

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



**TESIS**

**“MONITOREO DE LA VEGETACIÓN MEDIANTE ÍNDICES DE RADAR  
DE APERTURA SINTÉTICA (SAR) SENTINEL-1 Y ÓPTICA SENTINEL-2  
EN EL SECTOR DE LAGARTO, PROVINCIA DE TAMBOPATA –  
MADRE DE DIOS”**

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

**AUTORES:**

Bach. MACAHUACHE DÍAZ, Cesar

Bach. TORRES QUISPE, Angela  
Toribia

**ASESOR:**

Dr. Gabriel Alarcón Aguirre

**CO-ASESOR:**


M.Sc. Jorge S. Garate Quispe

**Puerto Maldonado, 2023**

**UNIVERSIDAD NACIONAL AMAZÓNICA DE MADRE DE DIOS**

**FACULTAD DE INGENIERÍA**

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



**TESIS**

**“MONITOREO DE LA VEGETACIÓN MEDIANTE ÍNDICES DE RADAR  
DE APERTURA SINTÉTICA (SAR) SENTINEL-1 Y ÓPTICA SENTINEL-2  
EN EL SECTOR DE LAGARTO, PROVINCIA DE TAMBOPATA –  
MADRE DE DIOS”**

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

**AUTORES:**

Bach. MACAHUACHE DÍAZ, Cesar

Bach. TORRES QUISPE, Angela  
Toribia

**ASESOR:**

Dr. Gabriel Alarcón Aguirre

**CO-ASESOR:**

M.Sc. Jorge S. Garate Quispe

**Puerto Maldonado, 2023**

## **Dedicatoria**

La presente tesis está dedicada en primer lugar a Dios por permitirnos culminarla e ir hacia el camino del éxito, a nuestras madres por apoyarnos siempre a pesar de las adversidades que presenta la vida y a nuestras amistades más cercanas por darnos el aliento y los ánimos que en algún momento nos faltó.

## **Agradecimientos**

Mi gratitud a la escuela académico de ingeniería Forestal y medio ambiente, a los docentes de la universidad y sobre todo a nuestro estimado asesor el Dr. Gabriel Alarcón por el constante apoyo y presión para culminar y no rendirnos en la elaboración de la presente tesis.



# TURNITIN\_ANGELA TORRES

## INFORME DE ORIGINALIDAD

18%

INDICE DE SIMILITUD

18%

FUENTES DE INTERNET

8%

PUBLICACIONES

6%

TRABAJOS DEL ESTUDIANTE

## FUENTES PRIMARIAS

1	<a href="https://repositorio.unamad.edu.pe">repositorio.unamad.edu.pe</a> Fuente de Internet	7%
2	<a href="https://hdl.handle.net">hdl.handle.net</a> Fuente de Internet	1%
3	<a href="https://acolita.com">acolita.com</a> Fuente de Internet	1%
4	<a href="https://ujcontent.uj.ac.za">ujcontent.uj.ac.za</a> Fuente de Internet	1%
5	<a href="https://www.scielo.sa.cr">www.scielo.sa.cr</a> Fuente de Internet	1%
6	Alex Sandro Alves de Araujo. "Estudo da dinâmica da vegetação na América do Sul: mudanças de longo prazo, efeitos antrópicos e controles climáticos", Universidade de São Paulo. Agência de Bibliotecas e Coleções Digitais, 2023 Publicación	<1%
7	Submitted to Aston University Trabajo del estudiante	<1%

## Resumen

Este estudio tiene como objetivo monitorear la relación entre la reflexión óptica Sentinel-2 y la retrodispersión SAR Sentinel-1 de los cambios de la vegetación en un área de intervención antropogénica en el sector de Lagarto entre los periodos 2015 y 2022 utilizando el Índice de vegetación de diferencia normalizada (NDVI) y el Índice de Vegetación de Radar (RVI). El método consistió en medir y comparar el área y la distribución de categorías producida por las transformaciones NDVI y RVI. NDVI para 2015 reporta 22 784,36 ha para áreas con vegetación y 1 315,43 ha para áreas sin vegetación. Mientras que el NDVI para 2022 con 20 877,67 ha para áreas con vegetación y 3 222,13 ha para áreas sin vegetación. RVI para 2015 cuantificó 23 827,59 ha para áreas con vegetación y 272,20 ha para áreas sin vegetación, para 2022 23 702,47 ha para áreas con vegetación y 397,31 ha para áreas sin vegetación. A nivel de precisión, NDVI mostró una confiabilidad considerable y moderada para 2015 y 2022. Entre tanto, de RVI fue aceptable para 2015 y 2022. En cuanto a la relación espacial de NDVI-RVI por la I de Moran Bivariante implicó una autocorrelación positiva baja. La detección de cambios mediante NDVI y RVI destacan un cambio gradual en la cobertura de la vegetación y sin vegetación. Áreas “Sin vegetación” del 2015 al 2022 en NDVI aumentaron en 243,70%, a la vez áreas con vegetación disminuyó en -9,09%. Áreas “Sin vegetación” del 2015 al 2022 en RVI aumentaron en 146,58% y áreas con vegetación disminuyó en -0,54%. Este estudio destaca el interés de los datos ópticos y SAR de Sentinel sobre los perfiles temporales de retrodispersión SAR y NDVI de la vegetación.

**Palabras clave:** Sensores ópticos, SAR, NDVI, RVI, Autocorrelación espacial, Reflexión, retrodispersión, polarización.

## Abstract

This study aims to monitor the relationship between Sentinel-2 optical reflection and Sentinel-1 SAR backscatter of vegetation changes in an area of anthropogenic intervention in the Lagarto sector between the periods 2015 and 2022 using the Normalized Difference Vegetation Index (NDVI) and the Radar Vegetation Index (RVI). The method consisted of measuring and comparing the area and distribution of categories produced by the NDVI and RVI transformations. NDVI for 2015 reports 22 784.36 ha for vegetated areas and 1 315.43 ha for unvegetated areas. While NDVI for 2022 with 20 877.67 ha for areas with vegetation and 3 222.13 ha for areas without vegetation. RVI for 2015 quantified 23 827.59 ha for areas with vegetation and 272.20 ha for areas without vegetation, for 2022 23 702.47 ha for areas with vegetation and 397.31 ha for areas without vegetation. At the precision level, NDVI showed considerable and moderate reliability for 2015 and 2022. Meanwhile, RVI was acceptable for 2015 and 2022. As for the spatial relationship of NDVI-RVI by Bivariate Moran I implied a low positive autocorrelation. The detection of changes by NDVI and RVI highlight a gradual change in vegetation cover and no vegetation. Areas "Without vegetation" from 2015 to 2022 in NDVI increased by 243.70%, while areas with vegetation decreased by -9.09%. Areas "Without vegetation" from 2015 to 2022 in RVI increased by 146.58% and areas with vegetation decreased by -0.54%. This study highlights the interest of Sentinel optical and SAR data on the temporal profiles of SAR backscatter and NDVI of vegetation.

**Key words:** Optical sensors, SAR, NDVI, RVI, Spatial autocorrelation, Reflection, backscattering, polarization.

## Índice de contenidos

	Pág.
Dedicatoria.....	i
Agradecimientos .....	ii
Resumen .....	iii
Abstract.....	iv
Introducción .....	1
<b>CAPÍTULO I: PROBLEMA DE INVESTIGACIÓN.....</b>	<b>5</b>
1.1 Descripción del problema .....	5
1.2 Formulación del problema .....	6
1.2.1 Problema general.....	6
1.2.2 Problemas específicos .....	6
1.3 Objetivos de la investigación.....	7
1.3.1 Objetivo general.....	7
1.3.2 Objetivos específicos .....	7
1.4 Variables de la investigación.....	8
1.4.1 Identificación de variables.....	8
1.5 Operacionalización de variables .....	8
1.6 Hipótesis .....	10
1.7 Justificación e importancia.....	11
1.8 Consideraciones éticas.....	12
<b>CAPÍTULO II: MARCO TEÓRICO.....</b>	<b>13</b>
2.1 Antecedentes de la investigación .....	13
2.2 Base teórica.....	17
2.2.1 Vegetación.....	17

2.2.2	Uso de suelo y cambio de cobertura.....	17
2.2.3	Sistemas de Información Geográfica (SIG).....	17
2.2.4	Sensoramiento remoto.....	18
2.2.5	Espectro electromagnético .....	18
2.2.6	Teledetección activa y pasiva.....	20
2.2.7	Plataforma y sensores .....	21
	Con base en tierra .....	21
	Aerotransportado .....	22
	Satélite.....	22
2.2.8	Escáneres multiespectrales .....	23
2.2.9	Sistemas de exploración a radar.....	24
	Resolución espacial .....	26
	Radar de Apertura Sintética (SAR) .....	27
2.2.10	Clasificación de imágenes .....	27
	Proceso de clasificación de imágenes .....	28
2.2.11	Software de procesamiento de imágenes.....	29
	SNAP ESA.....	29
	Google Earth Engine.....	29
	ArcMap .....	29
2.2.12	Programa Copérnico.....	29
	Sentinel-1.....	30
	Sentinel-2.....	32
	Sentinel-2A – Sensor: MSI.....	32
	Sentinel-2B – Sensor: MSI.....	33
2.3	Definición de términos .....	34

<b>CAPÍTULO III: METODOLOGÍA DE INVESTIGACIÓN .....</b>	<b>36</b>
3.1 Tipo de estudio.....	36
3.2 Diseño del estudio .....	36
3.3 Delimitación espacial y temporal.....	36
3.3.1 Clima e hidrografía .....	38
3.4 Población y muestra .....	38
3.5 Método y técnicas .....	41
3.6 Tratamiento de datos .....	44
3.6.1 Procesamiento de datos .....	44
□ Proceso y análisis de imágenes Landsat y SAR.....	44
3.6.2 Precisión de datos .....	48
3.6.4 Análisis estadístico .....	50
<b>CAPÍTULO IV: RESULTADOS Y DISCUSIÓN .....</b>	<b>51</b>
4.1 Reflexión óptica Sentinel-2 y la retrodispersión SAR Sentinel-1 de la vegetación en un área de intervención antropogénica en el sector de Lagarto entre los años 2015 y 2022.....	51
4.1.1 Índice de vegetación de diferencia normalizada (NDVI) .....	55
4.1.2 Índice de vegetación de radar (RVI) .....	59
4.2 Evaluación de precisión de índices.....	65
4.2.1 Índice de vegetación de diferencia normalizada (NDVI) .....	65
4.2.2 Índice de vegetación de radar (RVI) .....	67
4.3 Correlación espacial .....	70
4.3.1 Año 2015.....	70
4.3.2 Periodo 2022.....	72
4.4 Cambios de cobertura.....	76
4.4.1 Índice de vegetación de diferencia normalizada (NDVI) .....	76

4.2.2 Índice de vegetación de radar (RVI) .....	79
<b>CONCLUSIONES .....</b>	<b>83</b>
<b>SUGERENCIAS.....</b>	<b>85</b>
<b>REFERENCIAS BIBLIOGRÁFICAS .....</b>	<b>86</b>
<b>ANEXOS.....</b>	<b>108</b>

## Índice de Tablas

	<b>Pág.</b>
Tabla 1. Operacionalización de variables .....	9
Tabla 2. Misiones de satélite SAR y radiómetro .....	26
Tabla 3. Características de la imagen de satélite Sentinel-1 .....	31
Tabla 4. Lista de combinaciones de bandas en Sentinel-2.....	32
Tabla 5. Información de adquisición de imágenes Sentinel-1 y -2 .....	44
Tabla 6. Índices ópticos adaptados para Sentinel-2 e índices de radar de apertura sintética (SAR) adaptados para Sentinel-1.....	46
Tabla 7. Valores del coeficiente kappa .....	49
Tabla 8. Cuantificación de la clasificación de NDVI para los años 2015 y 2022 .....	58
Tabla 9. Tasa y pérdida de Vegetación anual promedio de NDVI .....	58
Tabla 10. Cuantificación de la clasificación de RVI para los años 2015 y 2022 .....	62
Tabla 11. Tasa y pérdida de Vegetación anual promedio de RVI.....	63
Tabla 12. Matriz de confusión e Índice de kappa de datos aleatorizados frente a datos NDVI Sentinel-2 del año 2015.....	65
Tabla 13. Matriz de confusión e Índice de kappa de datos de campo frente a datos NDVI Sentinel-2 del año 2022.....	66
Tabla 14. Matriz de confusión e Índice de kappa de datos aleatorizados frente a datos RVI Sentinel-1 del año 2015 .....	68
Tabla 15. Matriz de confusión e Índice de kappa de datos aleatorizados frente a datos RVI Sentinel-1 del año 2022 .....	69
Tabla 16. Cambio de cobertura de vegetación mediante NDVI de los años 2015-2022.....	77



Tabla 17. Cambio de cobertura de vegetación mediante RVI de los años 2015-2022.....	80
---	----

## Índice de Figuras

	<b>Pág.</b>
<i>Figura 1.</i> Un sensor de detección remota mide la energía reflejada o emitida. Un sensor activo tiene su propia fuente de energía.....	19
<i>Figura 2.</i> Vectores eléctricos (E) y magnéticos (M) de una onda electromagnética. ....	19
<i>Figura 3.</i> Relación entre longitud de onda, frecuencia y energía. ....	20
<i>Figura 4.</i> El espectro electromagnético.....	20
<i>Figura 5.</i> Descripción general de los sensores. ....	21
<i>Figura 6.</i> Ángulo de incidencia del radar y ángulo de incidencia local. ....	25
<i>Figura 7.</i> Distorsiones geométricas en RADAR. ....	26
<i>Figura 8.</i> El proceso de clasificación; El componente más importante es el entrenamiento en combinación con la selección del algoritmo. ....	28
<i>Figura 9.</i> Ubicación de área de estudio. ....	37
<i>Figura 10.</i> Distribución de muestras en el área de estudio; a) Sentinel-2 y b) Sentinel-1 de 2015.....	40
<i>Figura 11.</i> Distribución de muestras distribuidas al azar por estratos por exclusión e inclusión en el área de estudio; a) Sentinel-2 y b) Sentinel-1 de 2022.....	41
<i>Figura 12.</i> Cuadrante patrones espaciales de I de Moran. ....	48
<i>Figura 13.</i> Imagen de Satélite Sentinel-2, firmas espectrales en las bandas R (11) G (8) B (4); a. (1=-1 a 0,1) Sin vegetación, b. (2=0,1 a 0,4) Poca vegetación, c. (3=0,4 a 0,6) Vegetación media, y d. (4=0,6 a 1) Vegetación densa.....	52
<i>Figura 14.</i> Imagen de Satélite Sentinel-1, firmas espectrales en las bandas R (VH) G (VV) B (VV-VH); a. (1=0 a 1,5 y 2,3 a 4,0) Sin vegetación, b. (2=1,5 a 1,75) Poca vegetación, c. (3=1,75 a 2,0) Vegetación media, y d. (4=2,0 a 2,3) Vegetación densa. ....	53

<i>Figura 15.</i> Valores de índices espectrales de NDVI y RVI (años 2015 y 2022) de imágenes Sentinel-2 y 1 en el área de estudio. ....	54
<i>Figura 16.</i> Clasificación de NDVI para el año 2022. ....	56
<i>Figura 17.</i> Clasificación de NDVI para el año 2015. ....	56
<i>Figura 18.</i> Cuantificación de la clasificación de NDVI para el año 2015. ....	57
<i>Figura 19.</i> Cuantificación de la clasificación de NDVI para el año 2022. ....	57
<i>Figura 20.</i> Clasificación de RVI para el año 2015. ....	60
<i>Figura 21.</i> Clasificación de RVI para el año 2022. ....	61
<i>Figura 22.</i> Cuantificación de la clasificación de RVI para el año 2015. ....	61
<i>Figura 23.</i> Cuantificación de la clasificación de RVI para el año 2022. ....	62
<i>Figura 24.</i> I de Moran Bivariante 2015 de NDVI y RVI de imágenes Sentinel-2 y -1. ....	71
<i>Figura 25.</i> Significación espacial 2015 de NDVI y RVI de imágenes Sentinel-2 y -1. ....	71
<i>Figura 26.</i> Patrón espacial 2015 de NDVI y RVI de imágenes Sentinel-2 y -1. ....	72
<i>Figura 27.</i> I de Moran Bivariante 2022 de NDVI y RVI de imágenes Sentinel-2 y -1. ....	73
<i>Figura 28.</i> Significación espacial 2022 de NDVI y RVI de imágenes Sentinel-2 y -1. ....	74
<i>Figura 29.</i> Patrón espacial 2022 de NDVI y RVI de imágenes Sentinel-2 y -1. ....	74
<i>Figura 30.</i> Cambio de cobertura de la vegetación mediante NDVI 2015-2022. ....	77
<i>Figura 31.</i> Cambio de cobertura de la vegetación mediante RVI 2015-2022. ....	80

## Índice de anexos

	<b>Pág.</b>
Anexo 1. Matriz de consistencia. ....	109
Anexo 2. Puntos de muestreo distribuidos al azar por estratos en el sector de Lagarto, 2015.....	110
Anexo 3. Puntos de muestreo distribuidos al azar por estratos por exclusión e inclusión en el sector de Lagarto, 2022. ....	119
Anexo 4. Panel fotográfico.....	128

## Introducción

El monitoreo de los bosques y la vegetación en general en la Amazonia mediante satélites es de gran utilidad y proporciona información valiosa en la toma de decisiones en la política multisectorial nacional y regional (Perz et al. 2013; Perz et al. 2016; Gonenc et al. 2019; Holtgrave et al. 2020; Alarcon et al. 2021; Velásquez et al. 2021). Las diferentes actividades y la intensidad de uso son importantes en relación al medio ambiente y las condiciones globales cambiantes, como el cambio climático y el crecimiento demográfico (Chávez et al. 2013; Perz et al. 2016; Gonenc et al. 2019; Holtgrave et al. 2020). Las actividades más importantes ligadas directamente al bosque en la Amazonia son la extracción de madera, productos diferentes a la madera, ecoturismo y conservación, sin embargo, actividades no ligadas directamente pero que necesitan el área del bosque; son la agricultura, ganadería y la minería, estas actividades para iniciar operaciones y actividades necesitan realizar un desbosque, por consiguiente, eliminan mediante tala y roce la vegetación existente (Dourojeanni et al. 2009; Dourojeanni 2014a; Dourojeanni 2014b; Dourojeanni 2019; Alarcón et al. 2021; Martins et al. 2022). En esta situación, los agricultores y mineros de oro deben cumplir con una serie de requisitos para poder operar, no obstante, la precaria y débil control del gobierno en el monitoreo y fiscalización genera diversas modalidades de actividades; legales-formales e ilegales-informales (Alarcón et al. 2021; Martins et al. 2022).

Hasta la actualidad, el monitoreo de la vegetación de los bosques Amazónicos mediante satélites se ha centrado en la disponibilidad de información espacio temporal sin interferencia de las inclemencias ambientales (Holtgrave et al. 2020). El inicio de operaciones del programa Copernicus de la Agencia Espacial Europea (ESA) pone a disposición gratuita de datos satelitales ópticos y de radar de apertura sintética (SAR) con una alta resolución temporal y espacial de 60 m, 20 m, y 10 m (ESA 2013; Niro et al. 2021), ofreciendo una ventaja para el monitoreo de la vegetación de los bosques Amazónicos de Madre de Dios (Alarcon et al. 2021). El programa de la ESA comprende diferentes tipos de sensores para el monitoreo terrestre; un satélite SAR de

banda C llamado Sentinel-1 (S1A y 1B), y un satélite óptico denominado Sentinel-2 (S2A y 2B) (Niro et al. 2021).

La utilización de índices espectrales ópticos y de SAR en el monitoreo de la vegetación se basa en el hecho de que la radiación electromagnética en su rango espectral respectivo es sensible a parámetros biofísicos y/o eco-fisiológicos específicos de las plantas, como la clorofila y el contenido de agua o la estructura de hojas y plantas. Debido a los diferentes rangos espectrales de radiación óptica y SAR, los parámetros biofísicos de la planta detectados son completamente diferentes. Los datos ópticos se originan a partir de las características de reflexión y refracción de la superficie del dosel y del suelo. La radiación de radar medida resulta de la retrodispersión de las señales transmitidas, que está influenciada por la estructura geométrica y las características dieléctricas del dosel (Carranza et al. 2019). Estas evaluaciones, son medidas por ambos sensores, por ejemplo, biomasa , tipo de vegetación, regeneración (McNairn et al. 2009; Betbeder et al. 2016; Amazirh et al. 2018; Bousbih et al. 2018; Filgueiras et al. 2019; Gonenc et al. 2019; Liu et al. 2019; Nasirzadehdizaji et al. 2019; Holtgrave et al. 2020; Ajadi et al. 2021) o cambios de cobertura (Veloso et al. 2017; Nasirzadehdizaji et al. 2019; Wang et al. 2019b).

El uso de la teledetección óptica es más común y frecuente en el monitoreo de la vegetación respecto a los SAR debido que los datos ópticos como índices de vegetación, son fácilmente accesibles y han demostrado ser eficientes en el monitoreo de la vegetación (Gonenc et al. 2019; Liu et al. 2019; Navarro et al. 2019; Holtgrave et al. 2020). Lamentablemente, los sensores ópticos dependen de las condiciones climáticas favorables, lo que conlleva a la disponibilidad de datos de series temporales fraccionadas (Gonenc et al. 2019; Hosseini et al. 2019; Liu et al. 2019). A pesar que las imágenes de sensores SAR activos son más difíciles de entender debido a la señal de retrodispersión y la mayor interferencia de ruido respecto a las imágenes ópticas, su ventaja radica en su capacidad para penetrar las nubes y trabajar sin iluminación (Amazirh et al. 2018; Gonenc et al. 2019; Liu et al. 2019; Navarro et al. 2019; Elias et al. 2020; Holtgrave et al. 2020). Por consiguiente,

la detección de información no presenta interferencias climáticas y el tiempo de toma es corta (Elias et al. 2020; Puzzi et al. 2020; Puzzi et al. 2021). Asimismo, el uso de los SAR para monitoreo de la vegetación se encuentra documentado (Bai et al. 2021). Para diferentes satélites SAR, los índices de vegetación de radar se han establecido y utilizado en el monitoreo de la vegetación (Chen et al. 2010; Chirif 2018; Gonenc et al. 2019; Liu et al. 2019; Elias et al. 2020; Holtgrave et al. 2020; Puzzi et al. 2021). Se han realizado esfuerzos para combinar datos ópticos y de radar, con resultados sorprendentes (Chen et al. 2010; van Duijvenbode et al. 2014; Chatziantoniou et al. 2017; Dong et al. 2019; Puzzi et al. 2021), pero para ello, primero se hizo el análisis por separado de S1 y S2, para luego combinar o fusionar ambos en el análisis mediante algoritmos la clasificación de uso de la tierra (Chen et al. 2010; Gharbia et al. 2014; Chirif 2018; Erinjery et al. 2018; Dong et al. 2019; Huamani et al. 2021), biomasa, o el índice de área foliar (LAI, siglas en inglés) entre otros estudios (Verstraete et al. 1996; McNairn et al. 2009; Prabhakara et al. 2015; Betbeder et al. 2016; Veloso et al. 2017; Amazirh et al. 2018; Bousbih et al. 2018; Carranza et al. 2019; Filgueiras et al. 2019; Gonenc et al. 2019; Hosseini et al. 2019; Liu et al. 2019; Nasirzadehdizaji et al. 2019; Navarro et al. 2019; Wang et al. 2019a; Wang et al. 2019b; Holtgrave et al. 2020; Ajadi et al. 2021; Bai et al. 2021). Al realizar el análisis de datos ópticos y SAR, se determina el punto de intercambio y complemento (Holtgrave et al. 2020).

Las investigaciones sobre la retrodispersión SAR o los índices ópticos con parámetros de vegetación como la biomasa o la altura de la planta (Nasirzadehdizaji et al. 2019). La falta de datos de campo, la comparación de SAR con índices ópticos, han demostrado una eficiente correlación con estos parámetros de la vegetación, permitiendo obtener más evidencias sobre el conocimiento de la retrodispersión SAR (Gonenc et al. 2019; Holtgrave et al. 2020). Veloso et al. (2017) analizaron el índice de vegetación de diferencia normalizada (NDVI) con la retrodispersión S1 en polarización simple y la relación de retrodispersión dual de transmisión vertical, recepción horizontal (VH) y transmisión vertical, recepción vertical (VV) con la biomasa vegetal

(McNairn et al. 2009; Bousbih et al. 2018; Carranza et al. 2019; Filgueiras et al. 2019; Gonenc et al. 2019; Hosseini et al. 2019; Liu et al. 2019; Holtgrave et al. 2020; Bai et al. 2021). Los resultados, mostraron que la retrodispersión y las proporciones de SAR presentan un comportamiento temporal complementario (McNairn et al. 2009; Bousbih et al. 2018; Carranza et al. 2019; Filgueiras et al. 2019; Gonenc et al. 2019; Hosseini et al. 2019; Liu et al. 2019; Holtgrave et al. 2020; Bai et al. 2021). Otros hallazgos evidenciaron las relaciones del índice óptico y SAR sin compararlos con los parámetros de la vegetación (Gonenc et al. 2019; Holtgrave et al. 2020). Gonenc et al. (2019) determino una buena correlación de NDVI de Landsat 8 con el índice de vegetación de radar (RVI) de Radarsat-2 (Holtgrave et al. 2020).

Con este estudio, nuestro objetivo es investigar la relación entre la reflexión óptica S2 y la retrodispersión SAR S1 de la vegetación en un área de intervención antropogénica en el sector de Lagarto entre los periodos 2015 a 2022 para comprender las similitudes y diferencias de los dos tipos de datos para el monitoreo temporal de grandes áreas de vegetación en la Amazonia. El análisis considero varios aspectos del monitoreo de la vegetación en la Amazonia de Madre de Dios, para ello se incluirá tipos de uso de la tierra propuesta por el MINAM (2015); (MINAM 2020) utilizando varios índices ópticos y el RVI de S1, este último, muy poco utilizado y el cual permitirá sentar evidencias validas. Asimismo, evaluaremos la existencia de correlación entre los índices ópticos y el SAR en el monitoreo de la vegetación. El proceso, propuso el NDVI de los datos S2 y su relación con el RVI de la retrodispersión dual de la banda C de S1 VV y VH.



## **CAPÍTULO I: PROBLEMA DE INVESTIGACIÓN**

### **1.1 Descripción del problema**

El estudio de la vegetación en la Amazonia es uno de los puntos más importantes en la agenda internacional, ya que los bosques afectan directamente a la vida humana y al medio ambiente (Perz et al. 2016; Dourojeanni 2019). La cobertura de la vegetación cambia constantemente debido a la dinámica antropogénica (Alarcón et al. 2021).

El uso de tecnologías de teledetección para el monitoreo y detección cambios puede ayudar a los gestores y planificadores a realizar un control y una planificación eficiente (Alarcón et al. 2021; Martins et al. 2022). Los estudios de la vegetación son importantes en la gestión de los recursos naturales, la dinámica de la vegetación tiene un patrón de reflexión especial en la onda electromagnética, que se utiliza para hacer índices de vegetación (Holtgrave et al. 2020). Los índices de vegetación son transformaciones matemáticas definidas por diferentes bandas del sensor, y están diseñados para la evaluación y valoración de las plantas en las observaciones satelitales multiespectrales y de radar (Navarro et al. 2019). Los índices espectrales se correlacionan con la densidad de la vegetación, afectada por la altura, el ángulo de radiación solar, el suelo y la atmósfera (Filgueiras et al. 2019; Gonenc et al. 2019; Navarro et al. 2019; Holtgrave et al. 2020). Los índices de vegetación de sensores ópticos y radar más comunes para evaluar la cubierta vegetal y el verdor del terreno en diferentes períodos de tiempo son el NDVI y RVI (Filgueiras et al. 2019; Gonenc et al. 2019; Navarro et al. 2019; Holtgrave et al. 2020).

Las zonas áridas y semiáridas son más sensibles a los cambios en las precipitaciones, sin embargo, los patrones estacionales de precipitación influyen la cubierta terrestre en los trópicos más que los cambios en la

precipitación anual (Yaghobi et al. 2019). En ese sentido los índices espectrales de sensores ópticos presentan inconvenientes, siendo los sensores de radar SAR mediante la retrodispersión VV y VH muy eficientes sin importar las variaciones climáticas (Filgueiras et al. 2019; Gonenc et al. 2019; Navarro et al. 2019; Yaghobi et al. 2019; Holtgrave et al. 2020). El estudio reportó hallazgos del monitoreo de la vegetación en un área intervenida por minería de oro en el sector de Lagarto y muestra la cuantificación, cambios de la vegetación, y correlación de índices espectrales de S2 y S1. Los resultados de la evaluación y correlación de los índices de S2 y S1 sobre la vegetación en el período comprendido entre 2015 y 2022 revelaron la precisión y patrones de desimilitud entre ambos sensores.

## **1.2 Formulación del problema**

### **1.2.1 Problema general**

¿Cuáles serán los cambios y la relación entre la reflexión óptica Sentinel-2 y la retrodispersión SAR Sentinel-1 de los cambios de la vegetación en un área de intervención antropogénica en el sector de Lagarto entre los periodos 2015 y 2022?

### **1.2.2 Problemas específicos**

P.E.1 ¿Cuánto es la cobertura vegetal en un área de intervención antropogénica en el sector de Lagarto mediante el índice de vegetación de diferencia normalizada (NDVI) del sensor Sentinel-2 en los años 2015 y 2022?

P.E.2 ¿Cuánto es la cobertura vegetal en un área de intervención antropogénica en el sector de Lagarto mediante el índice de vegetación de radar (RVI) del sensor Sentinel-1 de retrodispersión dual VV y VH en los años 2015 y 2022?

P.E.3 ¿Cuál es la precisión de los métodos de cuantificación de la cobertura vegetal en un área de intervención antropogénica?

P.E.4 ¿Cómo es la correlación entre el índice de vegetación de diferencia normalizada (NDV) y el índice de vegetación de radar (RVI)?

P.E.5 ¿Cuánto son los cambios de la cobertura vegetal en un área de intervención antropogénica en el sector de Lagarto del índice de vegetación de diferencia normalizada (NDVI) de los años 2015 y 2022?

P.E.6 ¿Cuánto son los cambios de la cobertura vegetal en un área de intervención antropogénica en el sector de Lagarto del índice de vegetación de radar (RVI) de los años 2015 y 2022?

