

UNIVERSIDAD NACIONAL AMAZÓNICA DE MADRE DE DIOS

FACULTAD DE INGENIERÍA

ESCUELA ACADÉMICO PROFESIONAL DE INGENIERÍA
FORESTAL Y MEDIO AMBIENTE



TESIS

**ESTIMACIÓN DE LA GRAVEDAD DE QUEMAS A TRAVÉS DE
SENSORES DE RADAR DE APERTURA SINTÉTICA (SAR) EN EL
DISTRITO DE TAHUAMANU – MADRE DE DIOS, PERIODO 2020**

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

A handwritten signature in blue ink, appearing to be "Reynaldo", is written over a large, faint circular watermark.

Tesis presentada por:

Bachiller:

MIRANDA FIDHEL, Reynaldo
Fabrizzio

Asesor: Dr. Gabriel Alarcón Aguirre


Co-Asesor: M.Sc. Jorge Santiago Garate Quispe

Puerto Maldonado, enero de 2021

UNIVERSIDAD NACIONAL AMAZÓNICA DE MADRE DE DIOS

FACULTAD DE INGENIERÍA

ESCUELA ACADÉMICO PROFESIONAL DE INGENIERÍA
FORESTAL Y MEDIO AMBIENTE



TESIS

**ESTIMACIÓN DE LA GRAVEDAD DE QUEMAS A TRAVÉS DE
SENSORES DE RADAR DE APERTURA SINTÉTICA (SAR) EN EL
DISTRITO DE TAHUAMANU – MADRE DE DIOS, PERIODO 2020**

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

Tesis presentada por:

Bachiller:

MIRANDA FIDHEL, Reynaldo
Fabrizzio

Asesor: Dr. Gabriel Alarcón Aguirre

Puerto Maldonado, noviembre de 2021

Dedicatoria

Agradecimientos

Resumen

El creciente conocimiento de las capacidades de las imágenes por satélite para las aplicaciones de peligro de incendios es especialmente útil en situaciones de emergencia en las que el tiempo y la capacidad de cubrir grandes áreas son esenciales. En el caso de las imágenes a RADAR presenta una ventaja sobre imágenes ópticas (pasivas) en los efectos climáticos. Este estudio propone el uso de imágenes de radar de apertura sintética (SAR) Sentinel-1 para el análisis de la gravedad de las quemads en la parte norte de la región Amazónica de Madre de Dios, distrito de Tahuamanu – Perú (periodo 2020). Utilizando predictores absolutos, relativos, y Relación de Quemads (RBR) por medio del Índice Degradación Forestal del RADAR (RDFI) aplicando la coherencia de copolarización y polarización cruzada de la banda C VV y VH, así como, los patrones de longitud (dB) de la vegetación y áreas quemadas, validadas mediante la gravedad de la quemadura (CBI) en campo, se desarrolló una métrica para clasificar la gravedad de las quemads. Los resultados mostraron de; 1) Ab_Rel_VV_1 con 586,99 ha (Bajo), 1 1167,35 ha (Moderado), y 1 209,00 ha (Alto)., 2) Ab_Rel_VV_2 con 676,97 ha (Bajo), 1 223,04 ha (Moderado), y 1 208,27 ha (Alto)., 3) Ab_Rel_VH_1 con 435,28 ha (Bajo), 1 277,14 ha (Moderado), 1 208,27 ha (Alto)., 4) Ab_Rel_VH_2 con 519,03 ha (Bajo), 1 983,04 ha (Moderado), 1 470,67 ha (Alto)., 5) RDFI_VVVH con 536,18 ha (Bajo), 1 484,87 ha (Moderado), y 1 475,16 ha (Alto). La proporción de la severidad de quemads en los cocientes empleados, mostro rangos promedios de 38% a 42% en nivel Alto, de 39% a 50% en nivel Moderado, y 13% a 22% en el nivel Bajo. La investigación determina a los cocientes de cruzamiento de valores absolutos y relativos de polarización cruzada VH_2 ($k=0,734$) y RBR por medio del RDFI ($k=0,799$) como las más concordantes para determinar la severidad de quemads, mostrando una fuerza de concordancia Considerable respecto a una fuerza Moderada de los demás cocientes.

Palabras clave: Sentinel-1, copolarización, polarización, predictores absolutos y relativos.

Abstract

The growing awareness of the capabilities of satellite imagery for fire danger applications is especially useful in emergency situations where time and the ability to cover large areas are essential. In the case of RADAR imagery, it presents an advantage over optical (passive) imagery in weather effects. This study proposes the use of Sentinel-1 synthetic aperture radar (SAR) images for the analysis of the severity of burns in the northern part of the Amazonian region of Madre de Dios, district of Tahuamanu - Peru (period 2020). Using absolute, relative, and RBR predictors by means of the RADAR Forest Degradation Index (RDFI) applying C-band VV and VH co-polarization and cross-polarization coherence, as well as, the length patterns (dB) of vegetation and burned areas, validated by the burn severity (CBI) in the field, a metric was developed to classify the burn severity. The results showed that; 1) Ab_Rel_VVV_1 with 586.99 ha (Low), 1 1167.35 ha (Moderate), and 1 209.00 ha (High), 2) Ab_Rel_VVV_2 with 676.97 ha (Low), 1 223.04 ha (Moderate), and 1 208.27 ha (High), 3) Ab_Rel_VVV_2 with 676.97 ha (Low), 1 223.04 ha (Moderate), and 1 208.27 ha (High). Ab_Rel_VH_1 with 435.28 ha (Low), 1 277.14 ha (Moderate), 1 208.27 ha (High), 4) Ab_Rel_VH_2 with 519.03 ha (Low), 1 983.04 ha (Moderate), 1 470.67 ha (High), 5) RDFI_VVVVH with 536.18 ha (Low), 1 484.87 ha (Moderate), and 1 475.16 ha (High). The proportion of burn severity in the ratios used showed average ranges from 38% to 42% at the High level, 39% to 50% at the Moderate level, and 13% to 22% at the Low level. The research determines the cross ratios of absolute and relative values of cross polarization VH_2 ($k=0,734$) and RBR by means of RDFI ($k=0,799$) as the most concordant to determine the severity of burns, showing a considerable concordance strength with respect to a moderate strength of the other ratios.

Key words: Sentinel-1, co-polarization, polarization, absolute and relative predictors.

Índice de contenidos

	Pág.
<u>Dedicatoria</u>	i
<u>Agradecimientos</u>	ii
<u>Resumen</u>	iii
<u>Abstract</u>	iv
<u>Agradecimientos</u>	xiv
<u>Introducción</u>	1
CAPÍTULO I: PROBLEMA DE INVESTIGACIÓN	3
1.1 Planteamiento del problema de investigación	3
1.2 Formulación del problema	6
1.2.1 Problema general	6
1.2.2 Problemas específicos	6
1.3 Justificación e importancia	6
1.4 Objetivos de la investigación	7
1.4.1 Objetivo general	7
1.4.2 Objetivos específicos	7
1.5 Hipótesis	7
1.6 Variables de la investigación	8
1.6.1 Identificación de variables	8
1.6.2 Operacionalización de variables	8
1.7 Consideraciones éticas	8
CAPÍTULO II: MARCO TEÓRICO	10
2.1 Antecedentes de la investigación	10

2.2 Marco teórico.....	14
2.2.1 Comportamiento del fuego.....	14
Factores de comportamiento del fuego.....	15
2.2.2 Deforestación.....	17
2.2.3 Bosque.....	17
2.2.4 Sistemas de Información Geográfica (SIG).....	17
2.2.5 Sensoramiento remoto.....	18
2.2.6 Energía electromagnética.....	19
2.2.7 Teledetección activa y pasiva.....	22
2.2.8 Plataforma y sensores.....	23
Sensores.....	23
Plataformas.....	24
2.2.9 Escáneres multiespectrales.....	25
2.2.10 RADAR.....	25
Geometría de visualización de radar.....	26
Resolución espacial.....	28
Distorsiones en imágenes de radar.....	29
Clasificación de imágenes digitales.....	29
Clasificación de imágenes.....	30
Proceso de clasificación de imágenes.....	31
Clasificación de imágenes supervisada.....	31
Algoritmos de clasificación.....	32
2.2.11 Software de procesamiento de imágenes.....	32
SNAP ESA.....	32
Google Earth Engine.....	33
ENVI.....	33

ArcMap	33
2.2.12 Programa Copérnico	34
Sentinel-1	34
INSTRUMENTO C-SAR	35
2.3 Marco conceptual	36
CAPÍTULO III: METODOLOGÍA DE INVESTIGACIÓN.....	40
3.1 Tipo de investigación	40
3.2 Diseño de la investigación	40
3.3 Delimitación espacial y temporal.....	40
3.3.1 Clima e hidrografía.....	41
3.4 Población y muestra	42
3.5 Técnicas e instrumentos de recolección de datos.....	44
3.5.1 Método y técnicas	44
3.5.2 Procesamiento de datos y análisis estadístico	45
Tratamiento y análisis de la imagen SAR	47
Tratamiento de datos.....	50
Análisis estadístico	52
CAPÍTULO IV: RESULTADOS Y DISCUSIÓN	53
4.1 Cuantificación de la superficie deforestada por quemas mediante sensores de Radar de Apertura Sintetica (SAR) Sentinel-1 en distrito de Tahuamanu	53
4.2 Niveles de gravedad de quemas mediante sensores de Radar de Apertura Sintetica (SAR) Sentinel-1 en el distrito de Tahuamanu	61
4.3 Evaluacion de la precisión de los niveles de gravedad de quemas.....	66
CONCLUSIONES.....	71
RECOMENDACIONES.....	72

REFERENCIAS BIBLIOGRÁFICAS.....	73
ANEXOS	79

Índice de Tablas

	Pág.
Tabla 1. Variables e indicadores del estudio.....	8
Tabla 2. Características de la imagen de satélite Sentinel-1	35
Tabla 3. Información de adquisición de imágenes Sentinel-1	46
Tabla 4. Características de la imagen de satélite Sentinel-1	46
Tabla 5. Desglose de las decisiones para desarrollar el modelo de severidad de quemas SAR Sentinel-1 por medio de valores absolutos y relativos	49
Tabla 6. Criterio de las decisiones para desarrollar el modelo de severidad de quemas SAR Sentinel-1 por medio de RBR y RDFI	50
Tabla 7. Definiciones de las categorías de gravedad de CBI para comparar los valores absolutos, relativos y la Relación de Quemas (RBR) por medio del Índice Degradación Forestal del RADAR (RDFI) a partir de los datos de retrodispersión VV y VH	51
Tabla 8. Valoración del coeficiente kappa.....	52
Tabla 9. Matriz de confusión e Índice de kappa de datos de prueba CBI (columnas) frente a datos SAR Sentinel-1 de datos de retrodispersión VV1	67
Tabla 10, Matriz de confusión e Índice de kappa de datos de prueba CBI (columnas) frente a datos SAR Sentinel-1 de datos de retrodispersión VV1	68
Tabla 11, Matriz de confusión e Índice de kappa de datos de prueba CBI (columnas) frente a datos SAR Sentinel-1 de datos de retrodispersión VH1	68
Tabla 12, Matriz de confusión e Índice de kappa de datos de prueba CBI (columnas) frente a datos SAR Sentinel-1 de datos de retrodispersión VH2	69

Tabla 13, Matriz de confusión e Índice de kappa de datos de prueba CBI
(columnas) frente a datos SAR Sentinel-1 de RBR y RDFI de datos de
retrodispersión VV y VH70

Índice de Figuras

	Pág.
<i>Figura 1.</i> Un sensor de teledetección 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.	20
<i>Figura 3.</i> Relación entre longitud de onda, frecuencia y energía.	21
<i>Figura 4.</i> El espectro electromagnético.....	21
<i>Figura 5.</i> Descripción general de los sensores.	24
<i>Figura 6.</i> Ángulo de incidencia del radar y ángulo de incidencia local.....	27
<i>Figura 7.</i> Distorsiones geométricas en RADAR.	28
<i>Figura 8.</i> El proceso de clasificación; El componente más importante es el entrenamiento en combinación con la selección del algoritmo.....	31
<i>Figura 9.</i> Ubicación de área estudio.	41
<i>Figura 10.</i> Distribución de muestras para validar la severidad de quemas en el distrito de Tahuamanu.	43
<i>Figura 11.</i> Imágenes SAR Sentinel-1 con polarización VV; pre y post incendio 2020.	46
<i>Figura 12.</i> Imágenes SAR Sentinel-1 con polarización VH; pre y post incendio 2020.	47
<i>Figura 13.</i> Longitud de onda (microondas dB) de retrodispersión VV y VH para vegetación y áreas quemadas.	54
<i>Figura 14.</i> Tipos de gravedad de quemas (CBI): gravedad bajo (a), gravedad moderado (b), y gravedad alto (c).....	55
<i>Figura 15.</i> Determinación de áreas quemadas mediante valores absolutos y relativos de datos de retrodispersión VV1 pre y post incendio 2020; Ecuación 2 y 4.....	56

<i>Figura 16.</i> Determinación de áreas quemadas mediante valores absolutos y relativos de datos de retrodispersión VV2 pre y post incendio 2020; Ecuación 2 y 6.	56
<i>Figura 17.</i> Determinación de áreas quemadas mediante valores absolutos y relativos de datos de retrodispersión VH1 pre y post incendio 2020; Ecuación 3 y 5.	57
<i>Figura 18.</i> Determinación de áreas quemadas mediante valores absolutos y relativos de datos de retrodispersión VH2 pre y post incendio 2020; Ecuación 3 y 7.	57
<i>Figura 19.</i> Determinación de áreas quemadas a través de la Relación de Quemadas (RBR) por medio del Índice Degradación Forestal del RADAR (RDFI) a partir de los datos de retrodispersión VV y VH pre y post incendio 2020; Ecuación 9 y 10.	58
<i>Figura 20.</i> Cuantificación de áreas quemadas mediante valores absolutos, relativos y Relación de Quemadas (RBR) por medio del Índice Degradación Forestal del RADAR (RDFI) de datos de retrodispersión VV y VH pre y post incendio 2020; Ecuación 2, 3, 4, 5, 6, 7, 8, 9, 10.	59
<i>Figura 21.</i> Deforestación por nivel de gravedad de quemadas mediante valores absolutos, relativos de datos de retrodispersión VV1 pre y post incendio 2020; Ecuación 2 y 4.	62
<i>Figura 22.</i> Deforestación por nivel de gravedad de quemadas mediante valores absolutos, relativos de datos de retrodispersión VV2 pre y post incendio 2020; Ecuación 2 y 6.	62
<i>Figura 23.</i> Deforestación por nivel de gravedad de quemadas mediante valores absolutos, relativos de datos de retrodispersión VH1 pre y post incendio 2020; Ecuación 3 y 5.	63
<i>Figura 24.</i> Deforestación por nivel de gravedad de quemadas mediante valores absolutos, relativos de datos de retrodispersión VH2 pre y post incendio 2020; Ecuación 3 y 7.	63

Figura 25. Determinación del nivel de gravedad de quemas mediante la Relación de Quemadas (RBR) y del Índice Degradación Forestal del RADAR (RDFI) de datos de retrodispersión VV y VH pre y post incendio 2020; Ecuación 8, 9 y 10.64

Figura 26. Áreas por nivel de gravedad de quemas mediante valores absolutos, relativos y Relación de Quemadas (RBR) por medio del Índice Degradación Forestal del RADAR (RDFI) de datos de retrodispersión VV y VH pre y post incendio 2020; Ecuación 2, 3, 4, 5, 6, 7, 8, 9, 10.65

Índice de anexos

	Pág.
Anexo 1. Puntos de muestreo tomados en campo en el corredor minero de Madre de Dios.	81
Anexo 2. Panel fotográfico.	91
Anexo 3. Fichas de validación de campo.	98

Introducción

Los peligros vinculados con un incendio continúan incluso después del evento. Las consecuencias de un incendio generalmente ocasionan la pérdida de la cubierta vegetal, dejando el suelo expuesto y vulnerable a peligros posteriores al incendio. Estos peligros, según la región, incluyen; erosión, flujos de sedimentos, desprendimientos de rocas, inundaciones repentinas, flujos de escombros y liberación de gases de efecto de invernadero a la atmósfera (Addison & Oommen, 2018; Cannon & DeGraff, 2009; Cannon et al., 2010). El nivel de estos peligros consecuentes a un incendio es afectado según el nivel quema del mismo. Por lo tanto, es necesario evaluar la *gravedad y la vulnerabilidad* de las áreas afectadas por incendios para el manejo posterior (Addison & Oommen, 2018; Kern et al., 2017). En el Perú, y específicamente en Madre de Dios, hay iniciativas de respuesta a *emergencias en áreas quemadas (COER)*, cuya misión es mitigar y evaluar rápidamente la gravedad de los incendios y sus implicaciones para el manejo de estabilización de la emergencia.

Actualmente, el método para determinar la gravedad de las quemas por incendios es a través del uso de imágenes de satélite y técnicas de sensoramiento remoto, debido a que cubren extensas áreas y los resultados son objetivas (Addison & Oommen, 2018; Parks et al., 2014). En este conglomerado, las imágenes de satélites ópticos se han utilizado ampliamente y han demostrado ser útiles para cartografiar áreas quemadas (Addison & Oommen, 2018; Stroppiana et al., 2015). Sin embargo, el enfoque óptico se ve perjudicado por la estacionalidad y factores climáticos (nubes, el humo de los incendios forestales en curso, entre otros) (Allison et al., 2016), en ese caso, un usuario tendría que esperar al menos un ciclo temporal completo (dependiendo del satélite), situación, que en caso de posibles peligros de emergencia, podría ser potencialmente mortal y/o costosa. Por otro lado, investigaciones con sensores óptico, han evidenciado que la aplicación de Índices de Quemadas, muestra inconsistencias en la determinación de la gravedad de la quema por incendios (Murphy et al., 2008). Adicionalmente, los índices muestran una medida absoluta del cambio (vegetación), el cual no

considera el criterio heterogéneo de los paisajes, por lo que, la misma intensidad de quemadura podría variar según el tamaño, densidad y heterogeneidad de la vegetación por unidad de media de píxel (Parks et al., 2014).

En ese sentido, proponemos un método alternativo en esta investigación: la estimación de la gravedad de las quemas por sensores a Radar de Apertura Sintética (SAR), que, a diferencia de los ópticos, es una tecnología que atraviesa nubes y humo, fundamental en este tipo de situaciones. Las técnicas de radar de apertura sintética (SAR), “que consiste básicamente en el alargamiento artificial de la antena de un sensor al capitalizar el movimiento de vuelo para proporcionar imágenes de alta resolución”. “El SAR utiliza energía de microondas para cuantificar y discernir entre procesos ecológicos midiendo las diferencias en la dispersión según la rugosidad de la superficie objetivo, y energía de microondas que recibe y procesa en la imagen SAR resultante” (Kasischke et al., 1997). El éxito de la aplicación, es que la pérdida de la vegetación por quemas experimenta variaciones de dispersión, estos cambios son directamente proporcionales al grado de quemadura y, por lo tanto, permiten mapear la gravedad de las quemas (Mihai A. Tanase et al., 2015). La aplicación de SAR para determinar la gravedad de las quemas no es novedoso, sin embargo, la información es limitada y no está disponible en acceso abierto (M. A. Tanase et al., 2015). Finalmente, las investigaciones y publicaciones se enfocan en los bosques mediterráneos, por la fiabilidad única de los SAR en diferentes tipos de vegetación, por lo tanto, dado que el paisaje de Madre de Dios (distrito de Tahuamanu) contrasta diferentes tipos de bosque, zonas de transición, pasturas y agricultura, se justifica un estudio en el área, considerando que las medidas relativas de la gravedad de las quemas por SAR promedian la condición previa a la quema de cada paisaje para dar cuenta de su cambio relativo.

CAPÍTULO I: PROBLEMA DE INVESTIGACIÓN

1.1 Planteamiento del problema de investigación

La severidad de la quema, está referida al grado de cambio ambiental causado por el fuego (la pérdida de materia orgánica, tanto por encima como por debajo del suelo) (Morgan et al., 2014; Viedma et al., 2020), puede tener múltiples implicaciones ecológicas, y tiene impactos significativos en la vegetación y los suelos y puede influir en las trayectorias de respuesta de los ecosistemas (Shive et al., 2018), erosión del suelo después del incendio (Sánchez et al., 2019; Viedma et al., 2020), biodiversidad (Miller-Rushing et al., 2019) y también calidad del agua (Doerr et al., 2009; Viedma et al., 2020). Además, la gravedad de la quema afecta la heterogeneidad del paisaje, con implicaciones para la biodiversidad y los procesos de múltiples ecosistemas, incluidas las perturbaciones futuras (Collins et al., 2019). Dado el gran daño de los incendios, predecir con precisión la variabilidad espacial de la severidad de la quemas es esencial para priorizar áreas de manejo, obteniendo una cuantificación más precisa del balance de quema-vegetación y la predicción de impactos en el ecosistema (Shive et al., 2018).

Se ha demostrado que la gravedad de los incendios depende en gran medida tanto de la especie vegetal dominante como de la estructura del bosque (DeSiervo et al., 2015). La creciente disponibilidad de datos de detección (ópticos, SAR, y LIDAR) ofrece oportunidades para obtener información sobre la estructura horizontal y vertical de la vegetación antes del incendio, lo que puede ayudar a mejorar en gran medida nuestra comprensión de cómo la vegetación y los combustibles pueden gobernar la gravedad de la quema. No obstante, hasta este momento, si bien no es un tema novedoso, pero es poco aplicado sobre la severidad de las quemas en la Amazonia de Madre de Dios (distrito de Tahuamanu), los incendios no se han complementado con información con datos RADAR, aun cuando están disponibles.

Los patrones sinópticos asociados con grandes incendios de verano en la Amazonia están relacionados principalmente con la advección anómala de aire caliente y seco (Amraoui et al., 2015). El estrés hídrico y térmico de la vegetación, particularmente durante las olas de calor severas, está altamente correlacionado con la ocurrencia de los incendios más devastadores en la Amazonia (Lindner et al., 2010). Clima extremo de incendios; vientos fuertes, alta temperatura, baja humedad del aire, lo que aumenta la eficiencia de la transferencia de calor y la velocidad de propagación al tiempo que reduce la humedad del combustible (Cruz & Alexander, 2013), a menudo se considera que tiene una influencia predominante en la severidad del fuego y la quema (Bradstock et al., 2010; Coen et al., 2018). Para una comprensión altamente creíble del papel del clima en la severidad del fuego es necesario estudiar el impacto de diferentes variables a altas resoluciones temporales y espaciales, con una marcada atención a la velocidad y dirección del viento (Lahaye et al., 2018).

