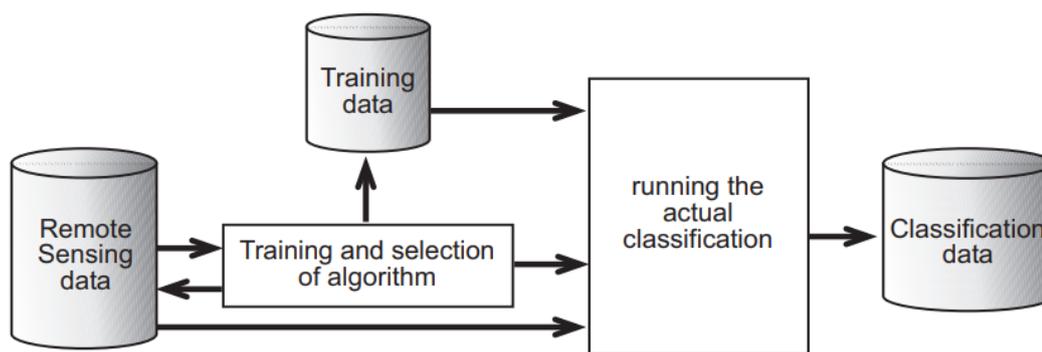


Figura 8. El proceso de clasificación; El componente más importante es el entrenamiento en combinación con la selección del algoritmo.

Fuente: Kerle et al. (2004).

Algoritmos de clasificación

Se puede utilizar un algoritmo de clasificación para clasificar las imágenes una vez que se han definido los conjuntos de muestras de entrenamiento. Los algoritmos de clasificación varían. El propósito de la clasificación, las características de la imagen y los datos de entrenamiento determinan el algoritmo a utilizar. El operador debe elegir si una clase "rechazada" o "desconocida" se permite. Luego se explican tres algoritmos clasificadores. Para facilitar la comprensión del principio, primero se explica el clasificador de cajas. El clasificador de cajas casi nunca se usa en la práctica. Además, se utilizarán algoritmos predictores basados en índices, en este caso índices de quema absolutos y relativos en imágenes SAR (Kerle et al. 2004; Jensen 2009).

2.2.11 Softwares de procesamiento de imágenes

SNAP ESA

SNAP es una herramienta de análisis de observación de la Tierra de acceso abierto que ha seguido creciendo en popularidad en los siete años transcurridos desde su lanzamiento y ahora se prevé que alcance un millón de descargas, anunció hoy la ESA en el Simposio Living Planet (Zuhlke et al. 2015).

Google Earth Engine

una avanzada plataforma de procesamiento geoespacial basada en la nube, diseñada principalmente para el análisis de datos ambientales a escala planetaria. Combina un catálogo de múltiples petabytes de imágenes satelitales y conjuntos de datos geoespaciales, que permiten a los usuarios visualizar , manipular , editar y crear datos espaciales de una manera fácil y rápida (Gorelick et al. 2017).

ENVI

Entorno para visualizar imágenes (software de procesamiento de imágenes; Research Systems, Inc.) (Canty 2014).

ArcMap

ArcMap es una de las principales aplicaciones de escritorio para GIS profesional. Es una aplicación central utilizada en ArcGIS Desktop, de Esri (Shaner y Wrightsell 2000).

ArcGIS Pro

ArcGIS Pro está diseñado para ser la principal aplicación para visualizar, editar y realizar análisis utilizando contenido de ArcGIS local o en línea. Tiene capacidades de visualización en 2D y 3D, y tiene una velocidad de 64 bits optimizada para mejorar la experiencia del usuario. El usuario de ESRI ahora controla una interfaz contextual con herramientas que aparecen solo cuando es necesario, en un entorno altamente integrado con otras herramientas de ESRI (Shaner y Wrightsell 2000).

2.2.12 Programa Copérnico

Copernicus es el componente de observación de la Tierra del programa espacial de la Unión Europea, que analiza nuestro planeta y su entorno para beneficiar a todos los ciudadanos europeos. Ofrece servicios de información que se basan en la observación de la Tierra por satélite y datos in situ (no

espaciales). La Comisión Europea gestiona el Programa. Se implementa en colaboración con los Estados miembros, la Agencia Espacial Europea (ESA), la Organización Europea para la Explotación de Satélites Meteorológicos (EUMETSAT), el Centro Europeo de Pronósticos Meteorológicos a Medio Plazo (ECMWF), las agencias de la UE y Mercator Océan. Grandes cantidades de datos globales de satélites y sistemas de medición terrestres, aéreos y marítimos brindan información para ayudar a los proveedores de servicios, las autoridades públicas y otras organizaciones internacionales a mejorar la calidad de vida de los ciudadanos europeos y más allá. Los servicios de información prestados son gratuitos y de libre acceso para los usuarios (Torres et al. 2012; Li et al. 2020).

Sentinel-1

La misión Sentinel-1 es una misión del Observatorio Europeo de Radar diseñada y desarrollada por la ESA para ser operada por la Comisión Europea bajo el programa Copernicus. Sentinel-1 proporcionará la continuidad de los datos del radar de apertura sintética de banda C para aplicaciones operativas en toda Europa y contribuirá al GEOSS (Sistema de sistemas de observación global de la Tierra). La misión se basa en los instrumentos ERS y Envisat SAR de la ESA para garantizar una alta calidad de los datos manteniendo las características clave de los instrumentos y garantizando productos de datos bien calibrados. Sentinel-1 incluye dos satélites en una órbita sincrónica solar. La nave espacial Sentinel-1 proporcionará productos de datos operativos a Copernicus Ocean, Land and Emergency, así como a los servicios nacionales de usuarios. Estos datos incluyen la observación del entorno marítimo (monitoreo del hielo marino, detección de derrames de petróleo, vigilancia de las zonas de transporte marítimo) y observaciones terrestres (monitoreo de la vegetación, mapeo de la superficie, soporte de crisis, desastres naturales como inundaciones y terremotos), y humanitario. ayuda. Los satélites Sentinel-1 operarán en un tiempo de revisita alto que permitirá la generación de una aplicación coherente de detección de cambios de interferometría SAR

para monitorear las deformaciones de la superficie y la dinámica de la criosfera (Torres et al. 2012; Li et al. 2020).

Tabla 2. Características de la imagen de satélite Sentinel-1

Parámetro	Sentinel-1
Fecha de lanzamiento	03 de abril de 2014 de S1-A 22 de abril de 2016 de S1-B
Tipo de órbita	SSO (órbita sincrónica del sol) ciclo de repetición de 12 días LTAN = 18:00 horas
Altitud orbital	693 kilómetros
Complemento de sensor	C-SAR (radar de apertura sintética de banda C)
Masa de la nave espacial Tamaño de la nave espacial Potencia de la nave espacial	2300 kg 3,4 m x 1,3 m x 1,3 m 4,8 kW (EOL)
Velocidad de datos de banda X de enlace descendente	520 Mbit/s
Banda S TT&C	64 kbit/s enlace ascendente 128 kbit/s 2 Mbit/s enlace descendente
Almacenamiento de datos científicos	1,4 Tbit (EOL)
Calidad de datos requerida	BER (tasa de error de bit): $< 10^{-9}$
Autonomía operativa	8 días
contratista principal	TAS-I (Thales Alenia Space-Italia)

Lanzador de línea de base	Soyuz (Kourou)
---------------------------	----------------

Fuente: Serrano et al. (2015).

2.3 Definición de términos

Sensoramiento remoto: La medición de la radiación reflejada y emitida a distancia de una región para detectar y monitorear sus características físicas (Chuvieco 1996).

Radar: Sensor electromagnético utilizado para detectar, localizar, rastrear y reconocer objetos de varios tipos a distancias considerables. Funciona transmitiendo energía electromagnética hacia objetos, comúnmente denominados objetivos, y observando los ecos que devuelven (Handbook 2005).

SAR: Un radar de apertura sintética (SAR, por sus siglas en inglés), o SAR, es un sistema de radar lateral coherente , principalmente aerotransportado o espacial, que utiliza la trayectoria de vuelo de la plataforma para simular electrónicamente una antena o apertura extremadamente grande, y que genera sensores remotos de alta resolución. Imágenes (Handbook 2005).

Polarimetría: Es una característica clave de una onda electromagnética plana. Se refiere a la regularidad y alineación de los componentes del campo eléctrico y magnético de la onda en un plano perpendicular a la dirección de propagación (Handbook 2005).

Sentinel-1: Dentro del Programa Copérnico, la ESA tiene un satélite en órbita polar destinado a la vigilancia tanto terrestre como oceánica (Handbook 2005). El cohete Soyuz lo llevó al espacio el 3 de abril de 2014 desde el puerto espacial Kourou (Guayana Francesa) (Serrano et al. 2015).

Firma espectral: Característica que permite la identificación de diferentes objetos, como el suelo, la vegetación y las aguas, a través del comportamiento de las superficies al recibir la radiación (Hernández y Montaner 2009) .

Bosque: Un bosque se puede definir como una región con una alta densidad de árboles, así como el hábitat de una variedad de seres vivos que incluyen plantas, animales y microorganismos (FAO 2012).

Vegetación secundaria: “Áreas de rebrote como consecuencia del abandono de actividades agrícolas, de pastoreo o mineras” (MINAM 2015; MINAM 2020).

Agricultura: “Tierras bajo cultivo para cultivos independientes del tamaño del campo y que pueden incluir huertas y arboledas, incluyendo plantaciones de banano y papaya, que son comunes en esta región” (MINAM 2015; MINAM 2020).

Pastizales: “Tierra utilizada predominantemente para pastoreo en un entorno manejado/cultivado (pastizales) o natural (tierras de pastoreo)” (MINAM 2015; MINAM 2020).

Minería: “Terreno utilizado para actividades mineras extractivas que se caracteriza predominantemente por sustrato desnudo (suelo desnudo y/o arena) en combinación con agua estancada” (MINAM 2015; MINAM 2020).

Urbano: “Áreas edificadas, asentamientos y otras áreas residenciales” (MINAM 2015; MINAM 2020).

Agua: “Masas de agua superficiales” (MINAM 2015; MINAM 2020).

CAPÍTULO III: METODOLOGÍA DE INVESTIGACIÓN

3.1 Tipo de estudio

El análisis de la variación espacial-estacional del uso del suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La Pampa y Guacamayo – Madre de Dios en el año 2021, se enmarca en una investigación “tipo descriptiva, correlacional y predictivo” (Castro 2003; Baray 2006; Cazau 2006; Hernández et al. 2010; Pei et al. 2021; González-Esteban y Patrici Calvo 2022).

3.2 Diseño del estudio

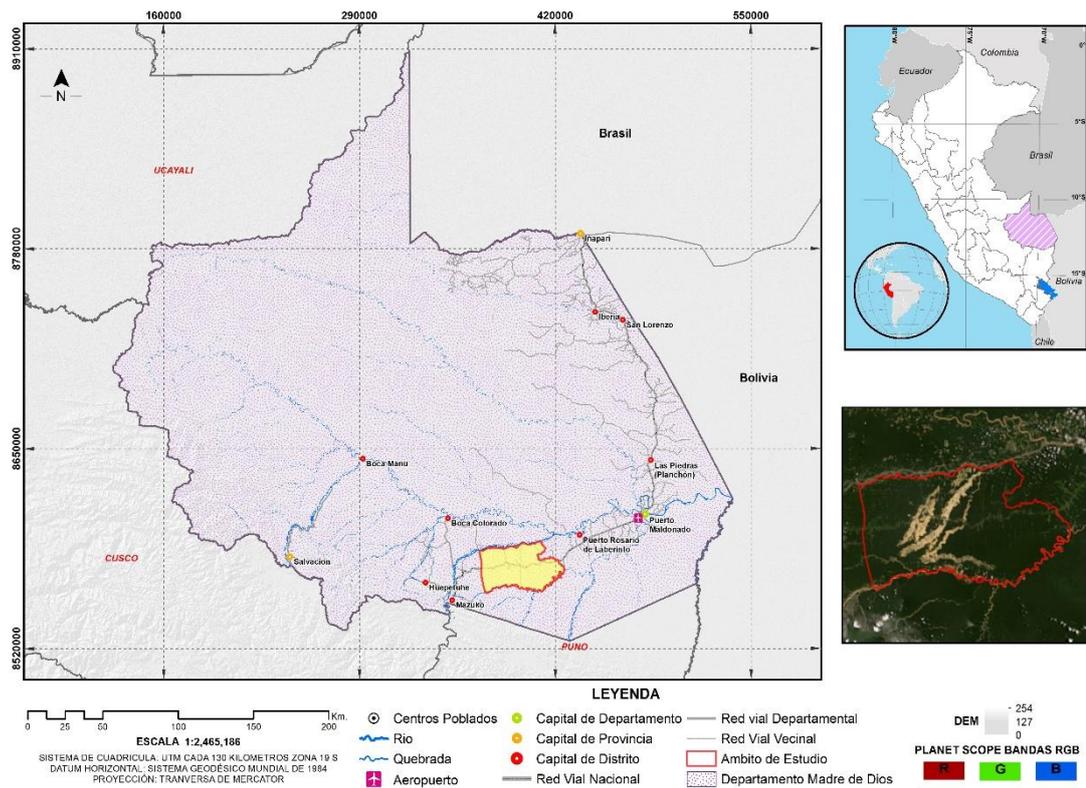
La investigación se enmarca en un “diseño Transaccional (transversal)”, porque analiza en tres cortes de tiempo del año 2021 la variación espacial del uso del suelo y cambio de cobertura por la minería de oro en los sectores de La Pampa y Guacamayo – Madre de Dios (Castro 2003; Baray 2006; Cazau 2006; Hernández et al. 2010; Pei et al. 2021; González-Esteban y Patrici Calvo 2022).

3.3 Delimitación espacial y temporal

La Amazonia de Madre de Dios se encuentra en el sureste de Perú. Limita con el departamento de Puno al sur, Cusco al oeste y Ucayali al norte. Tiene una superficie de aproximadamente 85 183,96 km² y habita aproximadamente 141 070 personas. También está conectada internacionalmente con Bolivia y Brasil (INEI 2017).

El estudio abarca las áreas de La Pampa y Guacamayo del distrito de Inambari, provincia de Tambopata, departamento de Madre de Dios, con una superficie total de 1 300,81 km² (13 0081,01 ha). Las áreas agrícolas, las

concesiones forestales para el ecoturismo, la reforestación y las tierras indígenas interactúan espacialmente en el área (Dourojeanni 2019). Situada entre los meridianos 69° 41' 49" y 70° 10' 45" de longitud Oeste y los paralelos 12° 44' 44" y 13° 03' 45" de latitud Sur, tiene una altitud promedio de 250 metros sobre el nivel del mar (GOREMAD y IIAP 2009; Chávez et al. 2013; Perz et al. 2013; Alarcón et al. 2016; Perz et al. 2016).



En cuanto a la evaluación temporal, el análisis de la variación espacial estacional del uso del suelo por minería de oro mediante el sensor SAR Sentinel-1 en el área de estudio se realizarán en tres épocas; marzo-abril (presencia de lluvias), agosto-septiembre (escases de lluvias), y noviembre-diciembre de 2021 (presencia de lluvias).

3.3.1 Clima e hidrografía

La temperatura es semicálida (Holdridge 1967), La temperatura promedio anual varía poco durante todo el año y oscila entre 25°C y 27°C. Los meses

de septiembre an abril tienen los promedios mensuales más altos, llegando a 10oC, mientras que los meses de mayo an agosto tienen los promedios mensuales más bajos, llegando a 10oC. La precipitación total promedio anual es de 1800 mm. De mayo a septiembre, las lluvias representan el 20 al 25% del total anual, pero son menos intensas (GOREMAD y IIAP 2009). La evapotranspiración oscila entre 598,4 mm y 652,6 mm, mientras que la humedad relativa oscila entre el 63 % y el 90 % (GOREMAD y IIAP 2009; Perz et al. 2016). Entre las redes de agua que reciben más caudal son el Río Madre de Dios y Malinowski (GOREMAD y IIAP 2009; Perz et al. 2016).

3.4 Población y muestra

Las zonas de La Pampa y Guacamayo tiene una extensión de 1 300,81 km² (130 081,01 ha). Se empleó la distribución binomial de probabilidad para analizar la variación espacial-estacional del uso del suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La Pampa y Guacamayo – Madre de Dios en 2021. Se tomaron un gran número de muestras del área a verificar en campo o con imágenes de alta resolución (Anaya y Chuvieco 2010; Chuvieco y Hantson 2010; Ochoa y Páez 2019). El tamaño de muestra se calculó mediante la siguiente fórmula (Ecuación 1):

$$n = \frac{Z^2 p(qN)}{(N-1)E^2 + Z^2 pq} \quad (\text{Ecuación 1})$$

Dónde:

Z: Es el valor de la curva normal estandarizada para un nivel determinado de probabilidad, 1,96 (95%).

p: indica el porcentaje de aciertos estimado, 0,50 (50%).

q: Indica el porcentaje de errores (q = 1 – p), 0,50 (50%).

N: Tamaño de la población.

E: El error permitido, 0,05 (5%).

$$= \frac{(1,96)^2 * 0,5(0,5 * 13\ 0081,01)}{(13\ 0081,01 - 1) * 0,05^2 + 1,96^2 * (0,5 * 0,5)}$$

$n = 383,03 = 383$

Para distribuir la muestra de manera representativa en el área de estudio, se utilizó un muestreo aleatorio estratificado con una probabilidad conocida superior a cero de ser seleccionado (inclusión) (Ochoa y Páez 2019).

La distribución considero 383 muestras levantadas con un criterio mixto (campo, imágenes de satélite y de Drone): (1) 70 muestras y/o puntos en la categoría de “Bosque” (50 de campo y 20 de imágenes), (2) 50 en “Vegetación secundaria” (40 de campo y 10 de imágenes), (3) 50 en “Agricultura” (40 de campo y 10 de imágenes), (4) 50 en “Pastos” (40 de campo y 10 de imágenes), (5) 83 en “Minería” (43 de campo y 40 de imágenes), (6) 50 en “Urbano” (40 de campo y 10 de imágenes) y (7) 30 en “Agua” (10 de campo y 20 de imágenes) (Olivares y López-Beltrán 2019).

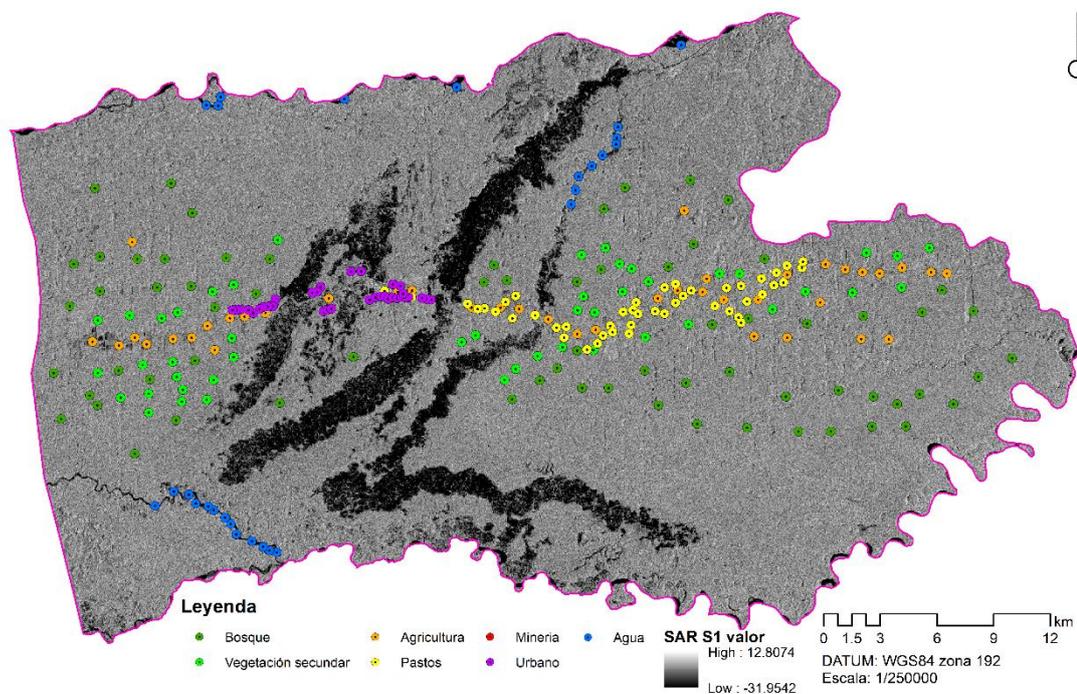


Figura 9. Distribución de muestras distribuidas al azar por estratos en el área de estudio.