### **1.3 Objetivos de la investigación**

#### **1.3.1 Objetivo general**

Monitorear la relación entre la reflexión óptica Sentinel-2 y la retrodispersión SAR Sentinel-1 de los cambios de la vegetación en un área de intervención antropogénica en el sector de Lagarto entre los periodos 2015 y 2022.

#### **1.3.2 Objetivos específicos**

O.E.1 Cuantificar la cobertura vegetal en un área de intervención antropogénica en el sector de Lagarto mediante el índice de vegetación de diferencia normalizada (NDVI) del sensor Sentinel-2 en los años 2015 y 2022.

O.E.2 Cuantificar la cobertura vegetal en un área de intervención antropogénica en el sector de Lagarto mediante el índice de vegetación de radar (RVI) del sensor Sentinel-1 de retrodispersión dual VV y VH en los años 2015 y 2022.

O.E.3 Evaluar la precisión de los métodos de cuantificación de la cobertura vegetal en un área de intervención antropogénica.

O.E.4 Determinar la correlación entre el índice de vegetación de diferencia normalizada (NDV) y el índice de vegetación de radar (RVI).

O.E.5 Analizar los cambios de la cobertura vegetal en un área de intervención antropogénica en el sector de Lagarto del índice de vegetación de diferencia normalizada (NDVI) de los años 2015 y 2022.

O.E.6 Analizar los cambios de la cobertura vegetal en un área de intervención antropogénica en el sector de Lagarto del índice de vegetación de radar (RVI) de los años 2015 y 2022.

## **1.4 Variables de la investigación**

### **1.4.1 Identificación de variables**

#### **Variable Dependiente**

- ✓ Reflexión y retrodispersión VV y VH de la vegetación en la unidad mínima de la imagen (píxel) en imágenes ópticas Sentinel-2 y radar SAR Sentinel-1.

#### **Variable Independiente**

- ✓ Dinámica de la vegetación en el periodo 2015 y 2022.

## **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
<b>Variable independiente</b>				
Monitorear el estado de la superficie terrestre mediante sensores ópticos (NDVI) permite clasificar y cartografiar la vegetación desde escalas locales a globales en un momento determinado o durante un período continuo.	Cuantificar la cobertura vegetal en un área de intervención antropogénica en el sector de Lagarto mediante el índice de vegetación de diferencia normalizada (NDVI) del sensor Sentinel-2 en los años 2015 y 2022.	Dinámica de la vegetación según NDVI y RVI de sensores ópticos y de radar SAR.  Nivel de precisión de resultados mediante la matriz de confusión y Kappa.	Superficie total (ha).	1
			Matriz de confusión e índice de Kappa.	2
Monitorear el estado de la superficie terrestre con SAR permite clasificar y cartografiar la vegetación en el medio ambiente y el ecosistema desde escalas locales a globales en un momento determinado o durante un período continuo.	Cuantificar la cobertura vegetal en un área de intervención antropogénica en el sector de Lagarto mediante el índice de vegetación de radar (RVI) del sensor Sentinel-1 de retrodispersión dual VV y VH en los años 2015 y 2022.	Dinámica de la vegetación según NDVI y RVI de sensores ópticos y de radar SAR.  Nivel de precisión de resultados mediante la matriz de confusión y Kappa.	Superficie total (ha).	3
			Matriz de confusión e índice de Kappa.	4
Grado de correlación de índice espectral de sensor óptico versus índice de radar.	Determinar la correlación entre NDV y RVI.	Grado de correlación entre NDV y RVI.	Grado de correlación.	5
Los cambios de cobertura con índices ópticos y SAR permiten comprender los estados y cambios producidos en el medio ambiente y el ecosistema.	Dinámica de cambios de la vegetación en los años 2015 y 2022.	Dinámica de la vegetación según NDVI y RVI de sensores ópticos y de radar SAR.	Superficie total (ha).	6

<b>Variable independiente</b>				
Comportamiento de la Reflexión y retrodispersión (VV y VH) de la vegetación en los sensores ópticos y SAR de la cobertura terrestre.	Firmas espectrales de la reflexión y retrodispersión VV y VH de la vegetación en la unidad mínima de la imagen (píxel) en imágenes ópticas Sentinel-2 y radar SAR Sentinel-1.	Rango espectral de índices ópticos y de SAR	Unidades de índice.	7

## 1.6 Hipótesis

### Hipótesis nula ( $H_0$ ):

- ✓ La detección del cambio de la cobertura vegetal a otros usos mediante la reflexión óptica Sentinel-2 (NDVI) y la retrodispersión SAR Sentinel-1 (RVI) de la cobertura vegetal en un área de intervención antropogénica en el sector de Lagarto, no sigue una tendencia creciente.
- ✓ La correlación espacial entre la reflexión óptica Sentinel-2 y la retrodispersión SAR Sentinel-1 de la dinámica de la vegetación en un área de intervención antropogénica en el sector de Lagarto es negativo.

### Hipótesis alterna ( $H_1$ ):

- ✓ La detección del cambio de la cobertura vegetal a otros usos mediante la reflexión óptica Sentinel-2 (NDVI) y la retrodispersión SAR Sentinel-1 (RVI) de la cobertura vegetal en un área de intervención antropogénica en el sector de Lagarto, sigue una tendencia creciente.
- ✓ La correlación entre la reflexión óptica Sentinel-2 (NDVI) y la retrodispersión SAR Sentinel-1 (RVI) de la cobertura vegetal en un área de intervención antropogénica en el sector de Lagarto es negativo.

## 1.7 Justificación e importancia

Las tecnologías de percepción remota abarcan datos a nivel mundial (Steinhausen et al. 2018). A partir de estos conjuntos de datos, se puede derivar información detallada del monitoreo de la vegetación en la Amazonia y los procesos de cambio, como la pérdida de bosques.

A la actualidad, los avances en la teledetección son considerables, existe mayor disponibilidad y acceso a la información óptica y radar, convirtiéndose pieza clave en los diferentes campos de análisis y monitoreo de la vegetación (Dong et al. 2019), especialmente en agricultura (Lesiv et al. 2018), bosque (Hansen et al. 2013), expansión urbano (Melchiorri et al. 2018; Zhu et al. 2019), monitoreo de la pérdida de bosque, minería, e infraestructura (Alarcón et al. 2016; Asner y Tupayachi 2017), entre otros.

Aunque los datos de teledetección óptica son más comunes y mayor utilizados en el monitoreo de la cobertura terrestre (Alarcón et al. 2016; Joshi et al. 2016; Caballero et al. 2018), estos sistemas afrontan el desafío de adquirir datos con una cobertura mínima de nubosidad y otros efectos climáticos, por lo que los estudios están supeditados a la temporalidad del clima (Asner et al. 2013; Alarcón et al. 2016; Asner y Tupayachi 2017; Caballero et al. 2018). En esta situación, la adquisición de información se restringe solo a periodos sin interferencia del clima (Asner et al. 2013; Asner y Tupayachi 2017), lo que es relevante en el monitoreo de la vegetación en la Amazonia. La Amazonia de Madre de Dios en el sector de Lagarto presenta estas características, la temporada de lluvias se asocia principalmente con el monzón sudamericano de invierno (octubre-abril) (Mariaca y Andrés 2007), lo que dificulta adquirir suficientes imágenes ópticas para cartografiar con éxito la vegetación en época de lluvias.

La teledetección activa, como el radar SAR, cuenta con su propia fuente de energía y no dependen de la luz solar, opera sin importar las condiciones climáticas, de día y de noche, superando ampliamente las limitaciones de la teledetección pasiva (Mariaca y Andrés 2007). Los datos de radar son excelentes para el monitoreo de la vegetación en zonas expuestas a alta nubosidad y precipitaciones como la vegetación de la cuenca Amazónica

(Rajah et al. 2018; Steinhausen et al. 2018). La data de retrodispersión simple V, H o dual VV, VH, HV de los radares de apertura sintética (SAR) incorporan información complementaria respecto a la data multiespectrales (Stefanski et al. 2014; Rajah et al. 2018; Steinhausen et al. 2018; Puzzi et al. 2021). En ese sentido, medir el grado de correlación de los resultados en el monitoreo de la vegetación de sensores ópticos y de radar resulta fundamental, con la finalidad de encontrar similitudes y poder completar la data para una mejor precisión en el monitoreo de la vegetación en la Amazonia de Madre de Dios en el sector de Lagarto.

La metodología de aplicación de índices de sensores ópticos y SAR (Sentinel-1 y -2) permitirán sentar bases y abrirán el camino para más sinergias entre las misiones espaciales (de radar y ópticas) para el monitoreo de la vegetación, en especial en los bosques Amazónicos. Por consiguiente, se podrían plantear soluciones alternativas, como la complementariedad de índices y la fusión de imágenes ópticas y SAR en regiones donde hay condiciones extremadamente húmedas.

## **1.8 Consideraciones éticas**

“La investigación utilizó criterios metodológicos sobre procesamiento de imágenes ópticas Sentinel-2 y SAR Sentinel-1, para ello se empleó los softwares SNAP ESA y Google Earth Engine de plataforma abierta, así como el ArcGisPro 2,9®, ArcGIS 10,8® del CETEGERN” adquiridos en cooperación técnica internacional con Consorcio Madre de Dios/ICAA-USAID. Para el desarrollo favorable de la investigación, se contó con el asesoramiento especializado del personal del Centro de Teledetección para el Estudio y Gestión de los Recursos Naturales (CETEGERN).

El levantamiento de información en campo para medir la precisión de la investigación para el año 2022, cumplió todas las medidas sanitarias de la pandemia (COVID19), con la finalidad de evitar riesgos de transmisión y contagio en las diferentes fases de recolección de data.



## **CAPÍTULO II: MARCO TEÓRICO**

### **2.1 Antecedentes de la investigación**

Bai et al. (2021) evaluaron la contribución de las características ópticas y polarimétricas de SAR para la clasificación de uso de suelo y cambio de cobertura (USCC), y la extracción de vegetación urbana tomando como sitio de estudio un área altamente urbanizada de Hong Kong. Descubrieron que el mecanismo de dispersión de volumen juega un papel vital en el modelo de clasificación a nivel de característica. Finalmente, la precisión de clasificación general del modelo de clasificación no creció significativamente después de que se ingresan varias características ópticas y SAR clave, lo que confirma nuevamente la alta correlación entre las características. En la extracción de vegetación, las características ópticas proporcionan la mayor parte de la información y lograron la alta precisión del 99,02%. Los resultados descubiertos en la investigación anterior podrían beneficiar a los algoritmos de diseño y selección de características para la clasificación USCC urbana de alta precisión y la extracción de vegetación basada en datos ópticos y SAR.

Holtgrave et al. (2020) compararon datos e índices Sentinel-1 y -2 para el monitoreo del uso de la tierra agrícola. Este estudio evaluó las correlaciones de tres índices ópticos Sentinel-2 con índices SAR Sentinel-1 en áreas agrícolas para obtener conocimiento sobre su relación. Se comparó Sentinel-2 Normalized Difference Vegetation Index, Normalized Difference Water Index, and Plant Senescence Radiation Index con Sentinel-1 SAR VV y VH ratio de VH/VV, y el índice de vegetación del radar Sentinel-1. El estudio se llevó a cabo en 22 sitios de prueba que cubren aproximadamente 35 000 ha de cuatro tipos principales de uso de suelo agrícola europeo, a saber, pastizales, maíz, cebada de primavera y trigo de invierno, en Baja Sajonia, Alemania, en 2018. Investigaron la relación entre índices de Sentinel-1 y

Sentinel-2 para cada tipo de uso del suelo considerando tres fenofases (creciente, verde, senescencia). La fuerza de las correlaciones de los índices óptico y SAR difirió entre el tipo de uso del suelo y la fenofase. No hubo una correlación genérica entre los índices óptico y SAR en nuestro estudio. Sin embargo, cuando los datos se dividieron por tipos de uso de suelo y fenofases, las correlaciones aumentaron notablemente. En general, las correlaciones más altas se encontraron para el índice de vegetación de radar y la retrodispersión VH.

Filgueiras et al. (2019) obtuvieron un índice de vegetación de diferencia normalizado (NDVI) producto despejado (NDVInc) mediante el modelado de NDVI Sentinel-2 utilizando diferentes técnicas de regresión y la retrodispersión del radar Sentinel-1 como entrada. El modelo con mejor rendimiento se utilizó en un análisis temporal del 2 de octubre de 2017 al 8 de agosto de 2018, con un total de 55 imágenes Sentinel-2 y 25 imágenes Sentinel-1. La selección del mejor algoritmo de regresión se basó en dos metodologías de validación: validación cruzada K-fold ( $k = 10$ ) y retención. Probaron cuatro enfoques de modelado con ocho algoritmos de regresión. El bosque aleatorio fue el algoritmo que presentó las mejores métricas estadísticas, independientemente de la metodología de validación y el enfoque utilizado. Por lo tanto, este modelo se aplicó a una serie temporal de imágenes Sentinel-1 para demostrar la robustez y aplicabilidad del modelo creado.

Wang et al. (2019a) examinaron el potencial de integrar datos de radar de apertura sintética (SAR, Sentinel-1) y sensores remotos ópticos (Landsat-8 y Sentinel-2) para monitorear las condiciones de un pasto nativo y un pasto introducido en Oklahoma, EE.UU. Índice de área foliar (LAI) y biomasa aérea (AGB) se usaron como indicadores de las condiciones de los pastos bajo diferentes climas y actividades humanas. Estimamos la dinámica estacional de LAI y AGB utilizando datos de Sentinel-1 (S1), Landsat-8 (LC8) y Sentinel-2 (S2), tanto de forma individual como integral, aplicando tres algoritmos ampliamente utilizados: Regresión lineal múltiple (MLR), Support Vector Machine (SVM) y Random Forest (RF). Los resultados indicaron que la integración de los datos LC8 y S2 proporcionaron datos suficientes para

capturar la dinámica estacional de los pastizales con una resolución espacial de 10 a 30 m y mejoraron las evaluaciones de la fenología crítica. etapas tanto en años pluviales como secos. Los modelos LAI y AGB basados en satélites desarrollados a partir de mediciones terrestres en 2015 predijeron razonablemente la dinámica estacional y la heterogeneidad espacial de LAI y AGB en 2016. En comparación, la integración de S1, LC8 y S2 tiene el potencial de mejorar la estimación de LAI y AGB más del 30 % en relación con el rendimiento de S1 con cobertura vegetal baja ( $LAI < 2 \text{ m}^2/\text{m}^2$ ,  $AGB < 500 \text{ g}/\text{m}^2$ ) y datos ópticos de LC8 y S2 con cobertura vegetal alta ( $LAI > 2 \text{ m}^2/\text{m}^2$ ,  $AGB > 500 \text{ g}/\text{m}^2$ ).

Yuliara et al. (2019) compararon el NDVI con RVI y eligieron un índice de vegetación más adecuado para el análisis de la vegetación en el distrito de Buleleng, Bali. La superficie estimada de la vegetación por NDVI fue de 7852,68 ha y el modelo RVI fue de 7669,44 ha, detectaron una diferencia estimada en 183,24 ha y una diferencia en la categoría de clase amplia de 2453,85 ha para la categoría Rara ( $NDVI > RVI$ ), para la clase Media de 1611,45 ha ( $RVI > NDVI$ ), y para la clase densa de 659,16 ha ( $RVI > NDVI$ ). Los resultados concluyeron que el RVI fue más adecuado para la estimación del área y la clase de distribución de la vegetación.

Amazirh et al. (2018) utilizaron datos de radar para recuperar y monitorear los cambios en la humedad del suelo superficial (SM) en diversas condiciones. Para ayudar a calibrar los enfoques de recuperación basados en radar para supervisar SM en alta resolución, este documento presenta un método sinérgico innovador que combina datos térmicos de microondas Sentinel-1 (S1) y Landsat-7/8 (L7/8). Encontraron que la polarización VV estaba mejor correlacionada con SM que la polarización VH con un coeficiente de determinación de 0,47 y 0,28, respectivamente. Al combinar los datos de S1 (VV) y L7/8, redujimos la diferencia cuadrática media entre el satélite y el SM in situ a  $0,03 \text{ m}^3 \text{ m}^{-3}$ , que es mucho menor que  $0,16 \text{ m}^3 \text{ m}^{-3}$  cuando se usa S1 (VV) solamente.

Bousbih et al. (2018) evaluaron la sinergia de datos ópticos y de radar para una cartografía regional del contenido de agua del suelo, a través de

campañas experimentales sobre los campos agrícolas en la llanura de Kairouan, en el centro de Túnez, durante dos temporadas agrícolas (2015-2016 y 2016-2017). En este contexto, proponen una cartografía de la humedad superficial a 20 m de resolución espacial con una frecuencia de repetición de seis días para todo el sitio estudiado. Este estudio reveló el alto potencial de los datos de Sentinel-1, cuando se combinan en sinergia con las imágenes ópticas (Sentinel-2), para la recuperación de la humedad y las características de la vegetación.

Veloso et al. (2017) analizaron la trayectoria temporal de los datos de teledetección para una variedad de cultivos de invierno y verano que se cultivan ampliamente en el mundo (trigo, colza, maíz, soja y girasol). La región de prueba se encuentra en el suroeste de Francia, donde se han adquirido datos de Sentinel-1 desde 2014. Debido a que los datos de Sentinel-2 no estaban disponibles para este estudio, utilizaron satélites ópticos similares a Sentinel-2, principalmente para derivar NDVI, para una comparación entre los comportamientos temporales con datos de radar. La retrodispersión SAR y los perfiles temporales de NDVI de campos con diversas prácticas de gestión y condiciones ambientales se interpretan físicamente. Luego describieron los hallazgos clave de este análisis, que conducen a posibles aplicaciones de los datos de Sentinel-1, con o sin la conjunción de Sentinel-2. Este estudio destaca el interés de los datos SAR y, en particular, la relación VH/VV, que está poco documentada en estudios anteriores.

Kumar et al. (2013) estudiaron la posibilidad de utilizar el Índice de Vegetación por Radar (RVI) para el seguimiento de la vegetación en campos de algodón y soja como alternativa al seguimiento con el Índice de Vegetación de Diferencia Normalizada (NDVI). El presente estudio se llevó a cabo en la región de Vidharba de Maharashtra, India, utilizando cuatro conjuntos de datos de Radarsat-2 adquiridos en la temporada del monzón de 2011 (es decir: 13 de julio de 2011, 06 de agosto de 2011, 30 de agosto de 2011, 23 de septiembre de 2011). El RVI obtenido se comparó con el producto MODIS NDVI de la misma fecha. La investigación muestra algunas mejoras significativas en la técnica RVI que NDVI en algunos contextos. El RVI es

linealmente creciente como el cultivo crece a diferencia de la NDVI se satura después de nivel de crecimiento en el cultivo. El cultivo comenzó en la primera semana de julio de 2011, el NDVI se satura principalmente en la segunda semana de agosto de 2011, sin embargo, el RVI muestra un aumento adicional en el 30 de agosto de 2011 con el crecimiento de la vegetación.

## **2.2 Base teórica**

### **2.2.1 Vegetación**

La vegetación es un conjunto de especies de plantas y la cobertura del suelo que proporcionan, siendo el más cercano la comunidad de plantas (Rangel-Ch y Velázquez 1997).

### **2.2.2 Uso de suelo y cambio de cobertura**

El uso del suelo y el cambio de cobertura es el estudio del cambio de la superficie terrestre. El uso de la tierra (como la agricultura, los pastos, las plantaciones o la minería) describe el uso humano de la tierra, mientras que la cobertura de la tierra (como el bosque o el desierto) describe las características biofísicas de la superficie terrestre (Turner et al. 1995; Naikoo et al. 2022).

### **2.2.3 Sistemas de Información Geográfica (SIG)**

Los datos SIG se pueden utilizar para recopilar y analizar datos sobre la superficie de la tierra y para crear mapas en capas, gráficos y modelos 3D de características geográficas, como montañas, ríos, bosques, calles o edificios. Las industrias y los gobiernos usan herramientas GIS para comprender mejor todo, desde la planificación urbana hasta el cambio climático (Jiang 2020). SIG es un acrónimo de "Sistema de Información Geográfica". Un sistema SIG utiliza computadoras y software para recopilar, administrar y analizar datos en función de la geografía y visualiza los datos en un mapa. El software de mapeo SIG utiliza datos espaciales para crear mapas

y modelos 3D a partir de capas de información visual, revelando patrones y relaciones en los datos SIG.

#### **2.2.4 Sensoramiento remoto**

La teledetección es la ciencia de obtener las propiedades físicas de un área sin estar allí. Permite a los usuarios capturar, visualizar y analizar objetos y características en la superficie de la Tierra. Al recopilar imágenes, podemos clasificarlas en cobertura terrestre y otros tipos de análisis (Kerle et al. 2004; Jensen 2009; Baghdadi y Zribi 2016).

La teledetección utiliza un sensor para capturar una imagen. Por ejemplo, los aviones, los satélites y los vehículos aéreos no tripulados tienen plataformas especializadas que transportan sensores (Kerle et al. 2004; Jensen 2009; Baghdadi y Zribi 2016).

#### **2.2.5 Espectro electromagnético**

El espectro electromagnético varía desde longitudes de onda cortas (como los rayos X) hasta longitudes de onda largas (como las ondas de radio).

Nuestros ojos solo ven el rango visible (rojo, verde y azul). Pero otros tipos de sensores pueden ver más allá de la visión humana. En última instancia, esta es la razón por la que la teledetección es tan poderosa (Kerle et al. 2004; Jensen 2009).

Nuestros ojos son sensibles en el espectro visible (390-700 nm). Pero los ingenieros diseñan sensores para capturar más allá de estas longitudes de onda en la ventana atmosférica .

Por ejemplo, el infrarrojo cercano (NIR) está en el rango de 700-1400 nm. La vegetación refleja más luz verde porque así es como la ven nuestros ojos. Pero es aún más sensible al infrarrojo cercano. Por eso usamos índices como NDVI para clasificar la vegetación (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).

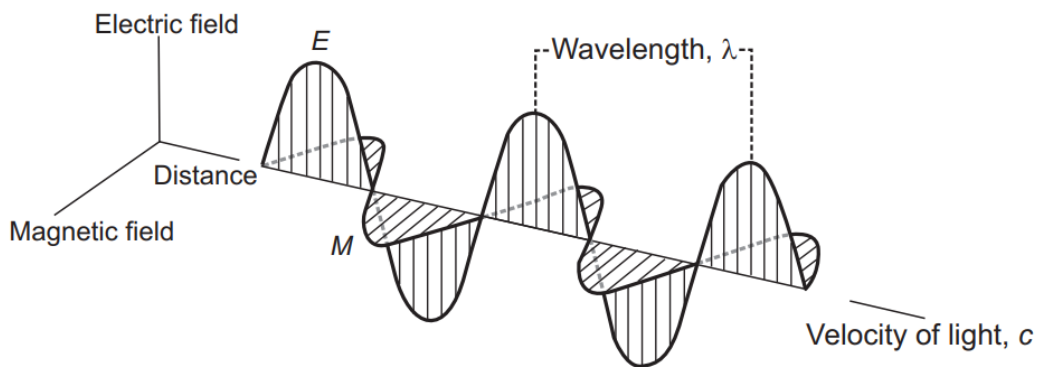


Figura 2. Vectores eléctricos (E) y magnéticos (M) de una onda electromagnética.

Fuente: Kerle et al. (2004)

Las bandas espectrales son grupos de longitudes de onda. Por ejemplo, el ultravioleta, el visible, el infrarrojo cercano, el infrarrojo térmico y las microondas son bandas espectrales.

Clasificamos cada región espectral según su frecuencia ( $\nu$ ) o longitud de onda. Hay dos tipos de imágenes para sensores pasivos: (i) Imágenes multispectrales y (ii) Imágenes hiperespectral. La principal diferencia

entre multiespectral e hiperespectral es el número de bandas y cuán estrechas son las bandas. Las imágenes hiperespectral tienen cientos de bandas estrechas, las imágenes multiespectrales constan de 3 a 15 bandas más anchas (Kerle et al. 2004; Jensen 2009).




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

Fuente: Kerle et al. (2004).

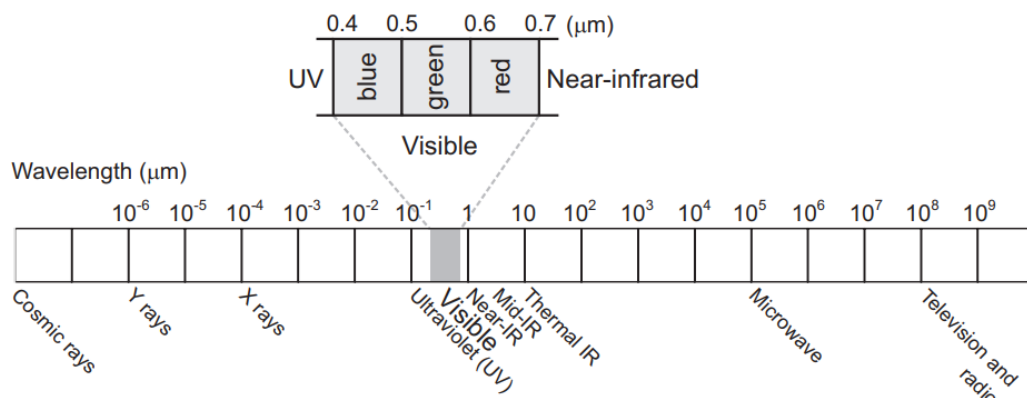


Figura 4. El espectro electromagnético.

Fuente: Kerle et al. (2004).

### 2.2.6 Teledetección activa y pasiva

Los dos tipos de sensores de teledetección son: Sensores pasivos y Sensores activos. La principal diferencia entre los sensores activos es que este tipo de sensor ilumina su objetivo. Luego, los sensores activos miden la luz reflejada. Por ejemplo, Radarsat-2 y Sentinel-1 son un sensor activo que utiliza un radar de apertura sintética. Imagina el flash de una cámara. Ilumina



a su objetivo. A continuación, captura la luz de retorno. Este es el mismo principio de cómo funcionan los sensores activos (Kerle et al. 2004; Jensen 2009). Los sensores pasivos miden la luz reflejada emitida por el sol. Cuando la luz del sol se refleja en la superficie de la Tierra, los sensores pasivos capturan esa luz, por ejemplo Landsat y Sentinel que capturan imágenes detectando la luz solar reflejada en el espectro electromagnético (Kerle et al. 2004; Jensen 2009).

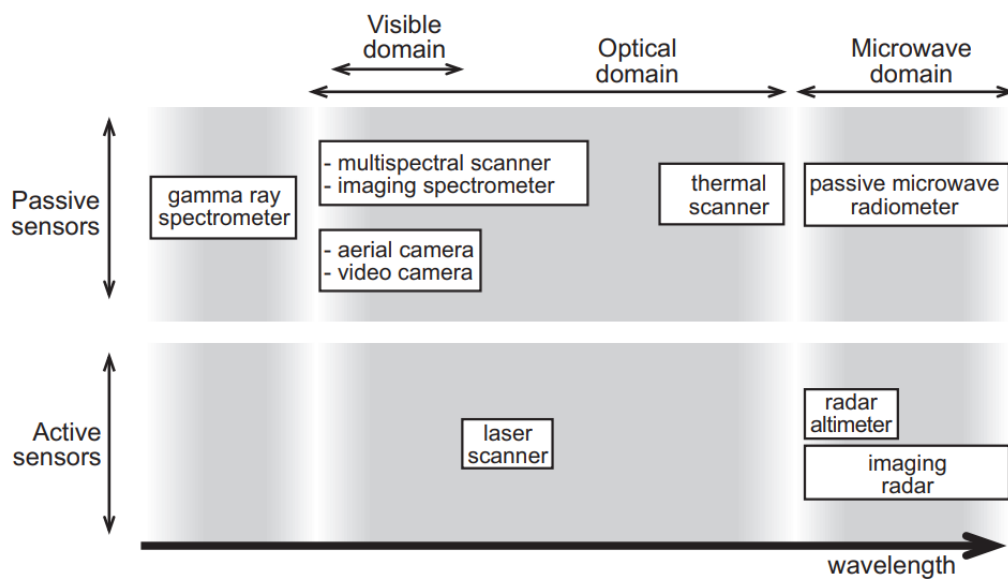


Figura 5. Descripción general de los sensores.

Fuente: Kerle et al. (2004).

### 2.2.7 Plataforma y sensores

Las plataformas se refieren a las estructuras o vehículos en los que se montan los instrumentos de teledetección (Kerle et al. 2004; Jensen 2009).

#### Con base en tierra

En la teledetección se utiliza una amplia variedad de plataformas con base en tierra. Algunos de los más comunes son dispositivos portátiles, trípodes, torres y grúas. Los instrumentos terrestres se utilizan a menudo para medir la cantidad y la calidad de la luz procedente del sol o para la caracterización de objetos a corta distancia. Por ejemplo, para estudiar las propiedades de una

sola planta o de una pequeña porción de hierba, tendría sentido utilizar un instrumento basado en el suelo (Kerle et al. 2004; Jensen 2009).

### **Aerotransportado**

Las plataformas aerotransportadas fueron las únicas plataformas no terrestres para los primeros trabajos de detección remota. Las primeras imágenes aéreas se adquirieron con una cámara que transportaba un globo en el aire en 1859. Hoy en día, los globos rara vez se utilizan porque no son muy estables y el curso del vuelo no siempre es predecible, aunque todavía se utilizan pequeños globos que llevan sondas desechables para algunos estudios meteorológicos. investigación. En la actualidad, los aviones son la plataforma aérea más común. Casi todo el espectro de aeronaves civiles y militares se utiliza para aplicaciones de teledetección. Cuando los requisitos de altitud y estabilidad para un sensor no son demasiado exigentes, se pueden utilizar aviones simples y de bajo costo como plataformas. Sin embargo, a medida que se hacen necesarios los requisitos para una mayor estabilidad de los instrumentos o altitudes más altas, se deben utilizar aeronaves más sofisticadas (Kerle et al. 2004; Jensen 2009).

### **Satélite**

La plataforma más estable en el aire es un satélite, que se encuentra en el espacio. El primer satélite de teledetección se lanzó en 1960 con fines meteorológicos. Ahora, se han lanzado más de cien satélites de teledetección y cada año se lanzan más. El transbordador espacial es una nave espacial única que funciona como un satélite de detección remota y puede reutilizarse para varias misiones (Kerle et al. 2004; Jensen 2009).