Otra consideración es la pavimentación de la carretera interoceánica, que permitirá el paso de más tráfico a través de la selva peruana de Madre de Dios. Los impactos negativos indirectos, son un costo de los beneficios de la carretera para la población (minería aurífera, tala ilegal, agricultura migratoria y de monocultivos, ganadería, entre otros). Del mismo modo, existe una mayor concentración de explotaciones agrícolas y ganaderas cerca de la costa del mar interior, lo que aumenta tanto la probabilidad de incendios forestales accidentales como el peligro de incendios intencionados. Se suma, las sequías severas, aumento de la población, y zonas deforestadas en el borde de la vía y la presencia de pastizales muy inflamable en la estación seca. El distrito de Tahuamanu se caracteriza por el desarrollo de actividades forestales como el aprovechamiento de la madera, de productos diferentes a la madera (castaña), actividades agrícolas y de ganadería. Sin embargo, las actividades formales, frecuente se ven amenazadas por la invasión de tierras por gente local y foráneas, que invaden concesiones castañeras y predios agrícolas titulados, donde los bosques primarios y secundarios se talan,

quemar y deforestan para agricultura y ganadería (Alarcón et al., 2016; Dourojeanni, 2014).

La detección en campo de la severidad de la quema a derivado a un costo relativamente alto, por lo que, ha llevado al uso generalizado de imágenes de detección remota para analizar grandes paisajes y determinar la severidad (Parks et al., 2014). Asimismo, existe un debate activo sobre cuál de los índices espectrales más utilizados es el más adecuado para estimar la gravedad del fuego y en qué condiciones (Harvey et al., 2019). Varios estudios han informado que el índice de combustión normalizado (NBR) y sus derivados, parecen ser los índices espectrales estándar más apropiados para estimar la severidad del fuego (Parks et al., 2014). Sin embargo, también se ha encontrado que en áreas heterogéneas, con alta presencia de arbustos y pastos, el NBR puede ser un mal predictor de las medidas de severidad de incendios basadas en el campo (Harvey et al., 2019; Viedma et al., 2020), debido a que la métrica de cambio absoluto está fuertemente correlacionado con la biomasa verde previa al incendio. Por lo tanto, las áreas con baja cobertura vegetal previa al incendio generalmente tendrán valores bajos, independientemente del grado de severidad del incendio (Parks et al., 2014).

La investigación propone un método alternativo, la estimación de la gravedad de las quemaduras por sensores a Radar de Apertura Sintética (SAR), que, a diferencia de los ópticos, es una tecnología que atraviesa nubes y humo, fundamental en este tipo de situaciones. Esta técnica utiliza energía de microondas para cuantificar y discernir entre procesos ecológicos, diferenciando la dispersión según la rugosidad de la superficie objetivo, y energía de microondas que recibe y procesa (Kasischke et al., 1997; Viedma et al., 2020), la pérdida de la vegetación por quemaduras experimenta variaciones de dispersión, mostrando la gravedad de la quemaduras (Mihai A. Tanase et al., 2015).

1.2 Formulación del problema

1.2.1 Problema general

¿Cuál fue la superficie y el nivel de gravedad de quemas a través de sensores de RADAR de Apertura Sintética (SAR) en el distrito de Tahuamanu – Madre de Dios, en el periodo 2020?

1.2.2 Problemas específicos

P.E1 ¿Cuánto será la superficie de área quemada a través de sensores de RADAR de Apertura Sintética (SAR) en el periodo 2020?

P.E.2 ¿Cuáles fueron los niveles de gravedad de quemas a través de sensores de RADAR de Apertura Sintética (SAR) en el periodo 2020?

1.3 Justificación e importancia

La aplicación de tecnologías de teledetección es facilitar la evaluación de recursos y eventos cada más precisos y a menor costo. Pero, implica el uso adecuado de procedimientos que garanticen su fiabilidad. Sin embargo, el uso de los SAR no es nuevo, pero tampoco de amplio conocimiento. La investigación a través del uso de los SAR, genera información única sobre el nivel de gravedad por quemas, debido, a que esta técnica consiste en alargar artificialmente la antena de un sensor para obtener imágenes de alta resolución aprovechando el movimiento del vuelo, para cuantificar y discernir entre procesos ecológicos, diferenciando la dispersión según la rugosidad de la superficie objetivo. La pérdida de la vegetación por quemas experimenta variaciones de dispersión, mostrando la gravedad de las quemas.

Esta investigación se centra en la clasificación de imágenes de radar de apertura sintética (SAR) utilizando una clasificación supervisada., estimando la gravedad y la deforestación por quemas en el distrito de Tahuamanu.

1.4 Objetivos de la investigación

1.4.1 Objetivo general

Estimar la superficie y nivel de gravedad de quemas a través de sensores de RADAR de Apertura Sintética (SAR) en el distrito de Tahuamanu – Madre de Dios, en el periodo 2020.

1.4.2 Objetivos específicos

O.E.1 Cuantificar la superficie de quemas a través de sensores de RADAR de Apertura Sintética (SAR) en el periodo 2020.

O.E.2 Estimar los niveles de gravedad de quemas a través de sensores de RADAR de Apertura Sintética (SAR) en el periodo 2020.

1.5 Hipótesis

Hipótesis nula (H_0): La superficie y nivel de gravedad de quemas a través de técnicas de procesamiento de imágenes de RADAR de Apertura Sintética (SAR) a través de predictores absolutos, relativos, y Relación de Quemas (RBR) por medio del Índice Degradación Forestal del RADAR (RDFI) no presenta un nivel de confiabilidad considerable y no sigue una tendencia creciente en el distrito de Tahuamanu – Madre de Dios.

Hipótesis alterna (H_1): La superficie y nivel de gravedad de quemas a través de técnicas de procesamiento de imágenes de RADAR de Apertura Sintética (SAR) a través de predictores absolutos, relativos, y Relación de Quemas (RBR) por medio del Índice Degradación Forestal del RADAR (RDFI) presenta un nivel de confiabilidad considerable y sigue una tendencia creciente en el distrito de Tahuamanu – Madre de Dios.

1.6 Variables de la investigación

1.6.1 Identificación de variables

Variable Dependiente

- ✓ Comportamiento de la vegetación pre y post incendio en función de la unidad mínima de la imagen (píxel).

Variable Independiente

- ✓ Cicatrices de quemas en el periodo 2020.

1.6.2 Operacionalización de variables

En la Tabla 1 se desglosan las variables y su operacionalización.

Tabla 1. *Variables e indicadores del estudio*

Objetivo	Variable	Dimensión	Indicadores	Finalidad
Cuantificar la superficie de quemas a través de sensores de RADAR de Apertura Sintética (SAR) en el periodo 2020	Área de cicatriz de quema	Área de cicatriz de quema a través de SAR	1. Superficie total 2. Validación	Determinar la superficie por quemas en el distrito de Tahuamanu a través de SAR
Estimar los niveles de gravedad de quemas a través de sensores de RADAR de Apertura Sintética (SAR) en el periodo 2020.	Área de cicatriz de quema	Área de cicatriz de quemas por niveles de gravedad	1. Nivel de gravedad de quema 2. Validación	Estimar los niveles de gravedad de quemas en el distrito de Tahuamanu a través de SAR

1.7 Consideraciones éticas

La investigación empleará aspectos metodológicos derivados del procesado de imágenes de RADAR de Apertura Sintética (SAR) con la plataforma abierta SNAP ESA y el software Google Earth Engine, así como ENVI 5.3®, ArcGisPro 2.1®, y ArcGIS 10.5® de CETEGERN.

El estudiante y los colaboradores sólo utilizarán la licencia CETEGERN y no tendrán acceso a las instalaciones de la Universidad Nacional Amazónica de Madre de Dios por razones de seguridad.

La investigación se adhiere a la política marco de la Comisión Nacional de Investigación y Desarrollo Aeroespacial (CONIDA), establecida por el Decreto Ley N° 20643.

En cuanto a la validación de campo, se seguirán todos los protocolos de seguridad del COVID19 en cuanto a transporte, alimentación y, de ser necesario, entrevistas

CAPÍTULO II: MARCO TEÓRICO

2.1 Antecedentes de la investigación

Addison and Oommen (2018) “determinaron la eficacia del uso de sensores remotos de radar satelital para estimar la gravedad de las quemas en el oeste de EE. UU, los resultados mostraron que el enfoque SAR produce métricas más altas en comparación con el dNBR”. La precisión global y kappa fueron de 60% y 0,35, respectivamente, en comparación con el 35% y 0,1 del enfoque dNBR” (Addison & Oommen, 2018). “Las diferencias más pequeñas en los valores de retrodispersión para los datos previos y posteriores al incendio se traducen en una menor gravedad de las quemas y viceversa” (Addison & Oommen, 2018). “Esto fue intuitivo porque para una gravedad baja, el paisaje no habría experimentado muchos cambios, lo que se traduciría en diferencias más bajas en la dispersión de las señales de radar y, en consecuencia, diferencias más bajas en los valores de retrodispersión” (Addison & Oommen, 2018). “Otro descubrimiento digno de mención fue que la presencia de bosques siempre verdes parecía limitar la gravedad de los incendios” (Addison & Oommen, 2018).

Verhegghen et al. (2016), evaluaron si los satélites Sentinel-1 pueden utilizarse para cartografiar y vigilar los incendios forestales en la cuenca del Congo, entonces podrían. Las zonas quemadas cartografiadas por los sensores SAR S1 demuestran que la mayoría de los incendios se produjeron en bosques de Marantaceae. Estos bosques tienen un dosel abierto y una extensa capa de plantas herbáceas altas. Los mapas revelan una correlación entre el origen de los incendios y la accesibilidad de los bosques, lo que sugiere una causa antropogénica (Verhegghen et al., 2016).

M. A. Tanase et al. (2015) “mostraron un método innovador para estimar la gravedad de los incendios mediante la combinación de conjuntos de datos de SAR previos y posteriores al incendio dentro de un marco de detección de

cambios para calcular un índice novedoso, el Radar Burn Ratio (RBR)” (M. A. Tanase et al., 2015). “Asimismo, se desarrolló y probó un RBR estandarizado en siete bosques templados ubicados en tres continentes con valores de biomasa aérea que oscilan entre 30 y más de 500 t ha⁻¹” (M. A. Tanase et al., 2015). “La estandarización de RBR permitió definir umbrales comunes y utilizarlos posteriormente para estimar el índice de combustión compuesto (CBI, una medida del impacto del fuego) sin la necesidad de información a priori sobre las condiciones locales posteriores al incendio” (M. A. Tanase et al., 2015). “La precisión de la estimación de la RBR estandarizada se comparó con modelos empíricos calibrados localmente basados en datos de CBI de campo” (M. A. Tanase et al., 2015). “Los resultados mostraron errores de estimación similares y un fuerte acuerdo con los datos in situ de referencia (es decir, kappa ponderado de Cohen > 0,61)” (M. A. Tanase et al., 2015). “El índice RBR más sensible a la severidad del fuego se basó en el canal de polarización cruzada aplicado en condiciones ambientales secas” (M. A. Tanase et al., 2015). “En condiciones húmedas, la precisión de la estimación fue considerablemente menor” (M. A. Tanase et al., 2015). “Los métodos propuestos en este estudio son particularmente valiosos para evaluaciones rápidas de la severidad del fuego a escalas regional a global” (M. A. Tanase et al., 2015), “requiriendo solamente que los umbrales RBR sean calibrados para una variedad de ambientes y que las puntuaciones CBI estén relacionadas con el consumo de combustible para cada tipo de bosque” (M. A. Tanase et al., 2015).

Polychronaki et al. (2013) “evaluaron el potencial de las imágenes del radar de apertura sintética de banda L (PALSAR) del satélite de observación terrestre avanzada (ALOS) Phased Array para mapear áreas quemadas en dos áreas de estudio en Grecia”. “Para este propósito, desarrollamos un esquema de clasificación basado en objetos para mapear las áreas perturbadas por el fuego utilizando las imágenes PALSAR adquiridas antes y poco después de los incendios” (Polychronaki et al., 2013). “El enfoque basado en objetos no solo fue el uso de la variación temporal del coeficiente de retrodispersión, incorpora en la clasificación de características topológicas, como objetos vecinos, y características relacionadas con la clase, como

objetos clasificados como quemados” (Polychronaki et al., 2013). “El esquema de clasificación resultó en el mapeo de las áreas quemadas con resultados satisfactorios: 0,71 y 0,82 probabilidades de detección para las dos áreas de estudio” (Polychronaki et al., 2013). “Concluyeron que las condiciones de la vegetación previas al incendio y la severidad del incendio deben tenerse en cuenta al mapear áreas quemadas usando PALSAR en las regiones mediterráneas” (Polychronaki et al., 2013). “En general, los hallazgos sugieren que el método podría aplicarse en una evaluación rápida de áreas quemadas, especialmente en áreas donde la cobertura de nubes y el humo del fuego inhiben el mapeo de áreas quemadas respecto a datos ópticos” (Polychronaki et al., 2013).

Bernhard et al. (2011) “muestra el potencial de los datos SAR en banda X para cartografiar los incendios forestales en la región mediterránea europea, la señal detectada de polarizaciones VV y HH mostró valores más altos en imágenes adquiridas después de los incendios”. “Sin embargo, los datos polarizados VV mostraron una mayor amplitud entre los niveles de retrodispersión antes y después del desastre que los datos polarizados HH” (Bernhard et al., 2011). “El resultado de la clasificación ha sido validado por los datos de SPOT 5 y logró una precisión general del 77,9%, por lo tanto, la detección de áreas quemadas con datos SAR” (Bernhard et al., 2011).

Tanase, Santoro, de La Riva, et al. (2010) investigaron los “datos del radar de apertura sintética (SAR) en las bandas X, C y L para determinar la relación entre la retrodispersión y la gravedad de las quemaduras de bosques en tres lugares de España”. Analizaron la dependencia de la retrodispersión SAR del ángulo de incidencia local y las condiciones ambientales. En las polarizaciones HH y VV, la retrodispersión en banda X y C aumentó con la gravedad de la quemadura, mientras que la retrodispersión en banda L disminuyó. La retrodispersión de polarización cruzada (HV) disminuyó con la gravedad de la quemadura para todas las frecuencias. Para datos copolarizados en bandas X y C, se observaron coeficientes de determinación más altos para pendientes orientadas hacia los sensores, mientras para datos con polarización cruzada, los coeficientes de determinación fueron más altos

para pendientes orientadas lejos del sensor” (Tanase, Santoro, de La Riva, et al., 2010). “En la banda L, la fuerza de asociación de los datos de polarización cruzada con la gravedad de la quemadura fue alta para todos los ángulos de incidencia local” (Tanase, Santoro, de La Riva, et al., 2010). La retrodispersión polarizada cruzada en bandas C y L mostró un mejor potencial para la estimación de la gravedad de las quemaduras en el entorno mediterráneo cuando se tiene en cuenta el ángulo de incidencia local (Tanase, Santoro, de La Riva, et al., 2010).

Tanase, Santoro, Wegmüller, et al. (2010) investigó la relación entre la gravedad de las quemaduras y la coherencia interferométrica en tres lugares afectados por incendios forestales en un entorno mediterráneo montañoso utilizando datos de radar de apertura sintética (SAR) (Tanase, Santoro, Wegmüller, et al., 2010). Las imágenes SAR de repetición estaban disponibles en los sensores TerraSAR-X, ERS-1/2, Envisat ASAR y ALOS PALSAR, se midió la gravedad de las quemaduras (Índice de quemaduras compuesto) y aplicación del índice de razón de quemaduras normalizada diferenciada (dNBR) (Tanase, Santoro, Wegmüller, et al., 2010). Los resultados del análisis mostraron que, tanto en la banda X como en la C, la coherencia copolarizada aumenta con el incremento de la gravedad de la quemadura, mientras que la coherencia de polarización cruzada fue en gran medida insensible a la gravedad de la quemadura (Tanase, Santoro, Wegmüller, et al., 2010). Se encontró una mayor sensibilidad a la gravedad de las quemaduras en la banda L tanto para los canales copolarizados como cruzados (Tanase, Santoro, Wegmüller, et al., 2010). La fuerza de asociación entre coherencia y severidad de la quemadura fue más fuerte en condiciones ambientales estables y secas (Tanase, Santoro, Wegmüller, et al., 2010). La intensidad de la asociación con la gravedad de las quemaduras en la banda L fue menos sensible al ángulo de incidencia local (Tanase, Santoro, Wegmüller, et al., 2010).

Gimeno et al. (2004) “investiga el potencial de los datos SAR espaciales multitemporales para monitorear la recuperación de la vegetación en áreas quemadas próximas a la costa mediterránea, con imágenes ERS-SAR, banda C y polarización VV, tomadas sobre el pinar de Castel Fusano, cerca de

Roma, Italia”. “El análisis, tanto en áreas quemadas y no quemadas, de las firmas de retrodispersión interanual multitemporal, el estudio presenta dos enfoques diferentes, uno más cualitativo y otro más cuantitativo, para la recuperación del rebrote de biomasa después del incendio” (Gimeno et al., 2004). “En el caso cuantitativo, el procedimiento de inversión calcula la tasa de recrecimiento de la biomasa mediante simulaciones realizadas con el modelo de dispersión de Tor Vergata” (Gimeno et al., 2004)

2.2 Marco teórico

2.2.1 Comportamiento del fuego

Comprender los principios básicos del comportamiento del fuego es fundamental para la evaluación de incendios. La capacidad de recrear la propagación probable del fuego, basada en el conocimiento de estos principios ayudará enormemente al investigador a identificar e interpretar correctamente los indicadores de dirección del fuego y los patrones generales de quema (Handbook, 2005; Hernández, 2019).

Para que ocurra un incendio forestal, una fuente de ignición debe entrar en contacto con el combustible anfitrión y tener suficiente calor para elevarlo a su temperatura de ignición (Handbook, 2005). El lugar donde esta fuente de ignición entra en contacto con el material que se incendió por primera vez y se produce una combustión sostenida se denomina punto de origen (Handbook, 2005). Cualquier resto físico de la fuente de ignición probablemente estará ubicado en este punto preciso (Handbook, 2005). Después de la ignición, el fuego progresará hacia afuera desde el punto de origen (Handbook, 2005). La propagación inicial del fuego será generalmente circular hasta que el fuego caiga bajo la influencia del viento, la pendiente y/o los combustibles (Handbook, 2005). Por lo general, presentará una menor intensidad y una propagación más lenta en esta primera fase de combustión (Handbook, 2005). Esta área que rodea inmediatamente al punto de origen se denomina origen específico. Debido a la menor intensidad asociada con esta área, a menudo se caracteriza por la presencia de más material sin quemar

(Handbook, 2005). A medida que el fuego se ve afectado por los diversos factores de comportamiento del fuego, comenzará a extenderse con intensidades y velocidades desiguales (Handbook, 2005). Esta área se conoce como el área de origen general. El fuego ahora exhibirá diferentes áreas de progresión. Estas áreas de progresión estarán marcadas por indicadores de dirección del fuego que mostrarán una característica vectorial distinta (Handbook, 2005; Hernández, 2019).

Del mismo modo, existen pruebas de que la inmensa mayoría de los incendios forestales se inician deliberadamente en condiciones controladas, la mayoría de ellos con fines silvícolas, mientras que sólo un 10% de los incendios son naturales, provocados por rayos y relámpagos (Rodríguez, 2000).

Factores de comportamiento del fuego

Un incendio forestal está influenciado por tres elementos principales. Estos son el clima, la topografía y los combustibles. Cada uno de estos elementos tiene varias subelementos. Es la combinación de estos elementos la que forma el triángulo de comportamiento del fuego. Comprender cómo interactúan y afectan la formación de los indicadores de dirección del fuego es crucial para interpretar correctamente el patrón de quema de un incendio forestal (Handbook, 2005; Hernández, 2019).

Clima: el viento, la temperatura y la humedad relativa son los tres componentes que componen el clima. El viento normalmente tiene el mayor efecto de todos los elementos en la propagación e intensidad del fuego. El fuego que se mueve con el viento arde más rápido que un fuego que retrocede contra el viento. Podrá observar la diferencia en los patrones de quemado y la cantidad de combustible consumido. Después de que el fuego alcance cierto tamaño, comenzará a crear su propio viento y arderá aún más rápido que antes. Los incendios generalmente se detectarán antes del incendio principal en la dirección en la que sopla el viento (Handbook, 2005; Hernández, 2019).

La humedad relativa afecta directamente la probabilidad de ignición y la intensidad del fuego. La humedad relativa también controla la humedad fina

del combustible muerto, particularmente en las categorías de combustible con retraso de una y diez horas (Handbook, 2005; Hernández, 2019).

La temperatura influye en el comportamiento del fuego por el efecto de secado y precalentamiento que tiene sobre los combustibles. Los patrones climáticos pueden cambiar rápidamente. Un cambio en la dirección del viento puede afectar sustancialmente los patrones de quema (Handbook, 2005; Hernández, 2019).

Topografía: La topografía consta de pendiente, aspecto y terreno. Después del viento, la pendiente es la siguiente mayor influencia potencial en la velocidad y dirección de propagación del fuego. Los incendios arderán más rápido cuesta arriba que cuesta abajo debido al precalentamiento de los combustibles cuesta arriba y a la influencia de los vientos diurnos de subida y bajada del cañón. Un fuego que retrocede cuesta abajo normalmente se moverá más lento que un fuego que avanza cuesta arriba. También es necesario considerar el aspecto de la pendiente. Generalmente, las laderas orientadas al sur exhiben mayor intensidad y tasas de propagación más rápidas (Lo contrario de esto es cierto para los incendios en el hemisferio sur) (Handbook, 2005; Hernández, 2019).

El terreno también puede afectar tanto la intensidad como la velocidad de propagación, particularmente cuando hay barreras o chimeneas naturales presentes. Las barreras, como un tronco, tierra desnuda o rocas, pueden hacer que el fuego disminuya o incluso se apague. Casi cualquier barrera al menos reducirá la intensidad del fuego a medida que pasa. Las barreras más grandes a menudo provocan remolinos de viento que pueden cambiar la dirección del fuego, al menos en distancias cortas. No confunda el efecto del cambio temporal de una barrera en la dirección de un incendio con la dirección real de donde proviene el incendio. Las chimeneas naturales pueden aumentar la velocidad del viento y acelerar la propagación del fuego y aumentar la intensidad sustancialmente (Handbook, 2005; Hernández, 2019).

2.2.2 Deforestación

La deforestación es la tala a gran escala de árboles en los bosques. Los árboles generalmente se eliminan para dar paso a la agricultura, las carreteras y el desarrollo urbano. No toda la deforestación es intencional, ya que algunos casos pueden ser causados por una combinación de factores naturales y humanos como los incendios forestales (FAO, 2016; Leite-Filho et al., 2020).