3.5 Método y técnicas

El programa Copernicus de la Agencia Espacial Europea (ESA) (ESA 2013; Deane et al. 2022) proporciona datos de radar de apertura sintética Sentinel-1 de banda C de doble polarización. Los datos se adquieren en diferentes modos de imagen, para el estudio se empleó el modo de barrido Interferometric Wide (IW) con una resolución espacial de 5 m x 20 m. Los SAR Sentinel-1 proporcionan información en polarización simple (VV o HH) y polarización dual (VV+VH o HH+HV). La investigación utilizó imágenes SAR durante los periodos marzo-abril, agosto-septiembre, y noviembre-diciembre de 2021 que serán adquiridas del portal web Alaska Satellite Facility (ASF) (Bouvet et al. 2018; Puzzi et al. 2020; Puzzi et al. 2021) y Google Earth Engine (GEE) (Mutanga y Kumar 2019). Sentinel-1A y -1B fueron utilizadas en la polarización dual. Los productos fueron imágenes de detección de rango terrestre (GRD) de ruta descendente. Las imágenes Sentinel-1 se procesaron con la finalidad de obtener productos geocodificadas y corregidas, todas en el sistema de proyección Universal Transverse Mercator (UTM). El procesamiento de corrección radiométrica del terreno (RTC) se basó en el algoritmo de integración de área de píxeles, para ello se dispuso de los datos del Digital Elevation Model (DEM) de la Shuttle Radar Topography Mission (SRTM) en el software SNAP ESA y GEE (Chen et al. 2010; ESA 2013; Steinhausen et al. 2018; Booyesen et al. 2021). Antes del RTC, se aplicó un filtro de mejorado para reducir el ruido del moteado característico en las imágenes SAR. El proceso de mejorado permitió colocar cada píxel en una de tres clases (“homogéneo, el valor del píxel se reemplaza por el promedio de la ventana del filtro; heterogéneo, el valor del píxel se reemplaza por un promedio ponderado; objetivo puntual, el valor del píxel sigue siendo el mismo”) (Chen et al. 2010; ESA 2013; Ajadi et al. 2016; Bouvet et al. 2018; Steinhausen et al. 2018; Zhou et al. 2018; Nicolau et al. 2019; Puzzi et al. 2020; Booyesen et al. 2021; Puzzi et al. 2021).

Para definir la cobertura de suelo se basó en los propuesto por el (MINAM 2015; MINAM 2020), considerándose las siguientes clases: bosque, vegetación secundaria, agricultura, pastos, minería, urbano y agua. De las

categorías evaluadas, se planteó para el estudio como motores de cambio y uso de la tierra a la agricultura, el pastoreo, la minería y el urbano.

La data de Sentinel-1 fueron procesadas en GEE y SNAP ESA (Potin 2013; Mutanga y Kumar 2019; Puzzi et al. 2021). Debido al moteado de las imágenes se compondrá en imágenes compuestas; con polarizaciones VV, VH, y la relación VV/VH (Lopez-Sanchez et al. 2014; Ajadi et al. 2016; Bouvet et al. 2018; Zhou et al. 2018). Asimismo se aplicó una adaptación del Radar Forest Degradation Index (RFDI) (Samat et al. 2018), que mide la fuerza de doble rebote de las polarizaciones HH y HV y detectar las variedades de vegetación (Tanase et al. 2015a). Por la disponibilidad de información, se planteó la versión adaptada (aRFDI) donde se utilizará la banda VV en lugar de la banda HH debido a que no está disponible en el Sentinel-1 en el área de estudio, donde el aRFDI resalta de la superficie rugosa debido a la sensibilidad de polarización VV, mientras que VH lo es al volumen (Ecuación 3) (Samat et al. 2018).

La medida de separabilidad de los datos de radar (Mansaray et al. 2021) permitieron una correcta definición en la clasificación con el árbol de decisión. La media fue útil, cuando la distancia de las medias de clase está bien separada y es mayor que la desviación estándar, los valores superiores a 0,8 serán útiles, mientras que valores superiores a 2,0, es casi completa (Kulczycki y Franus 2021).

Mediante la adquisición de firmas y métricas respectivas se definieron las reglas y umbrales del árbol de decisión para una clasificación de las categorías de uso y cobertura terrestre. El criterio estará en función al porcentaje de características que cumpla y no cumplan con la regla. Se considerarán los que tengan la tasa de verdaderos positivos más alta ($\geq 75\%$) o una tasa de falsos positivos más baja ($\leq 20\%$) (Kulczycki y Franus 2021).

Los puntos de muestra fueron distribuidos en tres periodos (marzo-abril, agosto-septiembre, y noviembre-diciembre de 2021). Para medir la precisión se aplicó un diseño de muestreo estratificado aleatorio (Zhang et al. 2020), dependiendo de la disponibilidad de datos se aplicó un método mixto mediante la visualización de imágenes WorldView (0,38 m) e imágenes de PlanetScope

(3 m) (Planet-Team 2021). Se genero una matriz de confusión, que arrojó la precisión general y el coeficiente kappa (κ), como un test de evaluación de los datos y la información real de campo (Cohen 1960; Elijah y Jensen 1996; Chuvieco 2002; Cohen et al. 2003; Chuvieco y Hantson 2010; Alarcón et al. 2016).

3.6 Tratamiento de datos

3.6.1 Procesamiento de datos

Bibliografía especializada: Se accedió a la base de datos de Scopus, Sciencedirect, y Google Académico.

Material cartográfico e imágenes de satélite:

1. El material cartográfico se obtuvo del Centro de Teledetección para el Estudio y Gestión de Recursos Naturales (CETEGERN) de la UNAMAD (Alarcón et al. 2016).
2. Las imágenes SAR Sentinel-1 de 2021 se obtuvieron del portal web de Alaska Satélite Facility (ASF) y Google Earth Engine (GEE) (Tabla 3 y 4).

Tabla 3. Información de adquisición de imágenes Sentinel-1

Sensor (satélite)	Fecha de imagen	Modo de adquisición	Nivel de procesamiento	Orbita
Sentinel-1A (SAR)	2021/03/29 2021/08/20 2021/12/18	Interferometric Wide Swath (IW)	Level-1 GRD	Descendente

Tabla 4. Características de la imagen de satélite Sentinel-1

Parámetro	Sentinel-1

Fecha de lanzamiento	03 de abril de 2014 de S1-A 22 de abril de 2016 de S1-B
Tipo de órbita	SSO (órbita sincrónica del sol) ciclo de repetición de 12 días LTAN = 18:00 horas
Altitud orbital	693 kilómetros
Complemento de sensor	C-SAR (radar de apertura sintética de banda C)
Masa de la nave espacial Tamaño de la nave espacial Potencia de la nave espacial	2300 kg 3,4 m x 1,3 m x 1,3 m 4,8 kW (EOL)
Velocidad de datos de banda X de enlace descendente	520 Mbit/s
Banda S TT&C	64 kbit/s enlace ascendente 128 kbit/so 2 Mbit/s enlace descendente
Almacenamiento de datos científicos	1,4 Tbit (EOL)
Calidad de datos requerida	BER (tasa de error de bit): $< 10^{-9}$
Autonomía operativa	8 días
contratista principal	TAS-I (Thales Alenia Space-Italia)
Lanzador de línea de base	Soyuz (Kourou)

Fuente: Serrano et al. (2015).

✓ Tratamiento y análisis de la imagen SAR

Se aplico tratamiento digital de las imágenes SAR Sentinel-1 descargadas de ASF y GEE. El procedimiento comprende tres (3) fases:

- 1. Pre-Procesamiento**, Consistió en realizar las correcciones y geocodificaciones de los datos SAR; Multilook, Calibración, Filtro de Speckle, Corrección por Topografía, y Recorte en función al área de estudio (Moran y Brondizio 1998; DeFries et al. 2010; Lopez-Sanchez

et al. 2014; Chen et al. 2016; Addison y Oommen 2018; Bouvet et al. 2018; Samat et al. 2018; Deane et al. 2022).

- 2. Procesamiento**, Los datos SAR Sentinel-1 presentan polarización VV y VH, se evaluara los valores medios de retrodispersión para la clasificación del uso del suelo por minería de oro en función a los coberturas propuesta (MINAM 2015; MINAM 2020): bosque, vegetación secundaria, agricultura, pastos, minería, urbano y agua (Moran y Brondizio 1998; DeFries et al. 2010; Tanase et al. 2013; Lopez-Sanchez et al. 2014; Tanase et al. 2015b; Chen et al. 2016; Addison y Oommen 2018; Bouvet et al. 2018; Samat et al. 2018; Deane et al. 2022).

Preliminarmente, se cuantifico las coberturas de uso de suelo general y luego se discrimino el uso de suelo por minería de oro mediante el método de clasificación Árbol de Decisión (AD) (Albuquerque et al. 2020). Debido al moteado de las imágenes se compondrá en imágenes compuestas; con polarizaciones VV, VH, y la relación VV/VH (Lopez-Sanchez et al. 2014; Chen et al. 2016; Ali et al. 2018; Bouvet et al. 2018; Samat et al. 2018; Albuquerque et al. 2020; Zhang et al. 2020; Deane et al. 2022).

donde: VV y VH es el coeficiente de retrodispersión en unidad σ_0 (Sigma0), debe ser expresa en decibeles (dB).

$$\sigma_{0,dB} = 10 \log_{10}(\sigma_0) \quad (\text{Ecuacion 2})$$

Asimismo, se aplicará una adaptación del Radar Forest Degradation Index (aRFDI), que mide la fuerza de doble rebote de las polarizaciones HH y HV y detectar las variedades de vegetación (Moran y Brondizio 1998; Bouvet et al. 2018; Samat et al. 2018; Liang y Liu 2020) (Ecuación 3).

$$aRDFI = (VV - VH)/(VV + VH) \quad (\text{Ecuacion 3})$$

donde: VV y VH representan el coeficiente de retrodispersión en unidades de potencia.

Por otro lado, para medir aRFDI a partir de los datos de retrodispersión VV y VH (Tabla 6) (Tanase et al. 2013; Tanase et al. 2015b; Addison y Oommen 2018; Bouvet et al. 2018), se utilizó el siguiente criterio:

Tabla 5. *Árbol de decisión para la clasificación del uso de suelo y cambio de cobertura por minería de oro mediante el SAR Sentinel-1*

Criterio de decisión	Uso de la tierra y cobertura terrestre
Valor mínimo – máximo sobre RDFI; -2,72 a -0,60	1. Urbano
Valor mínimo – máximo sobre RDFI; -0,60 a -0,245	2. Bosque
Valor mínimo – máximo sobre RDFI; -0,245 a -0,24	3. Vegetación secundaria
Valor mínimo – máximo sobre RDFI; -0,24 a -0,22	4. Agricultura
Valor mínimo – máximo sobre RDFI; -0,22 a -0,15	5. Minería
Valor mínimo – máximo sobre RDFI; -0,15 a -0,13	6. Pasto
Valor mínimo – máximo sobre RDFI; -0,13 a 0,005	7. Agua

Fuente: Tomado y adaptado de MINAM (2015); Puzzi et al. (2021); Saah et al. (2020).

Para los cambios entre los periodos estacionales entre marzo-abril, agosto-septiembre, y noviembre-diciembre se realizó una operación de diferencia (Ecuación 4) (Puyravaud 2003, p. 58; INRENA et al. 2006; CA 2007, p. 45; Alarcón et al. 2016, p. 321; Asner y Tupayachi 2017, p. 98).

Época (mar – abr)2021 * 10 + Época (ago – set) 2021 ...(Ecuación 4)

3. Post-Clasificación, La Post-clasificación es el “método que requiere de la rectificación y clasificación de cada imagen, para luego ser

comparados píxel a píxel” (Jensen et al. 1991; Xiuwan 2002; Alarcón et al. 2016), el procedimiento se realizó luego de realizar la clasificación mediante el AD de datos SR Sentinel-1 con retrodispersión VV, VH, VV/VH a través del aRFDI (Alarcón et al. 2016).

3.6.2 Precisión de datos

La matriz de confusión y el coeficiente kappa (κ) se utilizaron para evaluar la precisión de los datos SAR Sentinel-1 (Cohen 1960; Cohen et al. 2003; Cerda y Villarroel 2008; Alarcón et al. 2016), como un examen de evaluación de los datos procesados, información real de campo, imágenes WorldView (0,38 m x 0,38 m) y imágenes PlanetScope (3 m x 3 m) (Elijah y Jensen 1996; Chuvieco 2002; Chuvieco y Hantson 2010; Alarcón et al. 2016). La tabla 6 muestra los niveles de concordancia cualitativa utilizados para realizar la interpretación (Cohen 1960; Cohen et al. 2003; Cerda y Villarroel 2008; Kuhn y Johnson 2013; Alarcón et al. 2016).

$$Precision\ general = VP + VN / VP + FP + VN + FN \quad (\text{Ecuacion 5})$$

donde: VP es verdadero positivo, VN verdadero negativo, FP falso positivo, y FN falso negativo.

$$Kappa(k) = f_o - f_c / N - f_c \quad (\text{Ecuación 6})$$

donde: f_o : proporción de unidades concordantes, y f_c : proporción de unidades para las que se espera una concordancia al azar.

Tabla 6. Valores del coeficiente kappa

Coeficiente Kappa	Fuerza de la Concordancia
“0,00”	“Pobre (<i>Poor</i>)”
“0,01 – 0,20”	“Leve (<i>Slight</i>)”
“0,21 – 0,40”	“Aceptable (<i>Fair</i>)”
“0,41 – 0,60”	“Moderada (<i>Moderate</i>)”
“0,61 – 0,80”	“Considerable (<i>Substantial</i>)”

“0,81 – 1,00”	“Casi perfecta (<i>Almost perfect</i>)”
---------------	---

Fuente: Cerda y Villarroel (2008); Cohen (1960); (Cohen et al. 2003); Landis y Koch (1977).

El CIPEC, el Centro para el Estudio de Instituciones, Población y Cambios en el Medio Ambiente de la Universidad de Indiana, proporcionó la base para el protocolo de recopilación de información de campo (Moran y Brondizio 1998; Chávez et al. 2013).

La precisión de la clasificaciones estacionales de 2021 (marzo-abril, agosto-septiembre, y noviembre-diciembre), se realizó a través de 383 áreas de muestreo en campo e imágenes (unidad mínima cartografiada 0,5 ha) de mediana y alta resolución: PlanetScope (3 m), WorldView (0,38 m), y Drone (0,03 m) (Figura 10) (Cerda y Villarroel 2008, p. 45; Alarcón et al. 2016, p. 323).

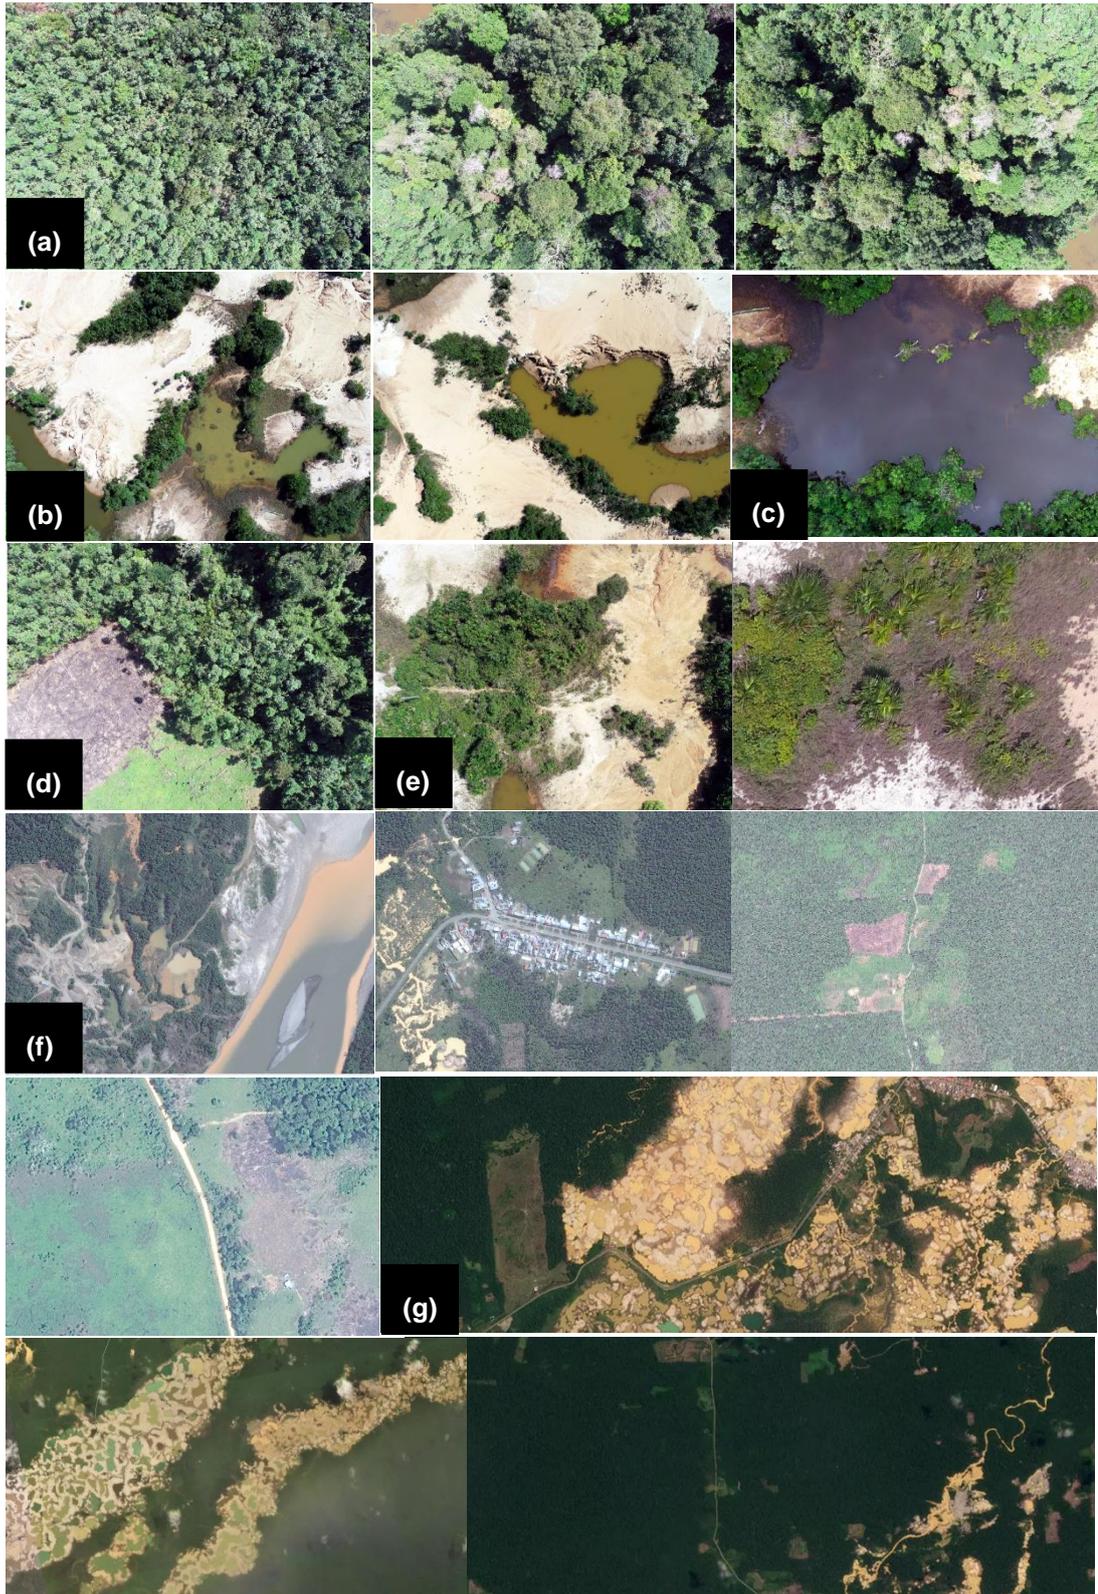


Figura 10. Validación de bosque (a, f, g), minería (b, f, g), agua (c, f, g), pastos (d, f, g), vegetación secundaria (e, f, g), agricultura (f, g) y urbano (f, g) con imágenes de Drone de 0,03 m x 0,03 m (a, b, c, d), WorldView de 0,38 m x 0,38 m de resolución espacial (f) e imágenes PlanetScope de 3 m x 3 m de resolución espacial (g).

Fuente: Planet-Team (2021).

3.6.4 Análisis estadístico

El procedimiento utiliza estadísticas descriptivas e inferenciales utilizando programas de acceso abierto y licenciados, como Microsoft Excel, ENVI 5,3®, ArcGis 10,5®, SNAP ESA y Google Earth Engine.

Para el primer, segundo y tercer objetivo, se creó una clasificación utilizando el método de árbol de decisión a partir de datos de retrodispersión VV, VH y una adaptación del Índice de Degradación Forestal del Radar (aRFDI) utilizando el sensor SAR Sentinel-1 en los sectores de La Pampa y Guacamayo durante el periodo estacional de marzo-abril, agosto-septiembre y noviembre-diciembre de 2021 (Tanase et al. 2013; Tanase et al. 2015b; Addison y Oommen 2018; Bouvet et al. 2018; Samat et al. 2018; Belenguer-Plomer et al. 2019). La precisión de la clasificación se evaluará mediante una matriz de confusión y el índice de Kappa (Cohen 1960; Landis y Koch 1977; Cohen et al. 2003; Cerda y Villarroel 2008; Alarcón et al. 2016).

Se utilizó la estadística descriptiva geoespacial utilizando ArcGis Pro 2,1®, ArcGis 10,5® y Microsoft Excel para alcanzar el cuarto objetivo, que consistía en determinar los cambios en el uso del suelo por minería de oro en los sectores de La Pampa y Guacamayo – Madre de Dios durante los periodos estacionales de 2021. (Puyravaud 2003, p. 58; INRENA et al. 2006; CA 2007, p. 45; Alarcón et al. 2016, p. 321; Asner y Tupayachi 2017, p. 98).

CAPÍTULO IV: RESULTADOS Y DISCUSIÓN

4.1 Retrodispersión del SAR Sentinel-1 en el sector de la Pampa y Guacamayo en periodos estacionales

Se utilizaron tres escenas de Sentinel-1 de acuerdo a las especificaciones de la tabla 3 de Sentinel Hub, Alaska Satellite Facility (ASF) (Bouvet et al. 2018; Holtgrave et al. 2020; Puzzi et al. 2020; Niro et al. 2021; Puzzi et al. 2021) y Google Earth Engine (GEE) (Mutanga y Kumar 2019). Las imágenes de Sentinel-1 calibradas radiométricamente y corregidas por el terreno se almacenan en Google Earth Engine (GEE) y un disco de almacenamiento procesada por SNAP ESA.