Los satélites se pueden clasificar por su geometría orbital y tiempo. Las tres órbitas comúnmente utilizadas para los satélites de teledetección son la geoestacionaria, la ecuatorial y la síncrona solar. Un satélite geoestacionario tiene un período de rotación igual al de la Tierra (24 horas) por lo que el satélite siempre permanece sobre el mismo lugar en la Tierra. Los satélites

meteorológicos y de comunicaciones suelen utilizar órbitas geoestacionarias, muchas de las cuales se encuentran sobre el ecuador. En una órbita ecuatorial, un satélite gira alrededor de la Tierra con una inclinación baja (el ángulo entre el plano orbital y el plano ecuatorial). El transbordador espacial utiliza una órbita ecuatorial con una inclinación de 57 grados (Kerle et al. 2004; Jensen 2009).

Los satélites heliosincrónicos tienen órbitas con ángulos de inclinación altos, pasando casi sobre los polos. Las órbitas están cronometradas de modo que el satélite siempre pasa sobre el ecuador a la misma hora del sol local. De esta forma los satélites mantienen la misma posición relativa con el sol en todas sus órbitas. Muchos satélites de teledetección son sincronizados con el sol, lo que garantiza condiciones de iluminación solar repetibles durante estaciones específicas. Debido a que una órbita síncrona del Sol no pasa directamente sobre los polos, no siempre es posible adquirir datos para las regiones polares extremas. La frecuencia a la que un sensor de satélite puede adquirir datos de toda la Tierra depende del sensor y de las características orbitales. Para la mayoría de los satélites de teledetección, la frecuencia de cobertura total oscila entre dos veces al día y una vez cada 16 días (Kerle et al. 2004; Jensen 2009).

Otra característica orbital es la altitud. El transbordador espacial tiene una altitud orbital baja de 300 km, mientras que otros satélites comunes de detección remota suelen mantener órbitas más altas que van desde 600 a 1000 km (Kerle et al. 2004; Jensen 2009).

### **2.2.8 Escáneres multiespectrales**

Los orígenes de la teledetección multiespectral comercial se remontan a la interpretación de la fotografía aérea de colores naturales e infrarrojos (CIR) a principios del siglo XX. La película CIR se desarrolló durante la Segunda Guerra Mundial como ayuda en la detección de camuflaje. También demostró ser de gran valor para ubicar y monitorear la condición de la vegetación. La vegetación verde saludable aparece en tonos de rojo; el agua clara y profunda parece oscura o casi negra; el hormigón y la grava aparecen en tonos de

gris. Fotografía CIR capturada bajo el Programa Nacional de Fotografía Aérea del USGS (el enlace es externo) fue interpretado manualmente para producir mapas del Inventario Nacional de Humedales (NWI) para gran parte de los Estados Unidos. Si bien la película está siendo reemplazada rápidamente por la adquisición digital directa, la mayoría de las cámaras aéreas digitales de hoy en día están diseñadas para replicar estas imágenes multispectrales familiares de colores naturales o infrarrojos (Sabins Jr 1987; Oppenheimer 1998; Kerle et al. 2004; Jensen 2009).

Los monitores de computadora están diseñados para mostrar simultáneamente 3 bandas de color. Los datos de imagen en color natural se componen de bandas rojas, verdes y azules. Los datos infrarrojos de color se componen de bandas infrarrojas, rojas y verdes. Para los datos multispectrales que contienen más de 3 bandas espectrales, el usuario debe elegir un subconjunto de 3 bandas para mostrar en un momento dado y, además, debe asignar esas 3 bandas a la pantalla de la computadora de tal manera que proporcione una imagen interpretable (Sabins Jr 1987; Oppenheimer 1998; Kerle et al. 2004; Jensen 2009).


En muchos sistemas de imágenes espaciales, incluidos SPOT, IRS, QuickBird, OrbView e IKONOS, se utiliza un escáner de matriz lineal o de barrido. La posición y la orientación del sensor se rastrean y registran con precisión en las efemérides de la plataforma. Sin embargo, otras distorsiones geométricas, como el sesgo causado por la rotación de la tierra, deben corregirse antes de que las imágenes puedan referenciarse a un sistema de coordenadas terrestres (Sabins Jr 1987; Oppenheimer 1998; Kerle et al. 2004; Jensen 2009).

### **2.2.9 Sistemas de exploración a radar**

La obtención de imágenes con la ayuda de sistemas de microondas, es decir, sistemas de radar, difiere mucho de las técnicas de adquisición de imágenes fotográficas y espectrales. El radar es una técnica de teledetección activa, es decir, utiliza su propia radiación en lugar de la luz solar. Un sistema de radar adjunto a un avión o satélite envía microondas que hacen contacto

con la superficie de la Tierra en un cierto ángulo. Allí, son reflejados y recibidos por el sistema de radar que, mientras tanto, se ha movido. Al mismo tiempo, envía nuevas microondas, por lo que cubre toda una franja del terreno (Kerle et al. 2004; Jensen 2009).

Los rangos del espectro electromagnético se caracterizan por diferentes frecuencias y longitudes de onda. La longitud de onda de las ondas infrarrojas, las ondas con las que trabajan los sistemas digitales, son miles de veces más pequeñas que las microondas utilizadas por los sistemas de radar. Pero la intensidad de las microondas utilizadas en la teledetección es menor que la intensidad de un horno de microondas. En un horno de microondas, las comidas como las palomitas de maíz se calientan porque no reflejan las microondas sino que las absorben (Kerle et al. 2004; Jensen 2009).



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

Fuente: Kerle et al. (2004).

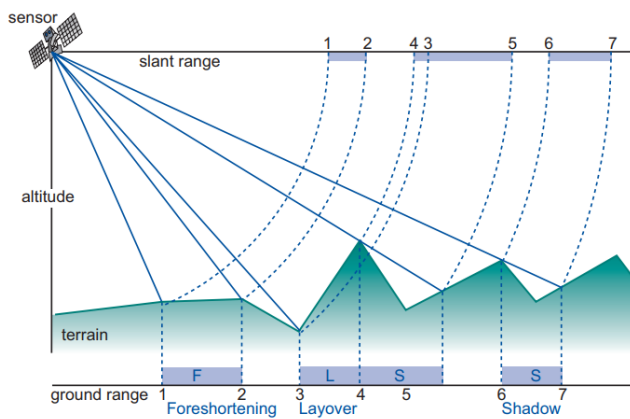


Figura 7. Distorsiones geométricas en RADAR.

Fuente: Kerle et al. (2004).

### Resolución espacial

“En casi todas las plataformas móviles, especialmente naves espaciales, los radares operan en un modo de apertura sintética” (Kerle et al. 2004; Jensen 2009), “lo que da como resultado mediciones de sección transversal de retrodispersión a escala sub kilométrica a costa de anchos de franja más pequeños” (Kerle et al. 2004; Jensen 2009). “Por otro lado, los radiómetros de apertura real producen productos de datos de temperatura de brillo (TB) a una escala de kilómetros o más grandes que cubren una franja muy grande” (Kerle et al. 2004; Jensen 2009).

Tabla 2. Misiones de satélite SAR y radiómetro

Satélite o instrumento	Años de operación	Instrumento	Frecuencia	Resolución nominal
SMOS	2009-presente	Radiómetro	Banda L	35 kilómetros
Acuario	2011–2015	Radiómetro	Banda L	40 kilómetros
AMSR-E	2002–2011	Radiómetro	Multibanda	5-50 km
SMAP	2015-presente	Radiómetro	Banda L	36 kilómetros

Satélite o instrumento	Años de operación	Instrumento	Frecuencia	Resolución nominal
SMAP	2015-presente	SAR	Banda L	300 metros
Radarsat-1/2	1995–2013	SAR	Banda C	3-8 m
	2007-presente			
Sentinal-1	2014-presente	SAR	Banda C	5 m
PALSAR	2006-presente	SAR	Banda L	7-100 m
ERS-1/2	1991–2011	SAR	Banda C	30 m

### **Radar de Apertura Sintética (SAR)**

A diferencia de la tecnología óptica, el radar de apertura sintética (SAR) puede "ver" a través de la oscuridad, las nubes y la lluvia, detectando cambios en el hábitat, niveles de agua y humedad, efectos de perturbaciones naturales o humanas y cambios en la superficie de la Tierra después de eventos como terremotos o aperturas de sumideros (Kerle et al. 2004; Jensen 2009).

El radar de apertura sintética (SAR) se ha utilizado en una amplia gama de aplicaciones, desde el estudio de los icebergs antárticos hasta el seguimiento de las rutas de los derrames de petróleo en pantanos sensibles y el mapeo de los humedales (Kerle et al. 2004; Jensen 2009).

#### **2.2.10 Clasificación de imágenes**

Cuando examinas una foto y tratas de extraer rasgos y características de ella, este es el acto de utilizar la interpretación de imágenes. Utilizamos la interpretación de imágenes en entornos forestales, militares y urbanos. Podemos interpretar características porque todos los objetos tienen su propia composición química única. En la teledetección, distinguimos estas diferencias obteniendo su firma espectral. La firma espectral es la

composición química de los objetos lo que impulsa su firma espectral. Puede clasificar cada mineral porque tiene su propia firma espectral única. Cuando tiene más bandas espectrales, esto le da un mayor potencial en la clasificación de imágenes (Kerle et al. 2004; Jensen 2009).

### Proceso de clasificación de imágenes

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

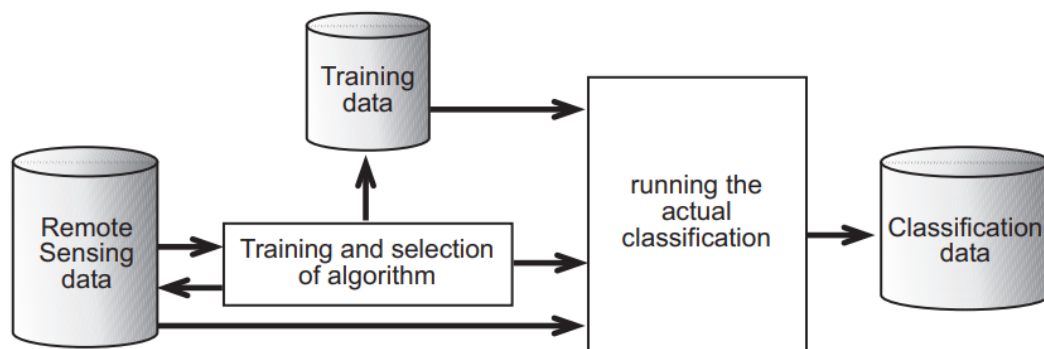


Figura 8. El proceso de clasificación; El componente más importante es el entrenamiento en combinación con la selección del algoritmo.

Fuente: Kerle et al. (2004).

Cuando asigna clases a las características en el suelo, este es el proceso de clasificación de imágenes. Los tres métodos principales para clasificar las imágenes son: Clasificación supervisada, Clasificación no supervisada, y Análisis de imágenes basado en objetos. El objetivo de la clasificación de imágenes es producir uso de la tierra/cobertura de la tierra mediante el uso de software de detección remota, así es como se clasifica el agua, los humedales, los árboles y las áreas urbanas en la cobertura del suelo (Kerle et al. 2004; Jensen 2009; Nair y Bindhu 2016).



### **2.2.11 Software de procesamiento de imágenes**

#### **SNAP ESA**

“El desarrollo reciente de la Agencia Espacial Europea (ESA) implicó la ampliación de las capacidades interferométricas de Sentinel Application Platform (SNAP) para permitir el análisis de series de tiempo interferométrico SAR a través del paquete de software Stanford Method of Persistent Scatterer (StaMPS)” (Zuhlke et al. 2015). “En el trabajo actual, demostramos el procesamiento de interferometría de dispersores persistentes (PSI) habilitado de los datos de la misión Copernicus Sentinel-1 a través del procesamiento integrado SNAP-StaMPS” (Zuhlke et al. 2015).

#### **Google Earth Engine**

Plataforma en la nube con la capacidad de análisis y procesamiento de información espacial (Gorelick et al. 2017).

#### **ArcMap**

“Uno de los paquetes GIS más conocidos, está diseñado como un sistema escalable que se puede implementar en todas las organizaciones, desde un escritorio individual hasta una red de personas distribuida globalmente” (Shaner y Wrightsell 2000). “Dado que ArcMap se construye utilizando la tecnología de modelo de objetos de componentes (COM) de Microsoft, es personalizable y se puede ampliar utilizando cualquier lenguaje de desarrollo compatible con COM” (Shaner y Wrightsell 2000).

### **2.2.12 Programa Copérnico**

“La Unión Europea (UE) ha establecido el Programa Copernicus, anteriormente llamado GMES” (Torres et al. 2012; Li et al. 2020); “una iniciativa de seguimiento de la Tierra impulsada por los usuarios llevada a cabo en asociación con la Agencia Espacial Europea (ESA) y los Estados miembros de la UE/ESA” (Torres et al. 2012; Li et al. 2020). “Copernicus está diseñado para garantizar el suministro continuo de datos e información fiables

sobre los servicios relacionados con el medio ambiente y la seguridad” (Torres et al. 2012; Li et al. 2020), “principalmente a los usuarios responsables de elaborar, implementar y supervisar las políticas pertinentes en la UE y sus Estados miembros” (Torres et al. 2012; Li et al. 2020). “Los servicios de Copernicus se basan en sensores in situ y datos satelitales, estos últimos proporcionados por Copernicus Space Component (CSC)” (Torres et al. 2012; Li et al. 2020). “La ESA es responsable de coordinar el CSC, es decir, las Misiones Centinela y el acceso a los datos de las Misiones Contribuyentes, en colaboración con EUMETSAT” (Torres et al. 2012; Li et al. 2020). “La primera misión satelital de Copérnico dedicada, Sentinel-1A, se lanzó con éxito el 3 de abril de 2014. Una vez finalizada la fase de puesta en servicio (23 de septiembre de 2014)” (Torres et al. 2012; Li et al. 2020), “comenzó la fase de aceleración de las operaciones” (Torres et al. 2012; Li et al. 2020). “Esta fase consiste en un despliegue gradual del sistema del segmento terrestre y una verificación/calibración de la calidad del producto del usuario” (Torres et al. 2012; Li et al. 2020). “Durante esta fase se amplió el suministro de datos, donde las actividades restantes se lograron antes de la Revisión de preparación de operaciones de rutina del Sentinel-1A, terminada en mayo de 2015” (Torres et al. 2012; Li et al. 2020). “Este hito marco la finalización de la calificación de operaciones de la misión y el inicio de las operaciones de rutina del satélite” (Torres et al. 2012; Li et al. 2020). “La capacidad operativa completa se alcanzará cuando dos unidades de Sentinel-1 entren en operaciones de rutina simultáneamente” (Torres et al. 2012; Li et al. 2020). “Las próximas misiones de Sentinel, comenzaron con la primera unidad de Sentinel-2 que funciona en mayo de 2015, posteriormente se cubrió progresivamente todos los dominios de la observación de la Tierra” (Torres et al. 2012; Li et al. 2020).

### **Sentinel-1**

“Los datos del radar de apertura sintética (SAR) Sentinel-1 tienen una resolución espacial mejorada y una alta frecuencia de revisión, lo que los hace útiles para una amplia gama de aplicaciones” (Torres et al. 2012; Li et al.

2020). “Si bien pocas aplicaciones de investigación necesitan datos de Sentinel-1 Ground Range Detected (GRD) con pocas correcciones aplicadas, una gama más amplia de usuarios necesita productos con un conjunto estándar de correcciones aplicadas” (Torres et al. 2012; Li et al. 2020). “Para facilitar la explotación de los productos Sentinel-1 GRD, existe la necesidad de estandarizar los procedimientos para preprocesar los datos SAR a un nivel de procesamiento superior” (Torres et al. 2012; Li et al. 2020), las características se presentan en la tabla 3.

Tabla 3. *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 mx 1,3 mx 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).

“Además, hay que tener en cuenta la polarización, los productos en modo WV solo estarán disponibles para polarización simple (VV o HH) y para los demás modos, SM, IW y EW, estarán disponibles dualmente (VV+VH o HH+HV) o simple” (Torres et al. 2012; Li et al. 2020).

## Sentinel-2

Sentinel-2 es una misión de observación de la Tierra del Programa Copernicus de la Unión Europea que adquiere sistemáticamente imágenes ópticas de alta resolución espacial sobre la tierra y las aguas costeras. La misión es una constelación con dos satélites gemelos. Copernicus es el nuevo nombre del Programa Europeo de Observación, anteriormente conocido como Monitoreo Global para el Medio Ambiente y la Seguridad (GMES) (Torres et al. 2012; Li et al. 2020).

Sentinel 2A/2B proporciona imágenes ópticas de alta resolución y proporciona continuidad para las misiones SPOT y Landsat actuales (Torres et al. 2012; Li et al. 2020).

Tabla 4. *Lista de combinaciones de bandas en Sentinel-2*

<b>Sentinel-2A – Sensor: MSI</b>				
<b>Nro.</b>	<b>Nombre de banda</b>	<b>Longitud de onda (nm)</b>	<b>Ancho de onda (nm)</b>	<b>Resolución (m)</b>
1	Coastal aerosol	443,9	27	60
2	Blue	496,6	98	10
3	Green	560	45	10
4	Red	664,5	38	10
5	Vegetation Red Edge	703,9	19	20
6	Vegetation Red Edge	740,2	18	20

7	Vegetation Red Edge	782,5	28	20
8	NIR	835,1	145	10
8a	Narrow NIR	864,8	33	20
9	Water vapour	945	26	60
10	SWIR – Cirrus	1373,5	75	60
11	SWIR	1613,7	143	20
12	SWIR	2202,4	242	20
<b>Sentinel-2B – Sensor: MSI</b>				
<b>Nro.</b>	<b>Nombre de banda</b>	<b>Longitud de onda (nm)</b>	<b>Ancho de onda (nm)</b>	<b>Resolución (m)</b>
1	Coastal aerosol	442,3	45	60
2	Blue	492,1	98	10
3	Green	559	46	10
4	Red	665	39	10
5	Vegetation Red Edge	703,8	20	20
6	Vegetation Red Edge	739,1	18	20
7	Vegetation Red Edge	779,7	28	20
8	NIR	833	45	10
8a	Narrow NIR	864	32	20
9	Water vapour	943,2	27	60
10	SWIR – Cirrus	1376,9	76	60
11	SWIR	1610,4	141	20

12	SWIR	2185,7	238	20
----	------	--------	-----	----

Fuente: Serrano et al. (2015).

### 2.3 Definición de términos

**Teledetección:** “seguimiento, la evaluación y la predicción de los recursos y las características de la superficie de la Tierra y su atmósfera a partir de los satélites, es una técnica emocionante y de rápido crecimiento utilizada por los científicos ambientales (Chuvieco 1996).

**Sensores ópticos:** “la teledetección óptica es una técnica pasiva para la observación de la tierra que se basa en la iluminación solar” (Booyesen et al. 2021)

**Radar:** sistema que usa ondas electromagnéticas (Handbook 2005) para detectar información de la cobertura terrestre (Handbook 2005).

**SAR:** “el radar de apertura sintética (SAR) es un método de generación de imágenes de microondas activo coherente, en la teledetección se utiliza para mapear las propiedades de dispersión de la superficie de la Tierra en el dominio de longitud de onda respectivo” (Handbook 2005).

**Polarimetría:** “Las técnicas polarimétricas se han incorporado ampliamente en sistemas de radar de última generación para imágenes de alta resolución mediante el principio de radar de apertura sintética (SAR)” (Handbook 2005).

**Programa Copérnico:** “la Unión Europea (UE) ha establecido el Programa Copernicus, anteriormente llamado GMES” (Torres et al. 2012; Li et al. 2020); “una iniciativa de seguimiento de la Tierra impulsada por los usuarios llevada a cabo en asociación con la Agencia Espacial Europea (ESA) y los Estados miembros de la UE/ESA (Torres et al. 2012; Li et al. 2020).

**Cobertura del suelo:** “se refiere al estado físico de la superficie terrestre e incluye vegetación, suelo, rocas, agua y estructuras artificiales, representa la consecuencia acumulativa de la influencia humana y los procesos ecológicos durante muchos miles de años” (Lund 2006).

**Uso de la tierra:** “corresponde a la descripción socioeconómica (dimensión funcional) de áreas utilizadas con fines residenciales, industriales o comerciales, agrícolas o forestales, con fines recreativos o de conservación, entre otros” (Lund 2006).

**Cobertura y uso de la tierra:** “cambio de uso de la tierra de diferentes usos a los bosques, tanto la regeneración natural como la plantación artificial cuentan como forestación” (Lund 2006).

**Índice de Vegetación de Diferencia Normalizada:** cociente de índices espectrales para medir la capacidad fotosintética de la vegetación (Varghese et al. 2021).

**El índice de Vegetación de Radar:** El RVI es una métrica de microondas bien establecida de la cobertura vegetal. El índice utiliza intensidades de dispersión lineal medidas a partir de polarización cruzada y copolar, y se normaliza en un rango ideal de 0 a 1, que aumenta con la cubierta vegetal (Rouse Jr et al. 1973).

## **CAPÍTULO III: METODOLOGÍA DE INVESTIGACIÓN**

### **3.1 Tipo de estudio**

En el estudio se monitoreó y comparó los índices Sentinel-1 y -2 en el monitoreo de la vegetación en el sector de Lagarto, Tambopata - Madre de Dios, periodo 2015 y 2022, para ello, “se aplicará una investigación de tipo descriptiva y correlacional. El análisis consistirá en el análisis geoestadístico para predecir patrones de comportamiento en el presente, mediante la descripción entre datos conocidos, la decisión y los resultados pronosticados para la toma de decisiones, en nuestro caso la cobertura vegetal y sus cambios (Castro 2003; Baray 2006; Cazau 2006; Hernández et al. 2010; Iglesias 2021).

### **3.2 Diseño del estudio**

La comparación de índices Sentinel-1 y -2 en el monitoreo de la vegetación en el sector de Lagarto, Tambopata - Madre de Dios, periodo 2015 y 2022 se enmarca a un diseño Transaccional (transversal) y longitudinal (Castro 2003; Baray 2006; Cazau 2006; Hernández et al. 2010; Iglesias 2021), debido a que el estudio analiza el espacio temporal mostrando la evolución de los cambios de la cobertura vegetal.

### **3.3 Delimitación espacial y temporal**

Madre de Dios, “es conocida como la capital de la biodiversidad del Perú”, priorizado para su conservación por contar con de los ecosistemas con mayor biodiversidad del mundo. Cuenta con una superficie aproximada de 85 183,96 km<sup>2</sup> (8 518 396 ha) (6,64 % del territorio nacional), y una población de 141 070 habitantes (INEI 2017).



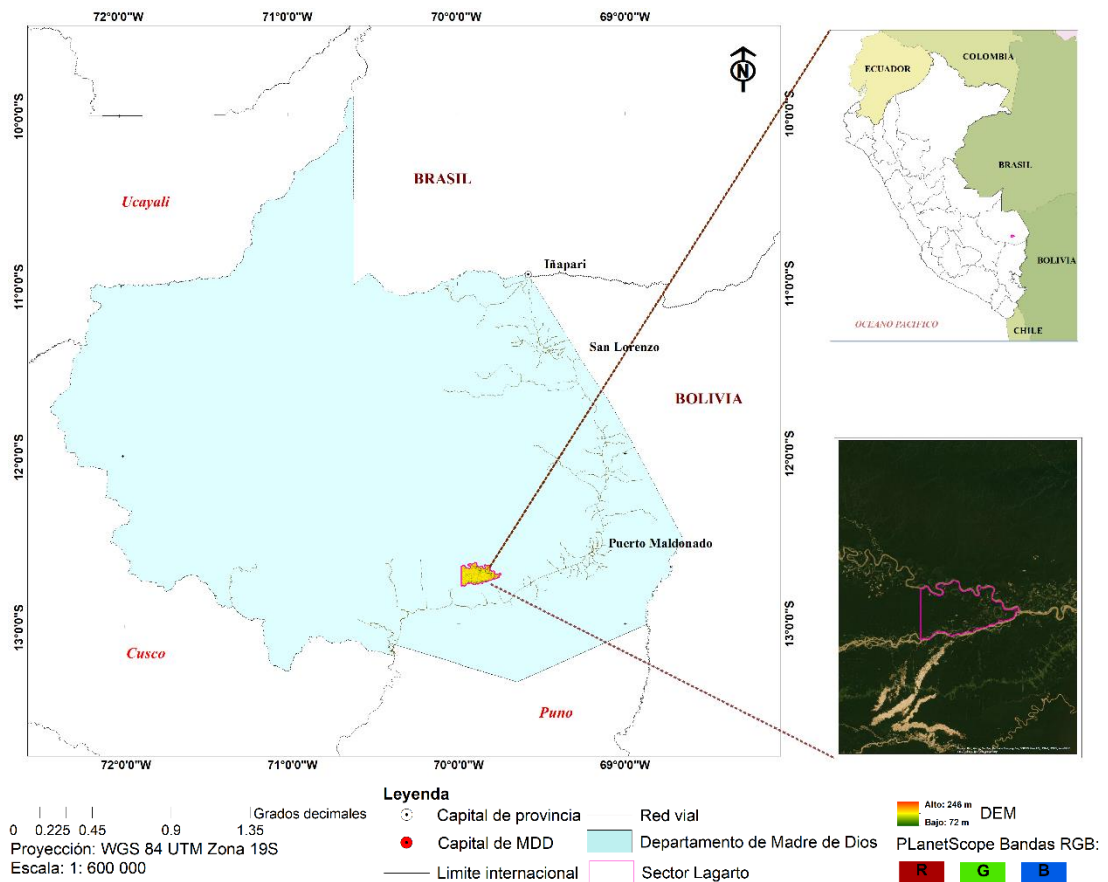


Figura 9. Ubicación de área de estudio.

El área de estudio comprende 240,997.35 km<sup>2</sup> (24 099,735 ha) del departamento de Madre de Dios de Perú (Figura 9), que es una región de importancia mundial para la conservación (Myers et al. 2000). Geográficamente se encuentra entre los paralelos 12° 38' 38" y 12° 47' 22" de latitud Sur y los meridianos 69° 41' 44" y 69° 59' 9" de longitud Oeste; altitud entre 200 m y 250 msnm (GOREMAD y IIAP 2009; Chávez et al. 2013; Perz et al. 2013; Alarcón et al. 2016; Perz et al. 2016)

Alrededor, también se localiza territorios de pueblos indígenas y más lejano, grupos indígenas no contactados que viven en aislamiento voluntario (Mamani 2021; Soriano Martinez 2022). La pérdida de vegetación es causada por la expansión agrícola y la ganadería en los años de 1980 y 1990 (Perz et al. 2013; Perz et al. 2016), y en el 2000 la minería de oro como motores en la dinámica de cambio del paisaje (Asner y Tupayachi 2017; Caballero et al.

2018; Alarcon et al. 2021), generando un mosaico y fragmentación en el uso de suelo (Asner y Tupayachi 2017; Dourojeanni 2019). El corredor vial Interoceánico Sur del tramo III conecta el área de estudio y conecta la región de Madre de Dios con el estado brasileño de Acre y la ciudad de Cobija, Bolivia (Southworth et al. 2011; Alarcon et al. 2021).

En cuanto a la evaluación temporal, el análisis de comparación de los índices Sentinel-1 y -2 en el monitoreo de la vegetación en el sector de Lagarto, Tambopata - Madre de Dios, periodo 2015 y 2022, corresponde al periodo 2015 y 2022.

### **3.3.1 Clima e hidrografía**

La temperatura es semicálida (Holdridge 1967), con una fluctuación promedio anual de 25°C a 27°C, y con ligeras variaciones en el año, siendo los periodos comprendidos entre septiembre y abril los rangos promedios más altos; de mayo y agosto los más bajos, llegando a hasta 10°C. “La precipitación media anual total es de 1 800 mm, la ocurrencia de las lluvias es de menor intensidad en los meses de mayo a septiembre, en los que caen del 20 al 25% del total anual” (GOREMAD y IIAP 2009). “La evapotranspiración fluctúa entre 598,4 mm y 652,6 mm, mientras que la humedad relativa varía entre 63% y 90%” (GOREMAD y IIAP 2009; Perz et al. 2016). La redes hídricas principales y con mayor tributario se encuentra los ríos Madre de Dios e Inambari (GOREMAD y IIAP 2009; Perz et al. 2016).

### **3.4 Población y muestra**

El área de estudio se encuentra en el sector Lagarto de la provincia de Tambopata, que abarca una superficie de 240,997.35 km<sup>2</sup> (24 099,735 ha).

Para comparar los índices Sentinel-1 y -2 en el monitoreo de la vegetación en el periodo 2015 y 2022 el número de muestras a levantar en campo o con imágenes de alta resolución, se empleó la distribución binomial de probabilidad (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%).

$$n = \frac{(1,96)^2 * 0,5(0,5 * 24\ 099,735)}{(24\ 099,735 - 1) * 0,05^2 + 1,96^2 * (0,5 * 0,5)}$$

$$n = 378,15 = 378$$

La muestra fue distribuida de manera representativa en el área de estudio. “Se aplicó un método de muestreo probabilista simple estratificado, donde todas las unidades de muestreo presentes en el área tengan una posibilidad conocida superior a cero de ser seleccionadas (inclusión)” (Ochoa y Páez 2019).

La distribución considero 378 muestras levantadas en campo para 2022 y 378 puntos distribuidos al azar por estratos para 2015; donde: (1) 94 muestras y/o puntos en la categoría de “Sin vegetación”, (2) 94 en “Poca vegetación”, (3) 95 en “Vegetación media”, y (4) 95 en “Vegetación densa” (Olivares y López-Beltrán 2019).