La deforestación ha tenido serios efectos ambientales. Si bien los bosques todavía representan el 30 por ciento de la Tierra, cada año se pierden aproximadamente 7,3 millones de hectáreas de bosque debido a las prácticas de deforestación. Esto ha causado daños a la tierra y al suelo, al tiempo que ha desplazado a plantas y animales que dependen del ecosistema creado por los bosques. Al mismo tiempo, la remoción de árboles significa que se liberan más gases de efecto invernadero a la atmósfera, ya que los árboles juegan un papel importante en el ciclo del carbono como absorbentes de dióxido de carbono. La tala de árboles también puede afectar los medios de vida porque las personas dependen de los bosques para obtener refugio, agua, combustible, seguridad alimentaria y empleo. La protección de nuestros bosques es extremadamente importante para limitar el impacto de estos efectos y garantizar un futuro sostenible (FAO, 2016; Leite-Filho et al., 2020).

2.2.3 Bosque

“Árboles de al menos 5 metros de altura y con una cubierta de copas de al menos el 10%, o árboles capaces de alcanzar esta altura in situ, en una parcela de más de 0,5 hectáreas” (FAO, 2016), excluyendo a áreas con uso predominantemente agrícola o urbano (FAO, 2016).

2.2.4 Sistemas de Información Geográfica (SIG)

Los sistemas de información geográfica (SIG) son marcos informáticos para el almacenamiento, manipulación, análisis, gestión y visualización de información referenciada geográficamente. La geografía, característica definitoria de esta tecnología, denota que algunos de los datos son de

naturaleza geográfica. Concretamente, información basada en la localización (Jiang, 2020).

Estos datos suelen ir acompañados de datos tabulares de atributos. Los datos de atributos suelen describir características espaciales. Los datos espaciales representan la ubicación real de los colegios. Los datos de atributos incluirían información adicional como el nombre del centro, el nivel de enseñanza impartido y la capacidad de los alumnos (Jiang, 2020). La combinación de estos dos tipos de datos permite que los SIG sean una herramienta tan poderosa para resolver problemas mediante el análisis espacial (Jiang, 2020).

Los SIG son más que un simple programa informático. Para realizar análisis espaciales, permite gestionar y elaborar mapas y gráficos de grandes conjuntos de datos, se combinan personas y métodos con programas y herramientas geoespaciales (Jiang, 2020).

2.2.5 Sensoramiento remoto

El sensoramiento remoto es la ciencia de adquirir, procesar e interpretar imágenes que registran la interacción entre la energía electromagnética y la materia (Jensen, 2009; Kerle et al., 2004).

También es el estudio de cómo aprender cosas sobre algo sin tocarlo nunca mediante el análisis de los datos recogidos por un dispositivo colocado a distancia (Jensen, 2009; Kerle et al., 2004).

Las dos definiciones tienen en común que los datos sobre las características de la superficie de la Tierra se adquieren mediante un dispositivo que no está en contacto con los objetos que se miden. El resultado generalmente se almacena como datos de imagen. Las características medidas por un sensor son la energía electromagnética reflejada o emitida por la superficie de la Tierra. Esta energía se relaciona con algunas partes específicas del espectro electromagnético: generalmente luz visible, pero también puede ser luz infrarroja u ondas de radio. Existe una amplia gama de sensores de teledetección. Los sensores, vinculados a una determinada plataforma, se clasifican según su distancia a la superficie de la Tierra: sensores aéreos y

espaciales. Juntos, contribuyen a la prospección aeroespacial, que es el uso combinado de métodos de teledetección y terrestres para recopilar información (Jensen, 2009; Kerle et al., 2004).

Otro término para introducir aquí es Observación de la Tierra (OT), que generalmente se refiere a la teledetección espacial. Antes de que los datos de la imagen puedan proporcionar la información requerida sobre los objetos o fenómenos de interés, deben procesarse. El análisis y la extracción de información o la producción de información es parte del proceso general de teledetección (Jensen, 2009; Kerle et al., 2004).

2.2.6 Energía electromagnética

La teledetección se basa en la medición de energía electromagnética (EM). La energía EM puede tomar varias formas diferentes. La fuente más importante de energía electromagnética en la superficie de la Tierra es el Sol, que nos proporciona, por ejemplo, luz (visible), calor (que podemos sentir) y luz ultravioleta, que puede ser dañina para nuestra piel (Jensen, 2009; Kerle et al., 2004).




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

Fuente: Kerle et al. (2004).

Muchos sensores utilizados en la teledetección miden la luz solar reflejada. Sin embargo, algunos sensores detectan la energía emitida por la propia Tierra o proporcionan su propia energía (Figura 1). Se requiere un

conocimiento básico de la energía EM, sus características y sus interacciones para comprender el principio del sensor remoto. Este conocimiento también es necesario para interpretar correctamente los datos de teledetección. Entre el sensor remoto y la superficie de la Tierra está la atmósfera que influye en la energía que viaja desde la superficie de la Tierra hasta el sensor (Jensen, 2009; Kerle et al., 2004).

La energía electromagnética (EM) se puede modelar de dos formas: mediante ondas o mediante partículas portadoras de energía llamadas fotones. En el modelo de ondas, se considera que la energía electromagnética se propaga a través del espacio en forma de ondas sinusoidales. Estas ondas se caracterizan por dos campos, campos eléctricos (E) y magnéticos (M), que son perpendiculares entre sí. Por esta razón, se utiliza el término energía electromagnética. La vibración de ambos campos es perpendicular a la dirección de viaje de la onda (Figura 2). Ambos campos se propagan a través del espacio a la velocidad de la luz c , que es de 299,790,000 m/s y puede redondearse a 3108 m/s (Jensen, 2009; Kerle et al., 2004).




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

Fuente: Kerle et al. (2004).

La longitud de onda -la distancia entre las crestas de las ondas- es crucial para la teledetección (Figura 3). “Para medir la longitud de onda se utilizan nanómetros (nm, 10^{-9} m) y micrómetros (μm , 10^{-6} m), la frecuencia, ν , es el número de ondas que pasan por un punto fijo en un tiempo determinado” (Jensen, 2009; Kerle et al., 2004). El hercio (Hz) es la unidad estándar de

frecuencia. La velocidad de la luz es constante (Jensen, 2009; Kerle et al., 2004).




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

Fuente: Kerle et al. (2004).

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




Figura 4. El espectro electromagnético.

Fuente: Kerle et al. (2004).

En teledetección se utilizan varias bandas del espectro electromagnético. La parte óptica del espectro EM se refiere a la parte del espectro EM en la que se pueden aplicar las leyes ópticas. Estos se relacionan con fenómenos, como la reflectancia y la refracción, que se pueden utilizar para enfocar la radiación.

El rango óptico se extiende desde los rayos X ($0,02 \mu\text{m}$) a través de la parte visible del espectro EM hasta e incluyendo el infrarrojo lejano ($1000 \mu\text{m}$). En términos de longitud de onda, la región ultravioleta (UV) del espectro contiene las longitudes de onda más cortas que pueden utilizarse para la teledetección. Este espectro de luz se extiende más allá del extremo violeta del espectro visible. Cuando se exponen a la luz ultravioleta, algunas de las rocas y minerales básicos que componen la superficie de la Tierra emiten luz visible o fluorescente. La gama de microondas cubre longitudes de onda de 1 mm a 1 m. La región visible del espectro (Figura 4) se denomina comúnmente "luz". Ocupa una porción relativamente pequeña en el espectro EM. Esta es la única parte del espectro que tiene algún significado en términos de percepción del color. Los colores primarios, o longitudes de onda de la luz visible, son el azul, el verde y el rojo (Jensen, 2009; Kerle et al., 2004).

Las longitudes de onda más largas utilizadas para la detección remota se encuentran en las regiones de infrarrojos térmicos y microondas. El infrarrojo térmico proporciona información sobre la temperatura de la superficie. La temperatura de la superficie puede estar relacionada, por ejemplo, con la composición mineral de las rocas o el estado de la vegetación. Las microondas pueden proporcionar información sobre la rugosidad de la superficie y las propiedades de la superficie, como el contenido de agua (Jensen, 2009; Kerle et al., 2004).

2.2.7 Teledetección activa y pasiva

En la teledetección, el sensor mide la energía. Se distinguen técnicas pasivas y activas. Las técnicas de percepción remota pasiva emplean fuentes naturales de energía, como el sol. Las técnicas activas de teledetección, por ejemplo, el radar y el láser, tienen su propia fuente de energía. Los sensores activos emiten un rayo de energía controlado a la superficie y miden la cantidad de energía reflejada al sensor (Figura 1). Los sistemas de sensores pasivos basados en el reflejo de la energía del sol solo pueden funcionar durante el día. Los sistemas de sensores pasivos que miden las longitudes de onda más largas relacionadas con la temperatura de la Tierra no dependen

del Sol como fuente de iluminación y se pueden operar en cualquier momento. Los sistemas de sensores pasivos deben lidiar con las diferentes condiciones de iluminación del Sol, que están muy influenciadas por las condiciones atmosféricas. La principal ventaja de los sistemas de sensores activos es que pueden funcionar día y noche y tienen una señal de iluminación controlada (Jensen, 2009; Kerle et al., 2004).

2.2.8 Plataforma y sensores

Dependiendo de las características de la superficie, la energía electromagnética del Sol o del sensor activo se refleja o la propia Tierra puede emitir energía. Esta energía se mide y registra los datos resultantes se pueden utilizar para obtener información sobre las características de la superficie (Jensen, 2009; Kerle et al., 2004).

Las mediciones de la energía electromagnética se realizan mediante sensores que están conectados a una plataforma estática o en movimiento. Se han desarrollado diferentes tipos de sensores para diferentes aplicaciones. Las aeronaves y los satélites se utilizan generalmente para transportar uno o más sensores (Jensen, 2009; Kerle et al., 2004).

La combinación sensor-plataforma determina las características de los datos de imagen resultantes. Por ejemplo, cuando un sensor en particular se opera desde una altitud mayor, el área total de la imagen aumenta mientras que el nivel de detalle que se puede observar se reduce. Según sus necesidades de información y los criterios de tiempo y presupuesto, puede determinar qué datos de imagen son los más apropiados (Jensen, 2009; Kerle et al., 2004).

Sensores

Los sensores registran la energía electromagnética. Existen dos grupos de sensores. El Sol alimenta los sensores pasivos (aunque a veces es la propia Tierra). El grupo de sensores pasivos abarca el espectro electromagnético desde los picómetros (rayos gamma) hasta los metros (microondas y ondas de radio). Las cámaras son sensores pasivos. Sensores activos autoalimentados Los sensores activos son más precisos porque no dependen

de la iluminación. Entre los sensores activos se encuentran los radares y los altímetros láseres infrarrojos. Los tipos de sensores se resumen en la Figura 5 (Jensen, 2009; Kerle et al., 2004).

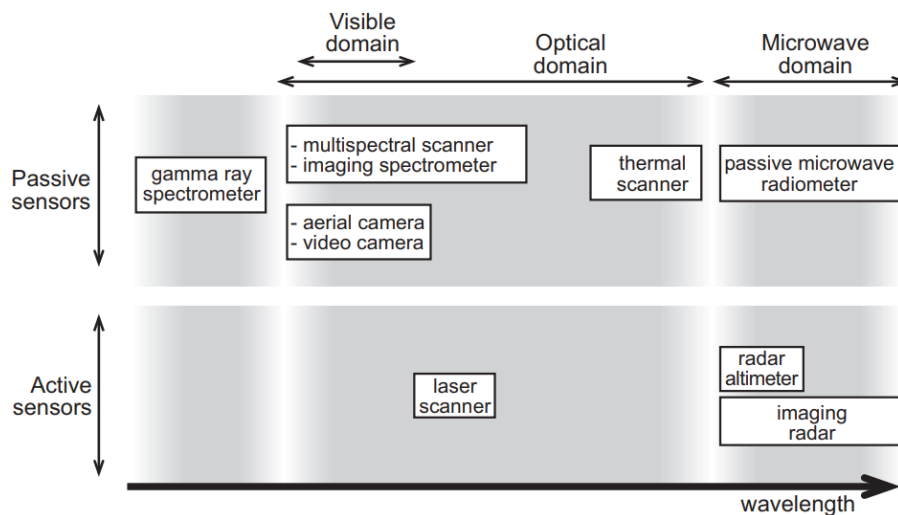


Figura 5. Descripción general de los sensores.

Fuente: Kerle et al. (2004).

Plataformas

Los sensores remotos están montados en plataformas. Los satélites y los aviones llevan sensores de teledetección. Las plataformas experimentales a veces son estáticas. Un sensor multiespectral montado en un poste puede medir la reflectancia de los cultivos a lo largo del día o de la estación (Jensen, 2009; Kerle et al., 2004).

Las aeronaves equipadas con sensores realizan observaciones aéreas. Las aeronaves con cámaras o escáneres aéreos necesitan agujeros en el suelo. La teledetección aérea utiliza VUL, globos, dirigibles o cometas. Una altitud de 100 m-30-40 km permite realizar observaciones aéreas. Hasta hace poco, la navegación de las aeronaves era uno de los principales retos de la teledetección aérea. La navegación por satélite ha mejorado el rendimiento de los vuelos en los últimos años. Los satélites realizan la teledetección desde el espacio. Los cohetes lanzan satélites (Jensen, 2009; Kerle et al., 2004).

2.2.9 Escáneres multiespectrales

Los escáneres multiespectrales exploran la superficie terrestre para medir la energía electromagnética reflejada. Los píxeles forman datos de imagen digital. Las mediciones multiespectrales abarcan todo el espectro electromagnético. Desde 1972, año del lanzamiento de Landsat, la teledetección utiliza escáneres multiespectrales. Es el segundo sensor más utilizado. Los datos de los escáneres multiespectrales se utilizan para cartografiar la cubierta terrestre, la vegetación, la mineralogía y las aguas superficiales (Jensen, 2009; Kerle et al., 2004).

“Existen dos tipos de escáneres multiespectrales: escáneres de barrido y escáneres de escena. Los escáneres multiespectrales se instalan en aviones y naves espaciales” Sentinel (Jensen, 2009; Kerle et al., 2004). Entre los escáneres más comunes, aunque no necesariamente los más importantes, se encuentran Meteosat, NOAA, Landsat, SPOT, IRS, IKONOS, Terra, EO y Sentinel (Jensen, 2009; Kerle et al., 2004).

2.2.10 RADAR

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

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

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

Los sensores RADAR pertenecen al grupo de sensores de microondas de imágenes activas más utilizados. El término RADAR es un acrónimo de Radio Detection and Ranging. Radio significa microondas y rango es otro término para distancia. Los sensores de radar fueron desarrollados y utilizados originalmente por los militares (Jensen, 2009; Kerle et al., 2004).

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

Geometría de visualización de radar

Los sensores de radar son instrumentos que miran hacia los lados. La parte de la imagen que está más cerca de la trayectoria nadir del satélite que transporta el radar se llama rango cercano. La parte de la imagen que está más alejada del nadir se denomina rango lejano (Jensen, 2009; Kerle et al., 2004).

El ángulo de incidencia del sistema se define como el ángulo entre el haz del radar y la vertical local. Moviéndose de un rango cercano a otro lejano, el ángulo de incidencia aumenta. Es importante distinguir entre el ángulo de incidencia del sensor y el ángulo de incidencia local, que difiere según la

pendiente del terreno y la curvatura de la tierra (Figura 6). Se define como el ángulo entre el haz del radar y la normal de la superficie local. El sensor de radar mide la distancia entre la antena y el objeto. Esta línea se llama rango inclinado. Pero la verdadera distancia horizontal a lo largo del suelo correspondiente a cada punto de medición en el rango inclinado se llama rango del suelo (Figura 7) (Jensen, 2009; Kerle et al., 2004).




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

Las señales transmitidas y retrodispersadas crean imágenes de teledetección por radar. El radar de apertura real crea una imagen a partir de cada pulso transmitido. La longitud del pulso y la anchura del haz de la antena determinan las resoluciones espaciales oblicua y acimutal. Las resoluciones espaciales oblicua y azimutal difieren debido a los distintos parámetros que las determinan. El remuestreo de las imágenes de radar a un espaciado regular de píxeles en ambas direcciones ayuda al procesamiento y la interpretación (Jensen, 2009; Kerle et al., 2004).

Radar de Apertura Sintética (SAR)

Existe un límite físico para la longitud de la antena, la apertura que se puede llevar en un avión o satélite. Por otro lado, acortar la longitud de onda tiene sus limitaciones para penetrar en las nubes. Por lo tanto, se aplica un enfoque en el que la apertura aumenta sintéticamente. Los sistemas que utilizan este enfoque se denominan radar de apertura sintética (SAR). La sintetización de

la longitud de la antena se logra aprovechando el movimiento hacia adelante de la plataforma y utilizando varias señales retrodispersadas que incluyen el mismo objeto para simular una antena muy larga. La mayoría de los sistemas de radar aerotransportados y espaciales utilizan este tipo de radar (Jensen, 2009; Kerle et al., 2004).

Distorsiones en imágenes de radar

“Las imágenes de radar están sujetas a graves distorsiones geométricas y radiométricas debidas a la geometría de visualización lateral” (Jensen, 2009; Kerle et al., 2004). En las imágenes de radar (elevación del terreno) se producen variaciones de escala (conversión del alcance oblicuo en alcance terrestre), escorzos, escalas y sombras. Los efectos de moteado se deben a las interferencias causadas por la coherencia de la señal (Jensen, 2009; Kerle et al., 2004).

Clasificación de imágenes digitales

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

La aplicación de la clasificación de imágenes se encuentra en muchos proyectos a escala regional. En Asia, la Asociación Asiática de Percepción Remota (AARS) está generando varios conjuntos de datos de cobertura terrestre basados en la clasificación (no) supervisada de datos satelitales multiespectrales. En el proyecto Africover (de la FAO), se están utilizando

técnicas de clasificación de imágenes para establecer un conjunto de datos de cobertura terrestre panafricana. La Comisión Europea requiere que los gobiernos nacionales verifiquen las afirmaciones de los agricultores relacionadas con los cultivos subvencionados. Estos gobiernos nacionales emplean empresas para hacer un primer inventario, utilizando técnicas de clasificación de imágenes, que es seguido por controles de campo (Jensen, 2009; Kerle et al., 2004).

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

Clasificación de imágenes

Las imágenes muestran la distribución del valor de los píxeles en bandas. Los vectores de las clases de cobertura del suelo se trazan en muestras espaciales. Cada clase de vectores de características ocupa una zona del espacio de características. “La clase corresponde a la región del espacio de características. Cada píxel de la imagen puede compararse con las clases del espacio de características y asignarse a una clase” (Jensen, 2009; Kerle et al., 2004).

Las imágenes pueden clasificarse en categorías comparando sus características espectrales entre sí. Por ejemplo, la comparación de las curvas de reflectancia espectral puede arrojar luz al respecto (Jensen, 2009; Kerle et al., 2004).

La clasificación de imágenes asigna píxeles a clases comparando sus vectores de características con grupos predefinidos del espacio de características. Al clasificar todos los píxeles se obtiene una imagen. La clasificación de imágenes requiere clusters y métodos de comparación de imágenes con grupos predefinidos. El entrenamiento implica la definición interactiva de clusters. Los algoritmos de clasificación comparan los píxeles (Jensen, 2009; Kerle et al., 2004).

Proceso de clasificación de imágenes

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

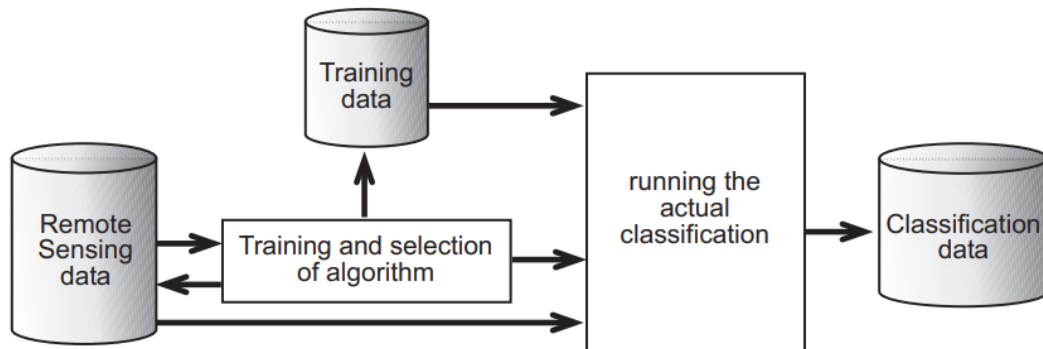


Figura 8. El proceso de clasificación; El componente más importante es el entrenamiento en combinación con la selección del algoritmo.

Fuente: Kerle et al. (2004).

Clasificación de imágenes supervisada

Uno de los pasos principales en la clasificación de imágenes es la "partición" del espacio de funciones. En la clasificación supervisada, esto lo realiza un operador que define las características espectrales de las clases identificando áreas de muestra (áreas de entrenamiento) (Jensen, 2009; Kerle et al., 2004).

La clasificación supervisada requiere que el operador esté familiarizado con el área de interés. El operador necesita saber dónde encontrar las clases de interés en el área cubierta por la imagen. Esta información puede derivarse de "conocimientos generales del área" o de observaciones de campo específicas. Una muestra de una clase específica, que consta de varios píxeles de entrenamiento, forma un grupo en el espacio de características. Los clústeres, seleccionados por el operador (Jensen, 2009; Kerle et al., 2004):

- ✓ Debe formar un conjunto de datos representativo para una clase determinada; esto significa que debe tenerse en cuenta la variabilidad de una clase dentro de la imagen. Además, en sentido absoluto, se

requiere un número mínimo de observaciones por grupo. Aunque depende del algoritmo clasificador que se utilice, una regla práctica útil es $30 \times n$ (n = número de bandas).

- ✓ No debe superponerse o superponerse de forma limitada con los otros grupos, de lo contrario, no es posible una separación fiable. Al utilizar un conjunto de datos específico, algunas clases pueden tener una superposición espectral significativa, lo que, en principio, significa que estas clases no pueden discriminarse por clasificación de imágenes. Las soluciones son agregar otras bandas espectrales y/o agregar datos de imagen adquiridos en otros momentos.

Algoritmos de clasificación

La aplicación de un algoritmo de clasificación a conjuntos de muestras de entrenamiento clasifica las imágenes. Existen algoritmos de clasificación. El objetivo de la clasificación, la imagen y los datos de entrenamiento determinan el algoritmo. El operador decide si se admiten clases "rechazadas" o "desconocidas". A continuación se presentan tres algoritmos de clasificación. Para simplificar el concepto, se explica primero el clasificador de caja. Los clasificadores de caja rara vez se utilizan. Se utilizarán algoritmos de predicción basados en índices para índices de quemas absolutos y relativos en imágenes SAR. (Jensen, 2009; Kerle et al., 2004).