Los satélites se encuentran en órbitas heliosincrónicas polares opuestas a una altitud de 693 km, con un ciclo de repetición de 12 días, que contiene 175 órbitas. Esto da como resultado una frecuencia de repetición de 24 horas en latitudes altas y de 3 días en el ecuador. El sistema SAR opera dentro de las frecuencias de la banda C (5,407 GHz) en uno de los cuatro modos de adquisición (Stripmap (SM), Interferometric Wide Swath (IW), Extra-Wide Swath (EW) y Wave (WV)). El estudio utilizó el modo IW como data predeterminado sobre tierra, operando bajo el principio TOPSAR (Terrain Observation with Progressive Scans SAR) (Clement et al. 2018)

Los datos de polarización cruzada (VH y HV) utilizadas producen una gama más amplia de valores de retrodispersión de las superficies terrestres con vegetación en comparación con los datos copolarizados (VV y HH), lo que lleva a una posible superposición con los valores bajos de retrodispersión asociados con el agua, lo que provoca una clasificación errónea de la tierra como inundado (Inglada et al. 2016; Bouvet et al. 2018; Clement et al. 2018; Samat et al. 2018; Doblaz et al. 2020; Janse van Rensburg y Kemp 2022). Las longitudes de onda polarizadas VV son más susceptibles a la rugosidad de la

superficie del agua, comúnmente causada por el viento o la lluvia, lo que aumenta el retorno de la retrodispersión al satélite, lo que hace que no se identifique la inundación (Inglada et al. 2016; Bouvet et al. 2018; Clement et al. 2018; Samat et al. 2018; Doblas et al. 2020; Janse van Rensburg y Kemp 2022). Las limitaciones de cada polarización a medida que varían las condiciones ambientales requieren reconocimiento al usar Sentinel-1 para el mapeo de inundaciones. Investigaciones anteriores concluyeron que VV proporciona una ligera ventaja al identificar inundaciones cuando se utilizan datos de Sentinel-1 (Mansaray et al. 2021).

Las polarizaciones muestran una secuencia similar para la zona de estudio (a. Urbano, b. Bosques, c. Vegetación secundaria, d. Agricultura y pasto, e. Minería, y f. Agua) donde confluye una fuerte interacción de la actividad minera de oro con el bosque y otros usos (Figuras de 11-17). Los perfiles muestran la estacionalidad en los periodos de evaluación, la primera y la tercera un periodo de lluvias, y la segunda en época seca con bajas precipitaciones. Se observa una disminución en la extensión de la inundación después del 29 de diciembre, antes de un aumento el 10 de enero al 4,9% (VH) y 4,2% (VV), la segunda mayor extensión observada.

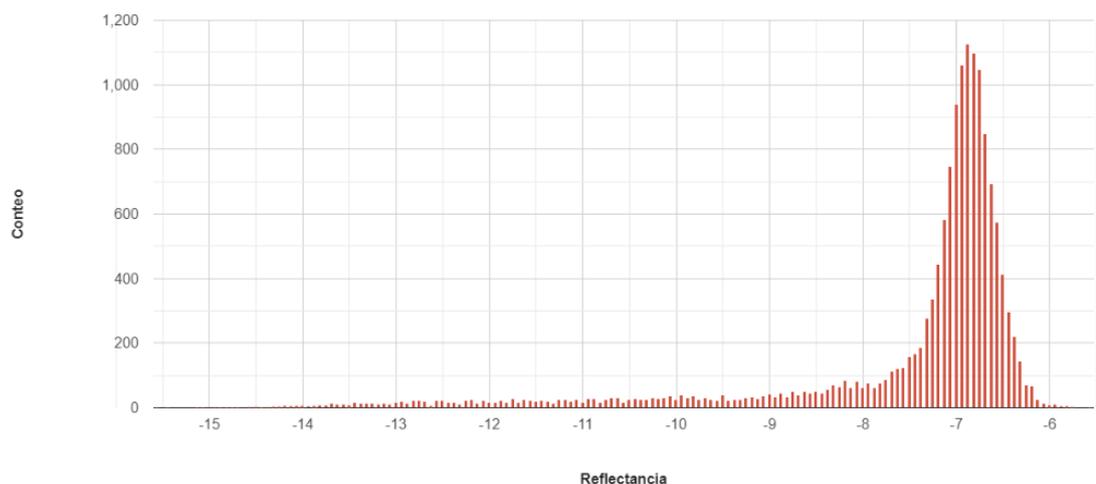


Figura 11. Polarización VV de banda C de SAR Sentinel-1 de marzo-abril de 2021.

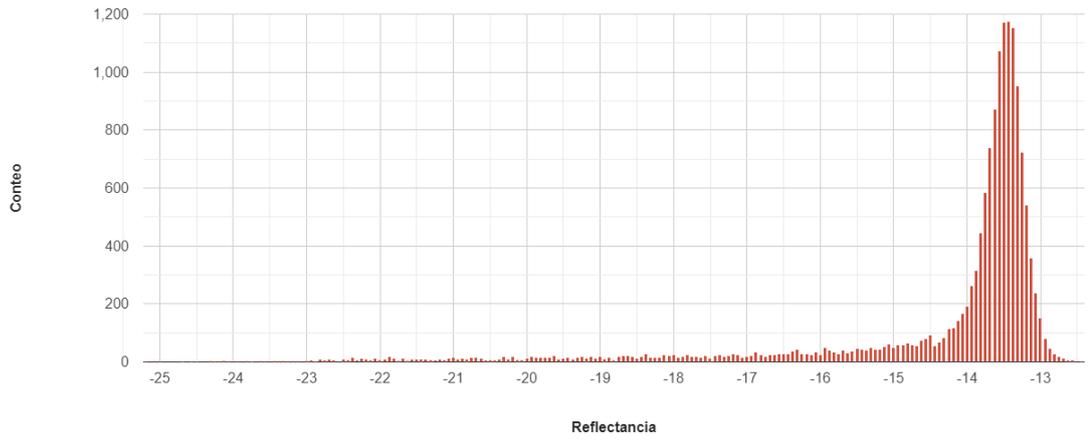


Figura 13. Polarización VH de banda C de SAR Sentinel-1 de marzo-abril de 2021.

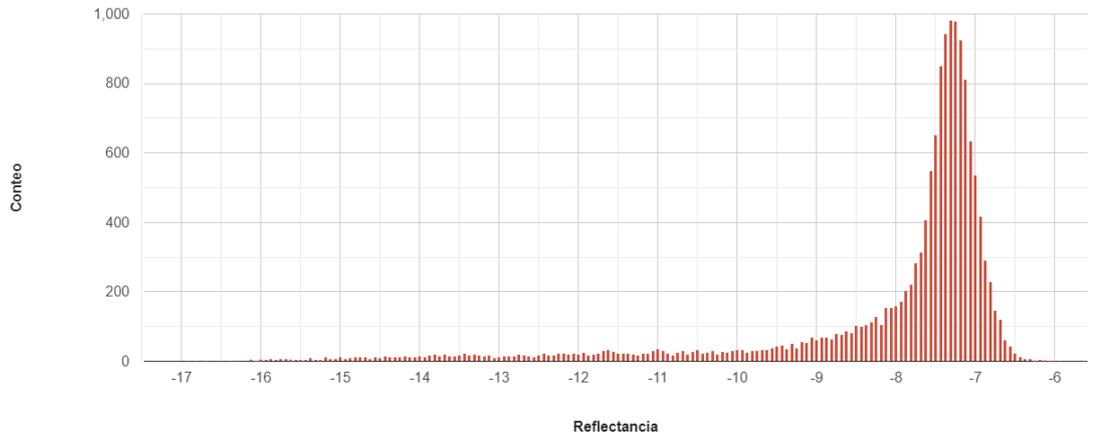


Figura 12. Polarización VV de banda C de SAR Sentinel-1 de agosto-septiembre de 2021.

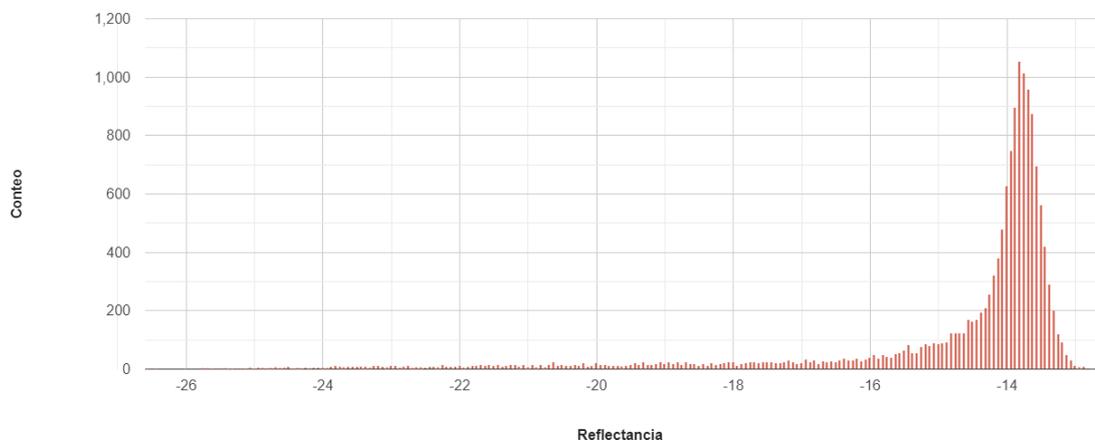


Figura 14. Polarización VH de banda C de SAR Sentinel-1 de agosto-septiembre de 2021.

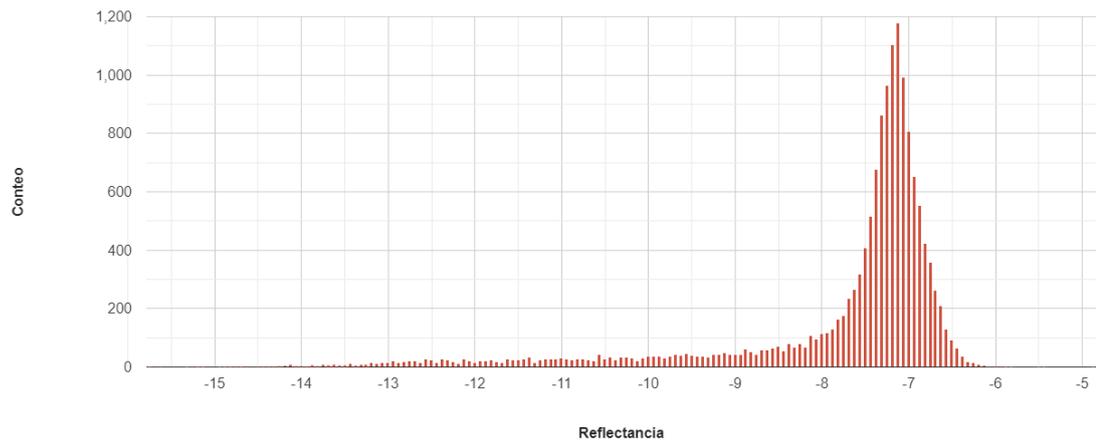


Figura 16. Polarización VV de banda C de SAR Sentinel-1 de noviembre-diciembre de 2021.

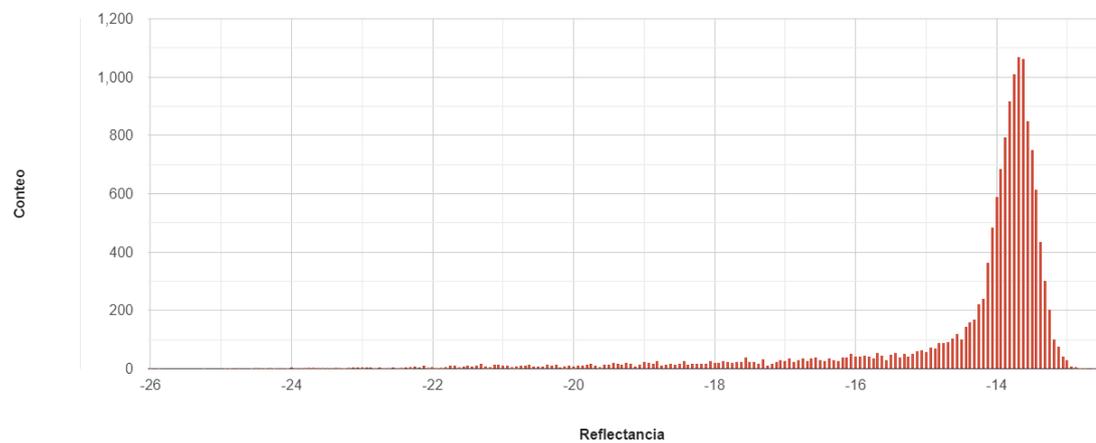


Figura 15. Polarización VH de banda C de SAR Sentinel-1 de noviembre-diciembre de 2021.

Las polarizaciones VV y VH están disponibles para todas las imágenes, lo que permite una comparación de su capacidad para delinear inundaciones o áreas con mayor humedad. Las series de tiempo observadas entre el conjunto de datos son similares, como se ve en las figuras 11-17. Las imágenes proporcionan diferentes grados con presencia de agua en la zona minera entre VV y VH. Las polarizaciones VH presentan un mayor grado de penetración mientras que VV identifica una mayor área de la zona.

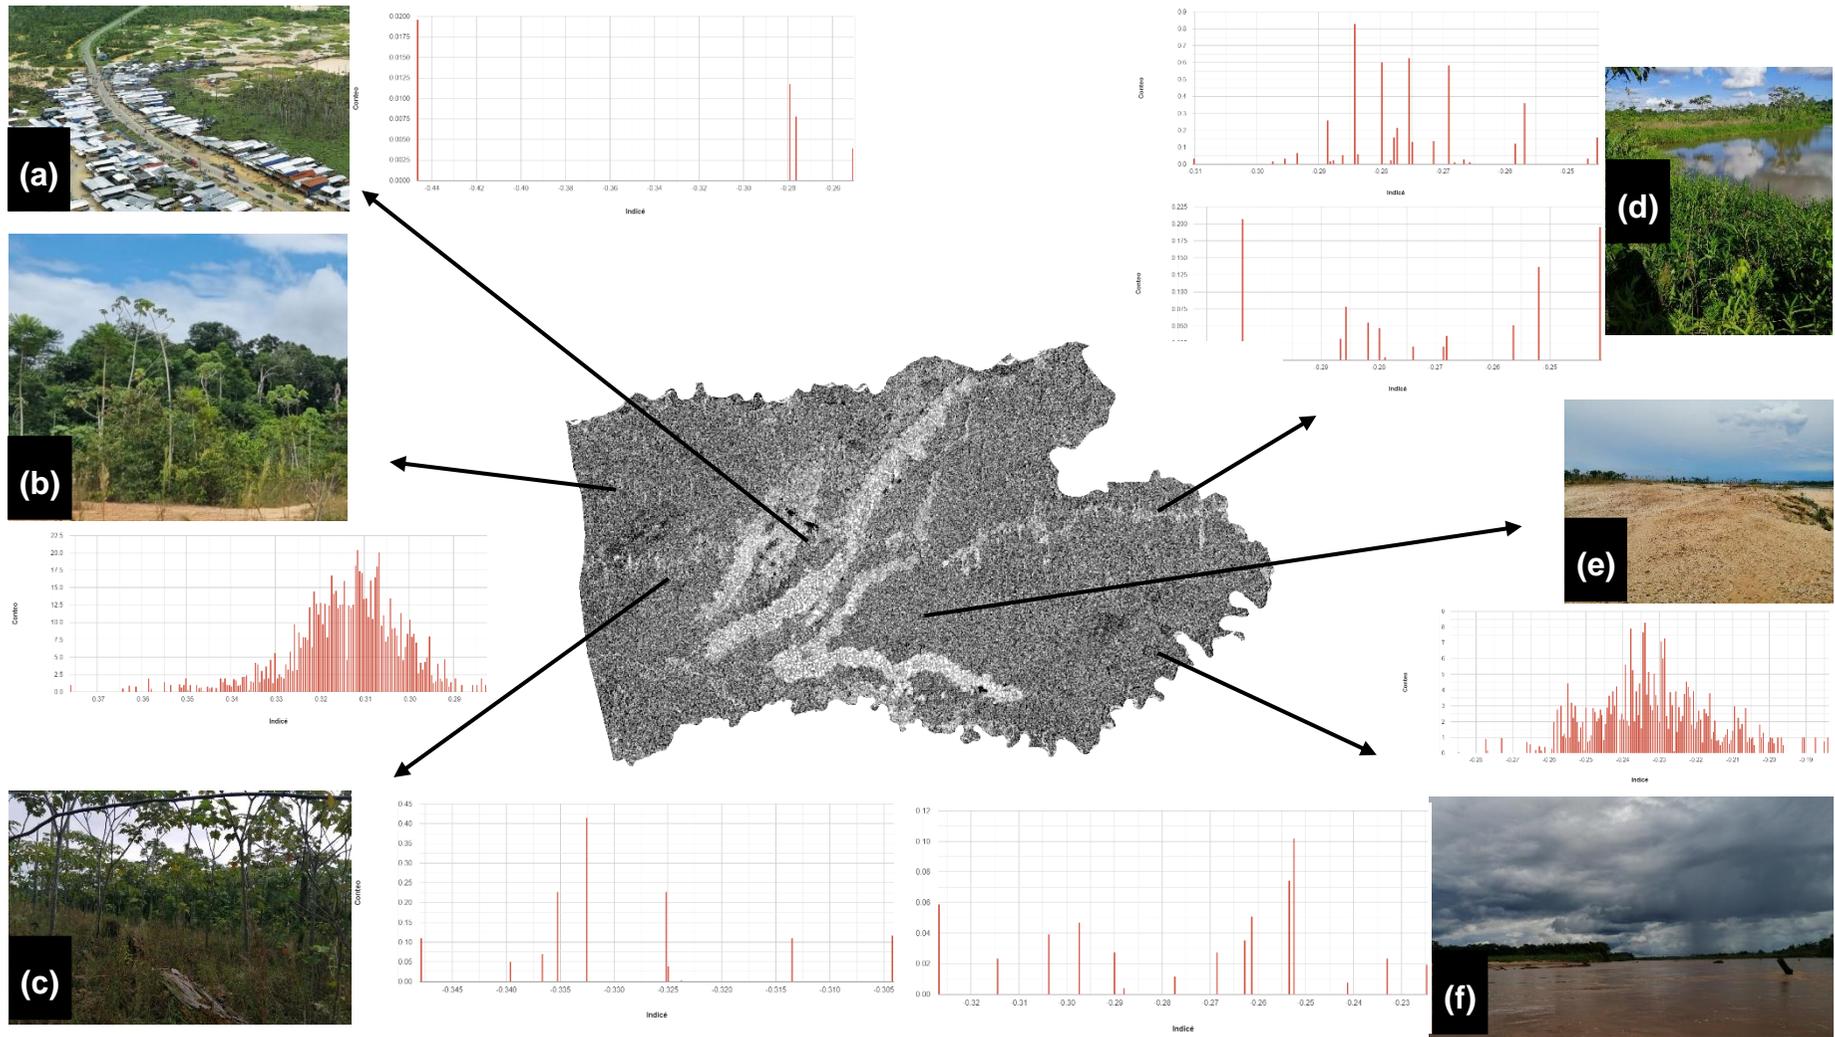


Figura 17. Adaptación del Índice de degradación forestal por radar (aRFDI) del Satélite Sentinel-1 (20/08/2021), con polarizaciones VV y VH; a. Urbano, b. Bosque, c. Vegetación secundaria, d. Agricultura y pasto, e. Minería, y f. Agua.

Dos fechas muestran una diferencia considerable entre las dos polarizaciones. El 29 de marzo y 18 de diciembre, la extensión de la inundación de VH es mayor que la de VV, sin embargo, VH identifica posibles inundaciones pluviales que el VV pasa por alto. De manera similar sucede con la imagen de 20 de agosto.

A nivel de la adaptación del Índice de Degradación Forestal de Radar (aRFDI) que integra en un índice las polarizaciones VV y VH, se observa mejor las áreas con presencia de inundaciones, con mayor proporción en la época de lluvias. Sin embargo, a nivel operaciones mineras estas se detectan con mayor incidencia en la época de estiaje. Esta característica se debe a que la polarización VH identifica una superficie de agua uniforme en comparación con las áreas separadas más pequeñas vistas en el VV (Figura 17). Este comportamiento, se asume a la falta de consistencia en la respuesta de retrodispersión VV es causada por la aspereza de la superficie del agua por el viento (Ajadi et al. 2016; Inglada et al. 2016; Bouvet et al. 2018; Li y Bijker 2019; Vargas et al. 2019; Albuquerque et al. 2020; Janse van Rensburg y Kemp 2022).

Para el análisis de variación espacial-estacional del uso del suelo por minería de oro, se adaptó el criterio de decisión de coberturas (Uso de la tierra y cobertura terrestre) propuesto por el MINAM (2015) (Tabla 5); 1. Urbano, 2. Bosque, 3. Vegetación secundaria, 4. Agricultura, 5. Minería, 6. Pasto, y 7. Agua.