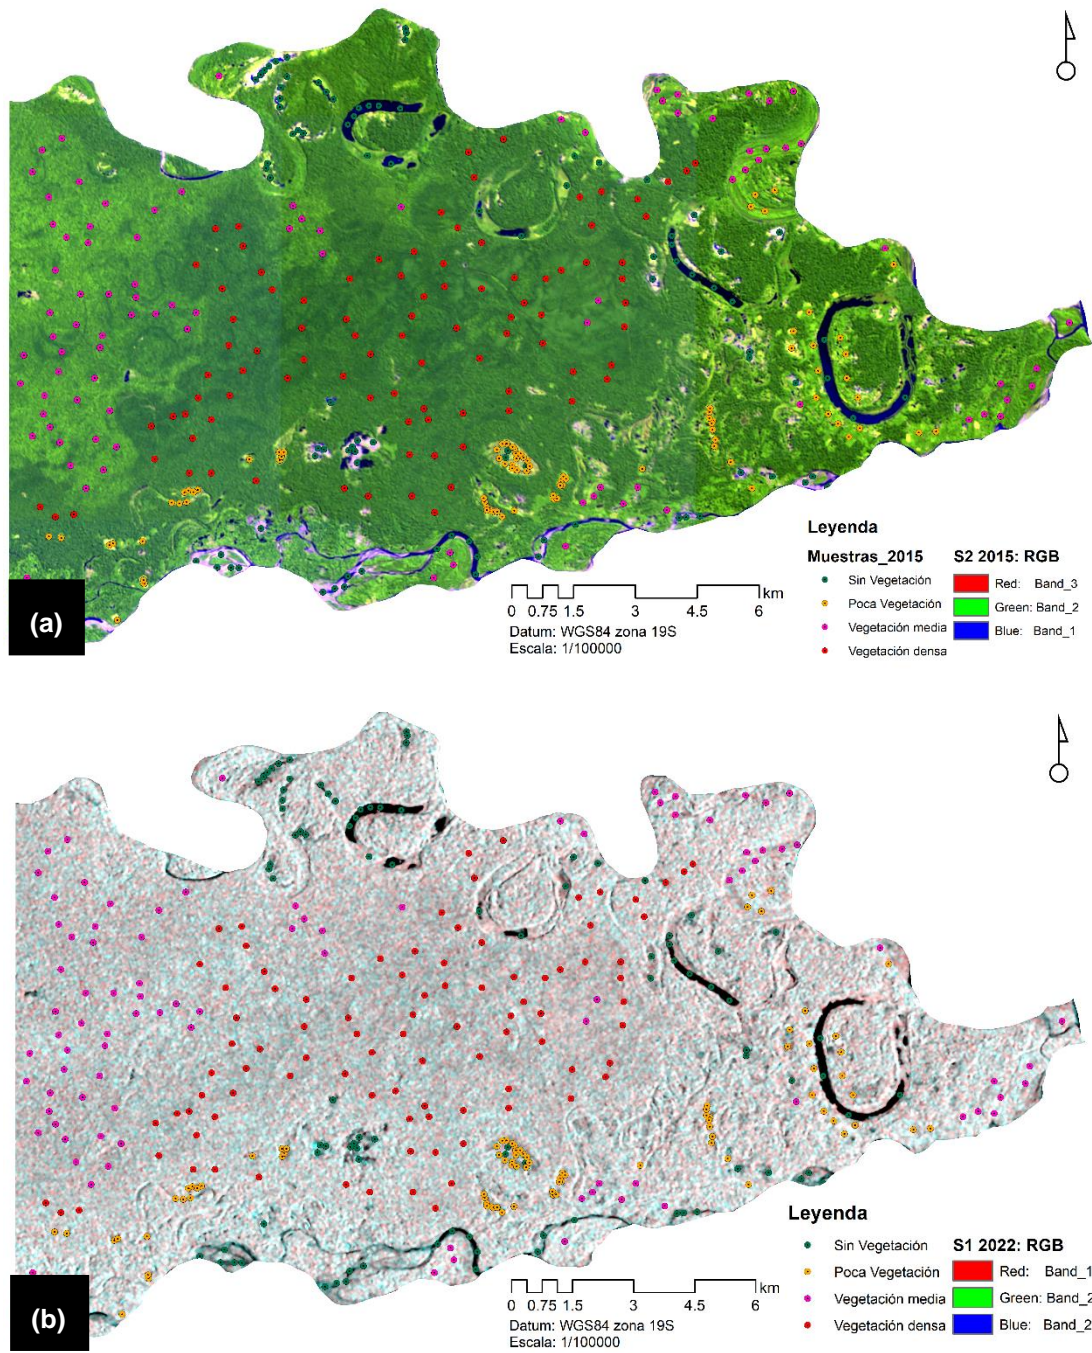


Figura 10. Distribución de muestras en el área de estudio; a) Sentinel-2 y b) Sentinel-1 de 2015.



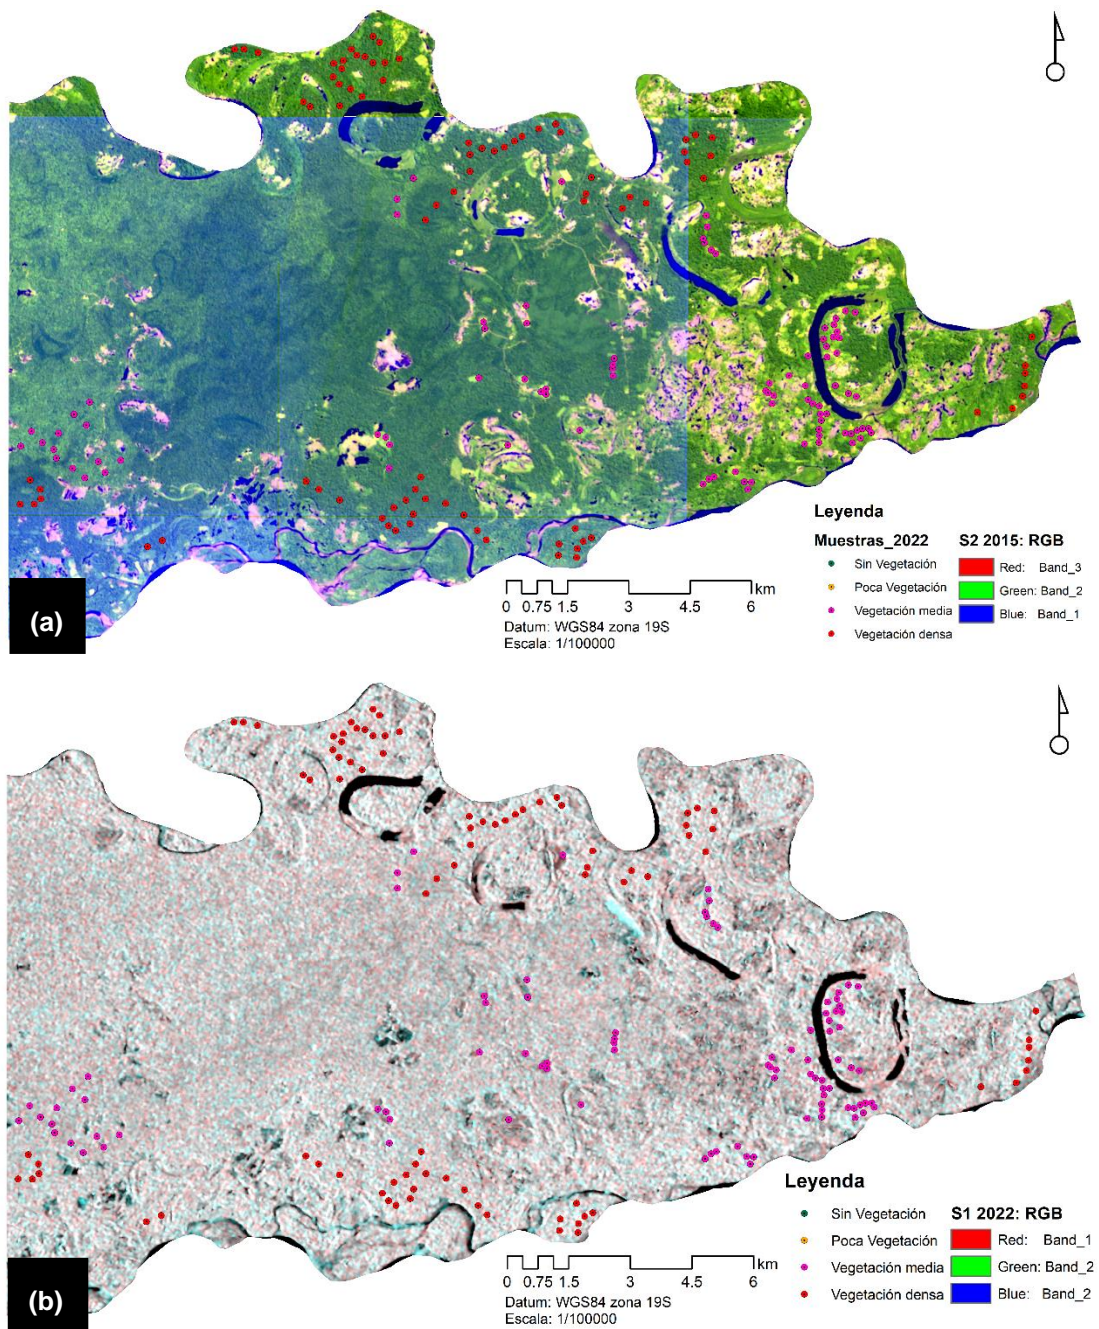


Figura 11. Distribución de muestras distribuidas al azar por estratos por exclusión e inclusión en el área de estudio; a) Sentinel-2 y b) Sentinel-1 de 2022.

### 3.5 Método y técnicas

Las imágenes Sentinel-1 y Sentinel-2 se descargaron 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) de mayo a septiembre de 2015 y 2022 (Tabla

5). Para los satélites S1 A y B, Interferometric Wide Swath (IW) es el modo predefinido sobre tierra y tiene un ancho de franja de 250 km (ESA 2013; Holtgrave et al. 2020; Niro et al. 2021). Proporciona imágenes de polarización dual en VV y VH (ESA 2013; Niro et al. 2021). Los datos S1 se descargarán como retrodispersión gamma nula detectada por rango de tierra (GRD) (ESA 2013; Niro et al. 2021). Se utilizó la opción ortorrectificada en resolución de 10 m, los pasos de preprocesamiento de S1 incluyo la calibración radiométrica y la reducción del ruido térmico (ESA 2013; Niro et al. 2021). La ortorrectificación se llevó a cabo mediante el modelo de elevación digital (DEM) de The Shuttle Radar Topography Mission (SRTM) (Farr et al. 2007). La aplicación de un filtro de mejorado redujo el ruido del moteado característico en las imágenes SAR (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). El preprocesamiento permitió obtener productos geocodificadas y corregidas, todas en el sistema de proyección Universal Transverse Mercator (UTM) (Niro et al. 2021); S2 cuenta con 13 bandas en el rango espectral óptico e infrarrojo. El tamaño de píxel depende de las bandas espectrales, variando entre 10 y 60 m. Se uso la banda visible 4 y la banda de infrarrojo cercano 8. Estas bandas tienen una resolución de 10 m. Para el S2 se utilizó como productos de nivel 2A, corregidos atmosféricamente con el algoritmo Sen2Cor y el modelo de elevación digital PlanetDEM (Varghese et al. 2021).

En el caso de imágenes S2 se empleó de libre o escasa nubosidad (<10%) y las escenas S1 serán en el mismo rango de fecha con la finalidad de evitar sesgos en la evaluación de la vegetación (Varghese et al. 2021).

A partir de los datos de S2, se calculó el NDVI, que es una función del contenido de clorofila verde y la estructura celular de las hojas de la planta, para ello, se utilizara la banda roja 4 (0,665  $\mu\text{m}$ ) y la banda infrarroja cercana 8 (0,842  $\mu\text{m}$ ) (Varghese et al. 2021; Koley y Chockalingam 2022) (la Tabla 2). Para S1 se usó el RVI con la finalidad de compararlos con el índice óptico. Charbonneau et al. (2005); Kim y van Zyl (2009) desarrollaron el RVI para datos SAR de cuatro polarizaciones (Ecuación 3). Trudel et al. (2012)

“modificó el índice bajo el supuesto que  $\sigma^{0HH} \approx \sigma^{0VV}$  y  $\sigma^{0HV} \approx \sigma^{0HH}$ ” (Ecuación 4). Kumar et al. (2013) “descubrió que este RVI es menos sensible a los cambios en las condiciones ambientales, como la humedad del suelo, que la retrodispersión de polarización simple y, por lo tanto, puede ser ventajoso para el monitoreo de la vegetación”. Nasirzadehdizaji et al. (2019) propuso recientemente una adaptación del índice modificado para datos S1 basado en los supuestos de Charbonneau et al. (2005) (Ecuación 5) (Tabla 6). Para realizar el procesamiento, la retrodispersión de las polarizaciones VV y VH (Holtgrave et al. 2020) fueron transformados a decibelios (dB) (Niro et al. 2021).

Se aplicó un enfoque paso a paso para investigar las relaciones entre el SAR y los datos ópticos realizando una correlación espacial. Para medir la similaridad se calculó las correlaciones espaciales del par de índices ópticos y SAR de los periodos de análisis mediante el modelo de correlación bivariado de I de Moran (Moran 1948). La correlación de I de Moran evaluó la fuerza y dirección de la relación entre los pares de parámetros S1 y S2. La correlación se basará en el criterio de la (i) Correlación en conjuntos de datos divididos por tipo vegetación y uso del suelo (Holtgrave et al. 2020).

El procesamiento aplicó programas de acceso libre y con licencia; “SNAP ESA, Google Earth Engine, y ArcGis 10,5® proporcionadas por el Centro de Teledetección para el Estudio y Gestión de los Recursos Naturales (CETEGERN) de la Universidad Nacional Amazónica de Madre de Dios” (Alarcón et al. 2016).

La validación del proceso se realizó mediante información real de campo para el 2022 y distribución al azar por estrato de categorías para el 2015. Para el trabajo de campo se usó el GPS Garmin Map 60 CSx y Garmin Map 62 CSx (Alarcón et al. 2016). Para medir la precisión de los índices se aplicó la matriz de confusión e Índice de Kappa (k) (Alarcón et al. 2016).

### 3.6 Tratamiento de datos

#### 3.6.1 Procesamiento de datos

El material cartográfico e imágenes S1 y S2 se obtuvo de:

1. La cartografía del área de estudio fue proporcionada por el Centro de Teledetección para el Estudio y Gestión de Recursos Naturales (CETEGERN) de la UNAMAD (Alarcón et al. 2016).
2. Las imágenes S1 y S2 se descargaron 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) para el periodo 2015 y 2022 (Tabla 5).

Tabla 5. Información de adquisición de imágenes Sentinel-1 y -2

Sensor (satélite)	Fecha de imagen	Modo de adquisición	Nivel de procesamiento	Orbita
Sentinel-1A (SAR)	2015/09/09 2022/09/03	Interferometric Wide Swath (IW)	Level-1 GRD	Descendente Ascendente
Sentinel-2A (Óptico)	2015/06/16, 2015/06/19, 2015/07/09, y 2015/08/18 2022/05/06, 2022/08/24, 2022/08/24, y 2022/09/06		1C y 2A	

#### ✓ Proceso y análisis de imágenes Landsat y SAR

El tratamiento digital se basó en la corrección de datos Sentinel-1 y -2 descargados de Sentinel Hub, ASF y GEE en cuatro (4) fases:

1. **Pre-Procesamiento.** Se preparó la data óptica y SAR. S2; se utilizó como productos de nivel 2A, corregidos atmosféricamente con el algoritmo Sen2Cor y el modelo de elevación digital PlanetDEM (Varghese et al. 2021), posteriormente se creó el mosaico de las cuatro escenas a una resolución de 10 m y recorte del área con el software



SNAP. Sentinel-1; Multilook, Calibración, Filtro de Speckle, Corrección por Topografía, y Recorte en función al área de estudio (Reiche et al. 2013; Rajah et al. 2018; Steinhausen et al. 2018).

- 2. Procesamiento.** Se clasificó; 1) índice espectral NDVI de S2 y 2) el índice de radar RVI de S1. Para el primer caso se utilizó las bandas multiespectrales 8 y 4, mientras que para el segundo caso se utilizó la retrodispersión dual VV y VH (Williams et al. 2006; Rajah et al. 2018; Holtgrave et al. 2020; Koley y Chockalingam 2022).

El NDVI se calculó según el siguiente algoritmo (Jiang et al. 2006):

$$NDVI = (NIR - Red)/(NIR + Red) \quad \text{(Ecuación 2)}$$

Donde **NIR** es luz infrarroja cercana 8 (0,842  $\mu\text{m}$ ) y Red es luz roja visible 4 (0,665  $\mu\text{m}$ ).

“Este índice fluctúa entre -1 a 1, los valores negativos esta caracterizado por nieve, agua y nubes, por el contrario, los valores cercanos a cero están formados principalmente por rocas y suelo descubierto” (Jiang et al. 2006). “Asimismo, valores muy pequeños (0,1 o menos) corresponden arena y/o nieve, áreas sin roca. Los valores medios (0,2 a 0,3) caracterizan arbustos y praderas, mientras valores mayores (0,6 a 0,8) representan los bosques” (Jiang et al. 2006; Koley y Chockalingam 2022). Para el estudio se consideró los siguientes categorías: (i) Sin vegetación (-1 a 0,1), (ii) Poca vegetación (0,1 a 0,4), (iii) Vegetación media (0,4 a 0,6), y (iv) Vegetación densa (0,6 a 1) (Olivares y López-Beltrán 2019).

S1 uso el RVI mediante las polarizaciones VV y VH que serán transformadas a decibelios (dB) (Niro et al. 2021). Charbonneau et al. (2005); Kim y van Zyl (2009) desarrollaron el RVI para datos SAR de cuatro polarizaciones (Ecuación 3). Trudel et al. (2012) “modificó el índice bajo el supuesto que  $\sigma^{0HH} \approx \sigma^{0VV}$  y  $\sigma^{0HV} \approx \sigma^{0HH}$ ” (Ecuación 4). Kumar et al. (2013) “descubrió que este RVI es menos sensible a los cambios en las condiciones ambientales, como la humedad del suelo, que la retrodispersión de polarización simple y, por lo tanto, puede ser

ventajoso para el monitoreo de la vegetación”. Nasirzadehdizaji et al. (2019) propuso recientemente una adaptación del índice modificado para datos S1 basado en los supuestos de Charbonneau et al. (2005) (Ecuación 5) (Tabla 6).

Tabla 6. *Índices ópticos adaptados para Sentinel-2 e índices de radar de apertura sintética (SAR) adaptados para Sentinel-1*

Satélite	Nombre	Fórmula y bandas originales	Fórmula adaptada para S1 o S2	Origen
Sentinel-2	Índice de vegetación de diferencia normalizada (NDVI)	$\frac{0,95 \mu\text{m} - 0,65 \mu\text{m}}{0,95 \mu\text{m} + 0,65 \mu\text{m}}$	$\frac{\text{Si } 8 - \text{Si } 4}{\text{Si } 8 + \text{Si } 4}$	Rouse Jr et al. (1973)
Sentinel-1	Proporción	$\frac{\text{VH}}{\text{VV}}$	$\frac{\text{CVH}}{\text{CVV}}$	Trudel et al. (2012); Kim y van Zyl (2009)
	Índice de vegetación de radar (RVI)	$\frac{8 \cdot \text{HV}}{\text{HH} + \text{VV} + 2 \cdot \text{HV}}$	$\frac{4 \cdot \text{VH}}{\text{VH} + \text{VV}}$	
	VH	VH	CVH	
	VV	VV	CVV	

$$RVI = 8 \cdot \text{HV} / \text{HH} + \text{VV} + 2 \cdot \text{HV} \quad (\text{Ecuación 3})$$

$$\approx = 4 \cdot \text{HV} / \text{HH} + \text{HV} \quad (\text{Ecuación 4})$$

$$\approx = 4 \cdot \text{VH} / \text{VH} + \text{VV} \quad (\text{Ecuación 5})$$

Este índice SAR se desarrolló para proporcionar un descriptor de vegetación relativamente simple y físicamente interpretable. Aunque estos índices de vegetación de radar son buenos indicadores del estado de la vegetación, sin embargo, el índice de vegetación basado en datos SAR Sentinel-1, es ventajoso para el monitoreo operativo de la vegetación en áreas extensas (Mandal et al. 2020). Para realizar el procesamiento, la retrodispersión de las polarizaciones VV y VH (Holtgrave et al. 2020) fueron transformados a decibelios (dB) (Niro et al. 2021).

Para el estudio se consideró los siguientes categorías: (i) Sin vegetación (0 a 1,5 y 2,3 a 4), (ii) Poca vegetación (1,5 a 1,75), (iii) Vegetación media (1,75 a 2,0), y (iv) Vegetación densa (2,0 a 2,3) (Olivares y López-Beltrán 2019; Mandal et al. 2020).

- 3. 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 aplicar el NDVI a S2 y RVI a S1 (Hosseini et al. 2019; Holtgrave et al. 2020). Para ello, se aplicó el algoritmo de análisis Majority/Minority con un kernel de  $3 \times 3$  y píxel central de 1 con el software ArcGis 10,5® (Handbook 1994; Mohammadi-Ghazi et al. 2020).
- 4. Correlación de datos.** Se aplicó la autocorrelación I de Moran Bivariante, índice que mide cómo un objeto es similar a otros que lo rodean. Mediante la autocorrelación espacial multidireccional y multidimensional se buscó patrones en conjuntos de datos complicados (Ecuación 6). I de Moran tiene un valor de -1 a 1, sin embargo, mientras que otros coeficientes miden una correlación perfecta o ninguna correlación, el de Moran es ligeramente diferente (debido a los cálculos espaciales más complejos): -1 es un agrupamiento perfecto de valores diferentes (también puede pensar en esto como una dispersión perfecta), 0 no es autocorrelación (aleatoriedad perfecta), y +1 indica un agrupamiento perfecto de valores similares (es lo opuesto a la dispersión) (Figura 13).

El I de Moran se diferencia de la mayoría de los otros coeficientes de correlación en que no se puede tomar el índice al pie de la letra, esto se hace con una prueba de hipótesis simple, calculando un puntaje z y su valor p asociado. Donde la hipótesis nula de la prueba es que los datos se distribuyen aleatoriamente y la hipótesis alternativa es que los datos están más agrupados espacialmente de lo que cabría esperar solo por casualidad. Los escenarios posibles son: 1. Un valor z positivo: los datos están agrupados espacialmente de alguna manera, y 2. Un

valor z negativo: los datos se agrupan de forma competitiva (Ecuación 6 y Figura 12).

$$I = (N/W) * \sum \sum W_{ij} (X_i - \bar{X})(X_j - \bar{X}) / \sum (X_i - \bar{X})^2 \text{ (Ecuacion 6)}$$

dónde:

N: El número de unidades espaciales indexadas por i y j

W: La suma de todos  $W_{ij}$

X: La variable de interés

$\bar{X}$ : La media de x

$W_{ij}$ : Una matriz de pesos espaciales

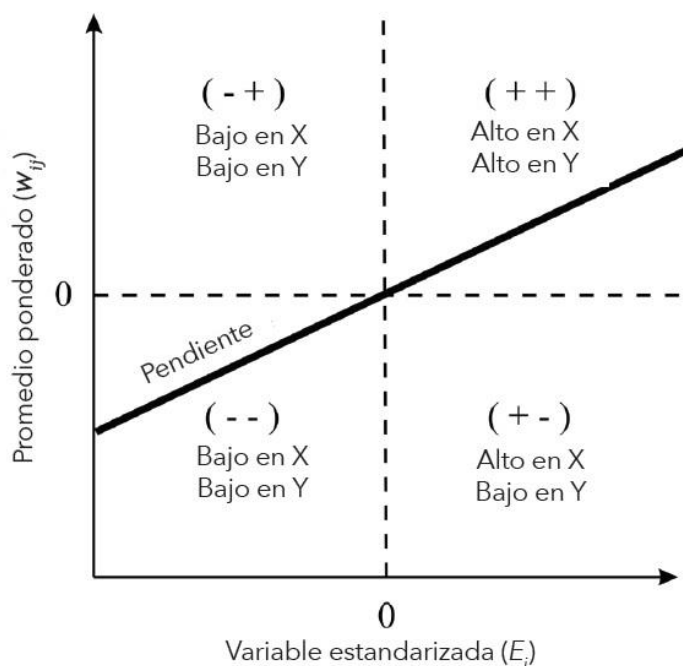


Figura 12. Cuadrante patrones espaciales de I de Moran.

Fuente: Moran (1948).

### 3.6.2 Precisión de datos

La medición de la precisión de los datos ópticos S2 y SAR S1 se realizó mediante operaciones estadísticas. Además se aplicó la matriz de confusión

y el coeficiente kappa ( $\kappa$ ) (Tabla 7) (Cohen 1960; Cohen et al. 2003; Cerda y Villarroel 2008; Alarcón et al. 2016), como un test de evaluación de los datos procesados, información real de campo para el 2022 y distribución al azar por estrato de categorías para el 2015 (Elijah y Jensen 1996; Chuvieco 2002; Chuvieco y Hantson 2010; Alarcón et al. 2016). “La interpretación se realizó en función a los niveles de concordancia cualitativa” (Tabla 7) (Cohen 1960; Cohen et al. 2003; Cerda y Villarroel 2008; Kuhn y Johnson 2013; Alarcón et al. 2016).

$$\textit{Precision general} = VP + VN / VP + FP + VN + FN \quad (\text{Ecuación 7})$$

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

$$\textit{Kappa}(k) = f_o - f_c / N - f_c \quad (\text{Ecuación 8})$$

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

Tabla 7. 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 protocolo de levantamiento de información de campo se basará al método aplicado por el Centro para el Estudio de Instituciones, Población y

Cambios en el Medio Ambiente de la Universidad de la Indiana (CIPEC)” (Moran y Brondizio 1998; Chávez et al. 2013).

#### **3.6.4 Análisis estadístico**

Para la evaluación geoestadística se empleó estadística descriptiva e inferencial, se usó programas de acceso abierto y con licencia; GeoDa, SigmaPlot, Microsoft Excel, ArcGis 10,5®, SNAP ESA, y el Google Earth Engine.

Para el primer y segundo objetivo, sobre cuantificar la dinámica de la vegetación en un área de intervención antropogénica en el sector de Lagarto mediante el NDVI del sensor Sentinel-2 (Jia et al. 2006) y el RVI del sensor Sentinel-1 de retrodispersión dual VV y VH (Nasirzadehdizaji et al. 2019) en los años 2015 y 2022, se aplicó algoritmos en los softwares SNAP ESA y GEE.

Sobre el tercer objetivo, sobre evaluar la precisión de los métodos de cuantificación de la dinámica de la vegetación en un área de intervención antropogénica, se “empleó un test de evaluación denominado matriz de confusión y el coeficiente kappa ( $\kappa$ )” (Cohen 1960; Elijah y Jensen 1996; Chuvieco 2002; Cohen et al. 2003; Chuvieco y Hantson 2010; Alarcón et al. 2016).

El cuarto objetivo, de evaluar y comparar la correlación entre el NDV y el RVI, se aplicará una correlación espacial para de índices ópticos y SAR para medir la similitud de los periodos de análisis. Se usó el método de correlación espacial bivariado de I de Moran, basada en bivariado el criterio en conjuntos de datos divididos por tipo vegetación y uso del suelo (Moran 1948; Holtgrave et al. 2020). Se empleo los softwares GeoDa y SigmaPlot.

Respecto al quinto y sexto objetivo, sobre cuantificar los cambios de la dinámica de la vegetación en un área de intervención antropogénica en el sector de Lagarto de NDVI y RVI de los años 2015 y 2022, se utilizó la estadística descriptiva geoespacial mediante los softwares ArcGis Pro 2,1®, ArcGis 10,5®, Microsoft Excel (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 Reflexión óptica Sentinel-2 y la retrodispersión SAR Sentinel-1 de la vegetación en un área de intervención antropogénica en el sector de Lagarto entre los años 2015 y 2022**

Se adquirieron cuatro escenas de Sentinel-2 y una escena de Sentinel-1 con la configuración que se indica en la tabla 5 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). Los índices de NDVI (Figura 13) y RVI (Figura 14) se extrajeron en función del AOI que se dibujó en función de la forma del área de estudio (Jiang et al. 2006; Williams et al. 2006; Potin 2013; Roy et al. 2014; Reiche et al. 2015; Rajah et al. 2018).

La clasificación consideró para NDVI y RVI los siguientes categorías: (i) Sin vegetación, (ii) Poca vegetación, (iii) Vegetación media, y (iv) Vegetación densa (Olivares y López-Beltrán 2019). Al producto de la clasificación se aplicó el algoritmo de análisis Majority/Minority con un kernel de  $3 \times 3$  y píxel central de 1 con el software ArcGis 10,5® (Handbook 1994; Mohammadi-Ghazi et al. 2020).



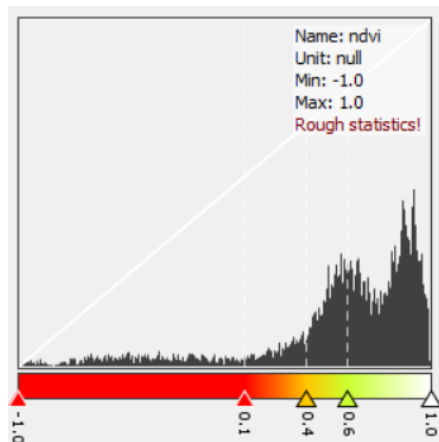


Figura 13. Imagen de Satélite Sentinel-2, firmas espectrales en las bandas R (11) G (8) B (4); a. (1=-1 a 0,1) Sin vegetación, b. (2=0,1 a 0,4) Poca vegetación, c. (3=0,4 a 0,6) Vegetación media, y d. (4=0,6 a 1) Vegetación densa.




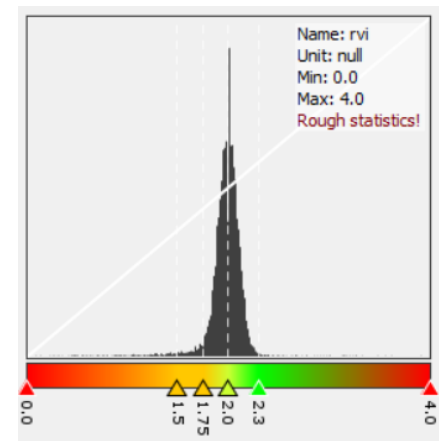


Figura 14. Imagen de Satélite Sentinel-1, firmas espectrales en las bandas R (VH) G (VV) B (VV-VH); a. (1=0 a 1,5 y 2,3 a 4,0) Sin vegetación, b. (2=1,5 a 1,75) Poca vegetación, c. (3=1,75 a 2,0) Vegetación media, y d. (4=2,0 a 2,3) Vegetación densa.

Adicionalmente se midió las métricas de los índices divididas en cuatro grupos (Figura 13 y 14) para cada una de las cuatro trayectorias espectrales (dos NDVI y dos RVI) en base a expectativas a priori de divergencia entre áreas sin vegetación y áreas con vegetación. Las métricas capturan información que está vinculada al tipo de perturbación de la cobertura de la vegetación (i. Sin vegetación, ii. Poca vegetación, iii. Vegetación media, y iv. Vegetación densa) (Olivares y López-Beltrán 2019). La trayectoria (Figura 15) muestra a las áreas con mayor vegetación con valores más altos respecto a las que menor o nula vegetación presentan. Los eventos de perturbación resultan en tendencias decrecientes (deforestación/degradación) o crecientes (regeneración y vegetación densa) a lo largo del tiempo.