2.2.11 Software de procesamiento de imágenes

SNAP ESA

La extensibilidad, la portabilidad, la plataforma cliente rica en módulos, la abstracción genérica de datos de observación de la Tierra, la gestión de memoria en mosaico y el marco de procesamiento de gráficos hacen que SNAP sea ideal para el procesamiento y el análisis de la observación de la Tierra; además es de acceso abierto (Zuhlke et al., 2015).

Google Earth Engine

Científicos, investigadores y desarrolladores pueden utilizar Google Earth Engine “para detectar cambios, trazar tendencias y cuantificar las diferencias de la superficie terrestre utilizando un catálogo de varios petabytes de imágenes de satélite y conjuntos de datos geoespaciales” (Gorelick et al., 2017). Es de acceso abierto.

ENVI

Con ENVI, puede extraer fácilmente información crucial de las imágenes, “utilizando su amplio conjunto de herramientas de análisis de imágenes y flujos de trabajo automatizados” (Canty, 2014). Nuevas aplicaciones automatizadas y herramientas mejoradas en ENVI 5 aumentan su capacidad de procesamiento y análisis de imágenes, lo que le permite tomar mejores decisiones basadas en esas imágenes. Aplicación en el Sector Privado (Canty, 2014).

ArcMap

Empleado principalmente para visualizar, editar, crear y analizar datos geoespaciales, ArcMap es la parte fundamental del paquete de software de procesamiento geoespacial ArcGIS de Esri. Los usuarios de ArcMap pueden examinar la información de un conjunto de datos, asignar símbolos significativos a las características y elaborar mapas personalizados. Su uso es comercial (Shaner & Wrightsell, 2000).

2.2.12 Programa Copérnico

Copernicus está dirigido por la ESA y la Agencia Europea de Medio Ambiente de la UE. anteriormente Vigilancia Mundial del Medio Ambiente y la Seguridad, para lograr una capacidad de observación de la Tierra completa, continua, autónoma y de alta calidad cuyos resultados estén a libre disposición de científicos y otros interesados. La gestión medioambiental, la comprensión del cambio climático y la seguridad civil requieren información precisa, fiable y continua. Analiza la "salud" de la Tierra utilizando datos de satélite y terrestres. Vigilancia Mundial del Medio Ambiente y la Seguridad (GMES) (Li et al., 2020; Torres et al., 2012).

El coste del programa para 1998-2020 es de 6.700 millones de euros, de los cuales 4.300 millones corresponden a 2014-2020. Como principal patrocinador, la ESA ha diseñado y cofinanciado las misiones Sentinel 1, 2, 3, 4, 5 y 6, cada una de las cuales cuenta con al menos dos satélites. El programa también proporcionará los instrumentos MTG y MetOp-SG de EUMETSAT. La ESA y EUMETSAT recogerán datos de 30 satélites para Copernicus (Li et al., 2020; Torres et al., 2012).

Sentinel-1

La Agencia Espacial Europea (ESA) construyó una flota de satélites llamados Sentinels para recoger y transmitir cantidades ingentes de datos e imágenes para el proyecto europeo Copérnico (Li et al., 2020; Torres et al., 2012).

Sentinel-1 se compone de un par de satélites en órbita polar diseñados para recopilar información espacial destinada a la vigilancia del medio ambiente y la seguridad, así como a la expansión económica y empresarial (Li et al., 2020; Torres et al., 2012).

La Guía de la Misión Sentinel-1 describe el satélite, su propósito y el segmento terreno con gran detalle. También se presentan las misiones heredadas, las áreas temáticas, las características orbitales y la cobertura, así como la carga útil de los instrumentos. (Li et al., 2020; Torres et al., 2012).

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

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

Fuente: Serrano et al. (2015).

Por otra parte, habrá que tener en cuenta el modo en que se tomen los datos, según Stripmap (SM), Interferometric Wide Swath (IW), Extra-Wide Swath (EW) y Wave Mode (WV).

También hay que considerar que en la polarización. Solo los productos con polarización VV o HH admitirán el modo WV, mientras que los de los modos SM, IW y EW se ofrecerán en polarización VV+VH o HH+HV, así como en polarización única (Li et al., 2020; Torres et al., 2012).

INSTRUMENTO C-SAR

El instrumento C-SAR y el software de apoyo fueron desarrollados por EADS Astrium GMBH de Alemania. El instrumento fue diseñado para proporcionar imágenes de detección remota en todas las condiciones

climáticas y períodos de tiempo. Es capaz de capturar datos de medición exactos en resoluciones altas y medias, aplicables para observaciones de zonas terrestres, costeras y de hielo (Li et al., 2020; Torres et al., 2012).

C-SAR es una antena de matriz activa en fase creada para proporcionar un escaneo más rápido en diferentes elevaciones y en azimut. Permite cubrir áreas más grandes de ángulo de incidencia, respaldar la operación de ScanSAR, utilizar técnicas TOPS y ayuda a ajustar el rendimiento de imagen requerido. El instrumento ha sido de doble canal para transmitir y recibir módulos que utilizan un par de guías de ondas polarizadas H/V, lo que hace posible satisfacer las demandas de polarización (Li et al., 2020; Torres et al., 2012).

La ventaja del C-SAR parece ser la capacidad de operar en una longitud de onda de banda C que no puede ser bloqueada por la cobertura de nubes o la luz insuficiente. Está equipado con un esquema de calibración interno que permite transmitir señales que luego se enrutan al receptor para registrar información. Este proceso ayuda a monitorear la amplitud y la fase para facilitar una alta estabilidad radiométrica (Li et al., 2020; Torres et al., 2012).

C-SAR también incluye guías de ondas metalizadas de radiación de plástico reforzado con fibra de carbono que pueden ayudar a garantizar una buena estabilidad radiométrica. Hay muchos tipos de elementos que no están cubiertos por el esquema de calibración interno habitual. Para cubrir esto, existe el generador de chirrido digital y el filtro de recepción seleccionable para anchos de números de banda específicos para aumentar el almacenamiento a bordo. Este proceso toma en consideración la dependencia de la resolución del terreno del ángulo de incidencia (Li et al., 2020; Torres et al., 2012).

2.3 Marco conceptual

Teledetección: “La teledetección consiste en recopilar datos sobre un objeto a gran distancia mediante sensores instalados en aviones o satélites” (Chuvieco, 1996).

Radar: “Termino que se refiere a un sistema que utiliza ondas electromagnéticas para determinar las posiciones relativas, alturas y velocidades de objetos inmóviles o móviles como edificios, barcos, coches, nubes e incluso el propio suelo” (Handbook, 2005).

SAR: “En un radar de apertura sintética (SAR), los datos recogidos por la antena del radar se procesan en un único barrido digital mediante un algoritmo” (Handbook, 2005).

Polarimetría: “Los materiales anisótropos, como la hierba, suelen reflejar las ondas de radar de distintas polarizaciones con intensidades variables porque las ondas de radar tienen una polarización y los distintos materiales reflejan las ondas de radar de forma diferente” (Handbook, 2005). “Gracias a la capacidad de algunos materiales de convertir una polarización en otra, es posible obtener varias imágenes a partir de la misma serie de impulsos. Esto se consigue emitiendo una combinación de polarizaciones” (Handbook, 2005).

Programa Copérnico: “Se trata del mayor programa de observación de la Tierra jamás emprendido, con el objetivo de facilitar el acceso a datos antes no disponibles para mejorar la gestión medioambiental, mitigar el cambio climático y garantizar la seguridad pública” (Handbook, 2005).

Sentinel-1: “Satélite en órbita polar del programa Copernicus para la vigilancia terrestre y oceánica” (Handbook, 2005). “Cohete Soyuz lanzado al espacio el 3 de abril de 2014 desde el puerto espacial de Kourou, en la Guayana Francesa” (Serrano et al., 2015).

Algoritmo: “Combinar datos espaciales y numéricos de forma que puedan ser comprobados por un algoritmo requiere un conjunto específico de operaciones de álgebra cartográfica y/o de bases de datos” (Brassard & Bratley, 1996).

Firma espectral: “La capacidad de identificar diferentes objetos: suelo, vegetación y agua, basándose en el comportamiento de las superficies cuando se exponen a la radiación” (Hernández & Montaner, 2009) .

Ráster: “El mundo puede concebirse como un mosaico ordenado formado por teselas básicas, en el que el valor medio de una variable está representado por cada tesela (altitud, reflectancia)” (Hijmans & van Etten, 2014).

Pixel: “Cada elemento discreto, término derivado del inglés picture element, se refiere a cada píxel individual de una imagen digital, es un término técnico” (Li et al., 2017).

Bosque: “Más de 0,5 ha de terreno cubierto por árboles de más de 5 metros de altura con una cubierta de copas superior al 10%, o terreno en el que los árboles existentes tengan potencial para alcanzar esta altura” (Fao, 2015)

Fuego: “Resultado de la combinación integrada de combustible, calor y oxígeno en una combustión” (Hernández, 2019).

Incendio de la cobertura vegetal: “Los incendios forestales se definen como cualquier fuego en la cubierta vegetal, ya sea de origen natural o antropogénico, que se propaga sin control y afecta o destruye una superficie superior a 5.000 m²” (Hernández, 2019).

Incendio forestal: “Sus orígenes se remontan a la propagación incontrolada y desenfrenada de los incendios en las zonas rurales” (Hernández, 2019).

Quema: “Incendio intencionado provocado por el hombre para eliminar o destruir vegetación no deseada u otros residuos sólidos, normalmente en entornos urbanos o rurales. El permiso para realizar este tipo de actividades sólo puede ser concedido por las Corporaciones Autónomas Regionales” (Hernández, 2019).

Fuego: “reacción química que libera energía en forma de luz, calor y llama. Momento de gran calor e intensa combustión” (Key & Benson, 2006).

Quemar: “Lesiones, efectos o daños causados por el calor. El resultado final de un incendio, y también un lugar con antecedentes de incendios” (Key & Benson, 2006).

Intensidad: “La fuerza o la cantidad de energía gastada. El nivel de calor producido por el fuego” (Key & Benson, 2006).

Severidad: “La fuerza de una fuerza; el grado en que causa dolor. El grado en que un incendio ha alterado su entorno, o cuánto ha costado socioeconómicamente a la sociedad” (Key & Benson, 2006).

CAPÍTULO III: METODOLOGÍA DE INVESTIGACIÓN

3.1 Tipo de investigación

Este estudio emplea algoritmos geoespaciales para analizar imágenes RADAR en busca de signos de deforestación y de la gravedad de los incendios en la región de Tahuamanu - Madre de Dios. Para este objetivo se utilizaron métodos de investigación que incluyen descripción, correlación y predictivo (Baray, 2006; Castro, 2003; Cazau, 2006; Hernández et al., 2010).

3.2 Diseño de la investigación

La investigación corresponde a un diseño Transaccional (transversal), debido a que se avalúa en un corte de tiempo (periodo 2020) la deforestación y la gravedad de las quemas en el distrito de Tahuamanu – Madre de Dios (Baray, 2006; Castro, 2003; Cazau, 2006; Hernández et al., 2010).

3.3 Delimitación espacial y temporal

Con una superficie de 85 183,96 km² (8 518 396 ha) (6,64% del territorio nacional), la región de Madre de Dios limita al sur con el departamento de Puno, al oeste con el de Cusco y al norte con el de Ucayali, y en el ámbito internacional con Bolivia y Brasil (INEI, 2017).

El área de estudio comprende una delimitación espacial corresponde al distrito de Tahuamanu del departamento de Madre de Dios, cuya superficie total es de 15 079,61 km² (1 507 961,50 ha) (Figura 9). Está situada entre los paralelos 9° 51' 12" y 11° 55' 56" de latitud Sur y los meridianos 68° 59' 18" y 72° 14' 39" de longitud Oeste; altitud entre 200 m y 550 msnm (Alarcón et al., 2016; Chávez et al., 2013; GOREMAD & IIAP, 2009; Perz et al., 2016; Perz et al., 2013).

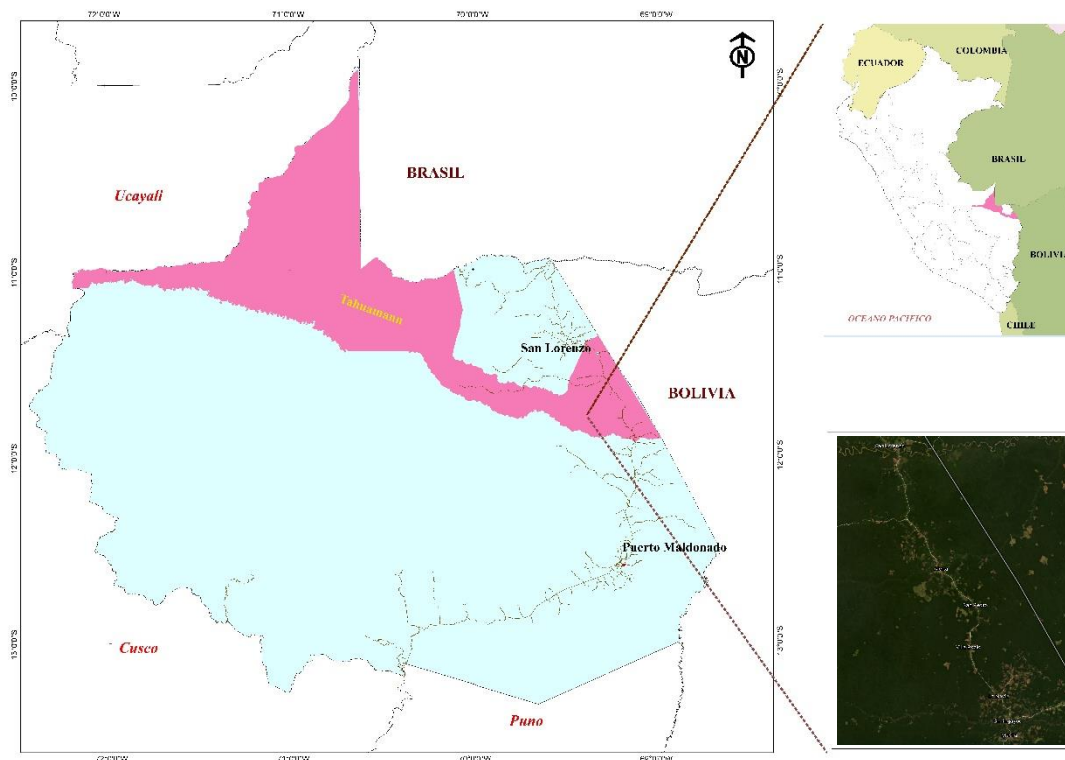


Figura 9. Ubicación de área estudio.

En cuanto a la evaluación temporal, la deforestación y la gravedad de quemas en el distrito de Tahuamanu a través de imágenes de Radar de Apertura Sintética (SAR), corresponde al 2020.

3.3.1 Clima e hidrografía

Los datos de las estaciones de Puerto Maldonado, Iapari, Iberia y Pakitza muestran que la temperatura media anual oscila entre 22°C y 26°C, con poca variación a lo largo del año. Los meses entre septiembre y abril representan los promedios mensuales más altos, mientras que los meses entre mayo y agosto muestran los promedios mensuales más bajos (GOREMAD & IIAP, 2009; Perz et al., 2016).

Sin embargo, la estación de Assis-Brasil ha registrado temperaturas máximas absolutas de 41 grados centígrados en 1959 y 39 grados centígrados en 1970. Sin embargo, las temperaturas más frías registradas fueron de 6 grados Celsius en 1957 y de 6,4 grados Celsius en 1999. (1974). El aire frío

procedente de la masa polar antártica, conocido como "Friaje" o "Surazo", se produce entre mayo y septiembre, provocando un descenso de las temperaturas (GOREMAD & IIAP, 2009; Perz et al., 2016).

La precipitación media anual ronda los 1.800 mm. Los meses más secos del año son de mayo a septiembre, con sólo un 20-25% del total anual. La mayor parte de las precipitaciones se producen entre octubre y abril, entre el 75% y el 80% del total anual. La lluvia es cada vez más intensa desde el sureste hacia el noroeste. Los meses de julio, agosto y septiembre registran la humedad relativa más baja del año. La extrema variabilidad climática (la temperatura disminuye con la altitud, la humedad relativa varía entre el 63% y el 90%, y la evapotranspiración fluctúa entre 598,4 mm y 652,6 mm) es característica de estas regiones. El clima es húmedo, cálido y húmedo, con inviernos secos y abundantes precipitaciones durante todo el año. (GOREMAD & IIAP, 2009; Perz et al., 2016).

3.4 Población y muestra

La población se calculará en función del tamaño del distrito de Tahuamanu, que es de 15.079,61 km² (1.507.961,50 ha).

El número de muestras del área a verificar en campo o con imágenes de alta resolución se determinará utilizando la distribución binomial de probabilidad al analizar imágenes SAR, Sentinel-1 para deforestación y severidad de quemas (Anaya & Chuvieco, 2010; Chuvieco & Hantson, 2010; Ochoa & Páez, 2019). Para determinar el tamaño de la muestra, utilizaremos la siguiente ecuación (Ecuación 1):

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

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%).

$$n = \frac{(1,96)^2 * 0,5(0,5 * 1\ 507\ 961,50)}{(1\ 507\ 961,50 - 1) * 0,05^2 + 1,96^2 + (0,5 * 0,5)}$$

$$n = 383,74 = 384$$

La muestra fue distribuida de manera representativa en el distrito de Tahuamanu. Se utilizó un método de muestreo probabilista, por medio de la técnica de inclusión y exclusión (Ochoa & Páez, 2019). Es decir, zonas con similares características, se optó por el más cercano. Para ello, se empleó 384 puntos de muestreo distribuidos según las categorías de severidad de quema; bajo, moderado y alto.

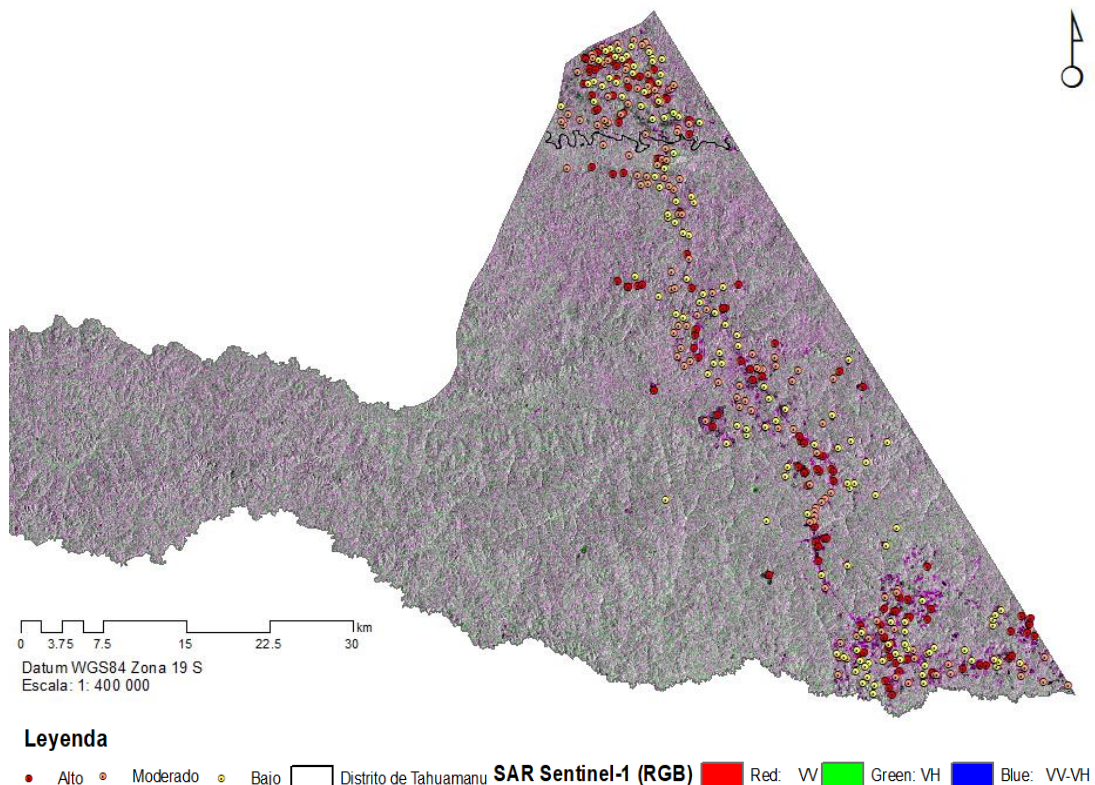


Figura 10. Distribución de muestras para validar la severidad de quemas en el distrito de Tahuamanu.

3.5 Técnicas e instrumentos de recolección de datos

3.5.1 Método y técnicas

Después de los incendios, los árboles pierden hojas y ramas, cambiando los mecanismos de dispersión que causan variaciones temporales en el coeficiente de retrodispersión.. En cualquier caso, la alteración temporal permite cartografiar la gravedad de las quemadas. La precisión de la salida del sensor SAR se ve afectada significativamente por su longitud de onda y polarización. Si se aumenta la longitud de onda de las señales SAR, éstas podrán viajar más lejos. Con una longitud de onda máxima de 24 centímetros, la banda L tiene mayor capacidad de penetración que las máximas de la banda C, de 5,6 y 3 centímetros, alcanzadas por Sentinel-1. Esta última será útil para evaluar la gravedad de las quemadas (Addison & Oommen, 2018; Mihai A. Tanase et al., 2015; M. A. Tanase et al., 2015).

En términos de polarizaciones, se ha demostrado que el estado de polarización cruzada (HV/VH) es sensible a los cambios de volumen, por lo tanto, la eliminación de hojas y ramas por el fuego y la consiguiente vegetación más delgada y seca da como resultado una menor retrodispersión (Addison & Oommen, 2018).

El *radar de apertura sintética de banda C de satélite de observación terrestre avanzada* (Sentinel-1) fue el sensor empleado en la investigación. Esto es debido a que es el único sensor de banda C de libre acceso. Los datos previos y posteriores al incendio se descargarán a través de la plataforma Alaska Satellite Facility (ASF) y Google Earth Engine (GEE), “como productos de polarización dual de haz fino (FBD), lo que significa que tendrán información de polarización VV y VH” (Addison & Oommen, 2018). La evaluación preliminar de los valores medios de retrodispersión fueron las ubicaciones de estudio antes y después del incendio, la data mostro que los lugares no quemados registrarán coeficientes de retrodispersión más altos en comparación con sus contrapartes quemadas para las polarizaciones VV y VH (Addison & Oommen, 2018).