4.1.1 Adaptación del Índice de degradación forestal por radar (aRFDI)

Las polarizaciones VV y VH se han usado ampliamente para la identificación de áreas inundadas. Ello se justifica por el excelente comportamiento que proporciona una reflectancia similar a la del agua. Hay extensiones de inundación o áreas con mayor humedad coincidentes en la polarización VV de estas áreas del 29 de marzo y 18 de diciembre. Mientras que la polarización VH identifica secciones adicionales de los bordes de la pista como área con humedad en comparación con las otras imágenes. Las áreas con presencia de agua o humedad pueden ser correcta, sin embargo, se requiere precaución

debido a la posibilidad de clasificación errónea en torno a estas características. Esta peculiaridad permite cuantificar con una mayor precisión las áreas de uso minero, sin embargo, por la estacionalidad de lluvias esta actividad se limita en sus operaciones y se maximiza en época seca (baja precipitación).

Una investigación preliminar en la región de Madre de Dios reveló áreas frecuentemente perturbadas con un continuo de suelos circundante perturbada a nivel de incendios (Alarcon-Aguirre et al. 2022). Para maximizar la detección de estas áreas, aprovechamos la ventaja de las imágenes SAR Sentinel-1 en una serie de tiempo estacional anual, por lo tanto, permite una mayor confianza para determinar su estado (perturbado/no perturbado), en comparación con solo dos observaciones. El algoritmo planteado es una adaptación del RDFI (aRDFI) que utiliza datos multitemporales como información intermedia para verificar las ubicaciones de perturbaciones, pero inicialmente no categoriza temporalmente los píxeles de cambio,

Las áreas conocidas por tener >50% de cobertura forestal (Joshi et al. 2016) presentan un valor de índice de degradación forestal por radar <0,245 (Figura 17). Si bien en la dinámica forestal sucesional se descarta el estudio de la agricultura, pastos, agua, urbano, y minería, esto debido a que la retrodispersión se relaciona con mayor incidencia con la biomasa respecto a las restantes (Figura 17) y se observa que disminuye con la perturbación y/o degradación. Dado que los bosques tienden a despolarizar la señal del radar (Joshi et al. 2016; Alarcon-Aguirre et al. 2022), dando valores altos que reducen la pérdida de cobertura forestal. Para analizar la variación espacial-estacional del uso del suelo por minería de oro, nuestra metodología adaptó la pérdida estacional anual en σ_{HV}^0 (Joshi et al. 2016; Alarcon-Aguirre et al. 2022) para la detección de perturbaciones por σ_{VH}^0 (Joshi et al. 2016; Alarcon-Aguirre et al. 2022).

Esta adaptación, finalmente agrego la relación VV/VH respecto a la original HH y HV, este cambio mantiene la fuerza para medir el doble rebote y distinguir los tipos de vegetación, siendo útil para el mapeo uso de la tierra y cobertura terrestre. En este caso, la versión adaptada (aRFDI) utiliza la banda

VV en lugar de la banda HH (Ecuación 3) ya que esta última no está disponible desde Sentinel-1 sobre esta área. Se espera que aRDFI resalte la superficie rugosa y la dispersión de doble rebote, ya que la polarización VV es sensible a estos dos mecanismos de dispersión, mientras que VH es principalmente sensible a la dispersión de volumen. Por lo tanto, encontramos que es potencialmente una capa útil para ayudar a diferenciar las coberturas y usos de la tierra (Tanase et al. 2010a; Tanase et al. 2010b; Tanase et al. 2013; Tanase et al. 2015b; Tanase et al. 2015a).

En la región de estudio se registraron diferencias significativas en la distribución de la retrodispersión VV y VH para áreas perturbadas y no perturbadas traducidas en los valores de la aRDFI; para la minería de oro se cuantificó para el primer periodo de 29 de marzo (1) de 8 250,42 ha, 12 223,39 ha para el 20 de agosto (2) y 9 143,96 ha para el 18 de diciembre (3). Destacándose otros usos como el de bosque con 116 260,73 ha para (1), 109 470,62 ha para (2), y 114 383,44 ha para (3). Agricultura con 3 688,77 ha, 5 955,20 ha, y 4 460,15 ha respectivamente. Mientras áreas urbanas presenta una menor proporción respecto a las demás categorías, 38,39 ha, 21,92 ha, 43,93 ha para (1), (2), y (3) (Figura 18-21).

El análisis mediante aRDFI reveló que (i) las categorías de menor tamaño se encuentran las categorías Urbano, Bosque, y Vegetación secundaria; (ii) los eventos de tamaño medio se encuentran la Minería y; (iii) eventos de gran tamaño para pastizales y superficies de agua.

De los datos, podemos deducir la mayor intensidad de la actividad minera de oro se produce en época de menor precipitación, por lo que, la precisión y el uso del SAR Sentinel-1 en ambos periodos son fiables.

La distribución espacial de las áreas afectadas por minería de oro se observó principalmente cercanas a las vías de acceso (fluvial o terrestre), en nuestro caso, incluso llegando a las Áreas Naturales Protegidas (Reserva Nacional Tambopata) (Figura 18-21).

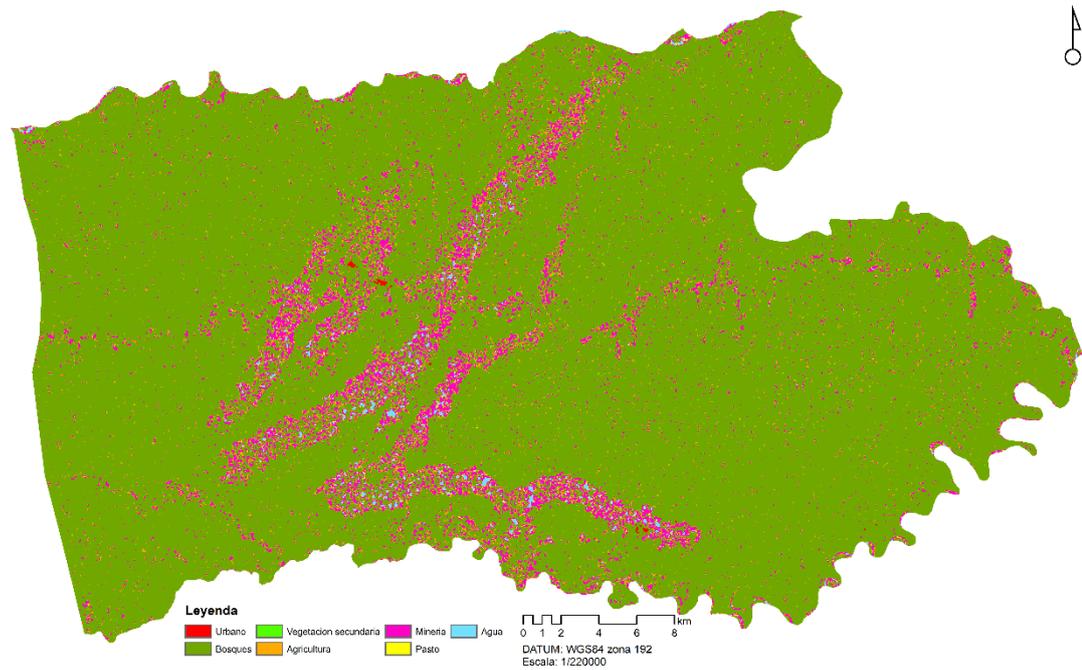


Figura 18. Adaptación del Índice de degradación forestal por radar (aRFDI) del Satélite Sentinel-1 (29/03/2021)

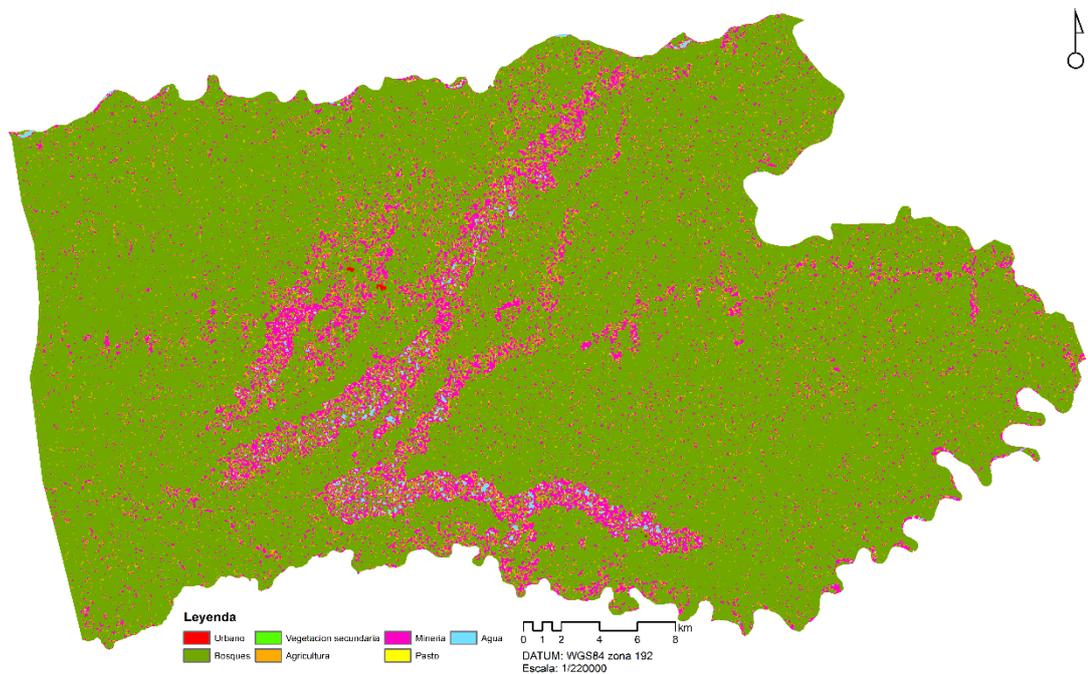


Figura 19. Adaptación del Índice de degradación forestal por radar (aRFDI) del Satélite Sentinel-1 (20/08/2021)

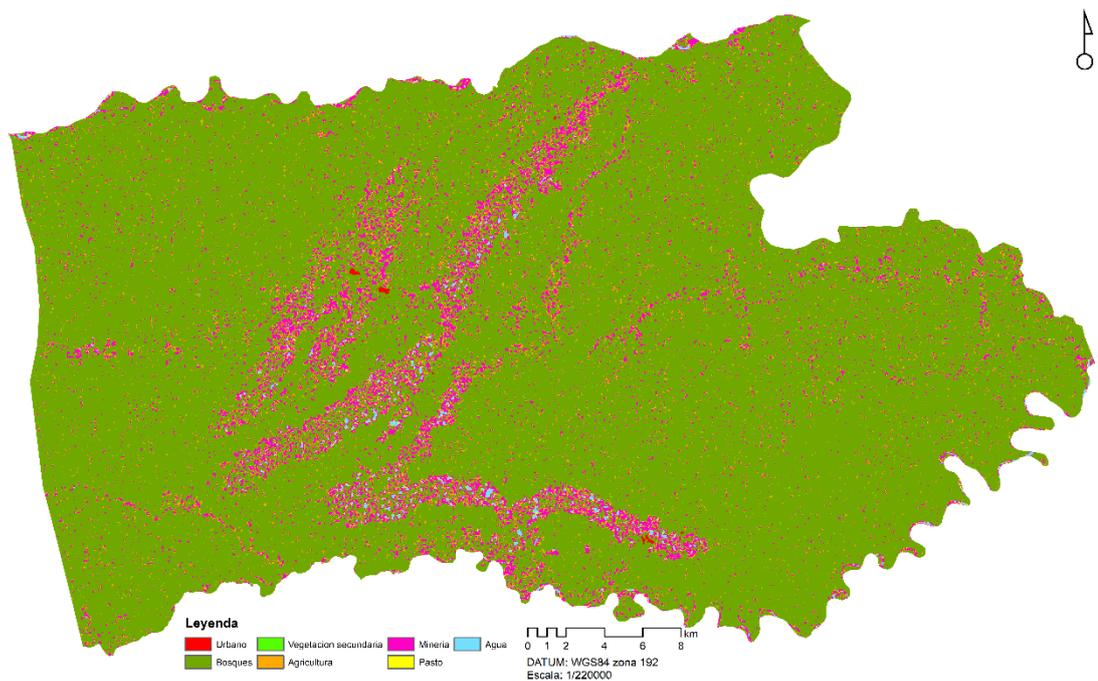


Figura 20. Adaptación del Índice de degradación forestal por radar (aRFDI) del Satélite Sentinel-1 (18/12/2021)

Tabla 7. Cuantificación de la aRFDI para los periodos estacionales 2021

Periodo	Categorías (ha)					
	1 (Urbano)	2 (Bosque)	3 (Vegetación secundaria)	4 (Agricultura)	5 (Minería)	6 (Pastos)
29/03/2021 ⁽¹⁾	38,39	116260,73	831,45	3688,77	8250,42	379,81
20/08/2021 ⁽²⁾	21,92	109470,62	1358,87	5955,20	12223,39	396,41
18/12/2021 ⁽³⁾	43,93	114383,44	1040,25	4460,15	9143,96	390,20

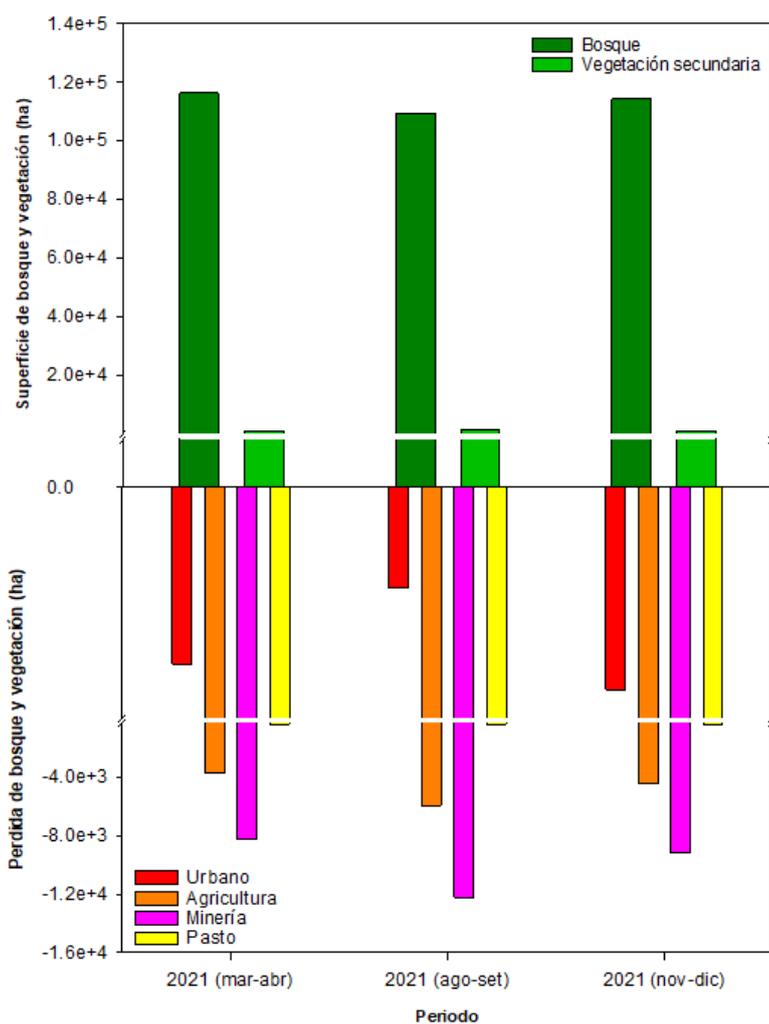


Figura 21. Cuantificación de la aRFDI para los periodos estacionales 2021

Durante los tres periodos estacionales del año 2021, la matriz de cambio del primer periodo respecto al segundo y del segundo con el tercero, cuantifica para el (1) una superficie de área de minería de oro versus el área total de 6,34%, el (2) de 9,40%, mientras que el (3) de 7,03% (Tabla 8). Estos resultados, reafirman el incremento de la actividad minera de oro se produce en mayor intensidad en la época de menor precipitación.

Tabla 8. Superficie de minería de oro respecto al área total de estudio

Periodos	Proporción de área respecto a la superficie total del primer periodo estacional (%)	Proporción de área respecto a la superficie total del segundo periodo estacional (%)
2021 ⁽¹⁾ -2021 ⁽²⁾	6,34	9,40
2021 ⁽²⁾ -2021 ⁽³⁾	9,40	7,03

El estudio presenta un algoritmo modificado del RDFI (aRDFI) para detectar perturbaciones y/o degradaciones forestales y del suelo usando radar, específicamente por minería de oro basándose en una trayectoria temporal de cambio de retrodispersión e identificando áreas con recuperación lenta.

Hay algunas advertencias que requieren reconocimiento al usar datos SAR respecto a los ópticos. Dentro de este estudio, se muestra las extensiones de sensibilidad de las polarizaciones VV y VH y la respuesta a la retrodispersión a las áreas inundadas, áreas mineras o con presencia de humedad en diferentes periodos estaciones, además, fueron validados en los mismos periodos, dando un mayor soporte y fiabilidad a los resultados. Estos hallazgos coinciden con investigadores locales e internacionales (Moran y Brondizio 1998; DeFries et al. 2010; Lopez-Sanchez et al. 2014; Ajadi et al. 2016; Chen et al. 2016; Inglada et al. 2016; Ali et al. 2018; Bouvet et al. 2018; Clement et al. 2018; Martinez et al. 2018; Martins et al. 2018; Samat et al. 2018; Zhou et al. 2018; Cortés-McPherson 2019; Fikriyah et al. 2019; Li y Bijker 2019; Nicolau et al. 2019; Vargas et al. 2019; Albuquerque et al. 2020; Doblas et al. 2020; Liang y Liu 2020; Saah et al. 2020; Zhang et al. 2020; Garate-Quispe et al. 2021; Kulczycki y Franus 2021; Mansaray et al. 2021; Deane et al. 2022; Janse van Rensburg y Kemp 2022).

4.2 Evaluación de precisión de índice

La precisión del algoritmo en los tres periodos estacionales se realizó mediante una matriz de confusión de los aRDFI (Tabla 7, 9-10).

Para el (1) se cuantifico un modelo general de 64,80% y una concordancia de kappa de 0,585 (Moderada) (Cohen 1960; Cohen et al. 2003) (Tabla 9). El (2) reporto un modelo general de 67,60% y una concordancia de 0,619 (Considerable) (Tabla 10). En tanto para el (3) arrojo un modelo general de 66,10% y una concordancia de 0,600 (Moderada) (Tabla 11) (Cohen 1960; Cohen et al. 2003).

Tabla 9. *Matriz de confusión e Índice de kappa de datos de campo e imágenes frente a datos de la aRDFI de Sentinel-1 29/03/2021*

Categoría	Datos de campo/imágenes							f_{aRDFI}
	1 (Urbano)	2 (Bosque)	3 (Vegetación secundaria)	4 (Agricultura)	5 (Minería)	6 (Pastos)	7 (Agua)	
1 (Urbano)	27 (4)	0	0	5	10	3	0	45
2 (Bosque)	0	55 (13)	6	3	3	2	0	69
3 (Vegetación secundaria)	0	11	28 (6)	3	0	8	0	50
4 (Agricultura)	2	2	3	35 (8)	4	6	0	52
5 (Minería)	5	2	3	8	45 (15)	8	8	79
6 (Pastos)	1	2	7	8	2	24 (6)	0	44
7 (Agua)	0	0	0	0	10	0	34 (5)	44
$f_{C/I}$	35	72	47	62	74	51	42	383
$f_o=$	248	$f_c=$	58					
$k=$	0,585	$k_M=$	1,028					
$\sigma_k=$	0,0287	$\sigma_{ko}=$	0,0215					
$z=$	27,222	Matriz de confusión=		0,648				

Los datos de campo e imágenes utilizadas en la validación (n=383) para el periodo estacional anual 2021 (Tablas 9) fueron significativos para medir el uso de la tierra y cobertura terrestre, especialmente por la minería de oro (Cohen 1960; Cohen et al. 2003; Yaghobi et al. 2019). Los datos muestreados fueron evaluados en base a un criterio de periodicidades (frecuencias). Los

valores de las diagonales presentan una concordancia e irrelevante para los demás valores.

Con un $k = 0,585$, más de la mitad de las muestras verificadas están de acuerdo (excluyendo el azar) de datos aRDFI de Sentinel-1. k_M es 1,028 por lo que una porción importante de las discrepancias se debe a diferencias marginales. La probabilidad de que x como valor poblacional se encuentre entre 0,529 y 0,641 es del 95 (Cohen 1960; Cohen et al. 2003). El valor de z (27,222) es significativo con una probabilidad de $(P) < 0,001$ (Tabla 9), que contrasta un parámetro hipotético de la población versus un valor observado (estadístico) (Yaghoobi et al. 2019; Koley y Chockalingam 2022).

Tabla 10. *Matriz de confusión e Índice de kappa de datos de campo e imágenes frente a datos de la aRDFI de Sentinel-1 20/08/2021*

Categoría	Datos de campo/imágenes							f_{aRDFI}
	1 (Urbano)	2 (Bosque)	3 (Vegetación secundaria)	4 (Agricultura)	5 (Minería)	6 (Pastos)	7 (Agua)	
1 (Urbano)	30 (4)	0	0	5	10	0	0	45
2 (Bosque)	0	58 (14)	6	2	1	2	0	69
3 (Vegetación secundaria)	0	11	33 (7)	2	0	4	0	50
4 (Agricultura)	2	2	3	35 (8)	4	6	0	52
5 (Minería)	5	2	3	8	45 (15)	8	8	79
6 (Pastos)	1	2	7	8	2	24 (5)	0	44
7 (Agua)	0	0	0	0	10	0	34 (5)	44
$f_{c/i}$	38	75	52	60	72	44	42	383
$f_{o=}$	259	$f_{c=}$	58					
$k=$	0,619	$k_M=$	1,018					
$\sigma_k=$	0,0281	$\sigma_{k_o}=$	0,0215					
$z=$	28,775	Matriz de confusión=			0,676			

Los datos de campo e imágenes utilizadas en la validación ($n=383$) para el periodo estacional anual 2021 (Tablas 10) fueron significativos para medir el uso de la tierra y cobertura terrestre, especialmente por la minería de oro (Cohen 1960; Cohen et al. 2003; Yaghoobi et al. 2019). Los datos muestreados fueron evaluados en base a un criterio de periodicidades (frecuencias). Los

valores de las diagonales presentan una concordancia e irrelevante para los demás valores.