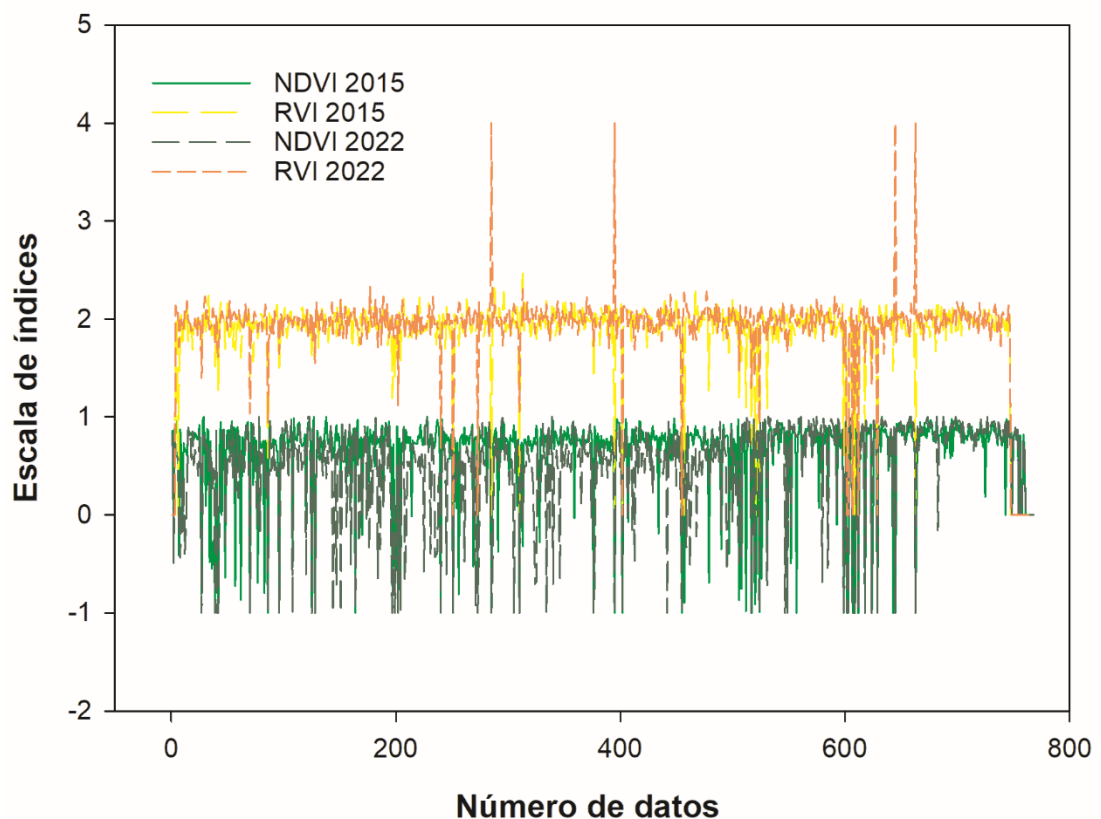


Figura 15. Valores de índices espectrales de NDVI y RVI (años 2015 y 2022) de imágenes Sentinel-2 y 1 en el área de estudio.

Las diferencias en las trayectorias y las métricas de los índices NDVI (Sentinel-2) y RVI (Sentinel-1) de los años 2015 y 2022 siguen patrones

diferentes; los NDVI fluctúan entre rangos de -1 a 1 y los RVI entre rangos de 0 a 4, estos últimos presenta una mayor valoración en cuanto a las escalas de medición de la cobertura de la vegetación, sin embargo, subvalora las áreas con escasa y nula presencia de vegetación, ello podría deberse al comportamiento de la Banda C de Sentinel-1 de la polarizaciones VV y VH que presentan un mejor comportamiento a la retrodispersión por doble rebote de la vegetación con presencia de agua, mientras que áreas con alta densidad de vegetación presenta saturación (Briceño et al. 2019; Sica et al. 2019; Pérez 2020; Puzzi et al. 2020; Reis et al. 2020; Alarcon-Aguirre et al. 2022). En el caso de NDVI, presenta alta sensibilidad a valores extremos de suelo desnudo y vegetación (Betbeder et al. 2016; Bousbih et al. 2018; Carranza et al. 2019; Gonenc et al. 2019; Holtgrave et al. 2020; Mandal et al. 2020; Ajadi et al. 2021), esta situación, ha permitido a los científicos el desarrollo de mejoras a los índices espectrales (por ejemplo; SAVI - Índice de vegetación ajustado al suelo, EVI - índice de vegetación mejorado, OSAVI - Índice de vegetación ajustado al suelo optimizado, entre otros) (Madonsela et al. 2017).

#### **4.1.1 Índice de vegetación de diferencia normalizada (NDVI)**

Uno de los índices importantes utilizados para determinar el cambio en la vegetación es el índice de vegetación de diferencia normalizada (NDVI) (Ecuación 2). Este índice está relacionado con el trabajo de Rouse Jr et al. (1973). Sin embargo, el concepto fue expresada por primera vez por Kriegler et al. (1969) (Jiang et al. 2006).

Elaborado los mapas utilizando NDVI de los años 2015 y 2022, se clasificó la densidad de la vegetación en el área de estudio en base al valor numérico del índice. Este índice va de -1 a +1 y los rangos del NDVI en 2015 fueron como valor mínimo de -0,82 y máximo de 0,96, mientras que de 2022 fueron como valor mínimo de -0,78 y máximo de 0,97. En base a este criterio la cobertura del suelo se clasificó en cuatro categorías; (i) "Sin vegetación", (ii) "Poca vegetación", (iii) "Vegetación media", y (iv) "Vegetación densa" (Olivares y López-Beltrán 2019). El valor numérico para "Sin vegetación" fue de -1 a 0,1, para áreas con "Poca vegetación" osciló entre 0,1 y 0,4, para "Vegetación

media” entre 0,4 y 0,6, y para “Vegetación densa” fue más de 0,6. Los mapas obtenidos del NDVI de 2015 y 2022 se muestran en las Figuras 16, y 17 respectivamente.




Figura 17. Clasificación de NDVI para el año 2015.




Figura 16. Clasificación de NDVI para el año 2022.



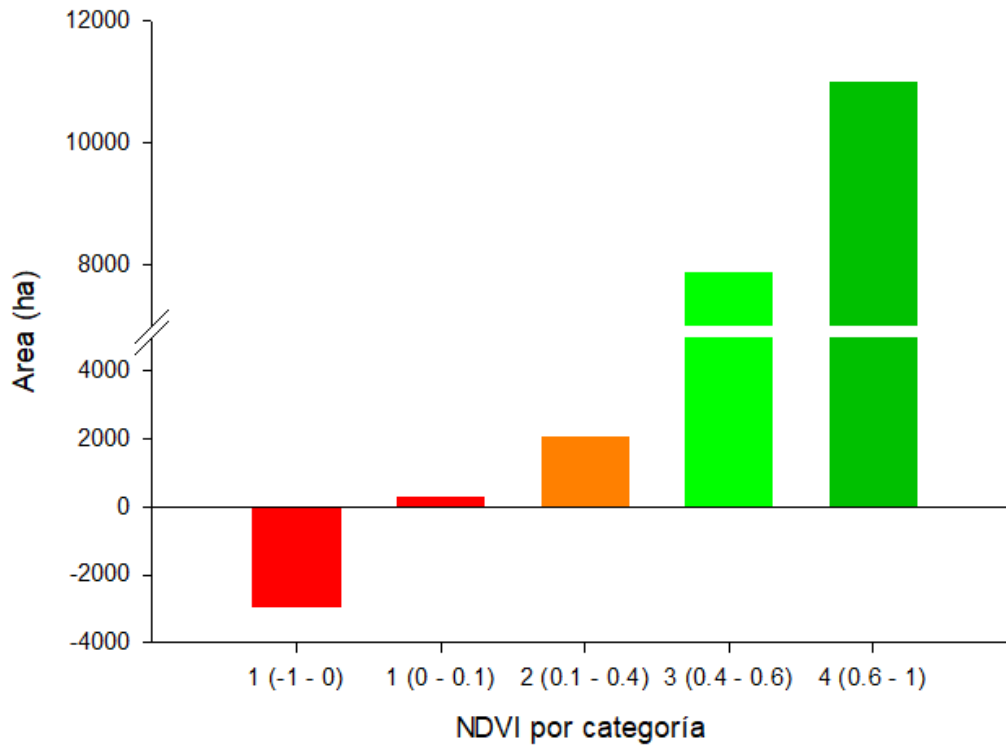


Figura 18. Cuantificación de la clasificación de NDVI para el año 2015.




Figura 19. Cuantificación de la clasificación de NDVI para el año 2022.

Las figuras 18, 19 y tabla 8 muestran el área de las categorías de cobertura de la vegetación de NDVI para 2015 y 2022. El NDVI para 2015 reporta 22 784,36 ha para áreas con vegetación (“Poca vegetación”, “Vegetación media”, y “Vegetación densa”) y 1 315,43 ha para áreas sin vegetación. Mientras que el NDVI para 2022 muestra 20 877,67 ha para áreas con vegetación (“Poca vegetación”, “Vegetación media”, y “Vegetación densa”) y 3 222,13 ha para áreas sin vegetación.

Tabla 8. Cuantificación de la clasificación de NDVI para los años 2015 y 2022

Años	Categorías (ha)			
	1 (Sin vegetación)	2 (Poca vegetación)	3 (Vegetación media)	4 (Vegetación densa)
2015	1 315,43	589,41	812,62	21 382,33
2022	3 222,13	1926,16	7949,78	11 001,73

La pérdida de vegetación entre los años 2015-2022 mediante el NDVI indican una tasa anual de cambio (q) de 1,30% y 271,26 ha/año (Tabla 9).

Tabla 9. Tasa y pérdida de Vegetación anual promedio de NDVI

Años	Tasa anual de pérdida de vegetación (%) (q)	Pérdida de vegetación total anual promedio (ha) (r)
2015-2022	1,30	271,260

Uno de los factores más importantes que afectan vegetación y la cobertura del suelo en general es la precipitación. La baja presencia de precipitación conlleva a una reducción de las actividades fotosintéticas y por consiguiente la reflectividad de las plantas (Eckert et al. 2015; Wang et al. 2019b). Las bandas en las plantas en el rango visible, infrarrojo cercano y medio varía en las diferentes épocas y presenta diferentes comportamientos en el NDVI (Kumar et al. 2013; Veloso et al. 2017; Amazirh et al. 2018; Bousbih et al. 2018; Filgueiras et al. 2019; Wang et al. 2019a; Holtgrave et al. 2020; Bai et al. 2021). Trabajar con imágenes ópticas (Sentinel-2) en la Amazonia

implica trabajar en épocas secas (junio a septiembre) para minimizar la influencia de factores ambientales en la obtención de imágenes, asimismo, el NDVI presenta desventajas den cuanto a la saturación en situaciones extremas con alta presencia de vegetación o suelos desnudos (Verstraete et al. 1996; Eckert et al. 2015), por lo que, un solo índice de vegetación no mostrara una evaluación precisa de la densidad y la determinación del tipo de cobertura de vegetación, de ahí la necesidad de contar con mayor información y la prueba de otros índices de vegetación espectral (Fern et al. 2018). Los diferentes índices tienen pros y contras en diferentes áreas (Frampton et al. 2013; Bajgain et al. 2015; Fern et al. 2018; Hu et al. 2021).

En las figuras 16 y 17 se representa el NDVI de 2015 y 2022 derivado de los datos Sentinel-2, el periodo evaluado correspondió a la época seca (junio a septiembre), que implica una baja presencia de lluvias. El estudio muestra la presencia de una “Vegetación media” a “Vegetación densa” entre los rangos de 0,4 a 1 como valor máximo. El NDVI en ambos periodos presento casi el mismo valor máximo; 0,96 para 2015 y 0,97 para 2022. Considerando que NDVI es una medida de verdor, el índice obtiene el máximo verdor antes que datos volumétricos, este comportamiento coincide por estudios planteados por Kumar et al. (2013), donde, los índices espectrales entre ellos el NDVI presento un mejor comportamiento para medir las fenofases de cultivos y plantaciones (creciente, verde, senescencia). Del mismo modo, Holtgrave et al. (2020) en el monitoreo del uso de la tierra agrícola con datos de Sentinel-2 determino que el NDVI se satura después de nivel de crecimiento en el cultivo, hallazgos que coinciden con el estudio realizado.

#### **4.1.2 Índice de vegetación de radar (RVI)**

RVI es un índice de vegetación simple propuesto por primera vez por Jordan (1969) y modificado por Rouse et al. (1974) quienes separaron la vegetación del suelo de fondo mediante imágenes MSS. El estudio planteo el uso de S1 mediante las polarizaciones VV y VH (Niro et al. 2021) planteado por Kumar et al. (2013) (Ecuación 5) en base a las modificaciones Trudel et

al. (2012) (Ecuación 4) y la base desarrollada por Charbonneau et al. (2005); Kim y van Zyl (2009) que desarrollaron el RVI para datos SAR de cuatro polarizaciones (Ecuación 3).

Elaborado los mapas utilizando RVI de los años 2015 y 2022, se clasificó la densidad de la vegetación en el área de estudio en base al valor numérico del índice. Este índice va de 1 a 4 y los rangos de RVI en 2015 fueron como valor mínimo de 1,32 y máximo de 4,00, mientras que de 2022 fueron como valor mínimo de 1,25 y máximo de 4,00. En base a este criterio la cobertura del suelo se clasificó en cuatro categorías; (i) “Sin vegetación”, (ii) “Poca vegetación”, (iii) “Vegetación media”, y (iv) “Vegetación densa” (Olivares y López-Beltrán 2019). El valor numérico para “Sin vegetación” fue de 0 a 1,50 y 2,30 a 4,00, para áreas con “Poca vegetación” osciló entre 1,50 y 1,75, para “Vegetación media” entre 1,75 y 2,00, y para “Vegetación densa” entre 2,00 a 2,30. Los mapas obtenidos de RVI de 2015 y 2022 se muestran en las Figuras 20 y 21 respectivamente.




Figura 20. Clasificación de RVI para el año 2015.






Figura 21. Clasificación de RVI para el año 2022.




Figura 22. Cuantificación de la clasificación de RVI para el año 2015.




Figura 23. Cuantificación de la clasificación de RVI para el año 2022.

Las figuras 22, 23, y tabla 10 muestran el área de las categorías de cobertura de la vegetación de RVI para 2015 y 2022. El RVI para 2015 reporta 23 827,59 ha para áreas con vegetación (“Poca vegetación”, “Vegetación media”, y “Vegetación densa”) y 272,20 ha para áreas sin vegetación. Mientras que el RVI para 2022 muestra 23 702,47 ha para áreas con vegetación (“Poca vegetación”, “Vegetación media”, y “Vegetación densa”) y 397,31 ha para áreas sin vegetación.

Tabla 10. Cuantificación de la clasificación de RVI para los años 2015 y 2022

Años	Categorías (ha)			
	1 (Sin vegetación)	2 (Poca vegetación)	3 (Vegetación media)	4 (Vegetación densa)
2015	272,20	400,01	13 655,55	9 772,03
2022	397,31	332,63	12 021,45	11 348,39

La pérdida de vegetación entre los años 2015-2022 mediante el RVI indican una tasa anual de cambio (q) de 10,08% y 18,15 ha/año (Tabla 11).

Tabla 11. *Tasa y pérdida de Vegetación anual promedio de RVI*

Años	Tasa anual de pérdida de vegetación (%)	Perdida de vegetación total anual promedio (ha) (r)
2015-2022	0,08	18,150

Al igual que en los índices espectrales de sensores ópticos, la precipitación es uno de los factores más importantes que afectan vegetación y la cobertura del suelo en índices de SAR (Sentinel-1). La baja presencia de precipitación conlleva a una reducción de las actividades fotosintéticas y por consiguiente diferentes respuestas a la retrodispersión en las polarizaciones de los SAR. La reflexión de las plantas en el rango de las microondas de la banda C con una longitud de onda de 5 cm varía en las diferentes épocas (lluvia y seca), mostrando diferentes comportamientos en el RVI (Kumar et al. 2013; Holtgrave et al. 2020). En nuestro caso, la obtención de imágenes SAR en época seca obedece a la comparación con imágenes Sentinel-2. Asimismo, el RVI utiliza copolarizaciones y polarización cruzada que se contralanza en V y H; i) VV: Transmitida Verticalmente, Recibida Verticalmente, y VH: Transmitida Verticalmente, Recibida Horizontalmente (Ecuación 5) (Meyer et al. 2015; Puzzi et al. 2020).

Los valores de RVI mostrados en las figuras 21, 22, 23 y 24 cuantifican a la “Vegetación media” a “Vegetación densa” en el rango de 1,75 a 2,3. La respuesta a la retrodispersión a las polarizaciones VV y VH determinó la sensibilidad del radar Sentinel-1 banda C en la medida de la dispersión volumétrica; según Holtgrave et al. (2020) la humedad del suelo se reduce debido a la vegetación cuando se compara con el caso de la superficie desnuda (Figuras 20, 21, 22, y 23). Los resultados mostraron la disminución de la intensidad debida a la vegetación, el cual no es necesariamente por la dispersión directa desde la superficie del suelo y la variación de la humedad (VV), se dio por la mejora en la sensibilidad en el cambio de la constante dieléctrica de la vegetación, este evento físico posibilita su incremento después de un evento de precipitación (Charbonneau et al. 2005; Trudel et al. 2012; Amziri et al. 2018; Carranza et al. 2019; Gonenc et al. 2019; Liu et al.

2019; Navarro et al. 2019; Yaghobi et al. 2019; Holtgrave et al. 2020; Bai et al. 2021). Los cambios por la constante dieléctrica de la vegetación están influenciadas por la dispersión de la vegetación y afectaron directamente el doble rebote (superficie y vegetación, VH) (Charbonneau et al. 2005; Trudel et al. 2012; Amazirh et al. 2018; Carranza et al. 2019; Gonenc et al. 2019; Liu et al. 2019; Navarro et al. 2019; Yaghobi et al. 2019; Holtgrave et al. 2020; Bai et al. 2021). Por consiguiente, el RVI del estudio en los periodos 2015 y 2022 estuvo influenciado por la penetración de la banda C de Sentinel-1 en función al tipo de vegetación y superficie; al existir áreas con vegetación densa, vegetación con presencia de agua, y superficies sin vegetación, pero influenciadas por la humedad contigua o fuentes agua cercas, el RVI en nuestro estudio sobredimensiono la cuantificación de la vegetación y subvaloro las áreas sin vegetación, estos resultados coinciden por las investigaciones desarrolladas por Veloso et al. (2017); Amazirh et al. (2018); Bousbih et al. (2018); Filgueiras et al. (2019); Wang et al. (2019a); Bai et al. (2021) donde el RVI presenta una tendencia creciente a medida que aumenta la densidad de la vegetación y el efecto del doble rebote por el tipo de superficie.

Finalmente, al comparar el área y la clase de distribución por tipo de cobertura de vegetación de NDVI respecto a RVI (1= "Sin vegetación", 2= "Poca vegetación", 3= "Vegetación media", y 4= "Vegetación densa") cuantifica para 2015;  $NDVI (1)_{2015} > RVI (1)_{2015}$ ,  $NDVI (2)_{2015} > RVI (2)_{2015}$ ,  $NDVI (3)_{2015} < RVI (3)_{2015}$ , y  $NDVI (4)_{2015} > RVI (4)_{2015}$ . Mientras que para 2022;  $NDVI (1)_{2022} > RVI (1)_{2022}$ ,  $NDVI (2)_{2022} > RVI (2)_{2022}$ , y  $NDVI (4)_{2022} < RVI (4)_{2022}$ . A nivel de diferencias, de NDVI-RVI de 2015 esta cuantificado por 1 043,23 ha "Sin vegetación", 189,40 ha en "Poca vegetación", -12 842,93 ha en "Vegetación media", y 11 610,31 ha en "Vegetación densa". De NDVI-RVI de 2022 esta cuantificado por 2 824,81 ha "Sin vegetación", 1 593,52 ha en "Poca vegetación", -4 071,67 ha en "Vegetación media", y -346,66 ha en "Vegetación densa".

La comparación por distribución por tipo de cobertura de vegetación muestra diferencias considerables, RVI sobreestima la cuantificación de la

vegetación, siendo más notorio en la categoría de ‘Vegetación media’. Sin embargo, a nivel general las diferencias de NDVI-RVI se reducen, -1 043,22 ha para áreas con vegetación para 2015 y -2 824,81 ha para 2022. Estas variaciones coinciden por la investigación propuesta por Yuliara et al. (2019), donde la clase media de la vegetación del modelo RVI cuantificó en mayor proporción respecto a NDVI (RVI > NDVI).

## 4.2 Evaluación de precisión de índices

### 4.2.1 Índice de vegetación de diferencia normalizada (NDVI)

Se aplicó la matriz de precisión general y la concordancia de kappa para el 2015 y 2022. La tabla 12 y 13 muestra la evaluación de precisión de la cuantificación de los tipos de vegetación de NDVI. Para 2015, la matriz de confusión mostro una precisión general de 66,90%, mientras que kappa 0,597 (Moderada) (Cohen 1960; Cohen et al. 2003). El 2022 los resultados de la matriz de confusión reporto una precisión general de 69,60%, mientras que kappa 0,631 (Considerable) (Cohen 1960; Cohen et al. 2003).

Tabla 12. *Matriz de confusión e Índice de kappa de datos aleatorizados frente a datos NDVI Sentinel-2 del año 2015*

Categoría		Puntos aleatorizados por estratos				
		1	2	3	4	$f_{NDVI\ Sentinel-2}$
NDVI Sentinel-2 (2015)	1	39(12)	5	3	3	<b>50</b>
	2	16	74(29)	15	10	<b>115</b>
	3	18	10	69(27)	11	<b>108</b>
	4	21	5	8	71(26)	<b>105</b>
	$f_{PAxE}$	<b>94</b>	<b>94</b>	<b>95</b>	<b>95</b>	<b>378</b>
$f_o=$	253			$f_c=$ 68,175		
$k=$	0,597			$k_M =$ 0,755		
$\sigma_k =$	0,030			$\sigma_{k_o} =$ 0,024		
$z=$	24,725			Matriz de confusión= 0,669		

Nota: 1: Sin vegetación, 2: Poca vegetación, 3: Vegetación media, y 4: Vegetación densa.

La proporción de áreas para la validación (n=378) con puntos aleatorizados en el NDVI 2015 (Tablas 12) fueron significativos para realizar mediciones sobre la estructura de la vegetación (Cohen 1960; Cohen et al. 2003; Yaghibi et al. 2019). La data fue analizada de acuerdo con el criterio de frecuencias. Se presentan los valores para la diagonal como opción de acuerdo e irrelevante para los demás valores.

Con un  $k = 0,597$ , vemos que más de la mitad de los juicios conjuntos son acuerdos (excluyendo el azar) de los a datos NDVI de Sentinel-2. Los marginales son tales que  $k_{Max}$  es 0,755 por lo que una parte sustancial de los desacuerdos es consecuencia de discrepancias marginales. La probabilidad de que  $x$  como valor poblacional se encuentre entre 0,539 y 0,654 es del 95%, con una fuerza de concordancia Moderada (0,41-0,60) (Cohen 1960; Cohen et al. 2003) y una matriz de confusión de 0,669. El valor de  $z$  (24,725) es significativo a una probabilidad de  $(P) < 0,001$  (Tabla 12), la cual mide la diferencia entre un parámetro hipotético de la población (unidades de desviación estándar) y un estadístico observado (Yaghibi et al. 2019; Koley y Chockalingam 2022).

Tabla 13. *Matriz de confusión e Índice de kappa de datos de campo frente a datos NDVI Sentinel-2 del año 2022*

Categoría		Datos de campo				$f_{NDVI\ Sentinel-2}$
		1	2	3	4	
NDVI Sentinel-2 (2022)	1	43(13)	3	4	3	53
	2	15	78(28)	13	7	113
	3	16	8	67(25)	10	101
	4	20	5	11	75(28)	111
	$f_{DC}$	94	94	95	95	378
$f_o =$	263			$f_c =$	66,664	
$k =$	0,631			$k_M =$	0,742	
$\sigma_k =$	0,029			$\sigma_{ko} =$	0,024	
$z =$	26,496			Matriz de confusión =	0,696	

Nota: 1: Sin vegetación, 2: Poca vegetación, 3: Vegetación media, y 4: Vegetación densa.

La proporción de áreas para la validación (n=378) con datos de campo en el NDVI 2022 (Tabla 13) fueron significativos para realizar mediciones sobre la estructura de la vegetación (Cohen 1960; Cohen et al. 2003; Yaghobi et al. 2019). La data fue analizada de acuerdo con el criterio de frecuencias. Se presentan los valores para la diagonal como opción de acuerdo e irrelevante para los demás valores.

Con un  $k = 0,631$ , vemos que más de la mitad de los juicios conjuntos son acuerdos (excluyendo el azar) de los a datos NDVI de Sentinel-2. Los marginales son tales que  $k_{Max}$  es 0,742 por lo que una parte sustancial de los desacuerdos es consecuencia de discrepancias marginales. La probabilidad de que  $x$  como valor poblacional se encuentre entre 0,574 y 0,687 es del 95%, con una fuerza de concordancia Considerable (0,61-0,80) (Cohen 1960; Cohen et al. 2003) y una matriz de confusión de 0,505. El valor de  $z$  (26,496) es significativo a una probabilidad de  $(P) < 0,001$  (Tabla 13), la cual mide la diferencia entre un parámetro hipotético de la población (unidades de desviación estándar) y un estadístico observado (Yaghobi et al. 2019; Koley y Chockalingam 2022).

#### **4.2.2 Índice de vegetación de radar (RVI)**

La evaluación de la precisión mediante una matriz de confusión de los RVI de los tipos de vegetación (Tabla 14 y 15) determinaron una precisión general para el año 2015 de 44,90% y un kappa de 0,335 (Aceptable) (Cohen 1960; Cohen et al. 2003). El año 2022 los resultados arrojaron una precisión general de 50,50% y un kappa de 0,400 (Aceptable) (Cohen 1960; Cohen et al. 2003).

Tabla 14. Matriz de confusión e Índice de kappa de datos aleatorizados frente a datos RVI Sentinel-1 del año 2015

Categoría		Puntos aleatorizados por estratos				
		1	2	3	4	$f_{RVI\ Sentinel-1}$
RVI Sentinel-1 (2015)	1	19(5)	1	0	0	20
	2	25	51(30)	21	24	121
	3	27	23	49(30)	21	120
	4	23	19	23	50(29)	115
	$f_{PAxE}$	94	94	93	95	376
$f_o=$	169		$f_c=$ 64,587			
$k=$	0,335		$k_M =$ 0,841			
$\sigma_k =$	0,031		$\sigma_{k_o} =$ 0,023			
$z=$	14,276		Matriz de confusión= 0,449			

Nota: 1: Sin vegetación, 2: Poca vegetación, 3: Vegetación media, y 4: Vegetación densa.

La proporción de áreas para la validación ( $n=378$ ) con puntos aleatorizados en el RVI 2015 (Tabla 14) fueron significativos para realizar mediciones sobre la estructura de la vegetación (Cohen 1960; Cohen et al. 2003; Yaghabi et al. 2019). La data fue analizada de acuerdo con el criterio de frecuencias. Se presentan los valores para la diagonal como opción de acuerdo e irrelevante para los demás valores.

Con un  $k = 0,335$ , vemos que menos de la mitad de los juicios conjuntos son acuerdos (excluyendo el azar) de los a datos RVI de Sentinel-1. Los marginales son tales que  $k_{Max}$  es 0,841 por lo que una parte sustancial de los desacuerdos es consecuencia de discrepancias marginales. La probabilidad de que  $x$  como valor poblacional se encuentre entre 0,275 y 0,396 es del 95%, con una fuerza de concordancia Aceptable (0,21-0,40) (Cohen 1960; Cohen et al. 2003) y una matriz de confusión de 0,449. El valor de  $z$  (14,276) es significativo a una probabilidad de  $(P)<0,001$  (Tabla 14), la cual mide la diferencia entre un parámetro hipotético de la población (unidades de desviación estándar) y un estadístico observado (Yaghabi et al. 2019; Koley y Chockalingam 2022).



Tabla 15. Matriz de confusión e Índice de kappa de datos aleatorizados frente a datos RVI Sentinel-1 del año 2022

Categoría		Datos de campo				
		1	2	3	4	$f_{RVI\ Sentinel-1}$
RVI Sentinel-1 (2022)	1	21(6)	1	1	0	23
	2	24	56(29)	18	18	116
	3	26	19	59(32)	22	126
	4	23	18	17	55(28)	113
	$f_{DC}$	94	94	95	95	378
$f_o=$	191		$f_c=$ 66,233			
$k=$	0,400		$k_M =$ 0,837			
$\sigma_k =$	0,031		$\sigma_{k_o} =$ 0,024			
$z=$	16,881		Matriz de confusión= 0,505			

Nota: 1: Sin vegetación, 2: Poca vegetación, 3: Vegetación media, y 4: Vegetación densa.

La proporción de áreas para la validación ( $n=378$ ) con datos de campo en el RVI 2022 (Tablas 15) fueron significativos para realizar mediciones sobre la estructura de la vegetación (Cohen 1960; Cohen et al. 2003; Yaghobi et al. 2019). La data fue analizada de acuerdo con el criterio de frecuencias. Se presentan los valores para la diagonal como opción de acuerdo e irrelevante para los demás valores.

Con un  $k = 0,400$ , vemos que menos de la mitad de los juicios conjuntos son acuerdos (excluyendo el azar) de los a datos RVI de Sentinel-1. Los marginales son tales que  $k_{Max}$  es 0,837 por lo que una parte sustancial de los desacuerdos es consecuencia de discrepancias marginales. La probabilidad de que  $x$  como valor poblacional se encuentre entre 0,339 y 0,461 es del 95%, con una fuerza de concordancia Aceptable (0,21-0,40) (Cohen 1960) y una matriz de confusión de 0,505. El valor de  $z$  (16,881) es significativo a una probabilidad de  $(P)<0,001$  (Tabla 14), la cual mide la diferencia entre un parámetro hipotético de la población (unidades de desviación estándar) y un estadístico observado (Yaghobi et al. 2019; Koley y Chockalingam 2022).