Los datos de Sentinel-1 serán descargados con corrección radiométrica del terreno (RTC) de ASF y GEE.. De esta manera, se realizó el co-registro de escenas obtenidas del mismo sensor y pista. También se realizó correcciones posteriores de tamaños de píxeles representativos, así como la reducción del ruido de moteado de los datos de SAR. Para imágenes con ruido moteado completamente, se realizó un filtrado adicional aplicando un filtro adaptativo o no adaptativo adecuado para el sensor, teniendo en cuenta la preservación de una buena resolución radiométrica y espacial. La geo codificación se hizo a través del mejor modelo de elevación digital (DEM) disponible, para ello, se descargó dos conjuntos de datos para cada incendio para escenarios previos y posteriores al incendio, respectivamente.

El análisis aplico ecuaciones predictoras absolutos, relativos e índices a partir de los datos de retrodispersión VV y VH para cuantificar la deforestación y gravedad de quemas.

La validación del proceso, empleo la distribución de puntos en campo, para ello se recolecto puntos de quemas como áreas entrenamiento en el distrito de Tahuamanu. La contrastación en campo se realizará mediante el uso de GPS (Garmin Map 60 CSx, y Garmin Map 62 CSx) (Alarcón et al., 2016). La matriz de confusión e Índice de Kappa se aplicó para medir la confiabilidad de la clasificación con los datos obtenidos de campo de la severidad del fuego de las parcelas (CBI) (Alarcón et al., 2016).

Los softwares e información cartográfica del área de estudio fueron proporcionadas por el CETEGERN.

3.5.2 Procesamiento de datos y análisis estadístico

Las referencias proceden de fuentes como ScienceDirect Freedom Collection, EBSCO, IEEE, IOP, Scopus, Sage, SAGE Research Methods, Taylor & Francis, Willey, Google Scholar, etc., que se encuentran en la biblioteca en línea del CONCYTEC..

Elección de una cobertura y adquisición de imágenes de satélite:

1. Comenzamos adquiriendo mapas del distrito de Tahuamanu del CETEGERN (Centro de Teledetección para el Estudio y Manejo de los Recursos Naturales) de la UNAMAD (Alarcón et al., 2016).
2. Seguidamente se utilizó imágenes SAR provenientes del portal Alaska Satellite Facility (ASF) y Google Earth Engine (GEE) del satélite Sentinel-1, del año 2020 (Tabla 3 y 4).

Tabla 3. Información de adquisición de imágenes Sentinel-1

Sensor	Periodo	Cobertura	Fecha de Imagen
Sentinel-1	Pre incendio	Distrito de Tahuamanu	01-31 de mayo de 2020
	Post incendio		30/09-15/10 de 2020

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

Parámetro	Sentinel-1
Fecha de lanzamiento	03 de abril de 2014 de S1-A 22 de abril de 2016 de S1-B
Tipo de órbita	SSO (órbita sincrónica del sol) ciclo de repetición de 12 días LTAN = 18:00 horas
Altitud orbital	693 kilómetros

Fuente: Serrano et al. (2015).




Figura 11. Imágenes SAR Sentinel-1 con polarización VV; pre y post incendio 2020.



Figura 12. Imágenes SAR Sentinel-1 con polarización VH; pre y post incendio 2020.

✓ Tratamiento y análisis de la imagen SAR

Para calibrar el tratamiento digital (GEE) se utilizaron datos de Sentinel-1 procedentes de la Alaska Satellite Facility (ASF) y de Google Earth Engine. El proceso de categorización de este estudio consistió en tres (3) etapas:

- 1. Pre-Procesamiento**, Para preparar los datos SAR, se realizaron las operaciones de Multilook, Calibración, Filtrado Speckle, Corrección Topográfica y Recorte de acuerdo con el área de estudio (Addison & Oommen, 2018).
- 2. Procesamiento**, Las imágenes de SAR Sentinel-1 tuvieron información de polarización VV y VH, la evaluación preliminar de los valores medios de retrodispersión para la localización de áreas de interés antes y después del incendio mostro que las ubicaciones no quemadas registrarán coeficientes de retrodispersión más altos en comparación con sus contrapartes quemadas para las polarizaciones VV y VH.

Para cuantificar la deforestación y la gravedad de quemas se utilizó predictores absolutos, relativos, y Relación de Quemadas (RBR) por medio del Índice Degradación Forestal del RADAR (RDFI) a partir de los datos de retrodispersión VV y VH, los algoritmos serán:

$$Abs_VV = VV_{pre} - VV_{post} \quad (2)$$

$$Abs_VH = VH_{pre} - VH_{post} \quad (3)$$

$$Rel_VV_1 = \frac{VV_{pre} - VV_{post}}{VV_{pre}} \quad (4)$$

$$Rel_VH_1 = \frac{VH_{pre} - VH_{post}}{VH_{pre}} \quad (5)$$

$$Rel_VV_2 = \frac{VV_{pre} - VV_{post}}{\sqrt{VV_{pre}}} \quad (6)$$

$$Rel_VH_2 = \frac{VH_{pre} - VH_{post}}{\sqrt{VH_{pre}}} \quad (7)$$

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

$$\sigma_{0,dB} = 10 \log_{10}(\sigma_0) \quad (8)$$

$$RBR_{xy} = \text{Promedio de post incendio}_{xy} / \text{promedio de pre incendio}_{xy} \quad (9)$$

La Relación de Quemadas del RADAR (RBR) implicó el cálculo de la relación post-pre-incendio de los coeficientes de retrodispersión en unidades de potencia (Ecuación 9).

$$RDFI = (VV - VH) / (VV + VH) \quad (10)$$

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

Las ecuaciones (2) y (3) son para medir los cambios absolutos del paisaje después de los incendios, mientras que las ecuaciones (4), (5), (6), (7) dan los cambios relativos con respecto a la condición existente en el suelo antes del incendio (Addison & Oommen, 2018; M. A. Tanase et al., 2015; Tanase et al., 2013).

Para medir el nivel de gravedad de las quemadas de los valor absolutos y relativos (Abs_{VV} , Abs_{VH} , Rel_{VV1} , Rel_{VV2} , Rel_{VH1} y Rel_{VH2}) se utilizó los

siguientes parámetros (Tabla 5) (Addison & Oommen, 2018; M. A. Tanase et al., 2015; Tanase et al., 2013):

Tabla 5. Desglose de las decisiones para desarrollar el modelo de severidad de quemas SAR Sentinel-1 por medio de valores absolutos y relativos

Gravedad de las quemas	Criterio de decisión
Moderado	Rel_VV/VH $\leq 0,57$ Evergreen = No Abs_VV/VH $\leq 0,03$
Alto	Rel_VV/VH $\leq 0,57$ Evergreen = No Abs_VV/VH $> 0,03$
Bajo	Rel_VV/VH $\leq 0,57$ Evergreen = Sí Abs_VV/VH $\leq 0,03$
Moderado	Rel_VV/VH $\leq 0,57$ Evergreen = Sí Abs_VV/VH $> 0,03$
Alto	Rel_VH $> 0,57$ Abs_VV/VH $\leq 0,19$
Moderado	Rel_VV/VH $\leq 0,57$ Abs_VV/VH $> 0,19$

Fuente: Addison and Oommen (2018).

Por otro lado, para medir Relación de Quemas (RBR) por medio del Índice Degradación Forestal del RADAR (RDFI) a partir de los datos de retrodispersión VV y VH (Tabla 6) (M. A. Tanase et al., 2015; Tanase et al., 2013), se utilizó el siguiente criterio:

Tabla 6. Criterio de las decisiones para desarrollar el modelo de severidad de quemas SAR Sentinel-1 por medio de RBR y RDFI

Criterio de decisión	Gravedad de las quemas
RDFI= -0,6- -0,47	Bajo
RDFI= -0,47-0,08	Moderado
RDFI= >0,8	Alto

Fuente: Modificado y adaptado de Mihai A. Tanase et al. (2015) y M. A. Tanase et al. (2015).

3. Post-Clasificación, una vez clasificadas, las imágenes se corrigieron y se compararon píxel a píxel (Xiuwan, 2002), una vez desarrollados las predicciones absolutos, relativos, y Relación de Quemadas (RBR) por medio del Índice Degradación Forestal del RADAR (RDFI) a partir de los datos de retrodispersión VV y VH. La validación se desarrolló mediante el uso de una matriz de confusión y el Índice de Kappa de los valores estimados con los datos obtenidos de campo de la severidad del fuego de las parcelas (CBI) (Addison & Oommen, 2018; Kuhn & Johnson, 2013; Townsend, 1971). Finalmente, se realizó la conversión del resultado de la predicción a formato vectorial, para su análisis en un SIG (Alarcón et al., 2016).

✓ Tratamiento de datos

Los datos se procesaron mediante métodos estadísticos; la matriz de confusión y el coeficiente kappa () se utilizaron como prueba para comparar los datos predictivos y la información real sobre el terreno (CBI) (Alarcón et al., 2016; Kuhn & Johnson, 2013; Townsend, 1971), es decir, el cambio de retrodispersión del SAR.

Para medir la severidad del fuego, se utilizó el intervalo CBI continuo en clases propuesto por Key and Benson (2006), adaptado para el estudio; sin cambios (CBI = 0), severidad baja ($0 < \text{CBI} \leq 1$), severidad media ($1 < \text{CBI} \leq 2$), gravedad alta ($\text{CBI} > 2$). Estas clases generalmente corresponden al protocolo de campo CBI definido por Key and Benson (2006) (Tabla 7).

Tabla 7. Definiciones de las categorías de gravedad de CBI para comparar los valores absolutos, relativos y la Relación de Quemados (RBR) por medio del Índice Degradación Forestal del RADAR (RDFI) a partir de los datos de retrodispersión VV y VH

Categoría	CBI	Descripción
Sin quemar	0	La ubicación no experimentó ningún incendio. Esto también puede incluir una ubicación que se recupere rápidamente después de los incendios.
Bajo	0 - ≤1	Consumo mínimo de vegetación; fragmentos de vegetación afectado.
Moderado	1 - ≤2	El paisaje presenta características intermedias entre las de gravedad baja y alta descritas.
Alto	>2	~ El consumo de todas las plantas es del 90%. Más de la mitad del suelo o la roca de estos lugares suele estar compuesta por minerales.

Esto permitió determinar la precisión global (ecuación 11), que mide el rendimiento global del modelo a la hora de identificar correctamente las tres clases distintas de gravedad de las quemados (Townsend, 1971). Va de 0 a 1, donde 0 representa un modelo sin capacidad predictiva y 1 representa un modelo perfecto (Townsend, 1971). “La precisión del test también fue medido por el Índice de Kappa de Cohen (Ecuación 12), La interpretación se encuentra en función a los niveles de concordancia cualitativa” (Tabla 8) (Alarcón et al., 2016; Cerda & Villarroel, 2008; Kuhn & Johnson, 2013).

$$Precision\ general = \frac{VP + VN}{VP + FP + VN + FN} \quad (11)$$

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

$$Kappa(k) = \frac{f_o - f_c}{N - f_c} \quad (12)$$

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

Tabla 8. Valoración del coeficiente kappa

Fuerza de la Concordancia	Coeficiente Kappa
Pobre (<i>Poor</i>)	0,00
Leve (<i>Slight</i>)	0,01 – 0,20
Aceptable (<i>Fair</i>)	0,21 – 0,40
Moderada (<i>Moderate</i>)	0,41 – 0,60
Considerable (<i>Substantial</i>)	0,61 – 0,80
Casi perfecta (<i>Almost perfect</i>)	0,81 – 1,00

Fuente: Cerda and Villarroel (2008); Landis and Koch (1977).

✓ **Análisis estadístico**

Se emplearán estadísticas descriptivas e inferenciales para realizar el análisis estadístico.

Para el primer objetivo de cuantificar el área deforestada causada por incendios mediante sensores de Radar de Apertura Sintética (SAR) en el distrito de Tahuamanu en el año 2020, se aplicaron modelos predictivos basados en datos de retrodispersión VV y VH del sensor Sentinel-1 (Addison & Oommen, 2018; M. A. Tanase et al., 2015; Tanase et al., 2013). La precisión de las predicciones se comprobó con ayuda de una matriz de confusión y el índice Kappa (Cerda & Villarroel, 2008).

Respecto al segundo objetivo, sobre estimar los niveles de gravedad de quemas a través de sensores de RADAR de Apertura Sintética (SAR), se aplicara el criterio de decisiones del modelo de severidad de quemas SAR Sentinel-1 propuesto por Addison and Oommen (2018); M. A. Tanase et al. (2015), que considera la presencia del tipo de vegetación en la cobertura.

CAPÍTULO IV: RESULTADOS Y DISCUSIÓN

4.1 Cuantificación de la superficie deforestada por quemas

Las imágenes SAR Sentinel-1 se descargaron del portal web Alaska Satellite Facility (ASF) y Google Earth Engine (GEE). Para evaluar las quemas con SAR según la topografía local, se han generado patrones de coherencia en función de la gravedad de la quemadura (CBI) y orientación al sensor (1A y 1B) (Figura 13 y 14). La minimización de las condiciones climáticas, se realizó a través de la adquisición de imágenes en condiciones ambientales secas pre post incendio. Para el distrito de Tahuamanu se trazaron como cocientes Abs_VV , Abs_VH , Rel_VV_1 , Rel_VH_1 , Rel_VV_2 , Rel_VH_2 , RBR_{xy} , y $RDFI$ (Ecuación 1, 2, 3, 4, 5, 6, 7, 8, 9, 10). La alteración temporal del sensor (1A y 1B) permite mapear la gravedad de las quemas, porque la precisión del sensor SAR depende en gran medida de su longitud de onda y polarización. El Sentinel-1 presenta un máximo de 5,6 cm y 3 cm en la banda C, que presenta menores capacidades de penetración, pero muy útiles en el mapeo de la gravedad de las quemas (Addison & Oommen, 2018).

La coherencia de copolarización y polarización cruzada de la banda C utilizada fueron VV y VH, con la finalidad de medir la sensibilidad de los cambios de volumen, por lo tanto, la eliminación de hojas y ramas por el fuego y la consiguiente vegetación más delgada y seca da como resultado una menor retrodispersión (Figura 13) (Addison & Oommen, 2018). La figura 13 muestra los patrones de longitud en decibeles (dB) de la vegetación y áreas quemadas, así como, de la gravedad de la quemadura (CBI).

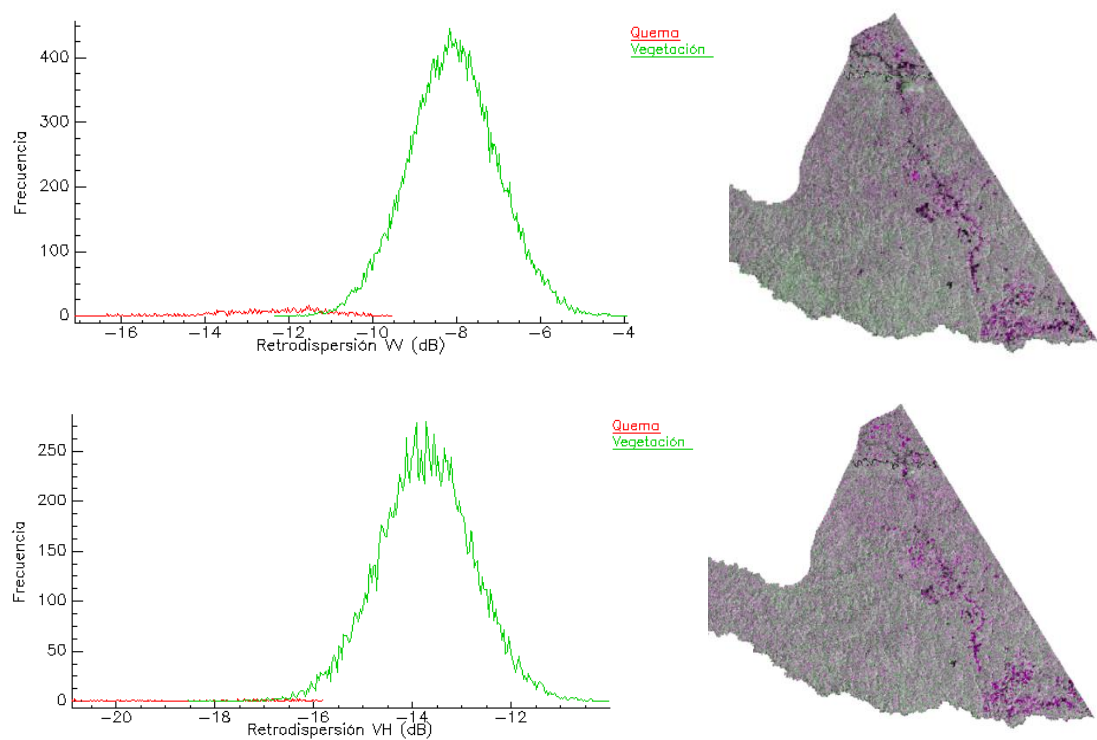


Figura 13. Longitud de onda (microondas dB) de retrodispersión VV y VH para vegetación y áreas quemadas.

Los datos mostrados en la figura 13 se caracterizaron por la mayor diferencia de retrodispersión entre la vegetación no quemado y quemado. Las imágenes de copolarización y polarización cruzada Sentinel-1 SAR se adquirieron en dos condiciones climáticas: 1) finalización de la época de lluvias y 2) alta incidencia de temperatura. El coeficiente de retrodispersión copolarizada de VV aumentó mínimamente con la gravedad de la quemadura respecto a la polarización VH en banda C. El aumento de la retrodispersión de las áreas quemadas podría explicarse como consecuencia de la menor atenuación en el dosel y la posterior exposición de la vegetación residual, así como, el aumento retrodispersión del suelo (Li et al., 2020; Stevens et al., 2020; Mihai A. Tanase et al., 2015; M. A. Tanase et al., 2015; Tanase et al., 2013; Tanase, Santoro, de La Riva, et al., 2010; Tanase, Santoro, Wegmüller, et al., 2010; Viedma et al., 2020).




Figura 14. Tipos de gravedad de quemas (CBI): gravedad bajo (a), gravedad moderado (b), y gravedad alto (c).

La retrodispersión de las gráficas CBI fue similar a la retrodispersión medida a nivel ondas copolarizadas y polarizaciones cruzadas (Figura 14). El protocolo de campo CBI toma en cuenta el consumo de la capa de atenuación (es decir, la capa de dosel y sotobosque), proporcionando así estimaciones indirectas del aumento de la exposición del suelo, lo que explica la asociación relativamente alta con la severidad de la quemadura para áreas orientadas al sensor donde la dispersión de componente del suelo de la vegetación es significativa. En niveles de severidad intermedios, el coeficiente de retrodispersión de las parcelas CBI estuvo cerca de los niveles registrados para el área no quemado. La banda C conservó en parte su sensibilidad para niveles de CBI bajos e intermedios, siendo más sensibles a los elementos de tamaño pequeño (Tanase et al., 2013; Viedma et al., 2020).




Figura 15. Determinación de áreas quemadas mediante valores absolutos y relativos de datos de retrodispersión VV1 pre y post incendio 2020; Ecuación 2 y 4.




Figura 16. Determinación de áreas quemadas mediante valores absolutos y relativos de datos de retrodispersión VV2 pre y post incendio 2020; Ecuación 2 y 6.




Figura 17. Determinación de áreas quemadas mediante valores absolutos y relativos de datos de retrodispersión VH1 pre y post incendio 2020; Ecuación 3 y 5.




Figura 18. Determinación de áreas quemadas mediante valores absolutos y relativos de datos de retrodispersión VH2 pre y post incendio 2020; Ecuación 3 y 7.




Figura 19. Determinación de áreas quemadas a través de la Relación de Quemadas (RBR) por medio del Índice Degradación Forestal del RADAR (RDFI) a partir de los datos de retrodispersión VV y VH pre y post incendio 2020; Ecuación 9 y 10.

Las perturbaciones de la vegetación cartografiada en el distrito de Tahuamanu con imágenes Sentinel-1 SAR a través de predictores absolutos, relativos, y Relación de Quemadas (RBR) por medio del Índice Degradación Forestal del RADAR (RDFI) cubrieron áreas de 2 963,34 ha (Ab_Rel_VV_1), 3 108,27 ha (Ab_Rel_VV_2), 2 920,68 ha (Ab_Rel_VH_1), 3 972,73 ha (Ab_Rel_VH_1), y 3 496,21 ha (RDFI_VVVH) respectivamente (Figuras 15, 16, 17, 18, 19, y 20).

Los resultados muestran variaciones espaciales y en la superficie de áreas quemadas según los tipos de predictores, oscilando 1 052,05 ha entre el mínimo (Ab_Rel_VH_1) y máximo (Ab_Rel_VH_2). En cuanto al nivel de precisión, será analizada en el subcapítulo 4.3.




Figura 20. Cuantificación de áreas quemadas mediante valores absolutos, relativos y Relación de Quemas (RBR) por medio del Índice Degradación Forestal del RADAR (RDFI) de datos de retrodispersión VV y VH pre y post incendio 2020; Ecuación 2, 3, 4, 5, 6, 7, 8, 9, 10.

Históricamente, las perturbaciones forestales relacionadas con las quemas en la Amazonia de Madre de Dios y del Perú se han asociado principalmente con una conversión de bosques naturales a usos agrícolas (Alarcon et al., 2021). Se han tratado de establecer políticas e instrumentos de gestión para regular las quemas, sin embargo, no han funcionado, debido a la débil presencia del gobierno con los actores sociales (GOREMAD & IIAP, 2009).

Una ventaja, pero no determinante es la ocupación de áreas por títulos habilitantes forestales, predios agrícolas titulados o con derechos de titulación, comunidades nativas o comunidades en general, que garantizan cierto resguardo y protección contra la invasión, pero no exento de quemas. A pesar de ello, se registran invasiones que realizan talas y quemas para fines agrícolas. Asimismo, quemas descontroladas que se extiende a campos agrícolas, pastizales, purmas, bosques secundarios, y dependiendo de la

gravedad a bosques primarios (Coen et al., 2018; Porcher et al., 2018; Santos et al., 2021).

Otra situación común en el distrito, son las quemas en parches o fragmentos más pequeños y en el borde de parches de bosque. La mayoría de las quemas son provocados por el hombre (pequeños y medianos agricultores) mediante; roza y quema del bosque, y tala de salvamento (en la que los árboles afectados por el fuego, pero capaces de recuperarse son talados) (dos Reis et al., 2021; Morello et al., 2022; Santos et al., 2021; Smith et al., 1999).