Con un $k = 0,619$, más de la mitad de las muestras verificadas están de acuerdo (excluyendo el azar) de datos aRFDI de Sentinel-1. k_M es 1,018 por lo que una porción importante de las discrepancias se debe a diferencias marginales. La probabilidad de que x como valor poblacional se encuentre entre 0,564 y 0,674 es del 95 (Cohen 1960; Cohen et al. 2003). El valor de z (28,775) es significativo con una probabilidad de $(P) < 0,001$ (Tabla 10), que contrasta un parámetro hipotético de la población versus un valor observado (estadístico) (Yaghoobi et al. 2019; Koley y Chockalingam 2022).

Tabla 11. *Matriz de confusión e Índice de kappa de datos de campo e imágenes frente a datos de la aRFDI de Sentinel-1 18/12/2021*

Categoría	Datos de campo/imágenes							f_{aRFDI}
	1 (Urbano)	2 (Bosque)	3 (Vegetación secundaria)	4 (Agricultura)	5 (Minería)	6 (Pastos)	7 (Agua)	
1 (Urbano)	27 (4)	0	0	5	10	3	0	45
2 (Bosque)	0	57 (13)	4	3	3	2	0	69
3 (Vegetación secundaria)	0	11	28 (6)	3	0	8	0	50
4 (Agricultura)	2	2	3	35 (8)	4	6	0	52
5 (Minería)	5	2	3	8	48 (16)	6	7	79
6 (Pastos)	1	2	7	8	2	24 (6)	0	44
7 (Agua)	0	0	0	0	10	0	34 (5)	44
f_{c1}	35	74	45	62	77	49	41	383
$f_{o=}$	253	$f_{c=}$	58					
$k=$	0,600	$k_M=$	1,028					
$\sigma_k=$	0,0285	$\sigma_{k_o}=$	0,0216					
$z=$	27,810	Matriz de confusión=			0,661			

Los datos de campo e imágenes utilizadas en la validación ($n=383$) para el periodo estacional anual 2021 (Tablas 11) fueron significativos para medir el uso de la tierra y cobertura terrestre, especialmente por la minería de oro (Cohen 1960; Cohen et al. 2003; Yaghoobi et al. 2019). Los datos muestreados fueron evaluados en base a un criterio de periodicidades (frecuencias). Los

valores de las diagonales presentan una concordancia e irrelevante para los demás valores.

Con un $k = 0,600$, más de la mitad de las muestras verificadas están de acuerdo (excluyendo el azar) de datos aRDFI de Sentinel-1. k_M es 1,028 por lo que una porción importante de las discrepancias se debe a diferencias marginales. La probabilidad de que x como valor poblacional se encuentre entre 0,544 y 0,656 es del 95 (Cohen 1960; Cohen et al. 2003). El valor de z (27,810) es significativo con una probabilidad de $(P) < 0,001$ (Tabla 11), que contrasta un parámetro hipotético de la población versus un valor observado (estadístico) (Yaghoobi et al. 2019; Koley y Chockalingam 2022).

4.3 Cambios de uso de suelo

Los cambios espacio-temporal uso de la tierra y cobertura terrestre respecto a la minería de oro con la aRDFI (Tabla 12-13), muestran un cambio gradual respecto a la época de mayor precipitación ($_1$ y $_3$) y baja precipitación ($_2$). Respecto a los cambios de la minería de oro en ($_1$) y ($_2$) podemos cuantificar que para el primer caso presenta una superficie de 8 250,42 ha, 12 223,39 ha para el segundo, y 9 143,96 ha para el tercero (Tablas 12-14 y Figuras 22-24).

El incremento de superficie del primer al segundo periodo corresponde a 3 972,97 ha, mientras que del segundo al tercer periodo existe un decremento de 3 079,43 ha. Los resultados marcan una mayor área en la época de menor precipitación que no necesariamente contrasta con la activación de área mineras con aguas de disposición residual, que podría suponer una mayor cuantificación. Sin embargo, el análisis espacio-temporal de los periodos $2021_{(1)}-2021_{(2)}$ $2021_{(2)}-2021_{(3)}$ $2021_{(1)}-2021_{(3)}$ reporta valores esperados, una tasa diaria de cambio (q) de 1,48% (27,59 ha/día y 827,70 ha/mes), 0,75% (-25,66 ha/día y -769,80 ha/mes), y 1,11% (3,38 ha/día y 101,40 ha/mes) respectivamente.

Caso contrario, sucede con el bosque y la vegetación secundaria. El primer periodo reporta 116 260,73 ha para bosque y 831,45 ha para vegetación secundaria, el segundo periodo con 109 470,62 ha y 1 358,87 ha, el tercer

periodo con 114 383,44 ha y 1 040,25 ha para bosque y vegetación secundaria respectivamente (Tablas 12-14 y Figuras 22-24).

Durante los tres periodos estacionales evaluados, la matriz de cambio del primer periodo respecto al segundo y del segundo con el tercero, cuantifica para el (1) una superficie de minería de oro versus el área total de 6,34%, el (2) de 9,40%, mientras que el (3) de 7,03% (Tabla 8). Estos resultados, reafirman el incremento de la actividad minera de oro se produce en mayor intensidad en la época de menor precipitación.

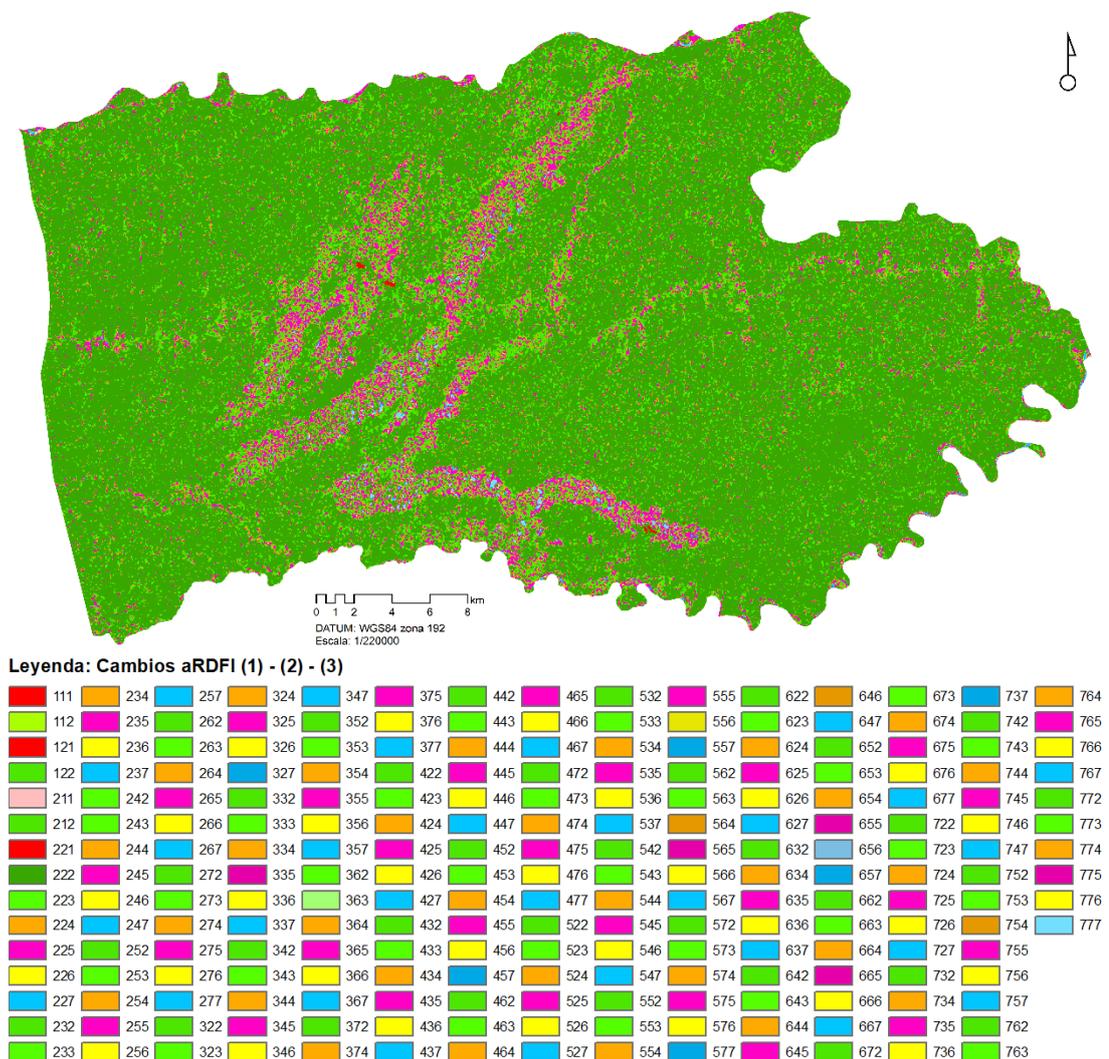


Figura 22. Cambio de cobertura de periodo estacional (1), (2), y (3).

Los resultados a nivel de visualización en el SAR Sentinel-1 muestra que la combinación de las polarizaciones VV y VH en un componente R (red) G (Green) B (blue) muestran un patrón de cambio del primer periodo al segundo con una coloración amarilla, del segundo al tercero el patrón refleja una coloración fucsia o purpura, mientras que la coloración más clara refleja un patrón de persistencia o no cambio (Figura 22 -23).

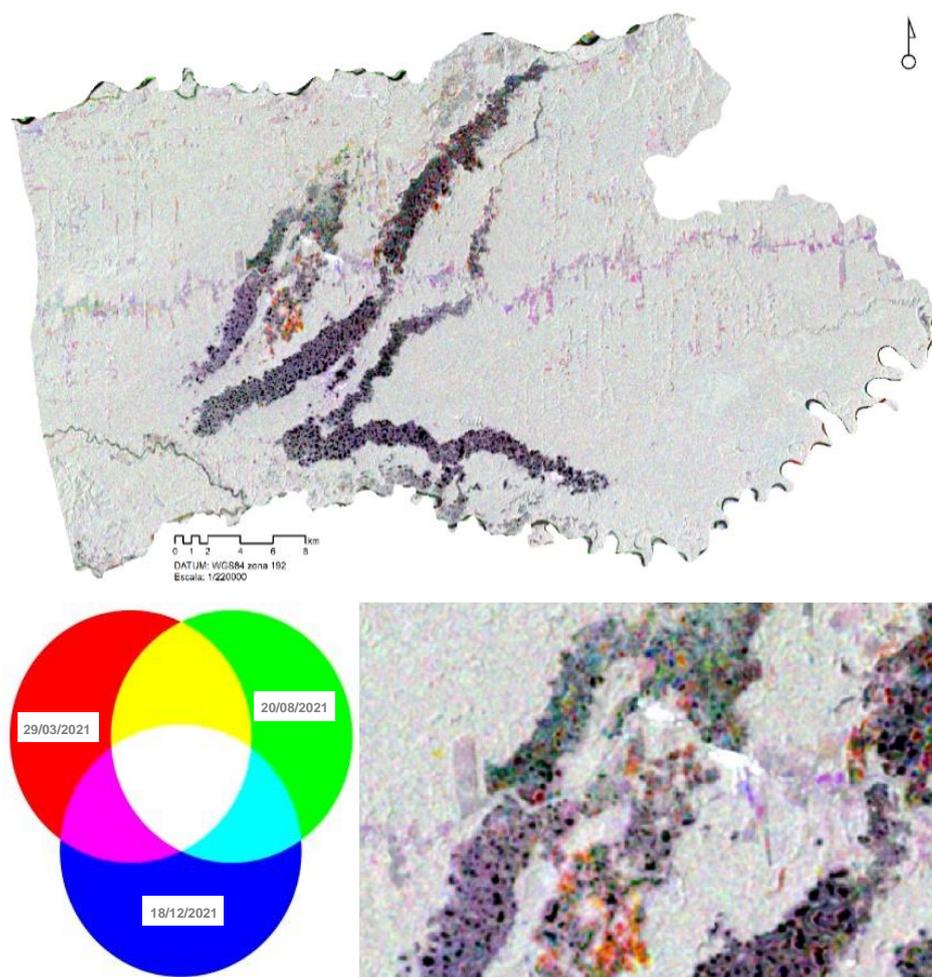


Figura 23. Cambios de cobertura en la polarización VV en el periodo estacional 2021.

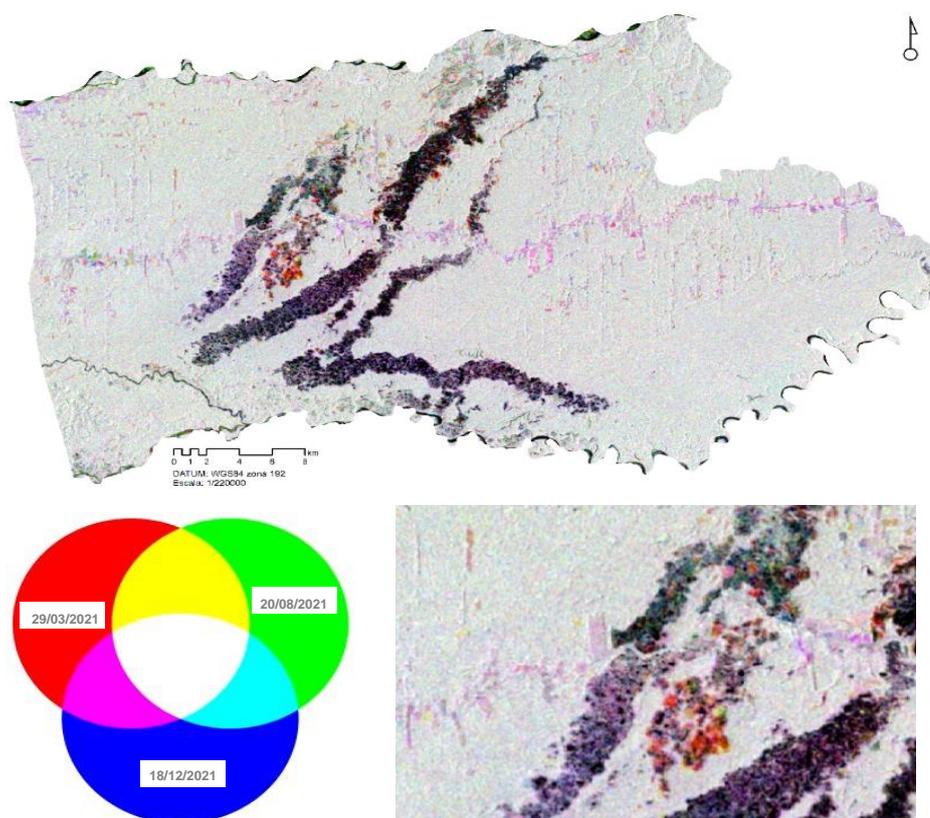


Figura 24. Cambios de cobertura en la polarización VH en el periodo estacional 2021.

Tabla 12. Cambio de cobertura de periodo estacional (1) y (2)

Categoría		Año 2021 (20/08/2021)							Total
		1 (Urbano)	2 (Bosque)	3 (Vegetación secundaria)	4 (Agricultura)	5 (Minería)	6 (Pastos)	7 (Agua)	
Año 2021 (29/03/2021)	1 (Urbano)	19,1552	19,2305	0,0000	0,0000	0,0000	0,0000	0,0000	38,39
	2 (Bosque)	2,7632	103761,7166	1046,0477	4419,3389	6923,6707	69,3103	37,8815	116260,73
	3 (Vegetación secundaria)	0,0000	466,5975	20,5172	98,0463	241,0235	3,3187	1,9478	831,45
	4 (Agricultura)	0,0000	2020,7387	96,6280	447,6698	1095,4441	18,2685	10,0172	3688,77
	5 (Minería)	0,0000	3124,7640	188,5472	955,8847	3590,2662	190,3168	200,6374	8250,42
	6 (Pastos)	0,0000	47,3476	4,2901	21,3176	189,4185	43,8185	73,6176	379,81
	7 (Agua)	0,0000	30,2271	2,8441	12,9450	183,5679	71,3794	330,4910	631,45
	Total	21,92	109470,62	1358,87	5955,20	12223,39	396,41	654,59	130081,01

Tabla 13. *Cambio de cobertura de periodo estacional (2) y (3)*

Categoría		Año 2021 (18/12/021)							Total
		1 (Urbano)	2 (Bosque)	3 (Vegetación secundaria)	4 (Agricultura)	5 (Minería)	6 (Pastos)	7 (Agua)	
Año 2021 (20/08/2021)	1 (Urbano)	20,7110	1,2074	0,0000	0,0000	0,0000	0,0000	0,0000	21,92
	2 (Bosque)	23,2221	102081,4235	653,1382	2671,5495	3946,4290	58,4682	36,3914	109470,62
	3 (Vegetación secundaria)	0,0000	1031,9082	23,5037	106,1301	190,8465	3,1507	3,3351	1358,87
	4 (Agricultura)	0,0001	4357,0882	111,3100	490,6254	965,1476	17,5524	13,4785	5955,20
	5 (Minería)	0,0000	6827,2456	247,1380	1163,4044	3618,4922	186,4170	180,6936	12223,39
	6 (Pastos)	0,0000	60,9934	3,1790	18,8474	202,6891	42,1787	68,5246	396,41
	7 (Agua)	0,0000	23,5730	1,9807	9,5900	220,3534	82,4295	316,6658	654,59
	Total	43,93	114383,44	1040,25	4460,15	9143,96	390,20	619,09	130081,01

Tabla 14. *Tasa y cambio de cobertura de minería de oro por periodo estacional*

Periodos	Tasa diaria de cambio de minería (%)	Cambio de cobertura de minería total (ha) (r)	
		Diario	Mensual
2021 ⁽¹⁾ -2021 ⁽²⁾	1,48	27,59	827,70
2021 ⁽²⁾ -2021 ⁽³⁾	0,75	-25,66	-769,80
2021 ⁽¹⁾ -2021 ⁽³⁾	1,11	3,38	101,40

El análisis de la variación espacial-estacional del uso del suelo por minería de oro con el sensor SAR Sentinel-1 en los sectores de la Pampa y Guacamayo está impulsado por uno de los factores más determinante en el cambio del paisaje en la Amazonia de Madre de Dios (Perz et al. 2016; Caballero et al. 2018; Cortés-McPherson 2019; Alarcon et al. 2021; Garate-Quispe et al. 2021; Alarcon-Aguirre et al. 2022; Alarcón-Aguirre et al. 2023), lo que se traduce en los valores de aRDFI de las áreas en estudio (Figura 22-23). La aRDFI mediante el uso del SAR Sentinel-1 con polarizaciones VV y VH, considera la medición de la dispersión por doble rebote del volumen, lo que implica un menor tamaño para áreas con vegetación y de tamaño medio para la minería de oro (Joshi et al. 2016). De otra manera, la deforestación y degradación del suelo debe analizarse con cuidado, considerando la época estacional e incidencia de actividades, ya que estos pueden incidir temporalmente en la sobre o sub cuantificación de la minería de oro (DeFries et al. 2010; Lopez-Sanchez et al. 2014; Ajadi et al. 2016; Chen et al. 2016; Inglada et al. 2016;

Bouvet et al. 2018; Clement et al. 2018; Martinez et al. 2018; Samat et al. 2018; Cortés-McPherson 2019; Janse van Rensburg y Kemp 2022).

El análisis de la variación espacial-estacional del uso del suelo por minería de oro con la ARDFI cuantifica resultados aceptables, los datos fueron verificados en campo y mediante imágenes para validar el método mediante umbrales de la aRDFI, en este caso se corroboró la fiabilidad de los SAR Sentinel-1 para áreas inundadas o con presencia de humedad sea esta por época de lluvias o por factores antrópicos que cambian el paisaje con presencia de agua residual propia de la actividad minera. Esta caracterización se manifiesta en investigaciones desarrolladas en diferentes partes del mundo y la naturaleza de la acción antrópica en el paisaje (Moran y Brondizio 1998; DeFries et al. 2010; Inglada et al. 2016; Ali et al. 2018; Bouvet et al. 2018; Samat et al. 2018; Cortés-McPherson 2019; Fikriyah et al. 2019; Li y Bijker 2019; Albuquerque et al. 2020; Saah et al. 2020; Zhang et al. 2020; Garate-Quispe et al. 2021; Mansaray et al. 2021)

CONCLUSIONES

En este estudio, se planteó la aplicación de datos espacio-temporales mediante la aRDFI del SAR Sentinel-1 en los sectores de La Pampa y Guacamayo, se concluye:

La minería de oro en el área de estudio se cuantificó para el primer periodo en 8 250,42 ha para el 29 de marzo del 2021, 12 223,39 ha para el 20 de agosto del 2021 y 9 143,96 ha para el 18 de diciembre del 2021, presentando una mayor incidencia en la época de menor precipitación.