### **4.3 Correlación espacial**

La autocorrelación espacial es una medida de similitud entre el valor de una variable en una ubicación y los valores de la misma variable en una o más ubicaciones próximas. Una herramienta ampliamente utilizada para medir la autocorrelación espacial es el coeficiente de Moran (Moran 1948; Moran 1950). De acuerdo con esta perspectiva, una medida del grado de autocorrelación espacial puede funcionar como una medida de la dispersión espacial de la muestra.

Un candidato natural para medir el grado de autocorrelación espacial de una y dos variables es el popular método de I Moran Bivariante (Moran 1948; Moran 1950). Este índice tiene un rango finito y tiene un valor de referencia definido que distingue la autocorrelación espacial negativa y positiva.

#### **4.3.1 Año 2015**

Después de obtener los índices de datos multiespectrales se Sentinel-2 y de SAR de Sentinel-1 derivados en NDVI y RVI, calculamos la I de Moran Bivariante global y local. El valor de la I de Moran Bivariante global (Figura 24) es 0,068 con  $p = 0,00001$  y  $z = 25,79$ , donde  $p$  representa probabilidad y  $z$  representa tiempos de la desviación estándar (0,0026). El valor de I de Moran Bivariante implica una autocorrelación positiva (Figura 24, 25, y 26) (Tillé et al. 2018; Dai et al. 2022; Hankach et al. 2022). Encontramos que la mitad de las áreas no muestran un agrupamiento significativo; áreas grises en las figuras 25 y 26 como no significativo. La agrupación Alto-Alto se ve reflejada en la “Vegetación densa” y “Sin vegetación” (Tillé et al. 2018; Dai et al. 2022; Hankach et al. 2022).




Figura 24. I de Moran Bivariante 2015 de NDVI y RVI de imágenes Sentinel-2 y -1.




Figura 25. Significación espacial 2015 de NDVI y RVI de imágenes Sentinel-2 y -1.

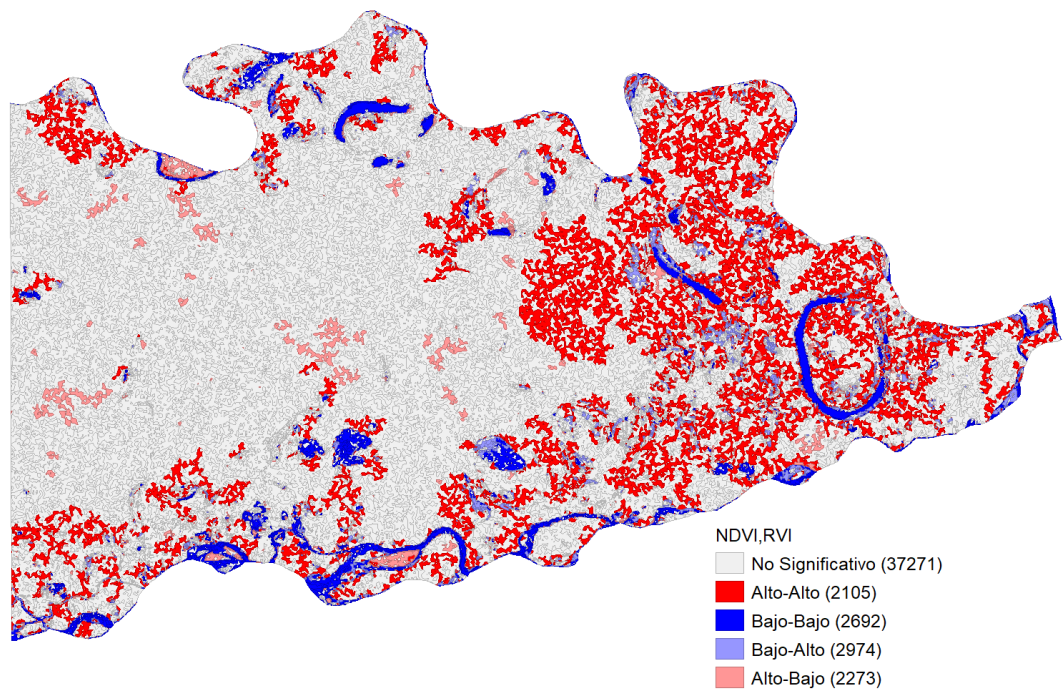


Figura 26. Patrón espacial 2015 de NDVI y RVI de imágenes Sentinel-2 y -1.

Se observa áreas “Sin vegetación” con presencia de agua y “Poca vegetación” con un agrupamiento Bajo-Bajo y Bajo-Alto. También encontramos valores atípicos Alto-Bajo de RVI con presencia de vegetación donde el estudio de campo encontró áreas sin vegetación concordante con el NDVI (Moran 1948; Moran 1950; Dai et al. 2022; Hankach et al. 2022). El análisis de I de Moran también muestra que las áreas altas de RVI están ubicadas zonas con algún tipo de vegetación, pero reduce la presencia de áreas sin vegetación (Figura 25 y 26). Estas zonas fueron afectadas por actividades antrópicas como las actividades forestales, agricultura, minería de oro, y la construcción de infraestructura, como lo muestran investigadores de la pérdida de bosques en la región Amazónica de Madre de Dios (Alarcón et al. 2016; Perz et al. 2016; Asner y Tupayachi 2017; Caballero et al. 2018; Alarcon et al. 2021).

#### 4.3.2 Periodo 2022

Después de obtener los índices de datos multiespectrales se Sentinel-2 y de SAR de Sentinel-1 derivados en NDVI y RVI, calculamos la I de Moran

Bivariante global y local. El valor de la I de Moran Bivariante global (Figura 27) es 0,121 con  $p = 0,00001$  y  $z = 57,57$ , donde  $p$  representa probabilidad y  $z$  representa tiempos de la desviación estándar (0,0021). El valor de I de Moran Bivariante implica una autocorrelación positiva (Figura 27, 28, y 29) (Tillé et al. 2018; Dai et al. 2022; Hankach et al. 2022). Encontramos que más de la mitad de las áreas no muestran un agrupamiento significativo; áreas grises en las figuras 28 y 29 como no significativo. La agrupación Alto-Alto se ve reflejada en la “Vegetación densa” y “Sin vegetación” (Tillé et al. 2018; Dai et al. 2022; Hankach et al. 2022).




Figura 27. I de Moran Bivariante 2022 de NDVI y RVI de imágenes Sentinel-2 y -1.



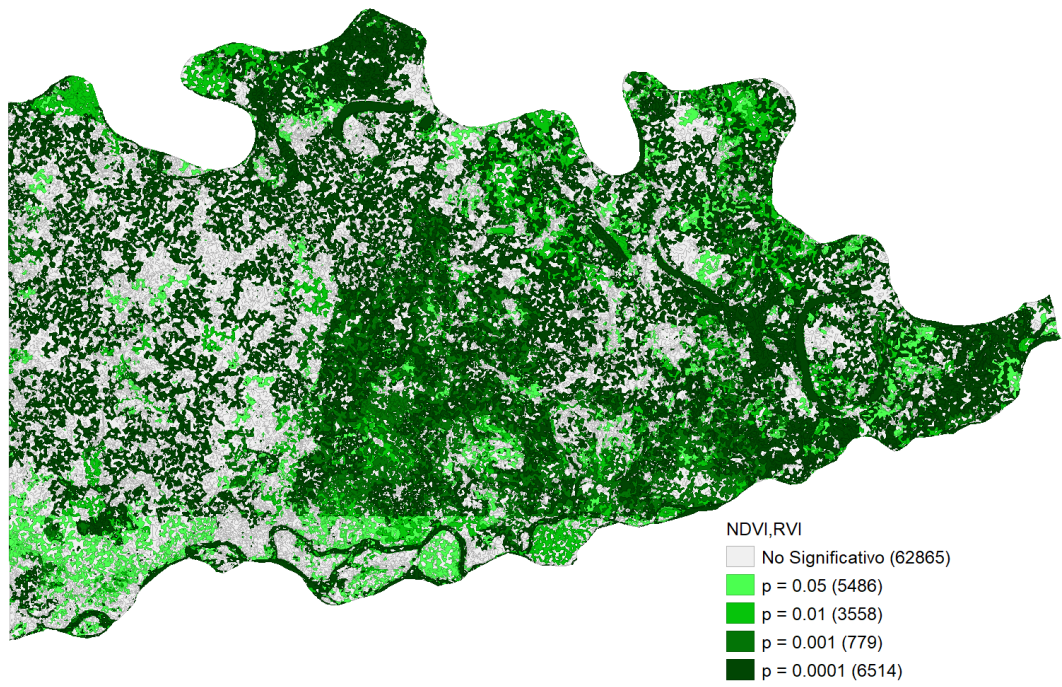


Figura 28. Significación espacial 2022 de NDVI y RVI de imágenes Sentinel-2 y -1.

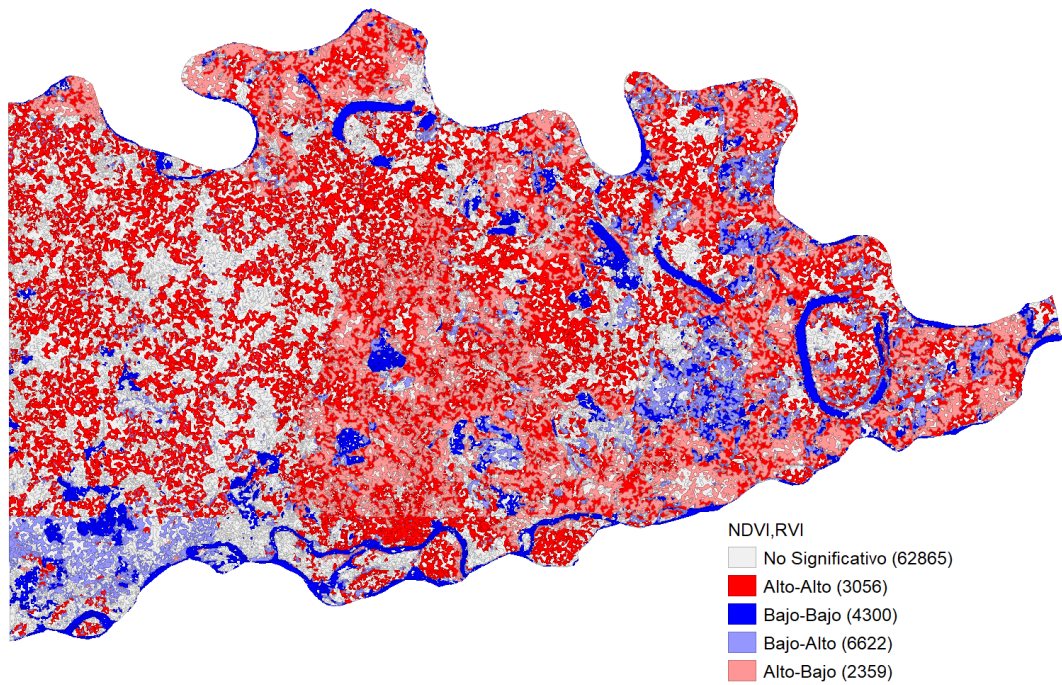


Figura 29. Patrón espacial 2022 de NDVI y RVI de imágenes Sentinel-2 y -1.

Se observa áreas “Sin vegetación” con presencia de agua y “Poca vegetación” con un agrupamiento Bajo-Bajo y Bajo-Alto. También encontramos valores atípicos Alto-Bajo de RVI con presencia de vegetación donde el estudio de campo encontró áreas sin vegetación concordante con el NDVI (Moran 1948; Moran 1950; Dai et al. 2022; Hankach et al. 2022). El análisis de I de Moran también muestra que las áreas altas de RVI están ubicadas zonas con algún tipo de vegetación, pero reduce la presencia de áreas sin vegetación (Figura 28 y 29). Estas zonas fueron afectadas por actividades antrópicas como las actividades forestales, agricultura, minería de oro, y la construcción de infraestructura, como lo muestran investigadores de la pérdida de bosques en la región Amazónica de Madre de Dios (Alarcón et al. 2016; Perz et al. 2016; Asner y Tupayachi 2017; Caballero et al. 2018; Alarcon et al. 2021).

El presente estudio comparó NDVI y RVI, y evaluó la autocorrelación entre ambos índices. Si bien los resultados muestran una autocorrelación Bivariante de I de Moran baja pero positiva (2015=0,068 y 2022=0,121), más de la mitad de las áreas no muestran un agrupamiento significativo (Moran 1948; Moran 1950; Ajadi et al. 2021; Bai et al. 2021). Asimismo, podemos observar que el RVI clasificó con mayor dimensión la vegetación densa en comparación con el NDVI (Kumar et al. 2013). Por otro lado, NDVI pudo identificar coberturas de vegetación más delgadas que el RVI. En el presente estudio, RVI tuvo menor precisión en la cuantificación de la cubierta con diferentes niveles de vegetación (Kumar et al. 2013; Holtgrave et al. 2020). La evaluación y comparación de los índices de vegetación usando imágenes satelitales Sentinel-1 y -2 en el sector de Lagarto, mostró que NDVI es muy eficiente en la cuantificación de áreas con vegetación, aun con las limitaciones que presenta (Kumar et al. 2013; Holtgrave et al. 2020). Sin embargo, también proporciona evidencias del potencial de RVI de Sentinel-1 para capturar coberturas con vegetación influenciadas por la humedad, que por efecto del doble rebote y la incidencia de la retrodispersión por la polarización cruzada VH identifica con mayor precisión respecto a NDVI (Kumar et al. 2013).

## **4.4 Cambios de cobertura**

### **4.4.1 Índice de vegetación de diferencia normalizada (NDVI)**

Los cambios de cobertura de la vegetación mediante monitoreo de NDVI de imágenes Sentinel-2 (Tabla 16) destacan un cambio gradual en la cobertura de la vegetación y sin vegetación. Áreas “Sin vegetación” del 2015 al 2022 aumentaron en 243,70%, mientras que área con vegetación disminuyó en -9,09%. De ello se puede deducir, que las áreas con vegetación; que áreas con “Poca vegetación” en el 2015 se incrementaron en 326,48% en el 2022, áreas con “Vegetación media” aumentaron en 967,81%, mientras que “Vegetación densa” disminuyó en -51,48%. A nivel general, el cambio de vegetación a sin vegetación es de 1 898,85 ha (2015-2022), a esto debe agregarse la persistencia de las categorías de áreas “Sin vegetación” (752,32 ha) y área con vegetación (10 673,17 ha); “Poca vegetación” representando el 1,16%, “Vegetación media” con el 1,92%, y “Vegetación densa” con el 96,92%.

La cartografía del monitoreo de la cobertura de la vegetación, confirmaron una tendencia creciente considerable en la dinámica de la pérdida de vegetación (Figura 31). La dinámica, ocasionó que las áreas “Sin vegetación” casi se triplicaran de 2015 hasta 2022, mientras que “Vegetación densa” se redujo a más de la mitad.

Los resultados de este estudio sobre cambios generales de NDVI en el sector de Lagarto (Figura 30), muestran un patrón de cambios ecológicos de la vegetación en la pérdida de cobertura y un incremento de áreas sin vegetación, situación que caracteriza a toda la región Amazónica de Madre de Dios (Alarcon et al. 2021). Sin embargo, aunque este estudio es coherente con las tendencias negativas del NDVI en las últimas décadas en la región, también reporta una correcta cuantificación de la vegetación por la actividad fotosintética o medida de verdor de la vegetación (Wang et al. 2019a).






Figura 30. Cambio de cobertura de la vegetación mediante NDVI 2015-2022.

Tabla 16. Cambio de cobertura de vegetación mediante NDVI de los años 2015-2022

Categoría	Año 2022						
	1	2	3	4	Total	Total <sub>1</sub>	
Año 2015	1	752,32	208,11	162,01	198,98	1321,43	22778,37
	2	154,25	123,42	141,14	172,02	590,83	
	3	181,71	151,21	205,18	283,49	821,60	
	4	2131,99	1446,18	7443,20	10344,57	21365,94	
	<b>Total</b>	<b>3220,27</b>	<b>1928,93</b>	<b>7951,54</b>	<b>10999,06</b>	<b>24099,79</b>	
	<b>Total<sub>1</sub></b>	<b>3220,27</b>	<b>20879,52</b>				

Nota: 1: Sin vegetación, 2: Poca vegetación, 3: Vegetación media, y 4: Vegetación densa.

La deforestación y degradación forestal en el sector de Lagarto en la región Amazónica de Madre de Dios está determinado por una serie de factores antropogénicos y efectos de las variaciones climatológicas que influyen en la desvitalización, marchitamiento y mortalidad de la vegetación (Alarcon et al. 2021; Velásquez et al. 2021; Alarcon-Aguirre et al. 2022). Algunos estudios en la Amazonia sobre los cambios en la vegetación confirman que las actividades extractivas (minería de oro) y productivas (agricultura y forestería) son los motores principales en generar el cambio en

la vegetación (Perz et al. 2016; Caballero et al. 2018; Alarcon et al. 2021; Garate-Quispe et al. 2021; Alarcon-Aguirre et al. 2022), lo que confirma las disminuciones de NDVI en las áreas afectadas del sector (Figura 30).

Sin embargo, debe considerarse que la medición del nivel de verdor, en este caso por el oscurecimiento en el área de evaluación por disminución de NDVI, no solo implica perturbaciones ecológicas simultáneas, sino también progresivas (Eckert et al. 2015; Bousbih et al. 2018; Olivares y López-Beltrán 2019; Wang et al. 2019b; Araújo-Flores et al. 2021). Por otro lado, la degradación (o mejora) de la vegetación o del suelo debe interpretarse con cautela, considerando los factores ambientales que pueden incidir de manera temporal con la presencia de áreas con vegetación estacional y que puede enmascarar una correcta cuantificación de la vegetación y disminuir la tendencia negativa de NDVI (Gonenc et al. 2019; Yaghobi et al. 2019; Yuliara et al. 2019; Holtgrave et al. 2020; Koley y Chockalingam 2022).

El análisis de cambios de la cobertura de la vegetación en el área de estudio mediante NDVI de sensores Sentinel-2 presenta una consistencia moderada, estos datos fueron verificados en la evaluación de la precisión del método, y por consiguiente muestra una medición ajustada a las diferentes categorías consideradas (“Sin vegetación”, “Poca vegetación”, “Vegetación media”, y “Vegetación densa”), hallazgos que son remarcados por investigadores como Filgueiras et al. (2019); Gonenc et al. (2019); Yaghobi et al. (2019); Holtgrave et al. (2020); (Koley y Chockalingam 2022) que compararon las bondades de índices espectrales de sensores ópticos y SAR. Sin embargo, también existe situaciones donde el RVI podría presentar mejor comportamiento respecto a NDVI, como lo manifiesta Yuliara et al. (2019) donde estudiaron la respuesta de un índice espectral de imágenes ópticas y SAR en la vegetación del distrito de Buleleng, Bali, concluyendo que índice espectral del modelo RVI fue el más adecuado para la estimación del área y la clase de distribución, ello podría deberse al buen comportamiento de la retrodispersión de las polarizaciones VV y VH de los SAR en zonas de bosques o vegetación con alta presencia de humedad (bosque de neblina).

#### 4.2.2 Índice de vegetación de radar (RVI)

Los cambios de cobertura de la vegetación mediante monitoreo de RVI de imágenes Sentinel-1 (Tabla 17) destacan un cambio gradual en la cobertura de la vegetación y sin vegetación. Áreas “Sin vegetación” del 2015 al 2022 aumentaron en 146,58%, mientras que área con vegetación disminuyó en -0,54%. De ello se puede deducir, que las áreas con vegetación; que áreas con “Poca vegetación” en el 2015 se incrementaron en 83,06% en el 2022, áreas con “Vegetación media” aumentaron en 88,061%, mientras que “Vegetación densa” disminuyó en -16,08%. A nivel general, el cambio de vegetación a sin vegetación es de 127,05 ha (2015-2022), a esto debe agregarse la persistencia de las categorías de áreas “Sin vegetación” (165,94 ha) y área con vegetación (11 784,21 ha); “Poca vegetación” representando el 1,16%, “Vegetación media” con el 1,92%, y “Vegetación densa” con el 96,92%.

La cartografía del monitoreo de la cobertura de la vegetación, confirman una tendencia creciente en la dinámica de la pérdida de vegetación (Figura 31). La dinámica, ocasionó que las áreas “Sin vegetación” aumentaran en casi 1,5 veces de 2015 hasta 2022, mientras que “Vegetación densa” se incrementó en un 16,08%.

Los resultados de este estudio sobre cambios generales de RVI en el sector de Lagarto (Figura 31), muestran un patrón de cambios ecológicos de la vegetación en la pérdida de cobertura pero en menor dimensión, a pesar de ello, los resultados cauterizan la dinámica de cambios en la vegetación en la región Amazónica de Madre de Dios (Alarcon et al. 2021). Por otro lado, aunque el estudio es coherente con las tendencias negativas de RVI en las últimas décadas en la región, también debemos precisar una sobreestimación en la cuantificación de la vegetación y subestimación de áreas sin vegetación, como respuesta a las polarizaciones VV y VH del SAR S1, detectando más eficientemente las medidas de dispersión volumétrica por doble rebote (Gonenc et al. 2019; Wang et al. 2019b; Yaghobi et al. 2019; Yuliara et al. 2019).

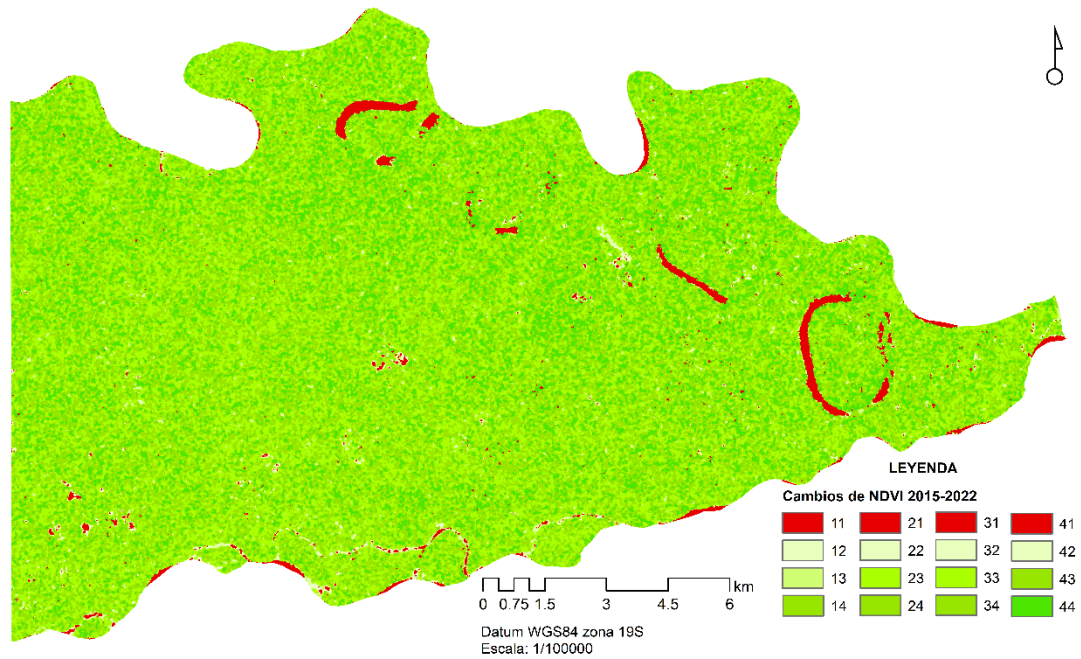


Figura 31. Cambio de cobertura de la vegetación mediante RVI 2015-2022.

Tabla 17. Cambio de cobertura de vegetación mediante RVI de los años 2015-2022

Categoría	Año 2022						
	1	2	3	4	Total	Total <sub>1</sub>	
Año 2015	1	165,94	15,85	44,68	46,32	<b>272,79</b>	<b>272,79</b>
	2	18,92	23,57	204,16	157,68	<b>404,34</b>	
	3	118,26	186,83	6981,10	6362,22	<b>13648,40</b>	
	4	96,73	109,58	4788,41	4779,54	<b>9774,25</b>	
	<b>Total</b>	<b>399,84</b>	<b>335,84</b>	<b>12018,35</b>	<b>11345,76</b>	<b>24099,79</b>	
	<b>Total<sub>1</sub></b>	<b>399,84</b>	<b>23699,94</b>				

Nota: 1: Sin vegetación, 2: Poca vegetación, 3: Vegetación media, y 4: Vegetación densa.

La deforestación y degradación forestal en el sector de Lagarto en la región Amazónica de Madre de Dios está determinado por una serie de factores antropogénicos y efectos de las variaciones climatológicas que influyen en la desvitalización, marchitamiento y mortalidad de la vegetación (Alarcon et al. 2021; Velásquez et al. 2021; Alarcon-Aguirre et al. 2022). Algunos estudios en la Amazonia sobre los cambios en la vegetación confirman que las actividades extractivas (minería de oro) y productivas (agricultura y forestería) son los motores principales en generar el cambio en

la vegetación (Perz et al. 2016; Caballero et al. 2018; Alarcon et al. 2021; Garate-Quispe et al. 2021; Alarcon-Aguirre et al. 2022), lo que confirma las disminuciones de RVI en las áreas afectadas del sector (Figura 31).

Sin embargo, debe considerarse que la medición de la dispersión volumétrica por doble rebote, en este caso áreas por aumento de RVI, no solo implica perturbaciones ecológicas simultaneas, sino también progresivas (Eckert et al. 2015; Bousbih et al. 2018; Olivares y López-Beltrán 2019; Wang et al. 2019b; Araújo-Flores et al. 2021). Por otro lado, la degradación (o mejora) de la vegetación o del suelo debe interpretarse con cautela, considerando los factores ambientales que pueden incidir de manera temporal con la presencia de áreas con vegetación estacional y que puede enmascarar una correcta cuantificación de la vegetación y disminuir la tendencia negativa de RVI por la respuesta de la retrodispersión de la polarizaciones VV y VH (Yaghoobi et al. 2019; Yuliara et al. 2019; Koley y Chockalingam 2022).

El análisis de cambios de la cobertura de la vegetación en el área de estudio mediante RVI del sensor Sentinel-1 presenta una consistencia aceptable, estos datos fueron verificados en la evaluación de la precisión del método, y por consiguiente muestra una medición ajustada a áreas sin vegetación y una sobredimensión a las diferentes categorías de áreas con vegetación (“Poca vegetación”, “Vegetación media”, y “Vegetación densa”), hallazgos que son remarcados por investigadores como Kumar et al. (2013); Veloso et al. (2017); (Mandal et al. 2020) que compararon las bondades de índices espectrales de sensores ópticos y SAR. Por otra parte, Yuliara et al. (2019) en su estudio de la vegetación del distrito de Buleleng, Bali mostraron que la respuesta espectral de RVI presento un mejor comportamiento respecto a NDVI, la estimación del área y la clase de distribución mediante polarizaciones VV y VH midieron eficientemente zonas de bosques o vegetación con alta presencia de humedad (bosque de neblina). Situación inversa con el área de estudio, que no contrasta completamente debido a la presencia de diferentes tipos de formaciones de bosque, muchos de ellos con mayor o menor interacción con recursos hídricos o humedad, generando una sobredimensionaron de la vegetación y subestimación de áreas sin

vegetación, hallazgos que coinciden por estudios realizados por Filgueiras et al. (2019); Gonenc et al. (2019); Yaghobi et al. (2019); Yuliara et al. (2019) Holtgrave et al. (2020); Koley y Chockalingam (2022).

## CONCLUSIONES

En este estudio, se utilizó datos temporales de RVI de Sentinel-1 y NDVI de Sentinel-2 (2015-2022) en el monitoreo de la vegetación en el sector de Lagarto, provincia de Tambopata – Madre de Dios. El estudio concluye lo siguiente:

El NDVI se utilizó para monitorear la vegetación considerando la actividad fotosintética y verdor de la vegetación, considerando en la evaluación las limitaciones de los sensores ópticos (Sentinel-2) por los factores ambientales intervinientes en la Amazonia. El NDVI para 2015 reporto 22 784,36 ha para áreas con vegetación y 1 315,43 ha para áreas sin vegetación. Mientras que el NDVI para 2022 muestro 20 877,67 ha para áreas con vegetación y 3 222,13 ha para áreas sin vegetación.

Mientras que el RVI se utilizó para monitorear la vegetación mediante la estimación del área y la clase de distribución (en cualquier temporada del año) debido a la capacidad de los SAR y la minimización de los factores ambientales en la captura de información. El RVI para 2015 reporto 23 827,59 ha para áreas con vegetación y 272,20 ha para áreas sin vegetación. Mientras que el RVI para 2022 muestro 23 702,47 ha para áreas con vegetación y 397,31 ha para áreas sin vegetación. A pesar de las limitaciones del NDVI por la saturación de valores en los extremos (suelo desnudo y vegetación densa), el RVI no puede reemplazar al NDVI, debido a que no cuenta con la capacidad para representar la actividad fotosintética o de verdor como el NDVI. Sin embargo, el RVI se pude usar para enmascarar la vegetación para monitorear la humedad del suelo por la alta sensibilidad de las polarizaciones de VV y VH a la humedad del suelo debido a la vegetación.

La evaluación de precisión de la cuantificación de los tipos de vegetación de NDVI para 2015 y 2022 determinó una concordancia moderada y considerable, mientras que RVI para 2015 y 2022 una concordancia aceptable.

La correlación espacial de los índices de datos multiespectrales se Sentinel-2 y de SAR de Sentinel-1 derivados en NDVI y RVI 2015 mediante la

I de Moran Bivariante fue una autocorrelación positiva baja de 0,068 con  $p = 0,00001$  y  $z = 25,79$ . Para NDVI y RVI 2022 presentó una autocorrelación positiva baja de 0,21 con  $p = 0,00001$  y  $z = 57,57$ .

Los cambios de cobertura de la vegetación mediante monitoreo de NDVI de imágenes Sentinel-2 destacan un cambio gradual en la cobertura de la vegetación y sin vegetación. Áreas “Sin vegetación” del 2015 al 2022 aumentaron en 243,70 %, mientras que área con vegetación disminuyó en -9,09 %.

La vegetación monitoreada mediante RVI de imágenes Sentinel-1 destacan un cambio gradual en la cobertura de la vegetación y sin vegetación. Áreas “Sin vegetación” del 2015 al 2022 aumentaron en 146,58%, mientras que área con vegetación disminuyó en -0,54%.