Estudios recientes muestran el potencial de uso de sensores a RADAR, ópticos y la combinación de ambos para detectar las perturbaciones de la vegetación por quemas (Addison & Oommen, 2018; Allison et al., 2016; Amraoui et al., 2015; Belenguer-Plomer et al., 2019; Bernhard et al., 2011; Bradstock et al., 2010; Cannon & DeGraff, 2009; Cannon et al., 2010; Coen et al., 2018; Collins et al., 2019; Cruz & Alexander, 2013; de Oliveira Alves et al., 2015; de Oliveira Alves et al., 2014; DeSiervo et al., 2015; Doerr et al., 2009; Gimeno et al., 2004; Harvey et al., 2019; Hernández, 2019; Jiang, 2020; Kasischke et al., 1997; Kerle et al., 2004; Kern et al., 2017; Lahaye et al., 2018; Leite-Filho et al., 2020; Li et al., 2020; Lindner et al., 2010; Martins et al., 2016; Miller-Rushing et al., 2019; Morgan et al., 2014; Murphy et al., 2008; Ochoa & Páez, 2019; Parks et al., 2014; Polychronaki et al., 2013; Porcher et al., 2018; Sánchez et al., 2019; Santos et al., 2021; Serrano et al., 2015; Shive et al., 2018; Stevens et al., 2020; Stroppiana et al., 2015; Townsend, 1971; Viedma et al., 2020). El uso de Sentinel-1 SAR copolarizada y polarización cruzada VV y VH se fundamentó para lograr una mayor densidad de observación y para superar los errores de omisión en las series de tiempo ópticas debido a las diversas influencias ambientales. Los hallazgos muestran, que las sensibilidades verticales y horizontales del SAR hacia los cambios en la cobertura fotosintética y no fotosintética de la vegetación permitió caracterizar las perturbaciones del bosque más allá de una detección binaria (bosques y quemas) (Addison & Oommen, 2018; Belenguer-Plomer et al., 2019; Bernhard et al., 2011; Kasischke et al., 1997; Li et al., 2020; Martins et al., 2016; Murphy et al., 2008; Polychronaki et al., 2013; Porcher et al., 2018; Santos et al., 2021;

Serrano et al., 2015; Tanase et al., 2013; Tanase, Santoro, de La Riva, et al., 2010; Tanase, Santoro, Wegmüller, et al., 2010). En ese sentido, el patrón de quemas es similar en sectores de Madre de Dios y regiones Amazónicas como Pando (Bolivia) y Acre (Brasil) (Melo et al., 2021; Perz et al., 2013; Southworth et al., 2011).

4.2 Niveles de gravedad de quemas mediante sensores de Radar de Apertura Sintética (SAR) Sentinel-1 en el distrito de Tahuamanu

Para inferir la utilidad de la retrodispersión para la estimación de la gravedad de las quemas, se utilizaron parámetros a través de predictores absolutos, relativos, y Relación de Quemas (RBR) por medio del Índice Degradación Forestal del RADAR (RDFI) según las tablas 5, 6, y 7. Los resultados mostraron una fuerza de asociación entre la retrodispersión y la severidad de la quemadura con la copolarización y polarización cruzada (VV y VH). El cruce de coeficientes absolutos-relativos y RDFI se pueden utilizar para comparar la fuerza relativa de las diversas polarizaciones y la gravedad de la quemadura. El uso simultáneo de canales con polarización cruzada y copolarizada proporcionó los coeficientes de determinación más altos y los errores más pequeños para las bandas C. Los altos valores registrados en la banda C están relacionados principalmente con la severidad de la quemadura de la vegetación.

Los valores absolutos y relativos de los índices de copolarización y polarización cruzada mostraron valores de Abs_VV con $-18,71$ a $-0,03$ (Moderado/Bajo), de $0,03$ a $0,19$ (Alto), y $>0,19$ (Moderado). Abs_VH con $<0,05$ (Moderado/Bajo), de $0,05$ a $0,09$ (Alto/Moderado), de $0,09$ a $0,16$ (Alto). Rel_VV1 de $-18,03$ a $0,57$ (Moderado/Alto), $>0,57$ (Alto). Rel_VH1 con valores de $0,76$ a $2,92$ (Alto). Rel_VH2 de $0,41$ a $0,57$ (Moderado), de $0,57$ a $1,52$ (Alto). Rel_VH2 de $-18,37$ a $0,57$ (Alto/Moderado/Bajo), y $>0,57$ (Alto).

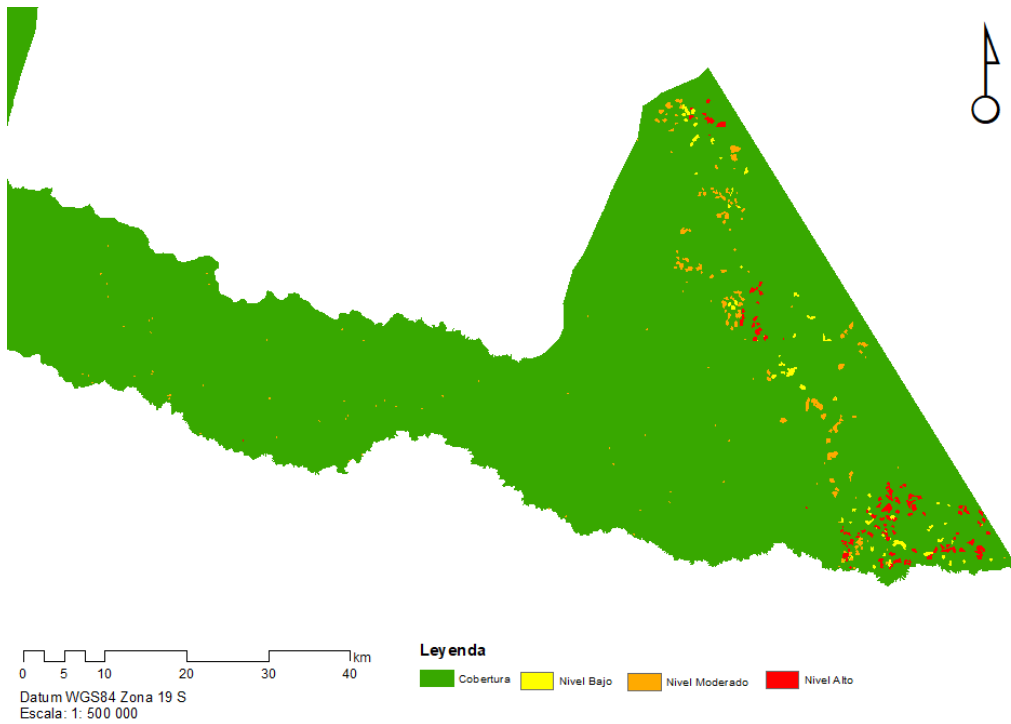


Figura 21. Deforestación por nivel de gravedad de quemas mediante valores absolutos, relativos de datos de retrodispersión VV1 pre y post incendio 2020; Ecuación 2 y 4.

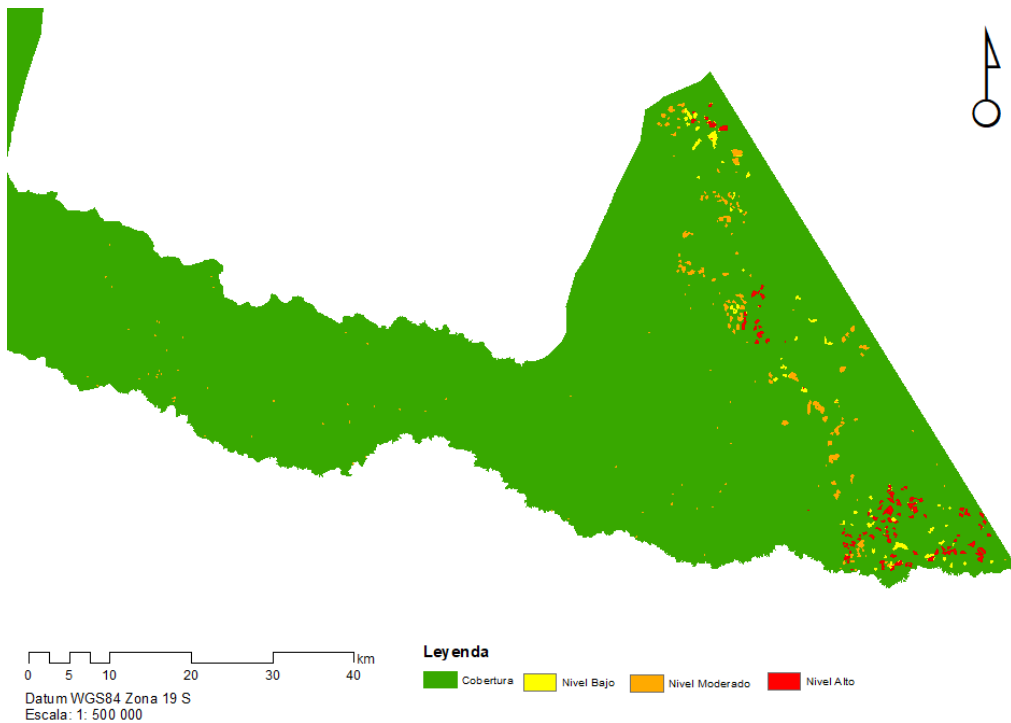


Figura 22. Deforestación por nivel de gravedad de quemas mediante valores absolutos, relativos de datos de retrodispersión VV2 pre y post incendio 2020; Ecuación 2 y 6.




Figura 23. Deforestación por nivel de gravedad de quemas mediante valores absolutos, relativos de datos de retrodispersión VH1 pre y post incendio 2020; Ecuación 3 y 5.

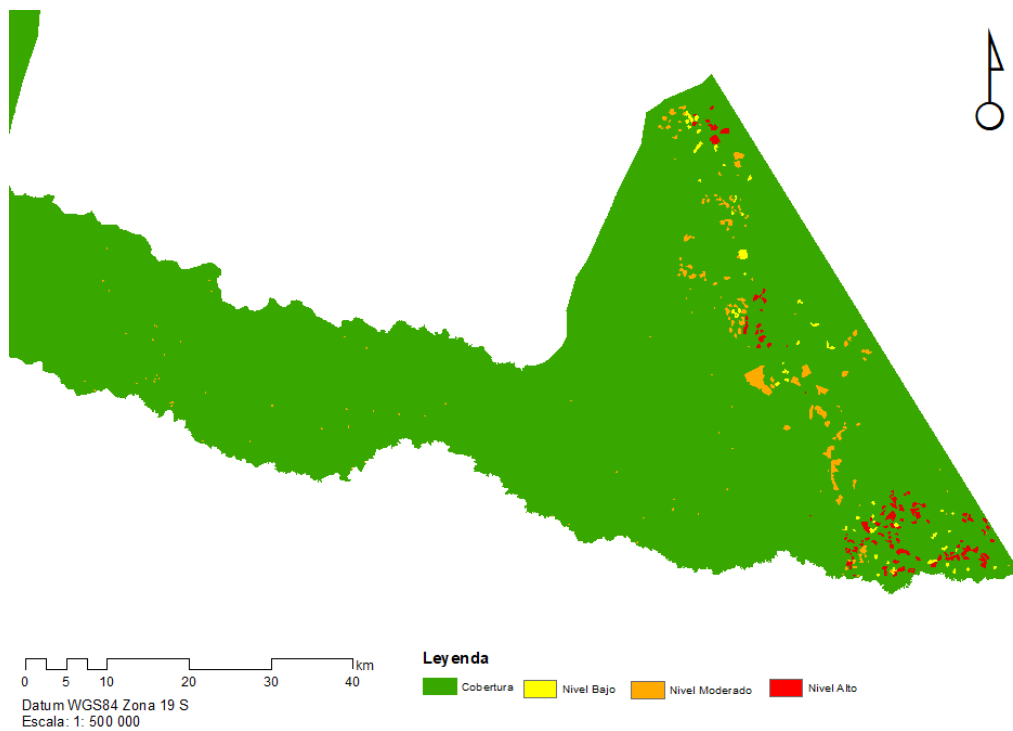


Figura 24. Deforestación por nivel de gravedad de quemas mediante valores absolutos, relativos de datos de retrodispersión VH2 pre y post incendio 2020; Ecuación 3 y 7.

En el caso de áreas quemadas en función a RBR y por medio RDFI, cuantifico la dispersión de la severidad de quemas, mostrando índices con valores de -0,6 a -0,47 en el nivel bajo, de -0,47 a 0,04 con nivel moderado, y de 0,04-0,16 con nivel alto (Figuras 21, 22, 23, 24, 25, 26, y 27).

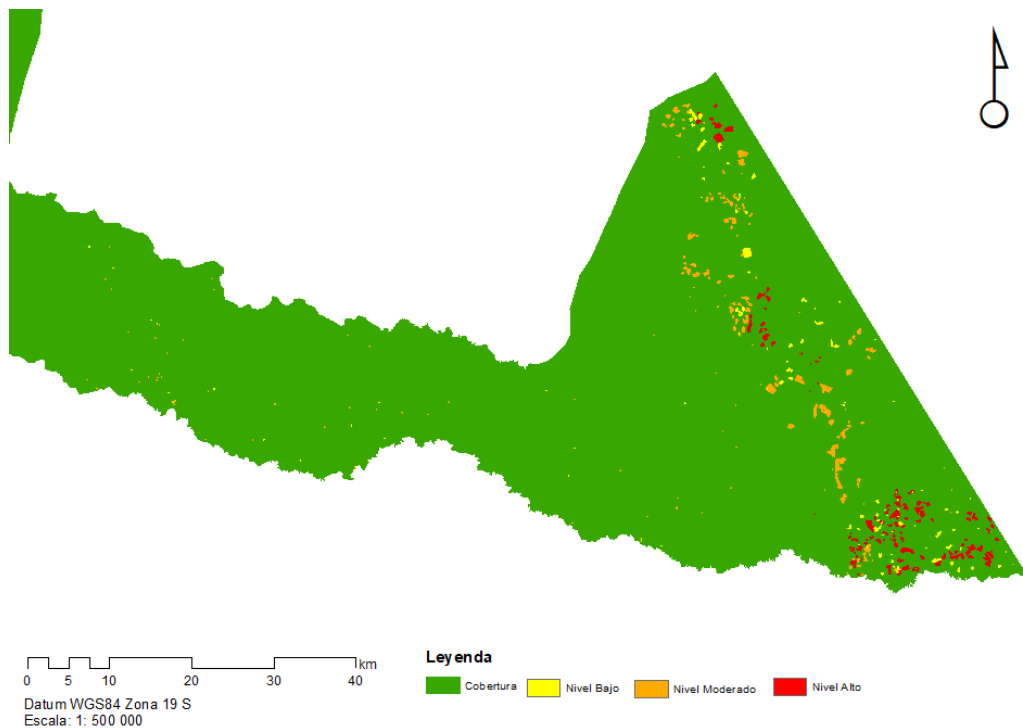


Figura 25. Determinación del nivel de gravedad de quemas mediante la Relación de Quemas (RBR) y del Índice Degradación Forestal del RADAR (RDFI) de datos de retrodispersión VV y VH pre y post incendio 2020; Ecuación 8, 9 y 10.

De los datos, se puede deducir la relación entre el cruce de cocientes absolutos-relativos, RDFI y la severidad del fuego estimada en el campo por cada quema por separado. Por lo tanto, fue factible estimar la severidad de las quemas a nivel de parcela, reportándose valores de; 1) Ab_Rel_VV_1 con 586,99 ha (Bajo), 1 167,35 ha (Moderado), y 1 209,00 ha (Alto)., 2) Ab_Rel_VV_2 con 676,97 ha (Bajo), 1 223,04 ha (Moderado), y 1 208,27 ha (Alto)., 3) Ab_Rel_VH_1 con 435,28 ha (Bajo), 1 277,14 ha (Moderado), 1 208,27 ha (Alto)., 4) Ab_Rel_VH_2 con 519,03 ha (Bajo), 1 983,04 ha (Moderado), 1 470,67 ha (Alto)., 5) RDFI_VVH con 536,18 ha (Bajo), 1 484,87 ha (Moderado), y 1 475,16 ha (Alto) (Figura 27).

Las áreas no afectadas mostraron 0 dB de cambio, con valores alrededor de 1 (lo esperado). Con el cruce de dispersión de la polarización cruzada VH, el coeficiente $Ab_Rel_VH_1$ mostro una ligera subestimación de la cuantificación sobre los otros cocientes. En el caso de $Ab_Rel_VH_2$ reporto una ligera sobrestimación respecto a los demás. Mientras que el $RDFI_VVVH$ mostro resultados mucho más consistentes, ello podría deberse a la dispersión del uso de copolarización (VV) y polarización cruzada (VH) en un mismo cociente (Figura 27) (Addison & Oommen, 2018; Belenguer-Plomer et al., 2019; Bernhard et al., 2011; Cannon & DeGraff, 2009; Coen et al., 2018; DeSiervo et al., 2015; Handbook, 2005; Kasischke et al., 1997; Lahaye et al., 2018; Martins et al., 2016; Morgan et al., 2014; Polychronaki et al., 2013; Sánchez et al., 2019; Stroppiana et al., 2015; Mihai A. Tanase et al., 2015; M. A. Tanase et al., 2015; Tanase et al., 2013; Tanase, Santoro, de La Riva, et al., 2010; Tanase, Santoro, Wegmüller, et al., 2010).

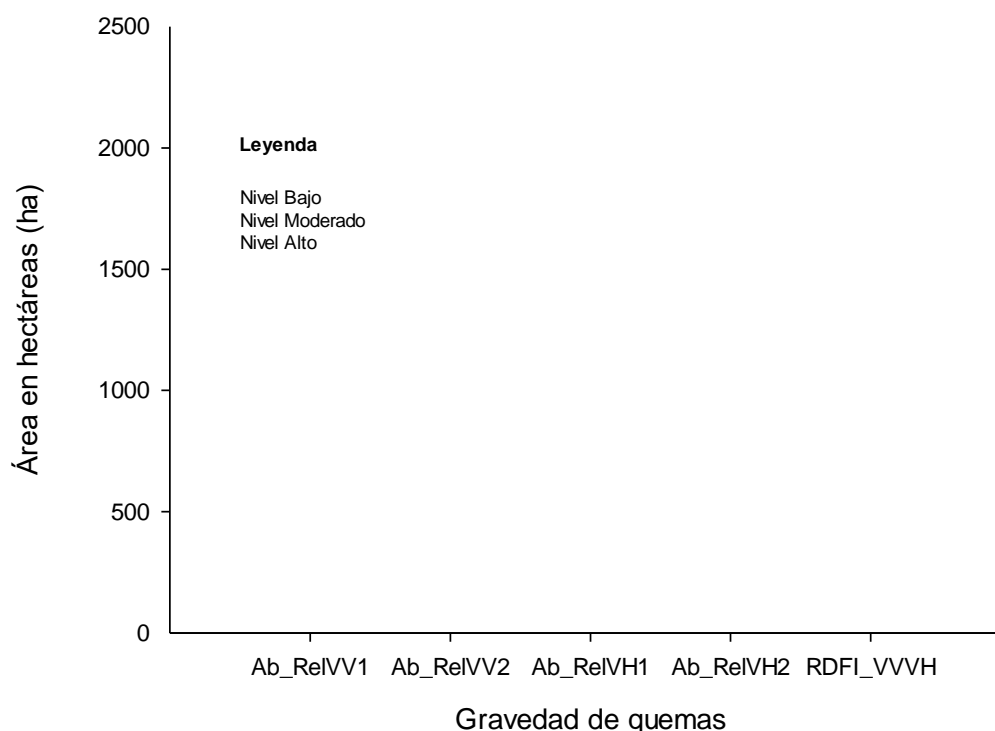


Figura 26. Áreas por nivel de gravedad de quemas mediante valores absolutos, relativos y Relación de Quemas (RBR) por medio del Índice Degradación Forestal del RADAR (RDFI) de datos de retrodispersión VV y VH pre y post incendio 2020; Ecuación 2, 3, 4, 5, 6, 7, 8, 9, 10.

La proporción de la severidad de quemas en los cocientes empleados, mostro rangos promedios de 38% a 42% en nivel Alto, de 39% a 50% en nivel Moderado, y 13% a 22% en el nivel Bajo.

Por otro lado, con el aumento de la severidad del fuego Ab_Rel_VV_1, Ab_Rel_VV_2, Ab_Rel_VH_1, Ab_Rel_VH_1, y RDFI_VVVH, aumento los valores posteriores al incendio, los más altos se explicaron por un efecto diferenciado de la severidad del incendio en las polarizaciones VV y VH respectivamente, con un disminución en la retrodispersión de VV debido a la eliminación de elementos de dispersión que se compensó con una mayor dispersión de la superficie (Addison & Oommen, 2018; Belenguer-Plomer et al., 2019; Bradstock et al., 2010; Porcher et al., 2018). El rango dinámico de los cocientes desde sin quemar (sin cambios) hasta niveles de severidad altos varió entre los incendios, estos resultados se asemejan a los hallazgos reportados por otros investigadores, donde, los valores se elevaron por la presencia de elementos dispersantes en bosques de la Amazonia (Bradstock et al., 2010; Hernández, 2019; Leite-Filho et al., 2020; Melo et al., 2021; Parks et al., 2014; Porcher et al., 2018; Santos et al., 2021). Sin embargo, el comportamiento es opuesto en bosque de coníferas, templados o boreales (Cannon & DeGraff, 2009; Collins et al., 2019; Lahaye et al., 2018; Martins et al., 2016; Polychronaki et al., 2013; Viedma et al., 2020) .

4.3 Evaluación de la precisión de los niveles de gravedad de quemas

Para medir la precisión de la severidad de quemas a los diferentes cocientes de copolarización y polarización cruzada, se llevó a cabo un análisis de coeficiente de concordancia para escalas nominales (kappa), y matriz de confusión a través datos obtenidos de campo sobre la severidad del fuego de las parcelas (CBI) (Cannon et al., 2010; Cohen, 1960; Cruz & Alexander, 2013; Murphy et al., 2008; Ochoa & Páez, 2019; Parks et al., 2014). La proporción de parcelas (n=384) con valores de CBI (Tablas 9, 10, 11, 12, y 13), fueron relativamente significativos. Sin embargo, es necesario realizar mediciones más detalladas sobre los parámetros de la estructura de la vegetación, para

aumentar la significancia del análisis estadístico (Cohen, 1960; Mihai A. Tanase et al., 2015; M. A. Tanase et al., 2015; Torres et al., 2012).

Las tablas 9, 10, 11, 12, y 13 presentan una matriz de acuerdo en términos de frecuencias. Se presentan las expectativas de azar para las casillas de la diagonal de acuerdo, ya que los demás valores son irrelevantes.