Los cambios espacio-temporal uso de la tierra y cobertura terrestre respecto a la minería de oro con la aRDFI, reportaron un cambio gradual respecto a la época de mayor precipitación (primer y tercer periodo) y baja precipitación (segundo periodo). Respecto a los cambios de la minería de oro en el primer y segundo periodo, se cuantificó una tasa diaria de cambio (q) de 1,48% (27,59 ha/día y 827,70 ha/mes), segundo y tercer periodo cuantificó tasa diaria de cambio (q) de 0,75% (-25,66 ha/día y -769,80 ha/mes), y del primer y tercer periodo una tasa de 1,11% (3,38 ha/día y 101,40 ha/mes). Los resultados marcan una mayor área en la época de menor precipitación que no necesariamente contrasta con la activación de las áreas mineras con aguas de disposición residual, que podría suponer una mayor cuantificación. Caso contrario, sucede con el bosque y la vegetación secundaria. El primer periodo reporta 116 260,73 ha para bosque y 831,45 ha para vegetación secundaria, el segundo periodo con 109 470,62 ha y 1 358,87 ha, el tercer periodo con 114 383,44 ha y 1 040,25 ha para bosque y vegetación secundaria respectivamente.

Se acepta la hipótesis nula, la detección y cuantificación del cambio de cobertura y uso de suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La Pampa y Guacamayo no se produce en mayor proporción en la época estacional de lluvias.

SUGERENCIAS

La teledetección espacial en los últimos años se ha convertido en una tecnología de uso transversal de la mayoría de las disciplinas, por consiguiente, su amplio uso permite una disposición y caracterización de la cobertura terrestre. En este alcance, las tecnologías SAR brindan mayores opciones de estudio, por lo que, es preciso conocer los fundamentos de la teledetección a RADAR.

REFERENCIAS BIBLIOGRÁFICAS

ADDISON, P. Y OOMMEN, T. Utilizing satellite radar remote sensing for burn severity estimation. *International Journal of Applied Earth Observation and Geoinformation*, 2018, 73, 292-299. doi:<https://doi.org/10.1016/j.jag.2018.07.002>

AJADI, O. A., MEYER, F. J. Y WEBLEY, P. W. Change Detection in Synthetic Aperture Radar Images Using a Multiscale-Driven Approach. *Remote Sensing*, 2016, 8(6). doi:10.3390/rs8060482

ALARCON-AGUIRRE, G., MIRANDA FIDHEL, R. F., RAMOS ENCISO, D., CANAHUIRE-ROBLES, R., RODRIGUEZ-ACHATA, L. Y GARATE-QUISPE, J. Burn Severity Assessment Using Sentinel-1 SAR in the Southeast Peruvian Amazon, a Case Study of Madre de Dios. *Fire*, 2022, 5(4). doi:10.3390/fire5040094

ALARCÓN-AGUIRRE, G., SAJAMI QUISPE, E., VÁSQUEZ ZAVALITA, T., PONCE TEJADA, L. V., RAMOS ENCISO, D., RODRÍGUEZ ACHATA, L. Y GARATE-QUISPE, J. Vegetation dynamics in lands degraded by gold mining in the southeastern Peruvian Amazon. *Trees, Forests and People*, 2023/03/01/2023, 11, 100369. doi:<https://doi.org/10.1016/j.tfp.2023.100369>

ALARCON, G., CANAHUIRE, R. R., GUEVARRA, F. M. G., RODRIGUEZ, L., GALLEGOS, L. E. Y GARATE-QUISPE, J. Dinámica de la pérdida de bosques en el sureste de la Amazonia peruana: un estudio de caso en Madre de Dios. *Ecosistemas*, 2021, 30(2), 2175-2175. doi:<https://doi.org/10.7818/ECOS.2175>

ALARCÓN, G., DÍAZ, J., VELA, M., GARCÍA, M. Y GUTIÉRREZ, J. Deforestación en el sureste de la amazonia del Perú entre los años 1999-2013; caso Regional de Madre de Dios (Puerto Maldonado–Inambari). *Journal of High Andean Research*, 2016, 18(3), 319-330. doi:<http://dx.doi.org/10.18271/ria.2016.221>

ALARCON, G., ZEVALLOS, P. A., QUISPE, R., RAMOS, D. Y GARATE-QUISPE, J. S. Valor de conservación de un bosque en el sureste de la Amazonia Peruana: El caso de Madre de Dios. *Revista Ecosistemas*, 2020, 29(3). doi:<https://doi.org/10.7818/ECOS.1947>

ALBUQUERQUE, J., ALVES, A. C., MEDEIROS, A. M., BOURBON, M. Y ANTUNES, M. Classification methods applied to familial hypercholesterolemia diagnosis at pediatric age: Comparison of Simon Broome criteria with modified decision tree models. *Atherosclerosis*, 2020/12/01/ 2020, 315, e205. doi:<https://doi.org/10.1016/j.atherosclerosis.2020.10.642>

ALI, I., CAO, S., NAEIMI, V., PAULIK, C. Y WAGNER, W. Methods to Remove the Border Noise From Sentinel-1 Synthetic Aperture Radar Data: Implications and Importance For Time-Series Analysis. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2018, 11(3), 777-786. doi:10.1109/JSTARS.2017.2787650

ANAYA, J. A. Y CHUVIECO, E. Validación para Colombia de la estimación de área quemada del producto L3JRC en el periodo 2001-2007/Validation of the L3JRC burned area product estimation in Colombia from 2001 to 2007. *Actualidades Biológicas*, 2010, 32(92), 29.

ASNER, G. P. Y TUPAYACHI, R. Accelerated losses of protected forests from gold mining in the Peruvian Amazon. *Environmental Research Letters*, 2017, 12(9), 94-104. doi:10.1088/1748-9326/aa7dab

BARAY, H. L. Á. *Introducción a la metodología de la investigación*. Edtion ed.: Juan Carlos Martínez Coll, 2006. ISBN 8469019996.

BELENGUER-PLOMER, M. A., TANASE, M. A., FERNANDEZ-CARRILLO, A. Y CHUVIECO, E. Burned area detection and mapping using Sentinel-1 backscatter coefficient and thermal anomalies. *Remote Sensing of Environment*, 2019, 233, 111345. doi:<https://doi.org/10.1016/j.rse.2019.111345>

BOOYSEN, R., GLOAGUEN, R., LORENZ, S., ZIMMERMANN, R. Y NEX, P. A. M. Geological Remote Sensing. In D. ALDERTON Y S.A. ELIAS eds. *Encyclopedia of Geology (Second Edition)*. Oxford: Academic Press, 2021, p. 301-314.

BOUVET, A., MERMOZ, S., BALLÈRE, M., KOLECK, T. Y LE TOAN, T. Use of the SAR Shadowing Effect for Deforestation Detection with Sentinel-1 Time Series. *Remote Sensing*, 2018, 10(8). doi:10.3390/rs10081250

CA, C. A. ¿ Y POR DÓNDE COMENZAMOS? Prioridades de la Comunidad Andina ante el Cambio Climático. Lima, Peru: Secretaría General de la Comunidad Andina, 2007.

CABALLERO, J., MESSINGER, M., ROMÁN-DAÑOBEYTIA, F., ASCORRA, C., FERNANDEZ, L. E. Y SILMAN, M. Deforestation and forest degradation due to gold mining in the Peruvian Amazon: A 34-year perspective. *Remote Sensing*, 2018, 10(12), 1903.

CABRAL, A. I. R., SAITO, C., PEREIRA, H. Y LAQUES, A. E. Deforestation pattern dynamics in protected areas of the Brazilian Legal Amazon using remote sensing data. *Applied Geography*, 2018/11/01/ 2018, 100, 101-115. doi:<https://doi.org/10.1016/j.apgeog.2018.10.003>

CANTY, M. J. *Image analysis, classification and change detection in remote sensing: with algorithms for ENVI/IDL and Python*. Edtion ed.: Crc Press, 2014. ISBN 1466570385.

CASTRO, F. El proceso de investigación y su esquema de elaboración. Editorial Uyapar. Caracas, 2003.

CAZAU, P. Introducción a la investigación en ciencias sociales. Lima. Editorial Universidad Ricardo Palma, 2006.

CERDA, J. Y VILLARROEL, L. Evaluación de la concordancia inter-observador en investigación pediátrica: Coeficiente de Kappa. Revista chilena de pediatría, 2008, 79(1), 54-58. doi:<http://dx.doi.org/10.4067/S0370-41062008000100008>

CHATZIANTONIOU, A., PSOMIADIS, E. Y PETROPOULOS, G. P. Co-Orbital Sentinel 1 and 2 for LULC mapping with emphasis on wetlands in a mediterranean setting based on machine learning. Remote Sensing, 2017, 9(12), 1259.

CHÁVEZ, A., HUAMANI, L., FERNANDEZ, R., BEJAR, N., VALERA, F., PERZ, S., BROWN, I., DOMÍNGUEZ, S., PINEDO, R. Y ALARCÓN, G. Regional Deforestation Trends within Local Realities: Land-Cover Change in Southeastern Peru 1996–2011. Land, 2013, 2(2), 131. doi:<https://doi.org/10.3390/land2020131>

CHEN, B., LI, X., XIAO, X., ZHAO, B., DONG, J., KOU, W., QIN, Y., YANG, C., WU, Z., SUN, R., LAN, G. Y XIE, G. Mapping tropical forests and deciduous rubber plantations in Hainan Island, China by integrating PALSAR 25-m and multi-temporal Landsat images. International Journal of Applied Earth Observation and Geoinformation, 2016/08/01/ 2016, 50, 117-130. doi:<https://doi.org/10.1016/j.jag.2016.03.011>

CHEN, S., ZHANG, R., SU, H., TIAN, J. Y XIA, J. SAR and multispectral image fusion using generalized IHS transform based on à trous wavelet and EMD decompositions. IEEE Sensors Journal, 2010, 10(3), 737-745.

CHIRIF, A. *Deforestación en tiempos de cambio climático*. Edtion ed.: IWGIA, Grupo Internacional de Trabajo sobre Asuntos Indígenas, 2018. ISBN 8792786847.

CHUVIECO, E. Empleo de imágenes de satélite para medir la estructura del paisaje: análisis cuantitativo y representación cartográfica. Serie Geográfica, 1996, 6, 131-147.

CHUVIECO, E. Teledetección espacial: la observación de la Tierra desde el espacio 2002.

CHUVIECO, E. Y HANTSON, S. Procesamiento estándar de imágenes Landsat. Documento técnico de algoritmos a aplicar. Version1. Plan Nacional de Teledetección. Instituto Geográfico Nacional. En línea; http://www.ign.es/PNT/pdf/especificacionestecnicas-pnt-medar-landsat_v2-2010.pdf, 2010.

CLEMENT, M. A., KILSBY, C. G. Y MOORE, P. Multi-temporal synthetic aperture radar flood mapping using change detection. Journal of Flood Risk Management, 2018/06/01 2018, 11(2), 152-168. doi:<https://doi.org/10.1111/jfr3.12303>

COELHO, S., CARDOSO-LEITE, E. Y CASTELLO, A. C. D. Composição florística e caracterização sucessional como subsídio para conservação e manejo do PNMCBio, Sorocaba-SP. Ciência Florestal, 2016, 26, 331-344.

COHEN, J. A Coefficient of Agreement for Nominal Scales. Educational and Psychological Measurement, 1960/04/01 1960, 20(1), 37-46. doi:<https://doi.org/10.1177/001316446002000104>

COHEN, J., MANION, L. Y MORRISON, J. Designing a qualitative study. In.: Newsbury Park: CA Sage, 2003.

CORTÉS-MCPHERSON, D. Expansion of small-scale gold mining in Madre de Dios: 'capital interests' and the emergence of a new elite of entrepreneurs in the Peruvian Amazon. The Extractive Industries and Society, 2019/04/01/ 2019, 6(2), 382-389. doi:<https://doi.org/10.1016/j.exis.2019.01.002>

DE ALBAN, J. D. T., CONNETTE, G. M., OSWALD, P. Y WEBB, E. L. Combined Landsat and L-Band SAR Data Improves Land Cover Classification and Change Detection in Dynamic Tropical Landscapes. Remote Sensing, 2018, 10(2). doi:10.3390/rs10020306

DEANE, C. S., DEANE, C. S., BORG, J., CAHILL, T., CARNERO-DIAZ, E., ETHERIDGE, T., HARDIMAN, G., LEYS, N., MADRIGAL, P., MANZANO, A., MASTROLEO, F., MEDINA, F. J., FERNANDEZ-ROJO, M. A., SIEW, K., SZEWCZYK, N. J., VILLACAMPA, A., WALSH, S. B., WEGING, S., BEZDAN, D., GIACOMELLO, S., DA SILVEIRA, W. A., HERRANZ, R., DA SILVEIRA, W. A. Y HERRANZ, R. Space omics research in Europe: Contributions, geographical distribution and ESA member state funding schemes. *iScience*, 2022/03/18/ 2022, 25(3), 103920. doi:<https://doi.org/10.1016/j.isci.2022.103920>

DEFRIES, R. S., RUDEL, T., URIARTE, M. Y HANSEN, M. Deforestation driven by urban population growth and agricultural trade in the twenty-first century. *Nature Geoscience*, 2010/03/01 2010, 3(3), 178-181. doi:10.1038/ngeo756

DOBLAS, J., SHIMABUKURO, Y., SANT'ANNA, S., CARNEIRO, A., ARAGÃO, L. Y ALMEIDA, C. Optimizing Near Real-Time Detection of Deforestation on Tropical Rainforests Using Sentinel-1 Data. *Remote Sensing*, 2020, 12(23). doi:10.3390/rs12233922

DONG, J., METTERNICHT, G., HOSTERT, P., FENSHOLT, R. Y CHOWDHURY, R. R. Remote sensing and geospatial technologies in support of a normative land system science: Status and prospects. *Current Opinion in Environmental Sustainability*, 2019, 38, 44-52.

DOUROJEANNI, M. Esbozo de una nueva política forestal peruana. *Revista Forestal del Perú*, 2019, 34(1), 4-20.

ELIAS, F., FERREIRA, J., LENNOX, G. D., BERENQUER, E., FERREIRA, S., SCHWARTZ, G., MELO, L. D. O., REIS JUNIOR, D. N., NASCIMENTO, R. O. Y FERREIRA, F. N. Assessing the growth and climate sensitivity of secondary forests in highly deforested Amazonian landscapes. *Ecology*, 2020, 101(3), e02954.

ELIJAH, R. Y JENSEN, J. R. Remote sensing of mangrove wetlands: relating canopy spectra to site-specific data 1996. doi:https://www.asprs.org/wp-content/uploads/pers/1996journal/aug/1996_aug_939-948.pdf

ERINJERY, J. J., SINGH, M. Y KENT, R. Mapping and assessment of vegetation types in the tropical rainforests of the Western Ghats using multispectral Sentinel-2 and SAR Sentinel-1 satellite imagery. Remote Sensing of Environment, 2018, 216, 345-354.

ESA Sentinel-1 user handbook. European Space Agency
2013.

FAO. FRA 2015: Terms and Definitions. In.: Food and Agriculture Organization of the UN Rome, Italy, 2012.

FAO Los bosques y el cambio climático en el Perú. Bosques y cambio climático. Documento de trabajo 14, 2016.

FAO. Evaluación de los recursos forestales mundiales 2020 – Principales resultados Roma: 2020.

FIKRIYAH, V. N., DARVISHZADEH, R., LABORTE, A., KHAN, N. I. Y NELSON, A. Discriminating transplanted and direct seeded rice using Sentinel-1 intensity data. International Journal of Applied Earth Observation and Geoinformation, 2019/04/01/ 2019, 76, 143-153. doi:<https://doi.org/10.1016/j.jag.2018.11.007>

GARATE-QUISPE, J. S., CANAHUIRE-ROBLES, R., SURCO-HUACACHI, O. Y ALARCÓN-AGUIRRE, G. Desarrollo estructural y composición florística arbórea en áreas afectadas por minería aurífera en la Amazonía peruana: a 20 años de su reforestación. Revista Mexicana de Biodiversidad, 2021, 92, 923437. doi:<https://doi.org/10.22201/ib.20078706e.2021.92.3437>

GHARBIA, R., AZAR, A. T., BAZ, A. E. Y HASSANIEN, A. E. Image fusion techniques in remote sensing. arXiv preprint arXiv:1403.5473, 2014.

GONZÁLEZ-ESTEBAN Y PATRICI CALVO, E. Ethically governing artificial intelligence in the field of scientific research and innovation. *Heliyon*, 2022/02/01/ 2022, 8(2), e08946. doi:<https://doi.org/10.1016/j.heliyon.2022.e08946>

GORELICK, N., HANCHER, M., DIXON, M., ILYUSHCHENKO, S., THAU, D. Y MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 2017, 202, 18-27.

GOREMAD Y IIAP. Macro Zonificación Ecológica Económica de Madre de Dios. Madre de Dios - Perú, 2009, p. 208.

HÄME, T., SIRRO, L., CABRERA, E., HAARPAINNER, J., HEINZEL, J., HÄMÄLÄINEN, J., DE JONG, B., PELLAT, F. P., PEDRAZZANI, D. Y REICHE, J. ReCover: Services for the Monitoring of Tropical Forest to Support REDD+. In *Let's Embrace Space, vol. II*. EU, 2012, p. 106-114.

HANDBOOK, N. Origin & Cause Determination Handbook. 2005.

HANSEN, M. C., POTAPOV, P. V., MOORE, R., HANCHER, M., TURUBANOVA, S. A., TYUKAVINA, A., THAU, D., STEHMAN, S. V., GOETZ, S. J. Y LOVELAND, T. R. High-resolution global maps of 21st-century forest cover change. *Science*, 2013, 342(6160), 850-853.

HERNÁNDEZ, H. Y MONTANER, D. Patrones de respuesta espectral. *Tecnologías Geoespaciales: Experiencias Aplicadas al Estudio y Gestión del Territorio*. Carlos Mena (Ed.) ISBN, 2009, 978-996.

HERNÁNDEZ, R., FERNÁNDEZ, C. Y BAPTISTA, P. *Metodología de la Investigación (Quinta edición ed.)*. (J. Mares Chacón, Ed.) Mexico, México DF. Edtion ed.: McGraw-Hill/Interamericana Editores, SA de CV, 2010.

HOLDRIDGE, L. R. Life zone ecology. Life zone ecology., 1967, (rev. ed.)).

HOLTGRAVE, A.-K., RÖDER, N., ACKERMANN, A., ERASMI, S. Y KLEINSCHMIT, B. Comparing Sentinel-1 and -2 Data and Indices for Agricultural Land Use Monitoring. *Remote Sensing*, 2020, 12(18). doi:10.3390/rs12182919

HONG, G., ZHANG, A., ZHOU, F. Y BRISCO, B. Integration of optical and synthetic aperture radar (SAR) images to differentiate grassland and alfalfa in Prairie area. *International Journal of Applied Earth Observation and Geoinformation*, 2014, 28, 12-19.

HUAMANI, V., ALARCÓN, G., CANAHUIRE, R., HERRERA-MACHACA, M. Y GARATE-QUISPE, J. Natural regeneration of trees and shrubs in degraded areas by gold mining in the Peruvian Amazon. In *Ensino, pesquisa e inovação em botânica*. Ponta Grossa – Paraná – Brasil: Atena Editora, 2021, p. 1-388.

HUANG, X., CAO, Y. Y LI, J. An automatic change detection method for monitoring newly constructed building areas using time-series multi-view high-resolution optical satellite images. *Remote Sensing of Environment*, 2020, 244, 111802.

IDEAM. Leyenda nacional de coberturas de la tierra. Metodología CORINE Land Cover adaptada para Colombia escala 1: 100.000. In.: Instituto de Hidrología Meteorología y Estudios Ambientales (IDEAM), Instituto Geográfico Agustín Codazzi (IGAC), and Corporación Aotónoma Regional del Magdalena (CORMAGDALENA), Bogotá, Colombia, 2010.

INEI. Magnitud y Crecimiento Poblacional. 2017.

INGLADA, J., VINCENT, A., ARIAS, M. Y MARAIS-SICRE, C. Improved Early Crop Type Identification By Joint Use of High Temporal Resolution SAR And Optical Image Time Series. *Remote Sensing*, 2016, 8(5). doi:10.3390/rs8050362

INPE. Amazon program—monitoring the Brazilian Amazon by satellite: the PRODES, DETER, DEGRAD and terraclass systems. 2020a.

INPE. Projeto PRODES: Monitoramento da Floresta Amazônica Brasileira por satélite. 2020b.

INRENA, SZF, Y CDC-UNALM. Hacia un Sistema de Monitoreo Ambiental Remoto Estandarizado para el SINANPE. Piloto V: Parque Nacional Manu, Parque Nacional Alto Purús, Reserva Comunal Purús y Santuario Nacional Megantoni (2000-2005). Lima-Perú 2006, 66.

JANSE VAN RENSBURG, G. Y KEMP, J. The Use of C-Band and X-Band SAR with Machine Learning for Detecting Small-Scale Mining. *Remote Sensing*, 2022, 14(4). doi:10.3390/rs14040977

JENSEN, J. R. *Remote sensing of the environment: An earth resource perspective 2/e*. Edition ed.: Pearson Education India, 2009. ISBN 8131716805.

JENSEN, J. R., LIN, H., YANG, X., RAMSEY III, E., DAVIS, B. A. Y THOEMKE, C. W. The measurement of mangrove characteristics in southwest Florida using SPOT multispectral data. *Geocarto International*, 1991, 6(2), 13-21. doi:<https://doi.org/10.1080/10106049109354302e>

JIANG, Z. Geographical Information System in Web Application: Developing Web Application to Serve Spatial Data to Users 2020. doi:<https://urn.fi/URN:NBN:fi:amk-202001231535>

JIANG, Z., HUETE, A. R., CHEN, J., CHEN, Y., LI, J., YAN, G. Y ZHANG, X. Analysis of NDVI and scaled difference vegetation index retrievals of vegetation fraction. *Remote Sensing of Environment*, 2006, 101(3), 366-378.