Se rechaza la hipótesis nula sobre: 1) La detección del cambio de la cobertura vegetal a otros usos mediante la reflexión óptica Sentinel-2 (NDVI) y la retrodispersión SAR Sentinel-1 (RVI) de la cobertura vegetal en un área de intervención antropogénica en el sector de Lagarto, no sigue una tendencia creciente., 2) La correlación espacial entre la reflexión óptica Sentinel-2 y la retrodispersión SAR Sentinel-1 de la dinámica de la vegetación en un área de intervención antropogénica en el sector de Lagarto es negativo. Debido a que en ambos índices la tendencia de la pérdida de vegetación sigue una tendencia creciente y presenta una autocorrelación positiva, pero baja. Asimismo, los hallazgos ayudan a comprender la dinámica de los procesos de conversión de bosque a otros usos en la Amazonia.



## **SUGERENCIAS**

Los avances tecnológicos en el monitoreo de la vegetación en la Amazonia mediante datos de satélite ópticos y SAR han permitido el desarrollo de técnicas de medición con mayor precisión, sin embargo, es necesario seguir estudiando y calibrando los diferentes algoritmos de detección y cuantificación de la vegetación.

Se requieren estudios adicionales para derivar parámetros biofísicos de RVI y su aplicación en la estimación de la vegetación con presencia de humedad.

## REFERENCIAS BIBLIOGRÁFICAS

AJADI, O. A., BARR, J., LIANG, S.-Z., FERREIRA, R., KUMPATLA, S. P., PATEL, R. Y SWATANTRAN, A. Large-scale crop type and crop area mapping across Brazil using synthetic aperture radar and optical imagery. *International Journal of Applied Earth Observation and Geoinformation*, 2021/05/01/ 2021, 97, 102294. doi:<https://doi.org/10.1016/j.jag.2020.102294>

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

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., DIAZ-REVOREDO, J. L. Y BARRIGA-PAREDES, V. Á. M. Dinámica de la pérdida de bosques en el sureste de la Amazonia peruana 2021/4/5 2021, 1(1). doi:<http://hdl.handle.net/20.500.14070/661>

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>

AMAZIRH, A., MERLIN, O., ER-RAKI, S., GAO, Q., RIVALLAND, V., MALBETEAU, Y., KHABBA, S. Y ESCORIHUELA, M. J. Retrieving surface soil moisture at high spatio-temporal resolution from a synergy between Sentinel-1 radar and Landsat thermal data: A study case over bare soil. *Remote Sensing of Environment*, 2018/06/15/ 2018, 211, 321-337. doi:<https://doi.org/10.1016/j.rse.2018.04.013>

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.

ARAÚJO-FLORES, J. M., GARATE-QUISPE, J., GARCÍA MOLINOS, J., PILLACA-ORTIZ, J. M., CABALLERO-ESPEJO, J., ASCORRA, C., SILMAN, M. Y FERNANDEZ, L. E. Seasonality and aquatic metacommunity assemblage in three abandoned gold mining ponds in the southwestern Amazon, Madre de Dios (Peru). *Ecological Indicators*, 2021/06/01/ 2021, 125, 107455. doi:<https://doi.org/10.1016/j.ecolind.2021.107455>

ASNER, G. P., LLACTAYO, W., TUPAYACHI, R. Y LUNA, E. R. Elevated rates of gold mining in the Amazon revealed through high-resolution monitoring. *Proceedings of the National Academy of Sciences*, 2013, 110(46), 18454-18459. doi:10.1186/1750-0680-8-7

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

BAGHDADI, N. Y ZRIBI, M. Introduction. In N. BAGHDADI Y M. ZRIBI eds. *Optical Remote Sensing of Land Surface*. Elsevier, 2016, p. xxxix-xlii.

BAI, Y., SUN, G., LI, Y., MA, P., LI, G. Y ZHANG, Y. Comprehensively analyzing optical and polarimetric SAR features for land-use/land-cover classification and urban vegetation extraction in highly-dense urban area.

International Journal of Applied Earth Observation and Geoinformation, 2021/12/01/ 2021, 103, 102496. doi:<https://doi.org/10.1016/j.jag.2021.102496>

BAJGAIN, R., XIAO, X., WAGLE, P., BASARA, J. Y ZHOU, Y. Sensitivity analysis of vegetation indices to drought over two tallgrass prairie sites. ISPRS Journal of Photogrammetry and Remote Sensing, 2015/10/01/ 2015, 108, 151-160. doi:<https://doi.org/10.1016/j.isprsjprs.2015.07.004>

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

BETBEDER, J., FIEUZAL, R. Y BAUP, F. Assimilation of LAI and dry biomass data from optical and SAR images into an agro-meteorological model to estimate soybean yield. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2016, 9(6), 2540-2553.

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.

BOUSBIH, S., ZRIBI, M., MOUGENOT, B., FANISE, P., LILI-CHABAANE, Z. Y BAGHDADI, N. Monitoring of surface soil moisture based on optical and radar data over agricultural fields. In.: IEEE, 2018, p. 1-5.

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

BRICEÑO, N. B. R., CASTILLO, E. B., QUINTANA, J. L. M., CRUZ, S. M. O. Y LÓPEZ, R. S. Deforestación en la Amazonía peruana: índices de cambios de cobertura y uso del suelo basado en SIG. Boletín de la Asociación de Geógrafos Españoles, 2019, (81).

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.

CARRANZA, C., BENNINGA, H.-J., VAN DER VELDE, R. Y VAN DER PLOEG, M. Monitoring agricultural field trafficability using Sentinel-1. Agricultural Water Management, 2019/09/01/ 2019, 224, 105698. doi:<https://doi.org/10.1016/j.agwat.2019.105698>

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>

CHARBONNEAU, F., TRUDEL, M. Y FERNANDES, R. Use of Dual Polarization and Multi-Incidence SAR for soil permeability mapping. In., 2005, p. 15-17.

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, 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](http://www.ign.es/PNT/pdf/especificacionestecnicas-pnt-medar-landsat_v2-2010.pdf), 2010.

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.

DAI, X., FENG, H., XIAO, L., ZHOU, J., WANG, Z., ZHANG, J., FU, T., SHAN, Y., YANG, X., YE, Y., XU, L., JIANG, X., FANG, S. Y YAO, Y. Ecological vulnerability assessment of a China's representative mining city based on hyperspectral remote sensing. *Ecological Indicators*, 2022/12/01/ 2022, 145, 109663. doi:<https://doi.org/10.1016/j.ecolind.2022.109663>

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. Impactos socioambientales probables de la carretera transoceánica (Río Branco-Puerto Maldonado-Ilo) y la capacidad de respuesta del Perú. *Boletín CF+ S*, 2014a, (19).

DOUROJEANNI, M. Ocupación humana y áreas protegidas de la Amazonia del Perú. *Ecología Aplicada*, 2014b, 13(2), 225-232.

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

DOUROJEANNI, M., BARANDIARÁN, A. Y DOUROJEANNI, D. *Amazonía peruana en 2021. Explotación de recursos naturales e infraestructura: ¿ Qué está pasando? ¿ Qué es lo que significa para el futuro?* Edtion ed.: Sociedad Peruana de Derecho Ambiental-SPDA, 2009. ISBN 6124569701.

ECKERT, S., HÜSLER, F., LINIGER, H. Y HODEL, E. Trend analysis of MODIS NDVI time series for detecting land degradation and regeneration in Mongolia. *Journal of Arid Environments*, 2015/02/01/ 2015, 113, 16-28. doi:<https://doi.org/10.1016/j.jaridenv.2014.09.001>

ELIAS, F., FERREIRA, J., LENNOX, G. D., BERENGUER, 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](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.

FARR, T. G., ROSEN, P. A., CARO, E., CRIPPEN, R., DUREN, R., HENSLEY, S., KOBRICK, M., PALLER, M., RODRIGUEZ, E., ROTH, L., SEAL, D., SHAFFER, S., SHIMADA, J., UMLAND, J., WERNER, M., OSKIN, M., BURBANK, D. Y ALSDORF, D. The Shuttle Radar Topography Mission. *Reviews of Geophysics*, 2007, 45(2). doi:10.1029/2005rg000183

FERN, R. R., FOXLEY, E. A., BRUNO, A. Y MORRISON, M. L. Suitability of NDVI and OSAVI as estimators of green biomass and coverage in a semi-arid rangeland. *Ecological Indicators*, 2018/11/01/ 2018, 94, 16-21. doi:<https://doi.org/10.1016/j.ecolind.2018.06.029>

FILGUEIRAS, R., MANTOVANI, E. C., ALTHOFF, D., FERNANDES FILHO, E. I. Y CUNHA, F. F. D. Crop NDVI monitoring based on sentinel 1. *Remote Sensing*, 2019, 11(12), 1441.

FRAMPTON, W. J., DASH, J., WATMOUGH, G. Y MILTON, E. J. Evaluating the capabilities of Sentinel-2 for quantitative estimation of biophysical variables in vegetation. *ISPRS Journal of Photogrammetry and Remote Sensing*,



2013/08/01/ 2013, 82, 83-92.  
doi:<https://doi.org/10.1016/j.isprsjprs.2013.04.007>

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.

GONENC, A., OZERDEM, M. S. Y EMRULLAH, A. Comparison of NDVI and RVI vegetation indices using satellite images. In.: IEEE, 2019, p. 1-4.

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. In G.D.R.N.Y.M. AMBIENTE. Madre de Dios - Perú, 2009, p. 208.

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

HANDBOOK, T. D. A. The Data Analysis Handbook. In I.E. FRANK Y R. TODESCHINI eds. *Data Handling in Science and Technology*. Elsevier, 1994, vol. 14, p. 1-352.

HANKACH, P., GASTINEAU, P. Y VANDANJON, P.-O. Multi-scale spatial analysis of household car ownership using distance-based Moran's eigenvector maps: Case study in Loire-Atlantique (France). *Journal of Transport Geography*, 2022/01/01/ 2022, 98, 103223. doi:<https://doi.org/10.1016/j.jtrangeo.2021.103223>

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, 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

HOSSEINI, M., MCNAIRN, H., MITCHELL, S., DINGLE ROBERTSON, L., DAVIDSON, A. Y HOMAYOUNI, S. Synthetic aperture radar and optical satellite data for estimating the biomass of corn. *International Journal of Applied Earth Observation and Geoinformation*, 2019/11/01/ 2019, 83, 101933. doi:<https://doi.org/10.1016/j.jag.2019.101933>

HU, P., SHARIFI, A., TAHIR, M. N., TARIQ, A., ZHANG, L., MUMTAZ, F. Y SHAH, S. H. Evaluation of Vegetation Indices and Phenological Metrics Using Time-Series MODIS Data for Monitoring Vegetation Change in Punjab, Pakistan. *Water* [Type of Work]. 2021, vol. 13, no. 18. ISSN 2073-4441. doi:10.3390/w13182550.

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.

IGLESIAS, M. E. *Metodología de la investigación científica: diseño y elaboración de protocolos y proyectos*. Edtion ed.: Noveduc, 2021. ISBN 987538464X.

INEI, I. N. D. E. E. I.-. *Magnitud y Crecimiento Poblacional*. 2017.

INRENA, I. N. D. R. N., SZF, S. Z. D. F. Y CDC-UNALM, C. D. D. P. L. C. *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.

JENSEN, J. R. *Remote sensing of the environment: An earth resource perspective 2/e*. Edtion 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>

JIA, G. J., BURKE, I. C., GOETZ, A. F., KAUFMANN, M. R. Y KINDEL, B. C. Assessing spatial patterns of forest fuel using AVIRIS data. *Remote Sensing of Environment*, 2006, 102(3), 318-327.

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.

JORDAN, C. F. Derivation of Leaf-Area Index from Quality of Light on the Forest Floor. *Ecology*, 1969/07/01 1969, 50(4), 663-666. doi:<https://doi.org/10.2307/1936256>

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.

KIM, Y. Y VAN ZYL, J. J. A time-series approach to estimate soil moisture using polarimetric radar data. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 47(8), 2519-2527.

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>

KRIEGLER, F. J., MALILA, W. A., NALEPKA, R. F. Y RICHARDSON, W. Preprocessing Transformations and Their Effects on Multispectral Recognition. In., 1969, p. 97.

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

KUMAR, D., RAO, S. Y SHARMA, J. R. Radar Vegetation Index as an alternative to NDVI for monitoring of soyabean and cotton. In., 2013, p. 19-21.

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>

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, 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>

LIU, C.-A., CHEN, Z.-X., SHAO, Y., CHEN, J.-S., HASI, T. Y PAN, H.-Z. Research advances of SAR remote sensing for agriculture applications: A review. *Journal of Integrative Agriculture*, 2019/03/01/ 2019, 18(3), 506-525.  
doi:[https://doi.org/10.1016/S2095-3119\(18\)62016-7](https://doi.org/10.1016/S2095-3119(18)62016-7)

LUND, H. G. *Definitions of forest, deforestation, afforestation, and reforestation*. Edtion ed.: Forest Information Services Gainesville, VA, 2006.

MADONSELA, S., CHO, M. A., RAMOELO, A. Y MUTANGA, O. Remote sensing of species diversity using Landsat 8 spectral variables. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2017/11/01/ 2017, 133, 116-127.  
doi:<https://doi.org/10.1016/j.isprsjprs.2017.10.008>

MAMANI, E. M. Políticas de protección para los pueblos indígenas en situación de aislamiento: el caso de los mashco piro de Madre de Dios 2021.  
doi:<http://repositorio.unap.edu.pe/handle/UNAP/15661>

MANDAL, D., KUMAR, V., RATHA, D., DEY, S., BHATTACHARYA, A., LOPEZ-SANCHEZ, J. M., MCNAIRN, H. Y RAO, Y. S. Dual polarimetric radar

vegetation index for crop growth monitoring using sentinel-1 SAR data. *Remote Sensing of Environment*, 2020/09/15/ 2020, 247, 111954. doi:<https://doi.org/10.1016/j.rse.2020.111954>

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.

MARTINS, W. B. R., RODRIGUES, J. I. D. M., DE OLIVEIRA, V. P., RIBEIRO, S. S., BARROS, W. D. S. Y SCHWARTZ, G. Mining in the Amazon: Importance, impacts, and challenges to restore degraded ecosystems. Are we on the right way? *Ecological Engineering*, 2022/01/01/ 2022, 174, 106468. doi:<https://doi.org/10.1016/j.ecoleng.2021.106468>

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.

MEYER, F. J., MCALPIN, D. B., GONG, W., AJADI, O., ARKO, S., WEBLEY, P. W. Y DEHN, J. Integrating SAR and derived products into operational volcano monitoring and decision support systems. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2015, 100, 106-117.

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.

MOHAMMADI-GHAZI, R., WELSCH, R. E. Y BÜYÜKÖZTÜRK, O. Kernel dependence analysis and graph structure morphing for novelty detection with high-dimensional small size data set. *Mechanical Systems and Signal Processing*, 2020/09/01/ 2020, 143, 106775. doi:<https://doi.org/10.1016/j.ymssp.2020.106775>

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.

MORAN, P. A. P. The interpretation of statistical maps. *Journal of the Royal Statistical Society. Series B (Methodological)*, 1948, 10(2), 243-251.

MORAN, P. A. P. Notes on continuous stochastic phenomena. *Biometrika*, 1950, 37(1/2), 17-23. doi:<https://doi.org/10.2307/2332142>

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

MYERS, N., MITTERMEIER, R. A., MITTERMEIER, C. G., DA FONSECA, G. A. B. Y KENT, J. Biodiversity hotspots for conservation priorities. *Nature*, 2000, 403(6772), 853-858. doi:<https://doi.org/10.1038/35002501>

NAIKOO, M. W., ISLAM, A. R. M. T., MALLICK, J. Y RAHMAN, A. Land use/land cover change and its impact on surface urban heat island and urban thermal comfort in a metropolitan city. *Urban Climate*, 2022, 41, 101052.

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

NASIRZADEHDIZAJI, R., BALIK SANLI, F., ABDIKAN, S., CAKIR, Z., SEKERTEKIN, A. Y USTUNER, M. Sensitivity analysis of multi-temporal

Sentinel-1 SAR parameters to crop height and canopy coverage. *Applied Sciences*, 2019, 9(4), 655.

NAVARRO, J. A., ALGEET, N., FERNÁNDEZ-LANDA, A., ESTEBAN, J., RODRÍGUEZ-NORIEGA, P. Y GUILLÉN-CLIMENT, M. L. Integration of UAV, Sentinel-1, and Sentinel-2 data for mangrove plantation aboveground biomass monitoring in Senegal. *Remote Sensing*, 2019, 11(1), 77.

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.

PÉREZ, S. Caracterización Basada en Imagen de la Función de Transferencia de Modulación de Instrumentos Ópticos para Teledetección. Universitat Politècnica de València, 2020.



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>

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

PRABHAKARA, K., HIVELEY, W. D. Y MCCARTY, G. W. Evaluating the relationship between biomass, percent groundcover and remote sensing indices across six winter cover crop fields in Maryland, United States. *International Journal of Applied Earth Observation and Geoinformation*, 2015/07/01/ 2015, 39, 88-102. doi:<https://doi.org/10.1016/j.jag.2015.03.002>

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>

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>

RANGEL-CH, J. O. Y VELÁZQUEZ, A. Métodos de estudio de la vegetación. Colombia diversidad biótica II. Tipos de vegetación en Colombia, 1997, 59-82.

REICHE, J., SOUZA, C. M., HOEKMAN, D. H., VERBESSELT, J., PERSAUD, H. Y HEROLD, M. Feature level fusion of multi-temporal ALOS PALSAR and Landsat data for mapping and monitoring of tropical deforestation and forest degradation. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2013, 6(5), 2159-2173.

REICHE, J., VERBESSELT, J., HOEKMAN, D. Y HEROLD, M. Fusing Landsat and SAR time series to detect deforestation in the tropics. *Remote Sensing of Environment*, 2015, 156, 276-293. doi:<https://doi.org/10.1016/j.rse.2014.10.001>

REIS, M. S., DUTRA, L. V., SANT'ANNA, S. J. S. Y ESCADA, M. I. S. Multi-source change detection with PALSAR data in the Southern of Pará state in the Brazilian Amazon. *International Journal of Applied Earth Observation and Geoinformation*, 2020, 84, 777-780.

ROUSE JR, J. W., HAAS, R. H., SCHELL, J. A. Y DEERING, D. W. Paper a 20. In.: Scientific and Technical Information Office, National Aeronautics and Space ..., 1973, vol. 1, p. 309.

ROUSE, J. W., HAAS, R. H., SCHELL, J. A. Y DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. NASA special publication, 1974, 351(1974), 309.

ROY, D. P., WULDER, M. A., LOVELAND, T. R., C.E, W., ALLEN, R. G., ANDERSON, M. C., HELDER, D., IRONS, J. R., JOHNSON, D. M., KENNEDY, R., SCAMBOS, T. A., SCHAAF, C. B., SCHOTT, J. R., SHENG, Y., VERMOTE, E. F., BELWARD, A. S., BINDSCHADLER, R., COHEN, W. B., GAO, F., HIPPLE, J. D., HOSTERT, P., HUNTINGTON, J., JUSTICE, C. O., KILIC, A., KOVALSKYY, V., LEE, Z. P., LYMBURNER, L., MASEK, J. G., MCCORKEL, J., SHUAI, Y., TREZZA, R., VOGELMANN, J., WYNNE, R. H. Y ZHU, Z. Landsat-8: Science and product vision for terrestrial global change research. *Remote Sensing of Environment*, 2014/04/05/ 2014, 145, 154-172. doi:<https://doi.org/10.1016/j.rse.2014.02.001>

SABINS JR, F. F. *Remote sensing--principles and interpretation*. Edition ed.: WH Freeman and company, 1987.

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*. Edition ed.: Esri, 2000. ISBN 1879102978.

SICA, F., PULELLA, A., NANNINI, M., PINHEIRO, M. Y RIZZOLI, P. Repeat-pass SAR interferometry for land cover classification: A methodology using Sentinel-1 Short-Time-Series. *Remote Sensing of Environment*, 2019, 232, 111-277.

SORIANO MARTINEZ, P. C. El proceso constitucional de la comunidad nativa Tres Islas y sus implicancias respecto a los derechos de los pueblos indígenas en el Perú 2022.

SOUTHWORTH, J., MARSIK, M., QIU, Y., PERZ, S., CUMMING, G., STEVENS, F., ROCHA, K., DUCHELLE, A. Y BARNES, G. Roads as Drivers of Change: Trajectories across the Tri-National Frontier in MAP, the Southwestern Amazon. *Remote Sensing*, 2011, 3(5), 1047-1066. doi:<https://doi.org/10.3390/rs3051047>

STEFANSKI, J., KUEMMERLE, T., CHASKOVSKYY, O., GRIFFITHS, P., HAVRYLUK, V., KNORN, J., KOROL, N., SIEBER, A. Y WASKE, B. Mapping land management regimes in western Ukraine using optical and SAR data. *Remote Sensing*, 2014, 6(6), 5279-5305.

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>

TILLÉ, Y., DICKSON, M. M., ESPA, G. Y GIULIANI, D. Measuring the spatial balance of a sample: A new measure based on Moran's I index. *Spatial Statistics*, 2018/03/01/ 2018, 23, 182-192. doi:<https://doi.org/10.1016/j.spasta.2018.02.001>

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>

TRUDEL, M., CHARBONNEAU, F. Y LECONTE, R. Using RADARSAT-2 polarimetric and ENVISAT-ASAR dual-polarization data for estimating soil

moisture over agricultural fields. *Canadian Journal of Remote Sensing*, 2012, 38(4), 514-527. doi:10.5589/m12-043

TURNER, B. L., SKOLE, D., SANDERSON, S., FISCHER, G., FRESCO, L. Y LEEMANS, R. Land-use and land-cover change: science/research plan. [No source information available], 1995.

VAN DUIJVENBODE, J. D., REICHE, J. Y FORSTREUTER, W. Forest stratification in Fiji using high resolution satellite imagery 2014.

VARGHESE, D., RADULOVIĆ, M., STOJKOVIĆ, S. Y CRNOJEVIĆ, V. Reviewing the potential of sentinel-2 in assessing the drought. *Remote Sensing*, 2021, 13(17), 3355. doi:<https://doi.org/10.3390/rs13173355>

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>

VELOSO, A., MERMOZ, S., BOUVET, A., LE TOAN, T., PLANELLS, M., DEJOUX, J.-F. Y CESCHIA, E. Understanding the temporal behavior of crops using Sentinel-1 and Sentinel-2-like data for agricultural applications. *Remote Sensing of Environment*, 2017, 199, 415-426. doi:<https://doi.org/10.1016/j.rse.2017.07.015>

VERSTRAETE, M. M., PINTY, B. Y MYNENI, R. B. Potential and limitations of information extraction on the terrestrial biosphere from satellite remote sensing. *Remote Sensing of Environment*, 1996/11/01/ 1996, 58(2), 201-214. doi:[https://doi.org/10.1016/S0034-4257\(96\)00069-7](https://doi.org/10.1016/S0034-4257(96)00069-7)

WANG, J., XIAO, X., BAJGAIN, R., STARKS, P., STEINER, J., DOUGHTY, R. B. Y CHANG, Q. Estimating leaf area index and aboveground biomass of grazing pastures using Sentinel-1, Sentinel-2 and Landsat images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2019/08/01/ 2019a, 154, 189-201. doi:<https://doi.org/10.1016/j.isprsjprs.2019.06.007>

WANG, Y., ZIV, G., ADAMI, M., MITCHARD, E., BATTERMAN, S. A., BUERMANN, W., SCHWANTES MARIMON, B., MARIMON JUNIOR, B. H., MATIAS REIS, S., RODRIGUES, D. Y GALBRAITH, D. Mapping tropical disturbed forests using multi-decadal 30 m optical satellite imagery. *Remote Sensing of Environment*, 2019/02/01/ 2019b, 221, 474-488. doi:<https://doi.org/10.1016/j.rse.2018.11.028>

WILLIAMS, D. L., GOWARD, S. Y ARVIDSON, T. Landsat. *Photogrammetric Engineering & Remote Sensing*, 2006, 72(10), 1171-1178.

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

YULIARA, I. M., RATINI, N. N. Y KASMAWAN, I. G. A. Comparative Study on NDVI with RVI for Estimated Area and Class Distribution. *International Journal of Physical Sciences and Engineering*, 2019, 3(2), 12-20. doi:<https://doi.org/10.29332/ijpse.v3n2.310>

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: monitoreo de la vegetación mediante índices de radar de apertura sintética (SAR) Sentinel-1 y óptica Sentinel-2 en el sector de Lagarto, provincia de Tambopata – Madre de Dios.

PROBLEMA GENERAL	OBJETIVO GENERAL	HIPOTESIS GENERAL	VARIABLES/INDICADORES	METODOLOGÍA
¿Cuál serán los cambios y la relación entre la reflexión óptica Sentinel-2 y la retrodispersión SAR Sentinel-1 de la cobertura vegetal en un área de intervención antropogénica en el sector de Lagarto entre los periodos 2015 y 2022?	Monitorear la relación entre la reflexión óptica Sentinel-2 y la retrodispersión SAR Sentinel-1 de los cambios de la vegetación en un área de intervención antropogénica en el sector de Lagarto entre los periodos 2015 y 2022.	La detección del cambio de la cobertura vegetal a otros usos mediante la reflexión óptica Sentinel-2 (NDVI) y la retrodispersión SAR Sentinel-1 (RVI) de la cobertura vegetal en un área de intervención antropogénica en el sector de Lagarto, no sigue una tendencia creciente.	<b>Variable Dependiente:</b> Reflexión y retrodispersión VV y VH de la vegetación en la unidad mínima de la imagen (píxel) en imágenes ópticas Sentinel-2 y radar SAR Sentinel-1.  <b>Indicadores:</b> Rango espectral de índices ópticos y SAR.	Diseño: Transaccional (transversal) y longitudinal. Tipo: descriptiva, correlacional y predictivo Método: 1. Preprocesamiento de imágenes S1 y S2 mediante el software SNAP ESA y plataforma Google Earth Engine. 2. Cuantificación de Índice de NDVI de S2 e índice de RVI de S1. 3. Validación de precisión de los métodos con trabajos de campo e imágenes de alta resolución. 4. Grado de correlación Pearson. 5. Cuantificación de cambios de NDVI y RVI de 2015 y 2022.  Población y muestra: se empleará la distribución binomial de probabilidad.  $n = \frac{Z^2 p(qN)}{(N-1)E^2 + Z^2 pq}$ "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%)".
PROBLEMAS ESPECIFICOS	OBJETIVOS ESPECÍFICOS	La correlación entre la reflexión óptica Sentinel-2 y la retrodispersión SAR Sentinel-1 de la dinámica de la vegetación en un área de intervención antropogénica en el sector de Lagarto no es significativo.	<b>Variable Independiente:</b> Dinámica de la vegetación en el periodo 2015 y 2022.  <b>Indicadores:</b> 1. Superficie total (ha) 2. Matriz de Confusión (Índice Global) e Índice de Kappa (k). 3. Grado de correlación	
P.E.1 ¿Cuánto es la cobertura vegetal en un área de intervención antropogénica en el sector de Lagarto mediante el índice de vegetación de diferencia normalizada (NDVI) del sensor Sentinel-2 en los años 2015 y 2022?	O.E.1 Cuantificar la cobertura vegetal en un área de intervención antropogénica en el sector de Lagarto mediante el índice de vegetación de diferencia normalizada (NDVI) del sensor Sentinel-2 en los años 2015 y 2022.			
P.E.2 ¿Cuánto es la cobertura vegetal en un área de intervención antropogénica en el sector de Lagarto mediante el índice de vegetación de radar (RVI) del sensor Sentinel-1 de retrodispersión dual VV y VH en los años 2015 y 2022?	O.E.2 Cuantificar la cobertura vegetal en un área de intervención antropogénica en el sector de Lagarto mediante el índice de vegetación de radar (RVI) del sensor Sentinel-1 de retrodispersión dual VV y VH en los años 2015 y 2022.			
P.E.3 ¿Cuál es la precisión de los métodos de cuantificación de la cobertura vegetal en un área de intervención antropogénica?	O.E.3 Evaluar la precisión de los métodos de cuantificación de la cobertura vegetal en un área de intervención antropogénica.			
P.E.4 ¿Cómo es la correlación entre el índice de vegetación de diferencia normalizada (NDV) y el índice de vegetación de radar (RVI)?	O.E.4 Determinar la correlación entre el índice de vegetación de diferencia normalizada (NDV) y el índice de vegetación de radar (RVI).			
P.E.5 ¿Cuánto son los cambios de cobertura vegetal en un área de intervención antropogénica en el sector de Lagarto del índice de vegetación de diferencia normalizada (NDVI) de los años 2015 y 2022?	O.E.5 Analizar los cambios de la cobertura vegetal en un área de intervención antropogénica en el sector de Lagarto del índice de vegetación de diferencia normalizada (NDVI) de los años 2015 y 2022.			
P.E.6 ¿Cuánto son los cambios de cobertura vegetal en un área de intervención antropogénica en el sector de Lagarto del índice de vegetación de radar (RVI) de los años 2015 y 2022?	O.E.6 Analizar los cambios de la cobertura vegetal en un área de intervención antropogénica en el sector de Lagarto del índice de vegetación de radar (RVI) de los años 2015 y 2022.			

Anexo 2. Puntos de muestreo distribuidos al azar por estratos en el sector de Lagarto, 2015.