Con un $k = 0,523$, vemos que algo más de la mitad de los juicios conjuntos son acuerdos (excluyendo el azar) de los a datos Sentinel-1 de datos de retrodispersión VV_1. Los marginales son tales que k_{Max} es 1,004 por lo que una parte sustancial de los desacuerdos es consecuencia de discrepancias marginales. Se estima que la probabilidad de que el valor poblacional de x se sitúe entre 0,454 y 0,593 es del 95%, con una fuerza de concordancia Moderada (0,41-0,60) (Cohen, 1960) y una matriz de confusión de 0,682. El valor de z (14,506) mide la diferencia entre un estadístico observado y su parámetro hipotético de población en unidades de la desviación estándar, siendo significativo a una probabilidad de $(P) < 0,001$ (Tabla 9).

Tabla 9. Matriz de confusión e Índice de kappa de datos de prueba CBI (columnas) frente a datos SAR Sentinel-1 de datos de retrodispersión VV1

Categoría		CBI			
		Bajo	Moderado	Alto	$f_{SAR Sentinel-1}$
SAR Sentinel-1 (VV1)	Bajo	88 (42)	23	15	126
	Moderado	24	83 (43)	22	129
	Alto	16	22	91 (43)	129
	f_{CBI}	128	128	128	384
$f_o =$	262	$f_c =$		128	
$k =$	0,523	$k_M =$		1,004	
$\sigma_k =$	0,0356	$\sigma_{ko} =$		0,0361	
$z =$	14,506	Matriz de confusión =		0,682	

Los a datos Sentinel-1 de datos de retrodispersión VV_2, presenta un $k = 0,516$, donde algo más de la mitad de los juicios conjuntos son acuerdos (excluyendo el azar). Los marginales son tales que k_{Max} es 1,016 por lo que una parte sustancial de los desacuerdos es consecuencia de discrepancias marginales. Se estima que la probabilidad de que el valor poblacional de x se

sitúe entre 0,445 y 0,586 es del 95%, con una fuerza de concordancia Moderada (0,41-0,60) (Cohen, 1960) y una matriz de confusión de 0,677. El valor de z (14,289) fue significativo a una probabilidad de (P)<0,001 (Tabla 10).

Tabla 10, *Matriz de confusión e Índice de kappa de datos de prueba CBI (columnas) frente a datos SAR Sentinel-1 de datos de retrodispersión VV1*

Categoría		CBI			
		Bajo	Moderado	Alto	$f_{\text{SAR Sentinel-1}}$
SAR Sentinel-1 (VV2)	Bajo	86 (41)	23	15	124
	Moderado	23	85 (44)	24	132
	Alto	19	20	89 (43)	128
	f_{CBI}	128	128	128	384
$f_o=$	260		$f_c=$	128	
$k=$	0,516		$k_M=$	1,016	
$\sigma_k=$	0,0358		$\sigma_{k_o}=$	0,0361	
$z=$	14,289		Matriz de confusión=	0,677	

Los datos de retrodispersión VH_1 del sensor Sentinel-1, reporta un $k = 0,477$, donde se observa que un poco menos de la mitad de los juicios conjuntos son acuerdos (excluyendo el azar). Los marginales son tales que k_{Max} es 1,012 por lo que una parte sustancial de los desacuerdos es consecuencia de discrepancias marginales. Se estima que la probabilidad de que el valor poblacional de x se sitúe entre 0,405 y 0,548 es del 95%, con una fuerza de concordancia Moderada (0,41-0,60) (Cohen, 1960) y una matriz de confusión de 0,651. El valor de z (13,207) fue significativo a una probabilidad de (P)<0,001 (Tabla 11).

Tabla 11, *Matriz de confusión e Índice de kappa de datos de prueba CBI (columnas) frente a datos SAR Sentinel-1 de datos de retrodispersión VH1*

Categoría		CBI			
		Bajo	Moderado	Alto	$f_{\text{SAR Sentinel-1}}$
SAR Sentinel-1 (VH1)	Bajo	79 (41)	25	19	123
	Moderado	27	83 (44)	21	131
	Alto	22	20	88 (43)	130
	f_{CBI}	128	128	128	384
$f_o=$	250		$f_c=$	128	

k=	0,477	k _M =	1,012
σ _k =	0,0365	σ _{k_o} =	0,0361
z=	13,207	Matriz de confusión=	0,651

Con $k = 0,672$, vemos que más de la mitad de los juicios conjuntos son acuerdos (excluyendo el azar) de los datos Sentinel-1 de retrodispersión VH₂. Los marginales son tales que k_{Max} es 1,043 por lo que una parte sustancial de los desacuerdos es consecuencia de discrepancias marginales. Se estima que la probabilidad de que el valor poblacional de x se sitúe entre 0,610 y 0,734 es del 95%, con una fuerza de concordancia Considerable (0,61-0,80) (Cohen, 1960) y una matriz de confusión de 0,781. El valor de z (18,602) fue significativo a una probabilidad de $(P) < 0,001$ (Tabla 12).

Tabla 12, *Matriz de confusión e Índice de kappa de datos de prueba CBI (columnas) frente a datos SAR Sentinel-1 de datos de retrodispersión VH2*

Categoría		CBI			
		Bajo	Moderado	Alto	$f_{SAR Sentinel-1}$
SAR Sentinel-1 (VH2)	Bajo	101 (43)	15	13	129
	Moderado	15	104 (46)	20	139
	Alto	12	9	95 (39)	116
	f_{CBI}	128	128	128	384
$f_{o=}$	300		$f_{c=}$	128	
k=	0,672		k _M =	1,043	
σ _k =	0,0316		σ _{k_o} =	0,0361	
z=	18,602		Matriz de confusión=	0,781	

Finalmente, los datos Sentinel-1 de datos de retrodispersión VVVH presenta un $k = 0,742$, vemos que más de la mitad de los juicios conjuntos son acuerdos (excluyendo el azar). Los marginales son tales que k_{Max} es 1,051 por lo que una parte sustancial de los desacuerdos es consecuencia de discrepancias marginales. Se estima que la probabilidad de que el valor poblacional de x se sitúe entre 0,686 y 0,799 es del 95%, con una fuerza de concordancia Considerable (0,61-0,80) (Cohen, 1960) y una matriz de confusión de 0,828.

El valor de z (20,568) fue significativo a una probabilidad de (P)<0,001 (Tabla 13).

Tabla 13, *Matriz de confusión e Índice de kappa de datos de prueba CBI (columnas) frente a datos SAR Sentinel-1 de RBR y RDFI de datos de retrodispersión VV y VH*

Categoría		CBI			
		Bajo	Moderado	Alto	$f_{\text{SAR Sentinel-1}}$
SAR Sentinel-1 (VVVH)	Bajo	108 (44)	11	12	131
	Moderado	13	111 (47)	17	141
	Alto	7	6	99 (37)	112
	f_{CBI}	128	128	128	384
$f_o =$	318	$f_c =$		128	
$k =$	0,742	$k_M =$		1,051	
$\sigma_k =$	0,0289	$\sigma_{k_o} =$		0,0361	
$z =$	20,568	Matriz de confusión =		0,828	

Los resultados de la fiabilidad, determina a los cocientes de cruzamiento de valores absolutos y relativos de polarización cruzada VH_2 ($k=0.734$) y la Relación de Quemadas (RBR) por medio del Índice Degradación Forestal del RADAR (RDFI) ($k=0,799$) como las más concordantes para determinar la severidad de quemadas, mostrando una fuerza de concordancia Considerable respecto a una fuerza Moderada de los demás cocientes (Cannon et al., 2010; Cohen, 1960; Cruz & Alexander, 2013; Murphy et al., 2008; Ochoa & Páez, 2019; Parks et al., 2014).

CONCLUSIONES

La investigación proporciona un alcance del conocimiento en el uso de Imágenes SAR Sentinel-1 en la estimación del nivel de gravedad de quemas mediante el cociente de valores absolutos, relativos, y Relación de Quemadas (RBR) por medio del Índice Degradación Forestal del RADAR (RDFI), validados a través de datos obtenidos en campo sobre la severidad del fuego de las parcelas (CBI) en el distrito de Tahuamanu en el 2020.

El estudio cuantificó áreas quemadas mediante el empleo de valores absolutos, relativos y RBR de 2 963,34 ha (Ab_Rel_VV_1), 3 108,27 ha (Ab_Rel_VV_2), 2 920,68 ha (Ab_Rel_VH_1), 3 972,73 ha (Ab_Rel_VH_1), y 3 496,21 ha (RDFI_VVVH) respectivamente.

En cuanto a severidad de quemas, los cocientes de Ab_Rel_VH_2 (1) y RDFI_VVVH (2) presentaron mejores respuestas de dispersión, alcanzando una fuerza de concordancia Considerable. Cuantificando áreas quemadas (1) a nivel Alto de 1 407,67 ha, 1 983,04 ha en nivel Moderado, y 519,03 ha en nivel Bajo, (2) con 1 475,16 ha en nivel Alto, con 1 484,87 ha en nivel Moderado, y 536,18 ha en nivel Bajo. A nivel de ocurrencia y superficie, se reporta las mayores incidencias en los niveles Moderados (39% a 50%) y niveles Altos (38% a 42%). En cuanto a la precisión, los cocientes de cruzamiento de valores absolutos y relativos de polarización cruzada VH_2 ($k=0.734$) y RBR por medio del RDFI ($k=0,799$) resultaron las más concordantes para determinar la severidad de quemas, mostrando una fuerza de concordancia Considerable respecto a una fuerza Moderada de los demás cocientes.

Finalmente, se rechaza la hipótesis nula, donde la superficie y nivel de gravedad de quemas a través de técnicas de procesamiento de imágenes de RADAR de Apertura Sintética (SAR) a través de predictores absolutos, relativos, y Relación de Quemadas (RBR) por medio del Índice Degradación Forestal del RADAR (RDFI) no presenta un nivel de confiabilidad considerable y no sigue una tendencia creciente en el distrito de Tahuamanu – Madre de Dios.

RECOMENDACIONES

La apertura de tecnología SAR y plataformas de acceso abierto permiten el monitoreo de incidencias de quemas y los niveles de severidad después del incendio, el cual debe ser articulado a planes gestión y uso del territorio.

Es necesario plantear estudios del uso combinado de sensores ópticos y de RADAR para medir la precisión en la cuantificación y severidad de quemas en la región de Madre de Dios.

REFERENCIAS BIBLIOGRÁFICAS

- Addison, P., & Oommen, T. (2018). Utilizing satellite radar remote sensing for burn severity estimation. *International journal of applied earth observation and geoinformation*, 73, 292-299. <https://doi.org/https://doi.org/10.1016/j.jag.2018.07.002>
- Alarcon, G., Canahuire, R. R., Guevarra, F. M. G., Rodriguez, L., Gallegos, L. E., & Garate-Quispe, J. (2021). Dinámica de la pérdida de bosques en el sureste de la Amazonia peruana: un estudio de caso en Madre de Dios. *Ecosistemas*, 30(2), 2175-2175.
- Alarcón, G., Díaz, J., Vela, M., García, M., & Gutiérrez, J. (2016). 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*, 18(3), 319-330. <https://doi.org/10.18271/ria.2016.221>
- Allison, R. S., Johnston, J. M., Craig, G., & Jennings, S. (2016). Airborne optical and thermal remote sensing for wildfire detection and monitoring. *Sensors*, 16(8), 1310. <https://doi.org/https://doi.org/10.3390/s16081310>
- Amraoui, M., Pereira, M. G., DaCamara, C. C., & Calado, T. J. (2015). Atmospheric conditions associated with extreme fire activity in the Western Mediterranean region. *Science of the total environment*, 524, 32-39.
- Anaya, J. A., & Chuvieco, E. (2010). 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*, 32(92), 29.
- Baray, H. L. Á. (2006). *Introducción a la metodología de la investigación*. Juan Carlos Martínez Coll.
- Belenguer-Plomer, M. A., Tanase, M. A., Fernandez-Carrillo, A., & Chuvieco, E. (2019). Burned area detection and mapping using Sentinel-1 backscatter coefficient and thermal anomalies. *Remote Sensing of Environment*, 233, 111345. <https://doi.org/https://doi.org/10.1016/j.rse.2019.111345>
- Bernhard, E.-M., Twele, A., & Gähler, M. (2011). Rapid mapping of forest fires in the European Mediterranean region—a change detection approach using X-band SAR-data. *Photogrammetrie-Fernerkundung-Geoinformation*, 2011(4), 261-270. <https://doi.org/10.1127/1432-8364/2011/0087>
- Bradstock, R. A., Hammill, K. A., Collins, L., & Price, O. (2010). Effects of weather, fuel and terrain on fire severity in topographically diverse landscapes of south-eastern Australia. *Landscape Ecology*, 25(4), 607-619.
- Brassard, G., & Bratley, P. (1996). *Fundamentals of algorithmics* (Vol. 33). Prentice Hall Englewood Cliffs.
- Cannon, S. H., & DeGraff, J. (2009). The increasing wildfire and post-fire debris-flow threat in western USA, and implications for consequences of climate change. In *Landslides—disaster risk reduction* (pp. 177-190). Springer.

- Cannon, S. H., Gartner, J. E., Rupert, M. G., Michael, J. A., Rea, A. H., & Parrett, C. (2010). Predicting the probability and volume of postwildfire debris flows in the intermountain western United States. *Bulletin*, 122(1-2), 127-144. <https://doi.org/https://doi.org/10.1130/B26459.1>
- Canty, M. J. (2014). *Image analysis, classification and change detection in remote sensing: with algorithms for ENVI/IDL and Python*. Crc Press.
- Castro, F. (2003). El proceso de investigación y su esquema de elaboración. *Editorial Uyapar. Caracas*.
- Cazau, P. (2006). Introducción a la investigación en ciencias sociales. *Lima. Editorial Universidad Ricardo Palma*.
- Cerda, J., & Villarroel, L. (2008). Evaluación de la concordancia inter-observador en investigación pediátrica: Coeficiente de Kappa. *Revista chilena de pediatría*, 79(1), 54-58.
- Chávez, A., Huamani, L., Fernandez, R., Bejar, N., Valera, F., Perz, S., Brown, I., Domínguez, S., Pinedo, R., & Alarcón, G. (2013). Regional Deforestation Trends within Local Realities: Land-Cover Change in Southeastern Peru 1996–2011. *Land*, 2(2), 131. <https://doi.org/https://doi.org/10.3390/land2020131>
- Chuvienco, E. (1996). Empleo de imágenes de satélite para medir la estructura del paisaje: análisis cuantitativo y representación cartográfica. *Serie Geográfica*, 6, 131-147.
- Chuvienco, E., & Hantson, S. (2010). 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-mediatar-landsat_v2-2010.pdf*.
- Coen, J. L., Stavros, E. N., & Fites-Kaufman, J. A. (2018). Deconstructing the King megafire. *Ecological applications*, 28(6), 1565-1580.
- Cohen, J. (1960). A Coefficient of Agreement for Nominal Scales. *Educational and Psychological Measurement*, 20(1), 37-46. <https://doi.org/10.1177/001316446002000104>
- Collins, L., Bennett, A. F., Leonard, S. W. J., & Penman, T. D. (2019). Wildfire refugia in forests: Severe fire weather and drought mute the influence of topography and fuel age. *Global Change Biology*, 25(11), 3829-3843. <https://doi.org/https://doi.org/10.1111/gcb.14735>
- Cruz, M. G., & Alexander, M. E. (2013). Uncertainty associated with model predictions of surface and crown fire rates of spread. *Environmental Modelling & Software*, 47, 16-28.
- de Oliveira Alves, N., Brito, J., Caumo, S., Arana, A., de Souza Hacon, S., Artaxo, P., Hillamo, R., Teinilä, K., Batistuzzo de Medeiros, S. R., & de Castro Vasconcellos, P. (2015). Biomass burning in the Amazon region: Aerosol source apportionment and associated health risk assessment. *Atmospheric Environment*, 120, 277-285. <https://doi.org/https://doi.org/10.1016/j.atmosenv.2015.08.059>
- de Oliveira Alves, N., de Souza Hacon, S., de Oliveira Galvão, M. F., Simões Peixotoc, M., Artaxo, P., de Castro Vasconcellos, P., & de Medeiros, S. R. B. (2014). Genetic damage of organic matter in the Brazilian Amazon: A comparative study between intense and moderate biomass

- burning. *Environmental Research*, 130, 51-58.
<https://doi.org/https://doi.org/10.1016/j.envres.2013.12.011>
- DeSiervo, M. H., Jules, E. S., & Safford, H. D. (2015). Disturbance response across a productivity gradient: postfire vegetation in serpentine and nonserpentine forests. *Ecosphere*, 6(4), 1-19.
- Doerr, S. H., Shakesby, R. A., & MacDonald, L. H. (2009). Soil water repellency: a key factor in post-fire erosion. In *Fire effects on soils and restoration strategies* (pp. 213-240). CRC Press.
- dos Reis, M., Graça, P. M. L. d. A., Yanai, A. M., Ramos, C. J. P., & Fearnside, P. M. (2021). Forest fires and deforestation in the central Amazon: Effects of landscape and climate on spatial and temporal dynamics. *Journal of Environmental Management*, 288, 112310.
<https://doi.org/https://doi.org/10.1016/j.jenvman.2021.112310>
- Dourojeanni, M. (2014). Impactos socioambientales probables de la carretera transoceánica (Río Branco-Puerto Maldonado-Ilo) y la capacidad de respuesta del Perú. *Boletín CF+ S*(19).
- FAO. (2016). Los bosques y el cambio climático en el Perú. *Bosques y cambio climático. Documento de trabajo 14*.
- Gimeno, M., San-Miguel-Ayanz, J., & Schmuck, G. (2004). Identification of burnt areas in Mediterranean forest environments from ERS-2 SAR time series. *International Journal of Remote Sensing*, 25(22), 4873-4888.
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote sensing of Environment*, 202, 18-27.
- GOREMAD, & IIAP. (2009). Macro Zonificación Ecológica Económica de Madre de Dios. 208.
- Handbook, N. (2005). Origin & Cause Determination Handbook.
- Harvey, B. J., Andrus, R. A., & Anderson, S. C. (2019). Incorporating biophysical gradients and uncertainty into burn severity maps in a temperate fire-prone forested region. *Ecosphere*, 10(2), e02600.
- Hernández, H., & Montaner, D. (2009). Patrones de respuesta espectral. *Tecnologías Geoespaciales: Experiencias Aplicadas al Estudio y Gestión del Territorio. Carlos Mena (Ed.) ISBN, 978-996*.
- Hernández, H. M. (2019). Lo que usted debe saber sobre incendios de cobertura vegetal.
https://repositorio.gestiondelriesgo.gov.co/bitstream/handle/20.500.11762/28309/Cartilla_Incendios_2019.pdf?sequence=4
- Hernández, R., Fernández, C., & Baptista, P. (2010). *Metodología de la Investigación (Quinta edición ed.)*.(J. Mares Chacón, Ed.) Mexico, México DF. McGraw-Hill/Interamericana Editores, SA de CV.
- Hijmans, R. J., & van Etten, J. (2014). raster: Geographic data analysis and modeling. *R package version*, 2(8).
- INEI, I. N. d. E. e. I.-. (2017). *Magnitud y Crecimiento Poblacional*.
<http://www.inei.gob.pe/estadisticas/indice-tematico/poblacion-y-vivienda>
- Jensen, J. R. (2009). *Remote sensing of the environment: An earth resource perspective 2/e*. Pearson Education India.

- Jiang, Z. (2020). Geographical Information System in Web Application: Developing Web Application to Serve Spatial Data to Users.
- Kasischke, E. S., Melack, J. M., & Dobson, M. C. (1997). The use of imaging radars for ecological applications—A review. *Remote sensing of environment*, 59(2), 141-156.
[https://doi.org/https://doi.org/10.1016/S0034-4257\(96\)00148-4](https://doi.org/https://doi.org/10.1016/S0034-4257(96)00148-4)
- Kerle, N., Janssen, L. L. F., & Huurneman, G. C. (2004). Principles of remote sensing. *ITC, Educational textbook series*, 2, 250.
- Kern, A. N., Addison, P., Oommen, T., Salazar, S. E., & Coffman, R. A. (2017). Machine learning based predictive modeling of debris flow probability following wildfire in the intermountain Western United States. *Mathematical Geosciences*, 49(6), 717-735.
<https://doi.org/https://doi.org/10.1007/s11004-017-9681-2>
- Key, C. H., & Benson, N. C. (2006). Landscape assessment (LA). In: Lutes, Duncan C.; Keane, Robert E.; Caratti, John F.; Key, Carl H.; Benson, Nathan C.; Sutherland, Steve; Gangi, Larry J. 2006. FIREMON: Fire effects monitoring and inventory system. Gen. Tech. Rep. RMRS-GTR-164-CD. Fort Collins, CO: US Department of Agriculture, Forest Service, Rocky Mountain Research Station. p. LA-1-55, 164.
- Kuhn, M., & Johnson, K. (2013). *Applied predictive modeling* (Vol. 26). Springer.
- Lahaye, S., Curt, T., Fréjaville, T., Sharples, J., Paradis, L., & Hély, C. (2018). What are the drivers of dangerous fires in Mediterranean France? *International Journal of Wildland Fire*, 27(3), 155-163.
- Landis, J. R., & Koch, G. G. (1977). The measurement of observer agreement for categorical data. *biometrics*, 159-174.
- Leite-Filho, A. T., Costa, M. H., & Fu, R. (2020). The southern Amazon rainy season: The role of deforestation and its interactions with large-scale mechanisms. *International Journal of Climatology*, 40(4), 2328-2341.
- Li, S., Kang, X., Fang, L., Hu, J., & Yin, H. (2017). Pixel-level image fusion: A survey of the state of the art. *Information Fusion*, 33, 100-112.
- Li, X., Zhou, Y., Gong, P., Seto, K. C., & Clinton, N. (2020). Developing a method to estimate building height from Sentinel-1 data. *Remote Sensing of Environment*, 240, 111705.
- Lindner, M., Maroschek, M., Netherer, S., Kremer, A., Barbati, A., Garcia-Gonzalo, J., Seidl, R., Delzon, S., Corona, P., & Kolström, M. (2010). Climate change impacts, adaptive capacity, and vulnerability of European forest ecosystems. *Forest ecology and management*, 259(4), 698-709.
- Martins, F. d. S. R. V., dos Santos, J. R., Galvão, L. S., & Xaud, H. A. M. (2016). Sensitivity of ALOS/PALSAR imagery to forest degradation by fire in northern Amazon. *International journal of applied earth observation and geoinformation*, 49, 163-174.
- Melo, V. F., Barros, L. S., Silva, M. C. S., Veloso, T. G. R., Senwo, Z. N., Matos, K. S., & Nunes, T. K. O. (2021). Soil bacterial diversities and response to deforestation, land use and burning in North Amazon, Brazil. *Applied Soil Ecology*, 158, 103775.
<https://doi.org/https://doi.org/10.1016/j.apsoil.2020.103775>