JOSHI, N., BAUMANN, M., EHAMMER, A., FENSHOLT, R., GROGAN, K., HOSTERT, P., JEPSEN, M. R., KUEMMERLE, T., MEYFROIDT, P. Y

MITCHARD, E. T. A. A review of the application of optical and radar remote sensing data fusion to land use mapping and monitoring. *Remote Sensing*, 2016, 8(1), 70.

KERLE, N., JANSSEN, L. L. F. Y HUURNEMAN, G. C. Principles of remote sensing. ITC, Educational textbook series, 2004, 2, 250.

KOLEY, S. Y CHOCKALINGAM, J. Sentinel 1 and Sentinel 2 for cropland mapping with special emphasis on the usability of textural and vegetation indices. *Advances in Space Research*, 2022/02/15/ 2022, 69(4), 1768-1785. doi:<https://doi.org/10.1016/j.asr.2021.10.020>

KUHN, M. Y JOHNSON, K. *Applied predictive modeling*. Edition ed.: Springer, 2013.

KULCZYCKI, P. Y FRANUS, K. Methodically unified procedures for a conditional approach to outlier detection, clustering, and classification. *Information Sciences*, 2021/06/01/ 2021, 560, 504-527. doi:<https://doi.org/10.1016/j.ins.2020.08.122>

LANDIS, J. R. Y KOCH, G. G. The measurement of observer agreement for categorical data. *biometrics*, 1977, 159-174. doi:<https://doi.org/10.2307/2529310>

LEITE-FILHO, A. T., COSTA, M. H. Y FU, R. The southern Amazon rainy season: The role of deforestation and its interactions with large-scale mechanisms. *International Journal of Climatology*, 2020, 40(4), 2328-2341. doi:<https://doi.org/10.1002/joc.6335>

LENNOX, G. D., GARDNER, T. A., THOMSON, J. R., FERREIRA, J., BERENQUER, E., LEES, A. C., MAC NALLY, R., ARAGÃO, L. E. O. C., FERRAZ, S. F. B. Y LOUZADA, J. Second rate or a second chance? Assessing biomass and biodiversity recovery in regenerating Amazonian forests. *Global Change Biology*, 2018, 24(12), 5680-5694.

LESIV, M., SCHEPASCHENKO, D., MOLTCHANOVA, E., BUN, R., DÜRAUER, M., PRISHCHEPOV, A. V., SCHIERHORN, F., ESTEL, S., KUEMMERLE, T. Y ALCÁNTARA, C. Spatial distribution of arable and abandoned land across former Soviet Union countries. *Scientific data*, 2018, 5(1), 1-12.

LI, M. Y BIJKER, W. Vegetable classification in Indonesia using Dynamic Time Warping of Sentinel-1A dual polarization SAR time series. *International Journal of Applied Earth Observation and Geoinformation*, 2019/06/01/ 2019, 78, 268-280. doi:<https://doi.org/10.1016/j.jag.2019.01.009>

LI, X., ZHOU, Y., GONG, P., SETO, K. C. Y CLINTON, N. Developing a method to estimate building height from Sentinel-1 data. *Remote Sensing of Environment*, 2020, 240, 111705. doi:<https://doi.org/10.1016/j.rse.2020.111705>

LIANG, J. Y LIU, D. A local thresholding approach to flood water delineation using Sentinel-1 SAR imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2020/01/01/ 2020, 159, 53-62. doi:<https://doi.org/10.1016/j.isprsjprs.2019.10.017>

LOPEZ-SANCHEZ, J. M., VICENTE-GUIJALBA, F., BALLESTER-BERMAN, J. D. Y CLOUDE, S. R. Polarimetric Response of Rice Fields at C-Band: Analysis and Phenology Retrieval. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(5), 2977-2993. doi:10.1109/TGRS.2013.2268319

MANSARAY, L. R., KABBA, V. T. S., ZHANG, L. Y BEBELEY, H. A. Optimal multi-temporal Sentinel-1A SAR imagery for paddy rice field discrimination; a recommendation for operational mapping initiatives. *Remote Sensing Applications: Society and Environment*, 2021/04/01/ 2021, 22, 100533. doi:<https://doi.org/10.1016/j.rsase.2021.100533>

MARIACA, B. Y ANDRÉS, W. Circulación atmosférica sobre territorio boliviano durante la fase activa y pasiva del monzón sudamericano. *Revista Boliviana de Física*, 2007, 13(13), 45-53.

MARTINEZ, G., MCCORD, S. A., DRISCOLL, C. T., TODOROVA, S., WU, S., ARAÚJO, J. F., VEGA, C. M. Y FERNANDEZ, L. E. Mercury Contamination in Riverine Sediments and Fish Associated with Artisanal and Small-Scale Gold Mining in Madre de Dios, Peru. *International journal of environmental research and public health*, 2018, 15(8). doi:10.3390/ijerph15081584

MARTINS, V. S., NOVO, E. M. L. M., LYAPUSTIN, A., ARAGÃO, L. E. O. C., FREITAS, S. R. Y BARBOSA, C. C. F. Seasonal and interannual assessment of cloud cover and atmospheric constituents across the Amazon (2000–2015): Insights for remote sensing and climate analysis. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2018/11/01/ 2018, 145, 309-327. doi:<https://doi.org/10.1016/j.isprsjprs.2018.05.013>

MCNAIRN, H., CHAMPAGNE, C., SHANG, J., HOLMSTROM, D. Y REICHERT, G. Integration of optical and Synthetic Aperture Radar (SAR) imagery for delivering operational annual crop inventories. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2009, 64(5), 434-449.

MELCHIORRI, M., FLORCZYK, A. J., FREIRE, S., SCHIAVINA, M., PESARESI, M. Y KEMPER, T. Unveiling 25 years of planetary urbanization with remote sensing: Perspectives from the global human settlement layer. *Remote Sensing*, 2018, 10(5), 768.

MINAM. Ministerio del Ambiente. Cuantificación y análisis de la deforestación en la Amazonía Peruana en el periodo 2010 – 2011 – 2013 – 2014. Dirección General de Ordenamiento Territorial. 2015.

MINAM. Bosque y pérdida de bosque del Perú. Perú 2020.

MORAN, E. F. Y BRONDIZIO, E. Land-use change after deforestation in Amazonia. People and pixels: Linking remote sensing and social science, 1998, 94-120.

MUTANGA, O. Y KUMAR, L. Google earth engine applications. In.: Multidisciplinary Digital Publishing Institute, 2019.

NAIR, M. Y BINDHU, J. S. Supervised techniques and approaches for satellite image classification. International Journal of Computer Applications, 2016, 134(16).

NICOLAU, A. P., FLORES-ANDERSON, A., GRIFFIN, R., HERNDON, K. Y MEYER, F. J. Assessing SAR C-band data to effectively distinguish modified land uses in a heavily disturbed Amazon forest. International Journal of Applied Earth Observation and Geoinformation, 2021/02/01/ 2021, 94, 102214. doi:<https://doi.org/10.1016/j.jag.2020.102214>

NICOLAU, A. P., HERNDON, K., FLORES-ANDERSON, A. Y GRIFFIN, R. A spatial pattern analysis of forest loss in the Madre de Dios region, Peru. Environmental Research Letters, 2019/12/01 2019, 14(12), 124045. doi:10.1088/1748-9326/ab57c3

NIRO, F., GORYL, P., DRANSFELD, S., BOCCIA, V., GASCON, F., ADAMS, J., THEMANN, B., SCIFONI, S. Y DOXANI, G. European Space Agency (ESA) calibration/validation strategy for optical land-imaging satellites and pathway towards interoperability. Remote Sensing, 2021, 13(15), 3003.

OCHOA, C. Y PÁEZ, O. Inferencia estadística: probabilidad, variables aleatorias y distribuciones de probabilidad. Evid Pediatr, 2019, 15, 27.

OLIVARES, B. O. Y LÓPEZ-BELTRÁN, M. A. Índice de Vegetación de Diferencia Normalizada aplicado al territorio indígena agrícola de Kashaama, Venezuela. Cuadernos de Investigación UNED, 2019, 11, 112-121. doi:<http://dx.doi.org/10.22458/urj.v11i2.2299>

OPPENHEIMER, C. Sabins, FF 1997. Remote Sensing. Principles and Interpretation, xiii+ 494 pp. New York: WH Freeman & Co. Price£ 32.95 (hard covers). ISBN 0 7167 2442 1. Geological Magazine, 1998, 135(1), 143-158.

OU, L. C., RONNIER LUO, M., SUN, P. L., HU, N. C., CHEN, H. S., GUAN, S. S., WOODCOCK, A., CAIVANO, J. L., HUERTAS, R. Y TREMÉAU, A. A cross-cultural comparison of colour emotion for two-colour combinations. Color Research & Application, 2012, 37(1), 23-43.

PEI, T., XU, J., LIU, Y., HUANG, X., ZHANG, L., DONG, W., QIN, C., SONG, C., GONG, J. Y ZHOU, C. GIScience and remote sensing in natural resource and environmental research: Status quo and future perspectives. Geography and Sustainability, 2021/09/01/ 2021, 2(3), 207-215. doi:<https://doi.org/10.1016/j.geosus.2021.08.004>

PERZ, S., CASTRO, W., ROJAS, R., CASTILLO, J., CHÁVEZ, A., GARCÍA, M., GUADALUPE, Ó., GUTIÉRREZ, T., HURTADO, A., MAMANI, Z., MAYNA, J., MELLO, R., PASSOS, V., REYES, J., SAAVEDRA, M., DE WIT, F., ACUÑA, N., ALARCÓN, G. Y ROJAS, D. La Amazonia como un sistema socio-ecológico: Las dinámicas de cambios complejos humanos y ambientales en una frontera trinacional. In J. POSTIGO Y K. YOUNG eds. *Naturaleza y sociedad: Perspectivas socio-ecológicas sobre cambios globales en América Latina*. Lima-Perú: desco, IEP e INTE-PUCP, 2016, p. 444.

PERZ, S., QIU, Y., XIA, Y., SOUTHWORTH, J., SUN, J., MARSIK, M., ROCHA, K., PASSOS, V., ROJAS, D., ALARCÓN, G., BARNES, G. Y BARALOTO, C. Trans-boundary infrastructure and land cover change: Highway paving and community-level deforestation in a tri-national frontier in the Amazon. Land Use Policy, 2013, 34, 27-41. doi:<http://dx.doi.org/10.1016/j.landusepol.2013.01.009>

PLANET-TEAM. Planet Application Program Interface: In Space for Life on Earth. 2021. Disponible en Internet:<<https://api.planet.com>>

POTIN, P. Sentinel-1 user handbook. In.: European Space Agency (ESA): Paris, France, 2013.

PUYRAVAUD, J.-P. Standardizing the calculation of the annual rate of deforestation. *Forest Ecology and Management*, 2003, 177(1), 593-596. doi:10.1016/S0378-1127(02)00335-3

PUZZI, A., FLORES-ANDERSON, A., GRIFFIN, R., HERNDON, K. Y MEYER, F. J. Assessing SAR C-band data to effectively distinguish modified land uses in a heavily disturbed Amazon forest. *International Journal of Applied Earth Observation and Geoinformation*, 2020, 94, 102-214.

PUZZI, A., FLORES-ANDERSON, A., GRIFFIN, R., HERNDON, K. Y MEYER, F. J. Assessing SAR C-band data to effectively distinguish modified land uses in a heavily disturbed Amazon forest. *International Journal of Applied Earth Observation and Geoinformation*, 2021/02/01/ 2021, 94, 102214. doi:<https://doi.org/10.1016/j.jag.2020.102214>

RAISG. Destrucción del Amazonas: las principales amenazas para la mayor selva tropical del mundo en los 9 países que la comparten (2001-2018). 2020a.

RAISG. Destrucción del Amazonas: las principales amenazas para la mayor selva tropical del mundo en los 9 países que la comparten (2001-2018). 2020b.

RAJAH, P., ODINDI, J. Y MUTANGA, O. Feature level image fusion of optical imagery and Synthetic Aperture Radar (SAR) for invasive alien plant species detection and mapping. *Remote Sensing Applications: Society and Environment*, 2018/04/01/ 2018, 10, 198-208. doi:<https://doi.org/10.1016/j.rsase.2018.04.007>

REYNOLDS, J. F., SMITH, D. M. S., LAMBIN, E. F., TURNER, B. L., MORTIMORE, M., BATTERBURY, S. P. J., DOWNING, T. E.,

DOWLATABADI, H., FERNÁNDEZ, R. J. Y HERRICK, J. E. Global desertification: building a science for dryland development. *Science*, 2007, 316(5826), 847-851.

ROMÁN-DAÑOBEYTIA, F., CABANILLAS, F., LEFEBVRE, D., FARFAN, J., ALFEREZ, J., POLO-VILLANUEVA, F., LLACSAHUANGA, J., VEGA, C. M., VELASQUEZ, M., CORVERA, R., CONDORI, E., ASCORRA, C., FERNANDEZ, L. E. Y SILMAN, M. R. Survival and early growth of 51 tropical tree species in areas degraded by artisanal gold mining in the Peruvian Amazon. *Ecological Engineering*, 2021/01/15/ 2021, 159, 106097. doi:<https://doi.org/10.1016/j.ecoleng.2020.106097>

SAAH, D., TENNESON, K., POORTINGA, A., NGUYEN, Q., CHISHTIE, F., AUNG, K. S., MARKERT, K. N., CLINTON, N., ANDERSON, E. R., CUTTER, P., GOLDSTEIN, J., HOUSMAN, I. W., BHANDARI, B., POTAPOV, P. V., MATIN, M., UDDIN, K., PHAM, H. N., KHANAL, N., MAHARJAN, S., ELLENBERG, W. L., BAJRACHARYA, B., BHARGAVA, R., MAUS, P., PATTERSON, M., FLORES-ANDERSON, A. I., SILVERMAN, J., SOVANN, C., DO, P. M., NGUYEN, G. V., BOUNTHABANDIT, S., ARYAL, R. R., MYAT, S. M., SATO, K., LINDQUIST, E., KONO, M., BROADHEAD, J., TOWASHIRAPORN, P. Y GANZ, D. Primitives as building blocks for constructing land cover maps. *International Journal of Applied Earth Observation and Geoinformation*, 2020/03/01/ 2020, 85, 101979. doi:<https://doi.org/10.1016/j.jag.2019.101979>

SAMAT, A., GAMBA, P., LIU, S., MIAO, Z., LI, E. Y ABUDUWAILI, J. Quad-PolSAR data classification using modified random forest algorithms to map halophytic plants in arid areas. *International Journal of Applied Earth Observation and Geoinformation*, 2018/12/01/ 2018, 73, 503-521. doi:<https://doi.org/10.1016/j.jag.2018.06.006>

SERRANO, M. A. M., CATANIA, M., SÁNCHEZ, J., VASCONCELOS, A., KUIJPER, D. Y MARC, X. Sentinel-1A flight dynamics LEOP operational experience. In., 2015.

SHANER, J. Y WRIGHTSELL, J. *Editing in arcMap*. Edtion ed.: Esri, 2000. ISBN 1879102978.

STEINHAUSEN, M. J., WAGNER, P. D., NARASIMHAN, B. Y WASKE, B. Combining Sentinel-1 and Sentinel-2 data for improved land use and land cover mapping of monsoon regions. *International Journal of Applied Earth Observation and Geoinformation*, 2018/12/01/ 2018, 73, 595-604. doi:<https://doi.org/10.1016/j.jag.2018.08.011>

TANASE, M. A., KENNEDY, R. Y APONTE, C. Fire severity estimation from space: A comparison of active and passive sensors and their synergy for different forest types. *International Journal of Wildland Fire*, 2015a, 24(8), 1062-1075. doi:<https://doi.org/10.1071/WF15059>

TANASE, M. A., KENNEDY, R. Y APONTE, C. Radar Burn Ratio for fire severity estimation at canopy level: An example for temperate forests. *Remote Sensing of Environment*, 2015b, 170, 14-31. doi:<https://doi.org/10.1016/j.rse.2015.08.025>

TANASE, M. A., SANTORO, M., APONTE, C. Y DE LA RIVA, J. Polarimetric properties of burned forest areas at C-and L-band. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2013, 7(1), 267-276. doi:10.1109/JSTARS.2013.2261053

TANASE, M. A., SANTORO, M., DE LA RIVA, J., FERNANDO, P. Y LE TOAN, T. Sensitivity of X-, C-, and L-band SAR backscatter to burn severity in Mediterranean pine forests. *IEEE Transactions on Geoscience and Remote Sensing*, 2010a, 48(10), 3663-3675. doi:10.1109/TGRS.2010.2049653

TANASE, M. A., SANTORO, M., WEGMÜLLER, U., DE LA RIVA, J. Y PÉREZ-CABELLO, F. Properties of X-, C-and L-band repeat-pass interferometric SAR coherence in Mediterranean pine forests affected by fires. *Remote Sensing of Environment*, 2010b, 114(10), 2182-2194. doi:<https://doi.org/10.1016/j.rse.2010.04.021>

TORRES, R., SNOEIJ, P., GEUDTNER, D., BIBBY, D., DAVIDSON, M., ATTEMA, E., POTIN, P., ROMMEN, B., FLOURY, N. Y BROWN, M. GMES Sentinel-1 mission. *Remote Sensing of Environment*, 2012, 120, 9-24. doi:<https://doi.org/10.1016/j.rse.2011.05.028>

VARGAS, C., ITOH, T., TSUJI, S., KOIDE, T., HIROSE, K. Y OKONOGLI, H. Automatic Deforestation Detection Methodology Using Sentinel-1. In *IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium*. 2019, p. 6590-6593.

VELÁSQUEZ, M. G., VEGA RUIZ, C. M., GOMRINGER, R. C., PILLACA, M., THOMAS, E., STEWART, P. M., GAMARRA MIRANDA, L. A., DAÑOBEYTIA, F. R., GUERRERO BARRANTES, J. A., GUSHIKEN, M. C., BARDALES, J. V., SILMAN, M., FERNANDEZ, L., ASCORRA, C. Y TORRES, D. D. C. Mercury in soils impacted by alluvial gold mining in the Peruvian Amazon. *Journal of Environmental Management*, 2021/06/15/ 2021, 288, 112364. doi:<https://doi.org/10.1016/j.jenvman.2021.112364>

XIUWAN, C. Using remote sensing and GIS to analyse land cover change and its impacts on regional sustainable development. *International journal of remote sensing*, 2002, 23(1), 107-124. doi:<https://doi.org/10.1080/01431160010007051>

YAGHOBI, S., HEIDARIZADI, Z. Y MIRZAPOUR, H. Comparing NDVI and RVI for forest density estimation and their relationships with rainfall (Case study: Malekshahi, Ilam Province). *Environmental Resources Research*, 2019, 7(2), 117-128. doi:10.22069/IJERR.2019.4819

ZHANG, G., WANG, J., XUE, Y., ZHANG, C., XU, B., CHENG, Y. Y REN, Y. Comparison of sampling effort allocation strategies in a stratified random survey with multiple objectives. *Aquaculture and Fisheries*, 2020/05/01/ 2020, 5(3), 113-121. doi:<https://doi.org/10.1016/j.aaf.2020.02.002>

ZHOU, T., ZHAO, M., SUN, C. Y PAN, J. Exploring the Impact of Seasonality on Urban Land-Cover Mapping Using Multi-Season Sentinel-1A and GF-1 WFV Images in a Subtropical Monsoon-Climate Region. *ISPRS International Journal of Geo-Information*, 2018, 7(1). doi:10.3390/ijgi7010003

ZHU, Z., ZHOU, Y., SETO, K. C., STOKES, E. C., DENG, C., PICKETT, S. T. A. Y TAUBENBÖCK, H. Understanding an urbanizing planet: Strategic directions for remote sensing. *Remote Sensing of Environment*, 2019, 228, 164-182. doi:<https://doi.org/10.1016/j.rse.2019.04.020>

ZUHLKE, M., FOMFERRA, N., BROCKMANN, C., PETERS, M., VECI, L., MALIK, J. Y REGNER, P. SNAP (sentinel application platform) and the ESA sentinel 3 toolbox. *ESASP*, 2015, 734, 21.

ANEXOS

Anexo 1. Matriz de consistencia.

Título: Análisis de la variación espacial-estacional del uso del suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La Pampa y Guacamayo – Madre de Dios, periodo 2021.