Nº	Categoría	Coordenadas UTM WGS84 zona 19S	
		Este	Norte
1	Sin vegetación	412831	8594649
2	Sin vegetación	412906	8593723
3	Sin vegetación	413519	8592767
4	Sin vegetación	414747	8593265
5	Sin vegetación	410647	8595558
6	Sin vegetación	410212	8595893
7	Sin vegetación	409695	8596208
8	Sin vegetación	409321	8596533
9	Sin vegetación	409206	8596932
10	Sin vegetación	409206	8597143
11	Sin vegetación	408754	8596099
12	Sin vegetación	411055	8594212
13	Sin vegetación	411065	8594349
14	Sin vegetación	412152	8593605
15	Sin vegetación	412387	8591206
16	Sin vegetación	412562	8591353
17	Sin vegetación	412914	8591091
18	Sin vegetación	410857	8591443
19	Sin vegetación	411601	8591350
20	Sin vegetación	408773	8596636
21	Sin vegetación	409731	8597650
22	Sin vegetación	410375	8596768
23	Sin vegetación	411758	8597235
24	Sin vegetación	406711	8598345
25	Sin vegetación	406895	8599062
26	Sin vegetación	407474	8598906
27	Sin vegetación	408612	8598488
28	Sin vegetación	406069	8589396
29	Sin vegetación	406202	8589796
30	Sin vegetación	406945	8590178
31	Sin vegetación	405762	8591574
32	Sin vegetación	405286	8591783
33	Sin vegetación	405337	8591951
34	Sin vegetación	404583	8588959
35	Sin vegetación	404623	8589391
36	Sin vegetación	404425	8589759
37	Sin vegetación	404011	8589894
38	Sin vegetación	403661	8589577
39	Sin vegetación	409569	8590355
40	Sin vegetación	409403	8590343

41	Sin vegetación	409889	8590387
42	Sin vegetación	401771	8592181
43	Sin vegetación	401721	8591918
44	Sin vegetación	401763	8591644
45	Sin vegetación	402144	8592140
46	Sin vegetación	401648	8592033
47	Sin vegetación	401566	8591949
48	Sin vegetación	400976	8591968
49	Sin vegetación	400842	8591988
50	Sin vegetación	400770	8591809
51	Sin vegetación	401138	8593095
52	Sin vegetación	399495	8590057
53	Sin vegetación	398547	8589422
54	Sin vegetación	397959	8589262
55	Sin vegetación	398455	8589106
56	Sin vegetación	398786	8589107
57	Sin vegetación	398972	8589097
58	Sin vegetación	400968	8588526
59	Sin vegetación	401247	8588611
60	Sin vegetación	401474	8588654
61	Sin vegetación	401555	8588907
62	Sin vegetación	401886	8589034
63	Sin vegetación	401775	8600202
64	Sin vegetación	401518	8599801
65	Sin vegetación	401985	8599056
66	Sin vegetación	402544	8598858
67	Sin vegetación	404636	8597728
68	Sin vegetación	405640	8597131
69	Sin vegetación	399333	8600878
70	Sin vegetación	399446	8600994
71	Sin vegetación	399539	8601100
72	Sin vegetación	399642	8601205
73	Sin vegetación	399807	8601322
74	Sin vegetación	400075	8601417
75	Sin vegetación	400077	8600954
76	Sin vegetación	399933	8600691
77	Sin vegetación	399903	8600427
78	Sin vegetación	399904	8600217
79	Sin vegetación	400340	8599660
80	Sin vegetación	400464	8599587
81	Sin vegetación	400216	8599576
82	Sin vegetación	399619	8598858
83	Sin vegetación	399588	8598742
84	Sin vegetación	399682	8598511
85	Sin vegetación	400821	8600810

86	Sin vegetación	400998	8600589
87	Sin vegetación	401174	8600411
88	Sin vegetación	402874	8602122
89	Sin vegetación	402865	8601848
90	Sin vegetación	402895	8602017
91	Sin vegetación	402250	8600257
92	Sin vegetación	402012	8600256
93	Sin vegetación	401662	8600002
94	Sin vegetación	402757	8600195
95	Poca vegetación	406653	8591326
96	Poca vegetación	406595	8591192
97	Poca vegetación	406630	8591117
98	Poca vegetación	406430	8590785
99	Poca vegetación	405493	8590502
100	Poca vegetación	404924	8590508
101	Poca vegetación	405207	8590358
102	Poca vegetación	404838	8590578
103	Poca vegetación	404787	8590716
104	Poca vegetación	404771	8590803
105	Poca vegetación	404846	8590515
106	Poca vegetación	404997	8590472
107	Poca vegetación	405090	8590476
108	Poca vegetación	405447	8591595
109	Poca vegetación	405539	8591757
110	Poca vegetación	405531	8591879
111	Poca vegetación	405500	8591994
112	Poca vegetación	405449	8592041
113	Poca vegetación	405309	8592115
114	Poca vegetación	405205	8592111
115	Poca vegetación	405077	8591976
116	Poca vegetación	405132	8591763
117	Poca vegetación	405269	8591630
118	Poca vegetación	405439	8591520
119	Poca vegetación	405556	8591481
120	Poca vegetación	405784	8591462
121	Poca vegetación	405858	8591576
122	Poca vegetación	405803	8591707
123	Poca vegetación	405710	8591789
124	Poca vegetación	405640	8591880
125	Poca vegetación	406503	8590797
126	Poca vegetación	406414	8590872
127	Poca vegetación	406580	8591109
128	Poca vegetación	406719	8591271
129	Poca vegetación	412049	8594441
130	Poca vegetación	412096	8594852

131	Poca vegetación	412466	8595314
132	Poca vegetación	412566	8594509
133	Poca vegetación	412681	8593900
134	Poca vegetación	410226	8592074
135	Poca vegetación	410251	8592227
136	Poca vegetación	410193	8592695
137	Poca vegetación	410620	8591691
138	Poca vegetación	411123	8591061
139	Poca vegetación	408523	8591521
140	Poca vegetación	410251	8592227
141	Poca vegetación	410188	8592469
142	Poca vegetación	410167	8592627
143	Poca vegetación	410105	8592748
144	Poca vegetación	410104	8592895
145	Poca vegetación	410125	8592984
146	Poca vegetación	413204	8594699
147	Poca vegetación	413204	8594699
148	Poca vegetación	413334	8594305
149	Poca vegetación	413334	8594305
150	Poca vegetación	413362	8593726
151	Poca vegetación	413622	8593253
152	Poca vegetación	413622	8593253
153	Poca vegetación	414465	8596466
154	Poca vegetación	411412	8597746
155	Poca vegetación	411076	8597851
156	Poca vegetación	411076	8597851
157	Poca vegetación	411178	8598140
158	Poca vegetación	411643	8598247
159	Poca vegetación	415484	8592443
160	Poca vegetación	415071	8592416
161	Poca vegetación	413676	8592517
162	Poca vegetación	413159	8592620
163	Poca vegetación	412925	8592856
164	Poca vegetación	412640	8593250
165	Poca vegetación	412640	8593250
166	Poca vegetación	412925	8592856
167	Poca vegetación	413418	8592305
168	Poca vegetación	396730	8588710
169	Poca vegetación	396730	8588710
170	Poca vegetación	395905	8589638
171	Poca vegetación	397675	8590916
172	Poca vegetación	397775	8590963
173	Poca vegetación	397992	8590980
174	Poca vegetación	399927	8591705
175	Poca vegetación	399973	8591792

176	Poca vegetación	399919	8591895
177	Poca vegetación	396714	8588796
178	Poca vegetación	396097	8587831
179	Poca vegetación	394765	8589808
180	Poca vegetación	394470	8589838
181	Poca vegetación	397373	8590670
182	Poca vegetación	397560	8590647
183	Poca vegetación	397730	8590687
184	Poca vegetación	396687	8589736
185	Poca vegetación	395990	8589678
186	Poca vegetación	397892	8590924
187	Poca vegetación	400027	8591895
188	Poca vegetación	399214	8591719
189	Vegetación media	395570	8592190
190	Vegetación media	394718	8592107
191	Vegetación media	394484	8592475
192	Vegetación media	394328	8592790
193	Vegetación media	394352	8593238
194	Vegetación media	394685	8593818
195	Vegetación media	394761	8594292
196	Vegetación media	394553	8594660
197	Vegetación media	394473	8595238
198	Vegetación media	395195	8595688
199	Vegetación media	395867	8595691
200	Vegetación media	396411	8595193
201	Vegetación media	395716	8594690
202	Vegetación media	395095	8594951
203	Vegetación media	395539	8593663
204	Vegetación media	395903	8592875
205	Vegetación media	396061	8592007
206	Vegetación media	395753	8591453
207	Vegetación media	394978	8591556
208	Vegetación media	393955	8588841
209	Vegetación media	397730	8594855
210	Vegetación media	396980	8595221
211	Vegetación media	396513	8595614
212	Vegetación media	396486	8595930
213	Vegetación media	397367	8595433
214	Vegetación media	397936	8595251
215	Vegetación media	400434	8597523
216	Vegetación media	400150	8597285
217	Vegetación media	400928	8596683
218	Vegetación media	400874	8597235
219	Vegetación media	402784	8597821
220	Vegetación media	398458	8600964

221	Vegetación media	395781	8597875
222	Vegetación media	394437	8598028
223	Vegetación media	394047	8598632
224	Vegetación media	394278	8599159
225	Vegetación media	394742	8599450
226	Vegetación media	395159	8598399
227	Vegetación media	395422	8597321
228	Vegetación media	395372	8596926
229	Vegetación media	396534	8597062
230	Vegetación media	396945	8597721
231	Vegetación media	397589	8598171
232	Vegetación media	407212	8595046
233	Vegetación media	407468	8595573
234	Vegetación media	407145	8599625
235	Vegetación media	406575	8599939
236	Vegetación media	408977	8600394
237	Vegetación media	408977	8600394
238	Vegetación media	410167	8599977
239	Vegetación media	400226	8597838
240	Vegetación media	400226	8597838
241	Vegetación media	395781	8597875
242	Vegetación media	394543	8597370
243	Vegetación media	407380	8590862
244	Vegetación media	407535	8591073
245	Vegetación media	411901	8599272
246	Vegetación media	411435	8599244
247	Vegetación media	411048	8599190
248	Vegetación media	411509	8600402
249	Vegetación media	411018	8600585
250	Vegetación media	410637	8598504
251	Vegetación media	410946	8598742
252	Vegetación media	411255	8598980
253	Vegetación media	409340	8600106
254	Vegetación media	409338	8600553
255	Vegetación media	408847	8600657
256	Vegetación media	395342	8591004
257	Vegetación media	394071	8592263
258	Vegetación media	393782	8593525
259	Vegetación media	393857	8594210
260	Vegetación media	395127	8593135
261	Vegetación media	395665	8594401
262	Vegetación media	394599	8596265
263	Vegetación media	394854	8597056
264	Vegetación media	416622	8592865
265	Vegetación media	416261	8592732

266	Vegetación media	417010	8592813
267	Vegetación media	417164	8593209
268	Vegetación media	417757	8593552
269	Vegetación media	417859	8593974
270	Vegetación media	418631	8595081
271	Vegetación media	414259	8596858
272	Vegetación media	412077	8600641
273	Vegetación media	408413	8591076
274	Vegetación media	408078	8590680
275	Vegetación media	404054	8589193
276	Vegetación media	406713	8589650
277	Vegetación media	407122	8590704
278	Vegetación media	412262	8599378
279	Vegetación media	417007	8593603
280	Vegetación media	403590	8588876
281	Vegetación media	403975	8589483
282	Vegetación media	409112	8590526
283	Vegetación media	412256	8593089
284	Vegetación densa	397869	8592224
285	Vegetación densa	398307	8592673
286	Vegetación densa	398744	8593254
287	Vegetación densa	399052	8593860
288	Vegetación densa	399386	8594335
289	Vegetación densa	400443	8594891
290	Vegetación densa	401502	8595106
291	Vegetación densa	402073	8594266
292	Vegetación densa	402644	8593320
293	Vegetación densa	403448	8592691
294	Vegetación densa	403605	8591823
295	Vegetación densa	403066	8590848
296	Vegetación densa	404274	8592852
297	Vegetación densa	405357	8593382
298	Vegetación densa	406880	8593861
299	Vegetación densa	406154	8594543
300	Vegetación densa	405403	8595172
301	Vegetación densa	404112	8594904
302	Vegetación densa	403334	8595665
303	Vegetación densa	402790	8596163
304	Vegetación densa	402272	8596556
305	Vegetación densa	401576	8596080
306	Vegetación densa	400492	8595550
307	Vegetación densa	399742	8595810
308	Vegetación densa	399482	8596230
309	Vegetación densa	399041	8596860
310	Vegetación densa	398936	8597334



311	Vegetación densa	398393	8597279
312	Vegetación densa	397931	8596409
313	Vegetación densa	398554	8595832
314	Vegetación densa	398815	8595096
315	Vegetación densa	398713	8594464
316	Vegetación densa	398225	8593752
317	Vegetación densa	397995	8593198
318	Vegetación densa	397686	8592803
319	Vegetación densa	397402	8592749
320	Vegetación densa	396886	8592510
321	Vegetación densa	396967	8591721
322	Vegetación densa	397795	8591382
323	Vegetación densa	398311	8591384
324	Vegetación densa	399371	8591203
325	Vegetación densa	394258	8590553
326	Vegetación densa	394621	8590318
327	Vegetación densa	395060	8590372
328	Vegetación densa	402033	8590844
329	Vegetación densa	401464	8591027
330	Vegetación densa	403610	8590455
331	Vegetación densa	403996	8591062
332	Vegetación densa	404276	8592036
333	Vegetación densa	405359	8592908
334	Vegetación densa	406856	8593150
335	Vegetación densa	407681	8593679
336	Vegetación densa	407783	8594022
337	Vegetación densa	408090	8594944
338	Vegetación densa	408114	8595523
339	Vegetación densa	408035	8596101
340	Vegetación densa	408035	8596101
341	Vegetación densa	407181	8596493
342	Vegetación densa	406587	8596307
343	Vegetación densa	406226	8596095
344	Vegetación densa	405477	8596119
345	Vegetación densa	404699	8596959
346	Vegetación densa	404129	8597325
347	Vegetación densa	403741	8597692
348	Vegetación densa	404513	8598537
349	Vegetación densa	404382	8599142
350	Vegetación densa	405207	8599461
351	Vegetación densa	403011	8591848
352	Vegetación densa	403343	8592954
353	Vegetación densa	403288	8594059
354	Vegetación densa	402821	8594716
355	Vegetación densa	404657	8594169

356	Vegetación densa	405301	8594777
357	Vegetación densa	406126	8595227
358	Vegetación densa	405711	8595515
359	Vegetación densa	404703	8595854
360	Vegetación densa	403796	8596456
361	Vegetación densa	403098	8596743
362	Vegetación densa	403824	8595903
363	Vegetación densa	403051	8595190
364	Vegetación densa	401710	8594712
365	Vegetación densa	400497	8594129
366	Vegetación densa	400111	8593680
367	Vegetación densa	401429	8593737
368	Vegetación densa	402077	8593213
369	Vegetación densa	402983	8592637
370	Vegetación densa	408598	8597603
371	Vegetación densa	407307	8597389
372	Vegetación densa	407021	8598072
373	Vegetación densa	407537	8598205
374	Vegetación densa	408390	8598024
375	Vegetación densa	409112	8598447
376	Vegetación densa	409551	8598712
377	Vegetación densa	409757	8598896
378	Vegetación densa	408034	8596496

Anexo 3. Puntos de muestreo distribuidos al azar por estratos por exclusión e inclusión en el sector de Lagarto, 2022.

Nº	Categoría	Coordenadas UTM WGS84 zona 19S	
		Este	Norte
1	Sin vegetación	394885	8587439
2	Sin vegetación	394947	8587398
3	Sin vegetación	394988	8587450
4	Sin vegetación	394957	8587508
5	Sin vegetación	394998	8587593
6	Sin vegetación	395024	8587493
7	Sin vegetación	395075	8587630
8	Sin vegetación	395178	8587709
9	Sin vegetación	395297	8587725
10	Sin vegetación	395359	8587799
11	Sin vegetación	395550	8587837
12	Sin vegetación	395473	8587747
13	Sin vegetación	395648	8587784
14	Sin vegetación	395746	8587753
15	Sin vegetación	395814	8587669
16	Sin vegetación	395866	8587627
17	Sin vegetación	395964	8587628
18	Sin vegetación	397890	8589330
19	Sin vegetación	397951	8589446
20	Sin vegetación	398101	8589499
21	Sin vegetación	398287	8589473
22	Sin vegetación	398545	8589506
23	Sin vegetación	398721	8589575
24	Sin vegetación	398633	8589432
25	Sin vegetación	398447	8589426
26	Sin vegetación	398221	8589247
27	Sin vegetación	398040	8589241
28	Sin vegetación	398443	8589116
29	Sin vegetación	398655	8589090
30	Sin vegetación	398862	8589086
31	Sin vegetación	399012	8589092
32	Sin vegetación	398950	8588997
33	Sin vegetación	398887	8589249
34	Sin vegetación	399223	8589224
35	Sin vegetación	399114	8589366
36	Sin vegetación	398974	8589465
37	Sin vegetación	398840	8589570
38	Sin vegetación	399514	8590125
39	Sin vegetación	399447	8590098
40	Sin vegetación	399494	8589999

41	Sin vegetación	399885	8589163
42	Sin vegetación	399941	8589253
43	Sin vegetación	399992	8589348
44	Sin vegetación	399971	8589516
45	Sin vegetación	399929	8589642
46	Sin vegetación	400863	8588572
47	Sin vegetación	401080	8588615
48	Sin vegetación	401266	8588684
49	Sin vegetación	401420	8588805
50	Sin vegetación	401544	8588895
51	Sin vegetación	401735	8589012
52	Sin vegetación	401791	8589154
53	Sin vegetación	401889	8589244
54	Sin vegetación	402033	8589392
55	Sin vegetación	402286	8589456
56	Sin vegetación	402617	8589409
57	Sin vegetación	402875	8589389
58	Sin vegetación	403546	8589502
59	Sin vegetación	401189	8588452
60	Sin vegetación	401421	8588590
61	Sin vegetación	411145	8593254
62	Sin vegetación	411000	8593023
63	Sin vegetación	410548	8593154
64	Sin vegetación	409998	8593481
65	Sin vegetación	409886	8593102
66	Sin vegetación	409320	8593281
67	Sin vegetación	409609	8593759
68	Sin vegetación	409558	8594598
69	Sin vegetación	407359	8595561
70	Sin vegetación	408552	8596124
71	Sin vegetación	408325	8596370
72	Sin vegetación	405577	8597200
73	Sin vegetación	409472	8596341
74	Sin vegetación	410313	8595867
75	Sin vegetación	402907	8594049
76	Sin vegetación	402616	8594147
77	Sin vegetación	402551	8594410
78	Sin vegetación	401752	8592022
79	Sin vegetación	401672	8591792
80	Sin vegetación	405547	8591756
81	Sin vegetación	405112	8591458
82	Sin vegetación	404486	8595124
83	Sin vegetación	411733	8597175
84	Sin vegetación	411508	8596747
85	Sin vegetación	411341	8598654

86	Sin vegetación	411825	8598787
87	Sin vegetación	396601	8592880
88	Sin vegetación	396469	8593538
89	Sin vegetación	396559	8595610
90	Sin vegetación	415687	8592483
91	Sin vegetación	417264	8594297
92	Sin vegetación	417104	8593672
93	Sin vegetación	395889	8590182
94	Sin vegetación	395199	8590813
95	Poca vegetación	414793	8592890
96	Poca vegetación	414867	8592896
97	Poca vegetación	415450	8592917
98	Poca vegetación	415548	8593435
99	Poca vegetación	415343	8593548
100	Poca vegetación	414861	8592979
101	Poca vegetación	415104	8592436
102	Poca vegetación	413730	8591870
103	Poca vegetación	413339	8591856
104	Poca vegetación	413413	8594067
105	Poca vegetación	414085	8593399
106	Poca vegetación	414326	8593608
107	Poca vegetación	414494	8593300
108	Poca vegetación	414469	8595384
109	Poca vegetación	414364	8595333
110	Poca vegetación	414302	8595244
111	Poca vegetación	414615	8596388
112	Poca vegetación	414646	8596281
113	Poca vegetación	414609	8596230
114	Poca vegetación	413693	8595943
115	Poca vegetación	413693	8595943
116	Poca vegetación	413792	8595893
117	Poca vegetación	412956	8595568
118	Poca vegetación	412640	8595283
119	Poca vegetación	412554	8595094
120	Poca vegetación	412604	8594892
121	Poca vegetación	412518	8594752
122	Poca vegetación	412456	8594695
123	Poca vegetación	412369	8594765
124	Poca vegetación	412004	8594561
125	Poca vegetación	412067	8594347
126	Poca vegetación	412203	8594290
127	Poca vegetación	412160	8594385
128	Poca vegetación	412110	8594480
129	Poca vegetación	412097	8594612
130	Poca vegetación	412078	8594719

131	Poca vegetación	412065	8594795
132	Poca vegetación	412359	8596097
133	Poca vegetación	412934	8596604
134	Poca vegetación	412952	8596743
135	Poca vegetación	412915	8596901
136	Poca vegetación	412852	8596977
137	Poca vegetación	412734	8597077
138	Poca vegetación	412734	8597077
139	Poca vegetación	412388	8592845
140	Poca vegetación	410378	8595188
141	Poca vegetación	410675	8595132
142	Poca vegetación	407094	8590428
143	Poca vegetación	406108	8590765
144	Poca vegetación	405497	8591528
145	Poca vegetación	406596	8591096
146	Poca vegetación	404912	8590477
147	Poca vegetación	403866	8590000
148	Poca vegetación	403965	8590038
149	Poca vegetación	403730	8589930
150	Poca vegetación	404220	8591561
151	Poca vegetación	404196	8591397
152	Poca vegetación	404234	8591264
153	Poca vegetación	404308	8591138
154	Poca vegetación	404345	8591296
155	Poca vegetación	404270	8591391
156	Poca vegetación	404276	8591498
157	Poca vegetación	404419	8591366
158	Poca vegetación	404487	8591366
159	Poca vegetación	405622	8591509
160	Poca vegetación	396610	8589065
161	Poca vegetación	396659	8588996
162	Poca vegetación	396703	8588914
163	Poca vegetación	396950	8589142
164	Poca vegetación	396926	8589041
165	Poca vegetación	395135	8588781
166	Poca vegetación	395135	8588781
167	Poca vegetación	395073	8588889
168	Poca vegetación	395073	8588889
169	Poca vegetación	395029	8589040
170	Poca vegetación	395029	8589040
171	Poca vegetación	395540	8588404
172	Poca vegetación	395086	8588712
173	Poca vegetación	394241	8587540
174	Poca vegetación	396910	8589900
175	Poca vegetación	396830	8589880

176	Poca vegetación	396731	8589804
177	Poca vegetación	396607	8589728
178	Poca vegetación	398079	8590877
179	Poca vegetación	398079	8590877
180	Poca vegetación	397700	8590875
181	Poca vegetación	397700	8590875
182	Poca vegetación	397799	8590977
183	Poca vegetación	397799	8590977
184	Poca vegetación	397198	8590823
185	Poca vegetación	397366	8590716
186	Poca vegetación	397466	8590660
187	Poca vegetación	397713	8590667
188	Poca vegetación	398175	8589929
189	Vegetación media	406373	8593258
190	Vegetación media	406373	8593390
191	Vegetación media	406257	8593317
192	Vegetación media	405862	8593625
193	Vegetación media	405467	8592018
194	Vegetación media	407183	8592386
195	Vegetación media	407973	8593717
196	Vegetación media	407966	8593888
197	Vegetación media	407973	8593981
198	Vegetación media	408004	8594139
199	Vegetación media	412564	8592068
200	Vegetación media	412913	8592108
201	Vegetación media	412919	8592273
202	Vegetación media	412912	8592424
203	Vegetación media	412963	8592641
204	Vegetación media	412943	8592799
205	Vegetación media	412761	8593048
206	Vegetación media	412645	8593147
207	Vegetación media	412579	8593489
208	Vegetación media	412184	8593731
209	Vegetación media	411720	8593545
210	Vegetación media	411630	8593361
211	Vegetación media	411688	8593308
212	Vegetación media	411824	8593243
213	Vegetación media	411786	8593052
214	Vegetación media	410913	8591385
215	Vegetación media	411127	8591142
216	Vegetación media	411295	8591129
217	Vegetación media	411211	8590958
218	Vegetación media	410403	8591258
219	Vegetación media	410281	8591205
220	Vegetación media	410139	8591080

221	Vegetación media	413539	8592334
222	Vegetación media	413681	8592321
223	Vegetación media	413829	8592400
224	Vegetación media	413951	8592447
225	Vegetación media	414100	8592447
226	Vegetación media	414158	8592349
227	Vegetación media	413901	8592210
228	Vegetación media	413707	8592097
229	Vegetación media	413091	8592806
230	Vegetación media	412916	8592996
231	Vegetación media	413613	8593301
232	Vegetación media	413296	8593491
233	Vegetación media	413801	8593229
234	Vegetación media	413332	8594287
235	Vegetación media	413247	8594675
236	Vegetación media	413040	8594898
237	Vegetación media	413008	8594622
238	Vegetación media	413080	8594444
239	Vegetación media	413100	8594188
240	Vegetación media	412641	8594213
241	Vegetación media	413768	8595275
242	Vegetación media	413536	8595314
243	Vegetación media	413310	8595129
244	Vegetación media	413266	8594971
245	Vegetación media	413337	8594807
246	Vegetación media	413389	8594656
247	Vegetación media	410425	8596699
248	Vegetación media	410315	8596791
249	Vegetación media	410159	8596961
250	Vegetación media	410120	8597066
251	Vegetación media	410222	8597350
252	Vegetación media	410196	8597626
253	Vegetación media	404764	8593651
254	Vegetación media	404905	8594852
255	Vegetación media	404872	8595016
256	Vegetación media	405906	8594987
257	Vegetación media	405888	8595415
258	Vegetación media	402638	8592015
259	Vegetación media	402540	8592196
260	Vegetación media	402346	8592261
261	Vegetación media	402624	8591440
262	Vegetación media	402796	8597625
263	Vegetación media	402795	8598003
264	Vegetación media	402795	8598003
265	Vegetación media	403181	8598514



266	Vegetación media	403181	8598514
267	Vegetación media	406734	8598444
268	Vegetación media	396197	8591614
269	Vegetación media	396197	8591614
270	Vegetación media	395827	8591317
271	Vegetación media	395343	8591183
272	Vegetación media	395051	8591412
273	Vegetación media	394598	8591871
274	Vegetación media	394323	8592035
275	Vegetación media	394063	8592313
276	Vegetación media	395079	8592728
277	Vegetación media	395370	8592466
278	Vegetación media	395370	8592466
279	Vegetación media	395664	8591579
280	Vegetación media	394709	8592266
281	Vegetación media	393806	8591951
282	Vegetación media	394663	8591658
283	Vegetación media	395449	8593026
284	Vegetación densa	404955	8589704
285	Vegetación densa	404744	8589934
286	Vegetación densa	404420	8590311
287	Vegetación densa	403983	8590589
288	Vegetación densa	403498	8590702
289	Vegetación densa	403209	8590323
290	Vegetación densa	403129	8590093
291	Vegetación densa	402790	8589927
292	Vegetación densa	402612	8590042
293	Vegetación densa	402466	8590222
294	Vegetación densa	402740	8590486
295	Vegetación densa	402740	8590486
296	Vegetación densa	401448	8590662
297	Vegetación densa	400946	8590924
298	Vegetación densa	400639	8591120
299	Vegetación densa	403030	8590668
300	Vegetación densa	403255	8590932
301	Vegetación densa	403383	8591228
302	Vegetación densa	407085	8589991
303	Vegetación densa	406698	8589611
304	Vegetación densa	406683	8589332
305	Vegetación densa	406683	8589332
306	Vegetación densa	407119	8589284
307	Vegetación densa	407135	8589498
308	Vegetación densa	407279	8589679
309	Vegetación densa	407473	8589762
310	Vegetación densa	393795	8590536

311	Vegetación densa	394134	8590537
312	Vegetación densa	394295	8590669
313	Vegetación densa	394278	8590900
314	Vegetación densa	394035	8591129
315	Vegetación densa	396851	8589511
316	Vegetación densa	396851	8589511
317	Vegetación densa	397205	8589660
318	Vegetación densa	397205	8589660
319	Vegetación densa	406698	8599644
320	Vegetación densa	406584	8599841
321	Vegetación densa	406181	8599725
322	Vegetación densa	405777	8599542
323	Vegetación densa	405600	8599427
324	Vegetación densa	405358	8599278
325	Vegetación densa	405116	8599178
326	Vegetación densa	404826	8599243
327	Vegetación densa	404502	8599374
328	Vegetación densa	404535	8599094
329	Vegetación densa	404537	8598683
330	Vegetación densa	404151	8598188
331	Vegetación densa	403732	8597858
332	Vegetación densa	403475	8597495
333	Vegetación densa	402832	8601424
334	Vegetación densa	402202	8601323
335	Vegetación densa	402200	8601965
336	Vegetación densa	401684	8601650
337	Vegetación densa	401265	8601303
338	Vegetación densa	401396	8600794
339	Vegetación densa	401414	8600268
340	Vegetación densa	401947	8600500
341	Vegetación densa	402446	8600896
342	Vegetación densa	402493	8601324
343	Vegetación densa	401814	8601503
344	Vegetación densa	410332	8599524
345	Vegetación densa	410301	8599080
346	Vegetación densa	410125	8598537
347	Vegetación densa	409736	8598930
348	Vegetación densa	409671	8599177
349	Vegetación densa	409702	8599473
350	Vegetación densa	409928	8599589
351	Vegetación densa	410301	8599080
352	Vegetación densa	408754	8597924
353	Vegetación densa	408189	8597791
354	Vegetación densa	408366	8598071
355	Vegetación densa	407268	8597968

356	Vegetación densa	407316	8598150
357	Vegetación densa	407444	8598545
358	Vegetación densa	400542	8600363
359	Vegetación densa	400704	8600249
360	Vegetación densa	401250	8600974
361	Vegetación densa	401460	8601173
362	Vegetación densa	401491	8601370
363	Vegetación densa	401814	8601503
364	Vegetación densa	402008	8601471
365	Vegetación densa	402008	8601471
366	Vegetación densa	402362	8601817
367	Vegetación densa	402362	8601817
368	Vegetación densa	401671	8600680
369	Vegetación densa	399456	8601560
370	Vegetación densa	399116	8601641
371	Vegetación densa	398890	8601641
372	Vegetación densa	417841	8593988
373	Vegetación densa	417842	8593807
374	Vegetación densa	417827	8593495
375	Vegetación densa	417779	8593248
376	Vegetación densa	417538	8592951
377	Vegetación densa	416698	8592850
378	Vegetación densa	418001	8594696

Anexo 4. Panel fotográfico.



Foto 1. Áreas sin vegetación.



Foto 2. Áreas sin vegetación.





Foto 3. Áreas con poca vegetación.



Foto 4. Áreas con poca vegetación.





Foto 5. Áreas con vegetación media.



Foto 6. Áreas con vegetación media.






Foto 7. Áreas con vegetación densa.




Foto 8. Áreas con vegetación densa.





Foto 9. Reconocimiento de campo.



Foto 10. Áreas con agua de disposición residual por minería.