PROBLEMA GENERAL	OBJETIVO GENERAL	HIPOTESIS GENERAL	VARIABLES/INDICADORES	METODOLOGÍA
¿Cuál es la variación espacial-estacional del uso del suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La pampa y Guacamayo – Madre de Dios en el año 2021?	Analizar variación espacial-estacional del uso del suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La pampa y Guacamayo – Madre de Dios en el año 2021.	La detección y cuantificación del cambio de cobertura y uso de suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La pampa y Guacamayo no se produce en mayor proporción en la época estacional de lluvias.	<p>Variable Dependiente:</p> <p>Comportamiento del suelo y la vegetación en la función de la unidad mínima de la imagen (píxel) y polarizaciones del SAR Sentinel-1 a través de la aRDFI.</p> <p>Indicadores:</p> <p>Rango espectral de índice de la aRDFI.</p> <p>Variable Independiente:</p> <p>Uso de suelo por minería de oro por periodo estacional en el año 2021.</p> <p>Cambio de cobertura por uso de suelo por la minería de oro en el año 2021.</p> <p>Indicadores:</p> <ol style="list-style-type: none"> Superficie de minería de oro (ha). Cambios de cobertura de minería de oro. Índice Global e Índice de Kappa (k). 	<p>Diseño: Transaccional (transversal) y longitudinal.</p> <p>Tipo: descriptiva, correlacional y predictivo</p> <p>Método:</p> <ol style="list-style-type: none"> Pre procesamiento de imágenes S1 mediante el software SNAP ESA y plataforma Google Earth Engine. Cuantificación de la aRDFI. Precisión general con datos de campo e imágenes de alta resolución. Medición de cambios de la aRDFI de 2021. <p>Población y muestra: se empleará la distribución binomial de probabilidad.</p> $n = \frac{Z^2 p(qN)}{(N - 1)E^2 + Z^2 pq}$ <p>“Z: Es el valor de la curva normal estandarizada para un nivel determinado de probabilidad, 1,96 (95%)”.</p> <p>“p: indica el porcentaje de aciertos estimado, 0,50 (50%)”.</p> <p>“q: Indica el porcentaje de errores (q = 1 – p), 0,50 (50%)”.</p> <p>“N: Tamaño de la población”.</p> <p>“E: El error permitido, 0,05 (5%)”.</p>
PROBLEMAS ESPECIFICOS	OBJETIVOS ESPECÍFICOS			
<p>P.E.1 ¿Cuánto es el uso de suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La pampa y Guacamayo en el periodo estacional de marzo-abril de 2021?</p> <p>P.E.2. ¿Cuánto es el uso suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La pampa y Guacamayo en el periodo estacional de agosto-septiembre de 2021?</p> <p>P.E.3 ¿Cuánto es el uso de suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La pampa y Guacamayo en el periodo estacional de noviembre-diciembre de 2021?</p> <p>P.E.4 ¿Cuáles son los cambios de uso del suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La pampa y Guacamayo – Madre de Dios de los periodos estacionales en el año 2021?</p>	<p>O.E.1 Cuantificar el uso de suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La pampa y Guacamayo en el periodo estacional de marzo-abril de 2021.</p> <p>O.E.2. Cuantificar el uso de suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La pampa y Guacamayo en el periodo estacional de agosto-septiembre de 2021.</p> <p>O.E.3 Cuantificar el uso de suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La pampa y Guacamayo en el periodo estacional de noviembre-diciembre de 2021.</p> <p>O.E.4 Determinar los cambios de uso del suelo por minería de oro mediante el sensor SAR Sentinel-1 en los sectores de La pampa y Guacamayo – Madre de Dios de los periodos estacionales en el año 2021.</p>			

Anexo 2. Puntos de muestreo distribuidos al azar por estratos en los sectores de La Pampa y Guacamayo, 2021.

Nº	Categoría	Este	Norte
1	Bosque	399603	8575377
2	Bosque	395899	8575456
3	Bosque	394682	8575350
4	Bosque	395211	8576276
5	Bosque	400873	8576038
6	Bosque	404445	8576170
7	Bosque	405768	8577388
8	Bosque	409525	8576594
9	Bosque	407620	8579742
10	Bosque	405609	8580801
11	Bosque	402143	8580404
12	Bosque	401032	8579266
13	Bosque	377391	8575072
14	Bosque	374348	8574874
15	Bosque	381029	8576660
16	Bosque	379243	8579041
17	Bosque	378119	8580629
18	Bosque	374084	8580364
19	Bosque	373819	8569318
20	Bosque	376994	8570178
21	Bosque	379375	8571170
22	Bosque	378383	8567995
23	Bosque	376200	8566209
24	Bosque	383873	8568921
25	Bosque	387776	8571368
26	Bosque	398558	8570773
27	Bosque	399616	8571699
28	Bosque	403188	8570641
29	Bosque	405371	8569979
30	Bosque	407686	8570575
31	Bosque	410663	8569252
32	Bosque	413441	8569582
33	Bosque	416549	8568855
34	Bosque	419526	8568855
35	Bosque	420584	8573816
36	Bosque	417872	8573750
37	Bosque	414764	8573551
38	Bosque	411787	8573154
39	Bosque	408678	8573419
40	Bosque	406760	8573088
41	Bosque	383344	8576594

42	Bosque	382617	8574742
43	Bosque	380434	8574014
44	Bosque	379177	8575139
45	Bosque	377788	8576594
46	Bosque	376333	8576594
47	Bosque	374348	8576726
48	Bosque	372959	8576329
49	Bosque	372761	8574080
50	Bosque	372298	8568061
51	Bosque	371901	8570508
52	Bosque	374216	8568789
53	Bosque	375341	8570641
54	Bosque	396177	8569119
55	Bosque	399881	8569715
56	Bosque	401270	8569715
57	Bosque	403916	8568789
58	Bosque	405966	8567796
59	Bosque	408612	8567598
60	Bosque	411324	8567399
61	Bosque	413044	8567399
62	Bosque	415293	8569252
63	Bosque	415227	8567664
64	Bosque	417013	8567664
65	Bosque	417740	8569384
66	Bosque	420849	8570310
67	Bosque	422635	8571302
68	Bosque	418931	8574940
69	Bosque	416814	8576131
70	Bosque	397632	8570111
71	Vegetacion secundaria	381327	8572368
72	Vegetacion secundaria	381433	8571362
73	Vegetacion secundaria	380427	8571733
74	Vegetacion secundaria	378205	8571098
75	Vegetacion secundaria	398842	8571891
76	Vegetacion secundaria	399953	8574590
77	Vegetacion secundaria	402017	8574855
78	Vegetacion secundaria	403393	8575384
79	Vegetacion secundaria	402493	8576072
80	Vegetacion secundaria	401858	8576336
81	Vegetacion secundaria	401118	8577183
82	Vegetacion secundaria	399848	8576813
83	Vegetacion secundaria	399636	8573849
84	Vegetacion secundaria	407150	8575807
85	Vegetacion secundaria	408208	8575807
86	Vegetacion secundaria	408208	8575807

87	Vegetacion secundaria	414929	8576918
88	Vegetacion secundaria	416569	8576760
89	Vegetacion secundaria	418263	8577183
90	Vegetacion secundaria	416781	8575066
91	Vegetacion secundaria	414188	8574802
92	Vegetacion secundaria	411701	8574855
93	Vegetacion secundaria	409955	8573902
94	Vegetacion secundaria	405510	8573108
95	Vegetacion secundaria	403234	8572421
96	Vegetacion secundaria	400483	8571733
97	Vegetacion secundaria	396355	8570727
98	Vegetacion secundaria	378416	8570304
99	Vegetacion secundaria	375929	8573585
100	Vegetacion secundaria	377623	8573426
101	Vegetacion secundaria	374236	8573320
102	Vegetacion secundaria	374236	8570516
103	Vegetacion secundaria	376617	8570939
104	Vegetacion secundaria	378469	8573743
105	Vegetacion secundaria	380321	8574855
106	Vegetacion secundaria	381433	8575225
107	Vegetacion secundaria	383761	8577606
108	Vegetación secundaria	380374	8570145
109	Vegetación secundaria	378734	8569616
110	Vegetación secundaria	376935	8569404
111	Vegetación secundaria	375453	8569193
112	Vegetación secundaria	376935	8568399
113	Vegetación secundaria	378681	8568981
114	Vegetación secundaria	380004	8569087
115	Vegetación secundaria	394238	8572526
116	Vegetación secundaria	393498	8572156
117	Vegetación secundaria	395773	8570145
118	Vegetación secundaria	397519	8571415
119	Vegetación secundaria	400536	8573743
120	Agricultura	401364	8573022
121	Agricultura	402552	8573861
122	Agricultura	403880	8574490
123	Agricultura	404929	8574910
124	Agricultura	406257	8574840
125	Agricultura	407376	8574420
126	Agricultura	407376	8574420
127	Agricultura	409193	8574420
128	Agricultura	410032	8575189
129	Agricultura	410731	8575749
130	Agricultura	411570	8576448
131	Agricultura	412758	8576308

132	Agricultura	413807	8576028
133	Agricultura	414716	8575888
134	Agricultura	415625	8575819
135	Agricultura	416814	8576131
136	Agricultura	418351	8575888
137	Agricultura	419190	8575819
138	Agricultura	400595	8572813
139	Agricultura	399616	8572603
140	Agricultura	398078	8573372
141	Agricultura	396540	8573931
142	Agricultura	395561	8574001
143	Agricultura	394023	8574001
144	Agricultura	390878	8574910
145	Agricultura	390109	8574840
146	Agricultura	386473	8574490
147	Agricultura	383118	8573721
148	Agricultura	381999	8573512
149	Agricultura	381231	8573442
150	Agricultura	380042	8573022
151	Agricultura	380427	8571733
152	Agricultura	379203	8572393
153	Agricultura	379203	8572393
154	Agricultura	378225	8572323
155	Agricultura	378225	8572323
156	Agricultura	376826	8572044
157	Agricultura	375358	8571974
158	Agricultura	373960	8572183
159	Agricultura	376197	8572393
160	Agricultura	376057	8577496
161	Agricultura	405278	8579174
162	Agricultura	410731	8572393
163	Agricultura	408983	8572463
164	Agricultura	412479	8574281
165	Agricultura	414646	8572323
166	Agricultura	416114	8572323
167	Agricultura	404929	8574910
168	Agricultura	406467	8575539
169	Agricultura	404929	8574910
170	Agricultura	402552	8573861
171	Pastos	402465	8573086
172	Pastos	402359	8572610
173	Pastos	401364	8573022
174	Pastos	396353	8574621
175	Pastos	394713	8573959
176	Pastos	395295	8573774

177	Pastos	396194	8573430
178	Pastos	397385	8573589
179	Pastos	399026	8572980
180	Pastos	398523	8572928
181	Pastos	402730	8574277
182	Pastos	402552	8573861
183	Pastos	402042	8573774
184	Pastos	404238	8575071
185	Pastos	404820	8575256
186	Pastos	408154	8573483
187	Pastos	408286	8573192
188	Pastos	407677	8573801
189	Pastos	406910	8574092
190	Pastos	408603	8574330
191	Pastos	409424	8574700
192	Pastos	410032	8575189
193	Pastos	410535	8575335
194	Pastos	411514	8576129
195	Pastos	411570	8576448
196	Pastos	410720	8576235
197	Pastos	410164	8575864
198	Pastos	409371	8575547
199	Pastos	408286	8575150
200	Pastos	407519	8575044
201	Pastos	390506	8574542
202	Pastos	389606	8574462
203	Pastos	393813	8574198
204	Pastos	394713	8573959
205	Pastos	395824	8574303
206	Pastos	398920	8572398
207	Pastos	400137	8571763
208	Pastos	400692	8572081
209	Pastos	400983	8572504
210	Pastos	401486	8572689
211	Pastos	402359	8572610
212	Pastos	402836	8573668
213	Pastos	403735	8573801
214	Pastos	404238	8573668
215	Pastos	404820	8574250
216	Pastos	405217	8574621
217	Pastos	405640	8574912
218	Pastos	394342	8573933
219	Pastos	390850	8574568
220	Pastos	389421	8574885
221	Minería	393549	8575102

222	Minería	393033	8575340
223	Minería	392596	8575697
224	Minería	393033	8575895
225	Minería	393311	8576292
226	Minería	392874	8576411
227	Minería	393549	8576768
228	Minería	393946	8577522
229	Minería	393946	8577522
230	Minería	393787	8578157
231	Minería	394303	8577999
232	Minería	394303	8577999
233	Minería	394065	8578673
234	Minería	394581	8579070
235	Minería	397914	8574586
236	Minería	397795	8575181
237	Minería	397954	8575578
238	Minería	397954	8575578
239	Minería	397954	8576133
240	Minería	398470	8575657
241	Minería	398152	8576689
242	Minería	392556	8573157
243	Minería	392080	8572681
244	Minería	392080	8572681
245	Minería	391088	8572125
246	Minería	390770	8571292
247	Minería	390135	8571133
248	Minería	389659	8570895
249	Minería	389659	8570895
250	Minería	389659	8570061
251	Minería	390374	8570101
252	Minería	390572	8570815
253	Minería	390770	8571292
254	Minería	391485	8571688
255	Minería	391683	8572244
256	Minería	397636	8572839
257	Minería	397319	8572482
258	Minería	397319	8572482
259	Minería	396803	8572244
260	Minería	396247	8572284
261	Minería	395771	8572085
262	Minería	396803	8572244
263	Minería	389302	8575538
264	Minería	388627	8576173
265	Minería	388627	8576173
266	Minería	388746	8576887

267	Minería	388746	8576887
268	Minería	388032	8577165
269	Minería	387516	8577284
270	Minería	388310	8577721
271	Minería	388111	8575141
272	Minería	387754	8574943
273	Minería	388032	8574228
274	Minería	387595	8573990
275	Minería	387476	8573554
276	Minería	387357	8573077
277	Minería	387000	8572760
278	Minería	386087	8572482
279	Minería	387040	8572046
280	Minería	384857	8573752
281	Minería	384222	8573792
282	Minería	384063	8573355
283	Minería	384063	8573355
284	Minería	384024	8572839
285	Minería	384024	8572839
286	Minería	383865	8572046
287	Minería	383428	8571927
288	Minería	383389	8572482
289	Minería	383587	8572998
290	Minería	384063	8573355
291	Minería	384817	8574863
292	Minería	385175	8575379
293	Minería	385333	8575776
294	Minería	385690	8576292
295	Minería	385849	8576729
296	Minería	386087	8577364
297	Minería	386484	8577840
298	Minería	385770	8571966
299	Minería	386365	8571728
300	Minería	386365	8573038
301	Minería	392239	8569148
302	Minería	398152	8576689
303	Minería	393946	8577522
304	Urbano	391875	8574433
305	Urbano	391627	8574466
306	Urbano	391395	8574516
307	Urbano	391395	8574516
308	Urbano	390254	8575160
309	Urbano	389857	8575243
310	Urbano	389857	8575243
311	Urbano	388171	8575938

312	Urbano	387641	8575921
313	Urbano	387641	8575921
314	Urbano	386037	8575111
315	Urbano	385855	8574846
316	Urbano	385591	8574797
317	Urbano	383640	8574449
318	Urbano	383640	8574449
319	Urbano	383573	8574267
320	Urbano	383573	8574267
321	Urbano	383507	8574069
322	Urbano	383507	8574069
323	Urbano	383243	8574052
324	Urbano	382962	8574019
325	Urbano	382962	8574019
326	Urbano	382796	8573920
327	Urbano	382796	8573920
328	Urbano	382465	8573705
329	Urbano	382465	8573705
330	Urbano	382217	8573871
331	Urbano	382217	8573871
332	Urbano	381771	8573887
333	Urbano	381771	8573887
334	Urbano	381589	8573887
335	Urbano	381374	8573871
336	Urbano	386203	8573804
337	Urbano	386385	8573871
338	Urbano	386600	8573937
339	Urbano	386600	8573937
340	Urbano	386600	8573937
341	Urbano	388617	8574416
342	Urbano	388931	8574549
343	Urbano	388931	8574549
344	Urbano	389229	8574598
345	Urbano	389444	8574598
346	Urbano	389606	8574462
347	Urbano	389857	8574549
348	Urbano	390089	8574499
349	Urbano	390304	8574565
350	Urbano	390506	8574542
351	Urbano	390684	8574549
352	Urbano	390506	8574542
353	Urbano	390403	8574730
354	Agua	401777	8583637
355	Agua	401711	8583042
356	Agua	401678	8582711

357	Agua	401678	8582711
358	Agua	400950	8582116
359	Agua	400388	8581553
360	Agua	399693	8580991
361	Agua	399528	8580264
362	Agua	399296	8579503
363	Agua	393244	8585754
364	Agua	387291	8585125
365	Agua	380610	8584762
366	Agua	379982	8584795
367	Agua	380742	8585225
368	Agua	405117	8588003
369	Agua	383719	8560949
370	Agua	383322	8561048
371	Agua	382991	8561247
372	Agua	382396	8561544
373	Agua	381569	8561908
374	Agua	381272	8562470
375	Agua	380974	8562801
376	Agua	380379	8563198
377	Agua	380081	8563396
378	Agua	379419	8563562
379	Agua	379056	8564025
380	Agua	379056	8564025
381	Agua	378262	8564190
382	Agua	378262	8564190
383	Agua	377270	8563429

Anexo 3. Panel fotográfico.



Foto 1. Minería.



Foto 2. Bosque.



Foto 3. Vegetación secundaria.

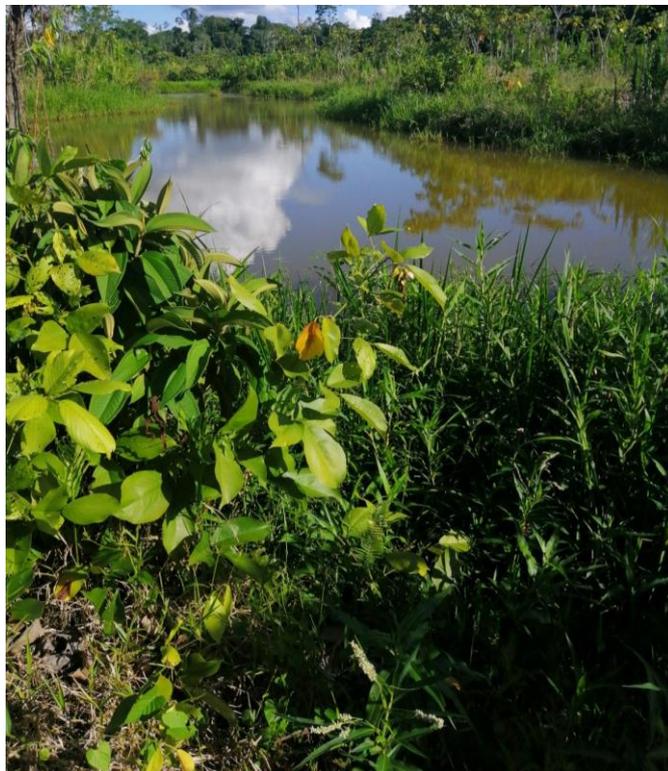


Foto 4. Agua.



Foto 5. Pastos.



Foto 6. Minería.

Puerto Maldonado, sábado, 10 de diciembre de 2022

Solicitud s/n-2022-JFAC

Señor (a):
Jaime Paul Bianqui Navarro
General de Brigada – Puerto Maldonado

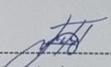
Puerto Maldonado. -

ASUNTO : Solicito permiso para acceder a la base Km 98.

Es grato dirigirme a usted, para saludarlo muy cordialmente, y a la vez solicitar permiso para ingresar a la base km 98, y poder tomar **IMÁGENES CON DRONE** en las zonas afectadas por la minería ilegal, con motivos de investigación de acuerdo a la **Resolución de Decanatura N°142-2022-UNAMAD-DFI** de fecha **16/05/2022**, la cual aprueba el proyecto de investigación de tesis titulado **"ANÁLISIS DE LA VARIACION ESPACIAL – ESTACIONAL DEL USO DEL SUELO POR MINERIA DE ORO MEDIANTE EL SENSOR SAR SENTINEL – 1 EN LOS SECTORES DE LA PAMPA Y GUACAMAYO – MADRE DE DIOS, PERIODO 2021"**, presentado por el Bachiller Sr. Javier Fritsch Apaza Choque, de la carrera Profesional de Ingeniera Forestal y Medio Ambiente de la Universidad Nacional Amazónica de Madre de Dios.

Sin otro particular, hago propicia la oportunidad para expresarle mi estima personal.

Atentamente,


Bach. Ing. Javier Fritsch Apaza Choque
DNI 46256718

cel 974440818



Anexo: 01 Copia de la Resolución de Decanatura N°142-2022-UNAMAD-DFI de fecha 16/05/2022
CC.
Archivo

1

Foto 7. Solicitud de permiso para acceder al km 98 para toma de datos con Drone Phantom 4 RTK.



Foto 8. Toma de Datos Drone Phantom 4 RTK - Minería



Foto 9. Toma de Datos Drone Phantom 4 RTK



Foto 10. Tramo arenal, para llegar al punto de muestreo.

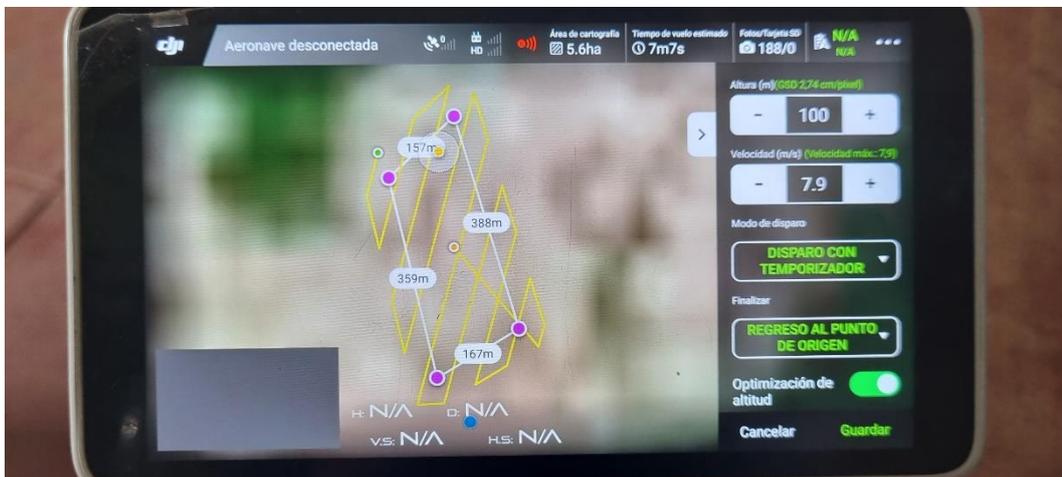


Foto 11. Proyección del área a validar con Drone Phantom 4 RTK



Foto 12. Rio



Foto 13. Vegetacion Secundaria.



Foto 14. Agua