- Miller-Rushing, A. J., Primackh, R. B., Devictor, V., Corlett, R. T., Cumming, G. S., Loyola, R., Maas, B., & Pejchar, L. (2019). How does habitat fragmentation affect biodiversity? A controversial question at the core of conservation biology.
- Morello, T., Anderson, L., & Silva, S. (2022). Innovative fire policy in the Amazon: A statistical Hicks-Kaldor analysis. *Ecological Economics*, 191, 107248. <https://doi.org/https://doi.org/10.1016/j.ecolecon.2021.107248>
- Morgan, P., Keane, R. E., Dillon, G. K., Jain, T. B., Hudak, A. T., Karau, E. C., Sikkink, P. G., Holden, Z. A., & Strand, E. K. (2014). Challenges of assessing fire and burn severity using field measures, remote sensing and modelling. *International Journal of Wildland Fire*, 23(8), 1045-1060.
- Murphy, K. A., Reynolds, J. H., & Koltun, J. M. (2008). Evaluating the ability of the differenced Normalized Burn Ratio (dNBR) to predict ecologically significant burn severity in Alaskan boreal forests. *International Journal of Wildland Fire*, 17(4), 490-499.
- Ochoa, C., & Páez, O. (2019). Inferencia estadística: probabilidad, variables aleatorias y distribuciones de probabilidad. *Evid Pediatr*, 15, 27.
- Parks, S. A., Dillon, G. K., & Miller, C. (2014). A new metric for quantifying burn severity: the relativized burn ratio. *Remote Sensing*, 6(3), 1827-1844. <https://doi.org/https://doi.org/10.3390/rs6031827>
- 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., & Rojas, D. (2016). La Amazonia como un sistema socio-ecológico: Las dinámicas de cambios complejos humanos y ambientales en una frontera trinacional. In J. Postigo & K. Young (Eds.), *Naturaleza y sociedad: Perspectivas socio-ecológicas sobre cambios globales en América Latina* (pp. 444). desco, IEP e INTE-PUCP.
- Perz, S., Qiu, Y., Xia, Y., Southworth, J., Sun, J., Marsik, M., Rocha, K., Passos, V., Rojas, D., Alarcón, G., Barnes, G., & Baraloto, C. (2013). Trans-boundary infrastructure and land cover change: Highway paving and community-level deforestation in a tri-national frontier in the Amazon. *Land Use Policy*, 34, 27-41. <https://doi.org/http://dx.doi.org/10.1016/j.landusepol.2013.01.009>
- Polychronaki, A., Gitas, I. Z., Veraverbeke, S., & Debieen, A. (2013). Evaluation of ALOS PALSAR imagery for burned area mapping in Greece using object-based classification. *Remote Sensing*, 5(11), 5680-5701.
- Porcher, V., Thomas, E., Corvera Gomringer, R., & Bardales Lozano, R. (2018). Fire- and distance-dependent recruitment of the Brazil nut in the Peruvian Amazon. *Forest Ecology and Management*, 427, 52-59. <https://doi.org/https://doi.org/10.1016/j.foreco.2018.05.052>
- Rodríguez, M. (2000). Incendios forestales. *El Ecologista*(21), 36-39.
- Sánchez, M. E. G., Borja, M. E. L., Álvarez, P. A. P., Romero, J. G., Cozar, J. S., Navarro, D. M., & de las Heras Ibáñez, J. (2019). Efecto de los trabajos de restauración forestal post-incendio en ladera sobre la recuperación de la funcionalidad del suelo. *Cuadernos de la Sociedad Española de Ciencias Forestales*(45), 35-44.

- Santos, A. M. d., Silva, C. F. A. d., Rudke, A. P., & Oliveira Soares, D. d. (2021). Dynamics of active fire data and their relationship with fires in the areas of regularized indigenous lands in the Southern Amazon. *Remote Sensing Applications: Society and Environment*, 23, 100570. <https://doi.org/https://doi.org/10.1016/j.rsase.2021.100570>
- Serrano, M. A. M., Catania, M., Sánchez, J., Vasconcelos, A., Kuijper, D., & Marc, X. (2015, 2015). Sentinel-1A flight dynamics LEOP operational experience.
- Shaner, J., & Wrightsell, J. (2000). *Editing in arcMap*. Esri.
- Shive, K. L., Preisler, H. K., Welch, K. R., Safford, H. D., Butz, R. J., O'Hara, K. L., & Stephens, S. L. (2018). From the stand scale to the landscape scale: predicting the spatial patterns of forest regeneration after disturbance. *Ecological Applications*, 28(6), 1626-1639.
- Smith, J., van de Kop, P., Reategui, K., Lombardi, I., Sabogal, C., & Diaz, A. (1999). Dynamics of secondary forests in slash-and-burn farming: interactions among land use types in the Peruvian Amazon. *Agriculture, Ecosystems & Environment*, 76(2), 85-98. [https://doi.org/https://doi.org/10.1016/S0167-8809\(99\)00075-4](https://doi.org/https://doi.org/10.1016/S0167-8809(99)00075-4)
- Southworth, J., Marsik, M., Qiu, Y., Perz, S., Cumming, G., Stevens, F., Rocha, K., Duchelle, A., & Barnes, G. (2011). Roads as Drivers of Change: Trajectories across the Tri-National Frontier in MAP, the Southwestern Amazon. *Remote Sensing*, 3(5), 1047-1066.
- Stevens, L. E., Schenk, E. R., & Springer, A. E. (2020). Springs ecosystem classification. *Ecological Applications*, e2218.
- Stroppiana, D., Azar, R., Calò, F., Pepe, A., Imperatore, P., Boschetti, M., Silva, J., Brivio, P. A., & Lanari, R. (2015). Integration of optical and SAR data for burned area mapping in Mediterranean Regions. *Remote Sensing*, 7(2), 1320-1345. <https://doi.org/https://doi.org/10.3390/rs70201320>
- Tanase, M. A., Kennedy, R., & Aponte, C. (2015). Fire severity estimation from space: A comparison of active and passive sensors and their synergy for different forest types. *International journal of wildland fire*, 24(8), 1062-1075. <https://doi.org/https://doi.org/10.1071/WF15059>
- Tanase, M. A., Kennedy, R., & Aponte, C. (2015). Radar Burn Ratio for fire severity estimation at canopy level: An example for temperate forests. *Remote Sensing of Environment*, 170, 14-31. <https://doi.org/https://doi.org/10.1016/j.rse.2015.08.025>
- Tanase, M. A., Santoro, M., Aponte, C., & de la Riva, J. (2013). Polarimetric properties of burned forest areas at C-and L-band. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(1), 267-276. <https://doi.org/10.1109/JSTARS.2013.2261053>
- Tanase, M. A., Santoro, M., de La Riva, J., Fernando, P., & Le Toan, T. (2010). Sensitivity of X-, C-, and L-band SAR backscatter to burn severity in Mediterranean pine forests. *IEEE Transactions on Geoscience and Remote Sensing*, 48(10), 3663-3675.
- Tanase, M. A., Santoro, M., Wegmüller, U., de la Riva, J., & Pérez-Cabello, F. (2010). Properties of X-, C-and L-band repeat-pass interferometric SAR coherence in Mediterranean pine forests affected by fires. *Remote Sensing of Environment*, 114(10), 2182-2194.

- Torres, R., Snoeij, P., Geudtner, D., Bibby, D., Davidson, M., Attema, E., Potin, P., Rommen, B., Floury, N., & Brown, M. (2012). GMES Sentinel-1 mission. *Remote Sensing of Environment*, 120, 9-24.
- Townsend, J. T. (1971). Theoretical analysis of an alphabetic confusion matrix. *Perception & Psychophysics*, 9(1), 40-50.
- Verhegghen, A., Eva, H., Ceccherini, G., Achard, F., Gond, V., Gourlet-Fleury, S., & Cerutti, P. O. (2016). The potential of sentinel satellites for burnt area mapping and monitoring in the Congo Basin forests. *Remote Sensing*, 8(12), 986.
- Viedma, O., Chico, F., Fernández, J. J., Madrigal, C., Safford, H. D., & Moreno, J. M. (2020). Disentangling the role of prefire vegetation vs. burning conditions on fire severity in a large forest fire in SE Spain. *Remote Sensing of Environment*, 247, 111891. <https://doi.org/https://doi.org/10.1016/j.rse.2020.111891>
- Xiuwan, C. (2002). Using remote sensing and GIS to analyse land cover change and its impacts on regional sustainable development. *International Journal of Remote Sensing*, 23(1), 107-124.
- Zuhlke, M., Fomferra, N., Brockmann, C., Peters, M., Veci, L., Malik, J., & Regner, P. (2015). SNAP (sentinel application platform) and the ESA sentinel 3 toolbox. *ESASP*, 734, 21.

ANEXOS

Anexo 1. Puntos de muestreo tomados en campo en el corredor minero de Madre de Dios.

Nº	Categoría se severidad de quema	Coordinada UTM (WGS84)	
		Este	Norte
1	Alto	486468	8687163
2	Alto	486494	8687428
3	Alto	486732	8687745
4	Alto	486653	8686449
5	Alto	487526	8685126
6	Alto	490595	8685047
7	Alto	486891	8683089
8	Alto	486547	8683644
9	Alto	486229	8684359
10	Alto	487208	8685893
11	Alto	486071	8688169
12	Alto	484351	8686846
13	Alto	483981	8686687
14	Alto	493188	8685391
15	Alto	494828	8685708
16	Alto	495384	8685682
17	Alto	497501	8686317
18	Alto	497712	8686555
19	Alto	499035	8688698
20	Alto	499670	8688354
21	Alto	497527	8688751
22	Alto	498480	8690153
23	Alto	499273	8689359
24	Alto	499326	8689889
25	Alto	486097	8688248
26	Alto	484298	8686872
27	Alto	488240	8690047
28	Alto	488240	8691661
29	Alto	486970	8690524
30	Alto	486071	8690762
31	Alto	485753	8689280
32	Alto	483954	8689254
33	Alto	488240	8686237
34	Alto	490436	8685073
35	Alto	488478	8690034
36	Alto	490066	8689876

37	Alto	490383	8690775
38	Alto	487208	8690564
39	Alto	487473	8691887
40	Alto	480012	8696861
41	Alto	480700	8697125
42	Alto	490013	8694638
43	Alto	475778	8693844
44	Alto	478901	8703211
45	Alto	480276	8703211
46	Alto	481546	8702311
47	Alto	479853	8698184
48	Alto	480911	8697178
49	Alto	480223	8696384
50	Alto	480171	8695167
51	Alto	478953	8703105
52	Alto	478424	8703634
53	Alto	480118	8703422
54	Alto	481335	8703369
55	Alto	480594	8704534
56	Alto	479218	8701941
57	Alto	481546	8703211
58	Alto	480329	8704692
59	Alto	478636	8705962
60	Alto	470698	8707232
61	Alto	471069	8708238
62	Alto	474244	8711413
63	Alto	474032	8712365
64	Alto	473238	8713106
65	Alto	469428	8713424
66	Alto	468952	8714323
67	Alto	475091	8711783
68	Alto	478477	8706333
69	Alto	484245	8710831
70	Alto	482076	8712154
71	Alto	478953	8705751
72	Alto	471598	8717763
73	Alto	469111	8715487
74	Alto	465354	8710513
75	Alto	471810	8717869
76	Alto	469164	8715964
77	Alto	468741	8719668
78	Alto	463925	8719879
79	Alto	463078	8719827

80	Alto	465724	8731362
81	Alto	467682	8726600
82	Alto	468370	8722790
83	Alto	476255	8714694
84	Alto	471598	8717922
85	Alto	472974	8719985
86	Alto	464295	8719985
87	Alto	463078	8719774
88	Alto	462073	8720303
89	Alto	465989	8731151
90	Alto	468582	8734855
91	Alto	465671	8736284
92	Alto	467153	8737871
93	Alto	465671	8737871
94	Alto	463131	8740041
95	Alto	461861	8740464
96	Alto	460485	8739829
97	Alto	459533	8739141
98	Alto	459110	8740411
99	Alto	460274	8740940
100	Alto	461332	8740676
101	Alto	462602	8740147
102	Alto	461703	8740094
103	Alto	466412	8736813
104	Alto	464878	8737183
105	Alto	464137	8738771
106	Alto	463025	8737765
107	Alto	459586	8739512
108	Alto	463555	8738824
109	Alto	461967	8738559
110	Alto	460115	8735649
111	Alto	459745	8737025
112	Alto	461650	8737077
113	Alto	462285	8735120
114	Alto	459758	8730560
115	Alto	461663	8729978
116	Alto	462615	8730084
117	Alto	460327	8735755
118	Alto	462179	8734590
119	Alto	459268	8740358
120	Alto	462020	8739670
121	Alto	466518	8736760
122	Alto	464930	8738400

123	Alto	465354	8739353
124	Alto	460062	8739406
125	Alto	459004	8738083
126	Alto	462602	8735490
127	Alto	465036	8738189
128	Alto	468582	8733585
129	Moderado	460866	8739903
130	Moderado	459798	8740771
131	Moderado	459745	8740115
132	Moderado	459872	8740411
133	Moderado	460718	8741459
134	Moderado	462062	8741766
135	Moderado	464814	8737522
136	Moderado	463830	8737744
137	Moderado	465502	8737596
138	Moderado	464825	8737871
139	Moderado	462898	8739660
140	Moderado	462983	8736368
141	Moderado	461226	8740210
142	Moderado	461226	8736972
143	Moderado	465650	8736982
144	Moderado	466730	8737596
145	Moderado	464803	8738930
146	Moderado	462962	8738485
147	Moderado	462814	8739395
148	Moderado	463544	8742062
149	Moderado	464581	8741787
150	Moderado	458464	8739162
151	Moderado	464888	8741321
152	Moderado	464253	8741639
153	Moderado	466952	8737712
154	Moderado	467206	8737988
155	Moderado	466074	8731310
156	Moderado	466539	8731288
157	Moderado	465692	8730844
158	Moderado	466455	8732347
159	Moderado	464571	8733574
160	Moderado	467555	8734061
161	Moderado	467428	8733786
162	Moderado	468508	8734485
163	Moderado	466010	8736474
164	Moderado	461015	8734400
165	Moderado	461226	8734633

166	Moderado	462348	8735416
167	Moderado	460866	8734887
168	Moderado	460231	8734400
169	Moderado	458707	8734887
170	Moderado	457247	8734379
171	Moderado	456993	8734781
172	Moderado	457628	8735352
173	Moderado	457501	8730505
174	Moderado	460761	8732664
175	Moderado	463102	8731661
176	Moderado	463893	8729870
177	Moderado	467640	8729510
178	Moderado	466328	8729637
179	Moderado	467598	8726335
180	Moderado	467915	8726357
181	Moderado	467132	8728621
182	Moderado	466751	8728875
183	Moderado	464825	8729087
184	Moderado	464676	8729722
185	Moderado	464211	8729024
186	Moderado	468487	8722292
187	Moderado	466984	8719625
188	Moderado	467217	8719710
189	Moderado	466963	8721128
190	Moderado	470159	8717826
191	Moderado	470624	8719308
192	Moderado	475196	8712408
193	Moderado	474879	8712365
194	Moderado	474646	8712471
195	Moderado	474265	8713720
196	Moderado	476276	8713487
197	Moderado	476403	8712704
198	Moderado	477863	8711328
199	Moderado	478371	8712281
200	Moderado	481589	8711519
201	Moderado	469989	8707730
202	Moderado	468614	8713127
203	Moderado	468127	8712746
204	Moderado	471217	8711243
205	Moderado	467471	8713529
206	Moderado	467746	8714270
207	Moderado	467132	8715646
208	Moderado	467576	8716302

209	Moderado	468317	8716345
210	Moderado	469312	8717234
211	Moderado	473080	8710926
212	Moderado	472868	8709868
213	Moderado	473651	8709508
214	Moderado	474180	8708640
215	Moderado	473080	8709000
216	Moderado	481335	8701316
217	Moderado	480869	8700766
218	Moderado	480467	8700448
219	Moderado	479980	8699940
220	Moderado	479874	8699581
221	Moderado	479917	8699115
222	Moderado	479768	8698734
223	Moderado	479472	8698649
224	Moderado	479451	8701972
225	Moderado	480128	8704830
226	Moderado	480615	8707518
227	Moderado	477927	8706947
228	Moderado	476636	8707074
229	Moderado	480827	8692701
230	Moderado	484256	8688891
231	Moderado	485483	8689696
232	Moderado	486267	8691855
233	Moderado	487410	8692617
234	Moderado	487283	8692236
235	Moderado	482160	8687748
236	Moderado	482097	8686415
237	Moderado	482880	8686351
238	Moderado	482012	8684870
239	Moderado	487156	8684679
240	Moderado	488828	8686373
241	Moderado	490627	8684827
242	Moderado	491960	8685822
243	Moderado	492130	8684933
244	Moderado	488320	8684065
245	Moderado	498797	8685494
246	Moderado	498533	8684753
247	Moderado	502713	8683854
248	Moderado	500543	8684224
249	Moderado	500649	8686394
250	Moderado	487050	8688934
251	Moderado	485938	8688722

252	Moderado	484774	8688087
253	Moderado	483716	8688352
254	Moderado	490013	8686764
255	Moderado	488796	8687082
256	Moderado	490860	8684806
257	Bajo	489590	8684806
258	Bajo	488214	8687135
259	Bajo	487579	8686182
260	Bajo	483981	8686129
261	Bajo	483716	8685283
262	Bajo	484774	8685865
263	Bajo	482552	8686394
264	Bajo	481864	8686764
265	Bajo	484086	8688669
266	Bajo	483716	8687082
267	Bajo	488002	8688775
268	Bajo	486732	8689569
269	Bajo	490648	8687293
270	Bajo	488055	8689569
271	Bajo	496257	8685600
272	Bajo	493453	8687082
273	Bajo	496469	8685970
274	Bajo	489696	8684118
275	Bajo	485145	8683113
276	Bajo	485303	8683854
277	Bajo	484245	8684118
278	Bajo	484616	8684648
279	Bajo	484404	8685547
280	Bajo	483610	8685124
281	Bajo	487156	8686764
282	Bajo	485991	8686076
283	Bajo	488055	8687611
284	Bajo	486573	8687611
285	Bajo	489854	8685653
286	Bajo	490225	8686817
287	Bajo	494035	8686129
288	Bajo	498374	8685865
289	Bajo	495993	8689251
290	Bajo	495993	8689780
291	Bajo	496151	8690204
292	Bajo	496681	8690627
293	Bajo	496046	8686182
294	Bajo	489643	8691527

295	Bajo	480488	8693802
296	Bajo	482816	8694702
297	Bajo	485356	8701105
298	Bajo	483028	8701687
299	Bajo	483451	8702163
300	Bajo	482869	8702163
301	Bajo	486309	8696501
302	Bajo	487314	8698141
303	Bajo	484510	8704068
304	Bajo	483134	8705973
305	Bajo	481441	8708301
306	Bajo	486415	8705814
307	Bajo	475408	8707190
308	Bajo	471968	8705761
309	Bajo	473715	8706449
310	Bajo	473768	8706978
311	Bajo	472921	8707349
312	Bajo	477207	8708778
313	Bajo	476413	8707772
314	Bajo	475726	8709730
315	Bajo	475302	8710788
316	Bajo	482922	8713275
317	Bajo	481970	8705285
318	Bajo	479853	8705655
319	Bajo	477207	8702745
320	Bajo	477419	8703645
321	Bajo	471492	8712905
322	Bajo	471281	8713910
323	Bajo	470804	8712905
324	Bajo	470222	8712005
325	Bajo	472974	8714493
326	Bajo	472921	8715498
327	Bajo	471810	8716450
328	Bajo	470910	8717456
329	Bajo	468317	8720525
330	Bajo	465777	8718990
331	Bajo	466465	8700628
332	Bajo	475567	8698776
333	Bajo	479271	8699411
334	Bajo	469481	8718408
335	Bajo	469799	8719202
336	Bajo	468000	8717085
337	Bajo	467418	8717350

338	Bajo	463660	8720790
339	Bajo	471598	8719837
340	Bajo	468529	8724441
341	Bajo	468000	8724653
342	Bajo	467312	8725605
343	Bajo	466677	8726028
344	Bajo	466624	8726346
345	Bajo	469005	8727404
346	Bajo	468741	8727986
347	Bajo	467418	8727510
348	Bajo	465883	8728833
349	Bajo	465460	8729733
350	Bajo	466306	8730473
351	Bajo	467206	8731902
352	Bajo	469481	8734601
353	Bajo	467629	8735130
354	Bajo	467206	8735448
355	Bajo	466306	8735024
356	Bajo	465301	8734918
357	Bajo	464348	8736083
358	Bajo	462549	8736982
359	Bajo	464507	8737353
360	Bajo	465830	8738252
361	Bajo	465989	8738993
362	Bajo	465248	8740422
363	Bajo	462973	8740686
364	Bajo	461332	8738623
365	Bajo	459956	8738305
366	Bajo	459480	8738093
367	Bajo	456993	8736083
368	Bajo	459956	8736559
369	Bajo	461967	8738252
370	Bajo	461861	8740581
371	Bajo	464983	8741004
372	Bajo	465301	8740157
373	Bajo	466095	8740316
374	Bajo	464243	8736136
375	Bajo	461438	8741321
376	Bajo	461015	8741057
377	Bajo	462179	8741216
378	Bajo	463343	8741480
379	Bajo	465830	8736559
380	Bajo	460433	8740210

381	Bajo	460697	8737935
382	Bajo	463449	8739099
383	Bajo	463608	8739734
384	Bajo	462549	8740316

Anexo 2. Panel fotográfico.



Foto 1. Reconocimiento de campo.



Foto 2. Lectura de datos de campo.



Foto 3. Captura de puntos UTM de quemas.



Foto 4. Puntos de campo, severidad de quemas.



Foto 5. Puntos de campo, severidad de quemas.



Foto 6. Levantamiento de punto de campo, quemas.



Foto 7. Puntos de muestreo de quemas.



Foto 8. Puntos de muestreo, severidad de quemas.



Foto 9. Puntos de muestreo, severidad de quemas.



Foto 10. Puntos de muestreo, severidad de quemas.



Foto 11. Puntos de muestreo, severidad de quemas.



Foto 12. Puntos de muestreo, severidad de quemas.



Foto 13. Puntos de muestreo, severidad de quemas.



Foto 14. Puntos de muestreo, severidad de quemas.

Anexo 3. Fichas de validación de campo.

BURN SEVERITY -- COMPOSITE BURN INDEX (BI)

GRAVEDAD DE LAS QUEMAS -- ÍNDICE COMPUESTO DE QUEMAS (CBI)

PD - Abridged		Examiners:		Fire Name:	
Registration Code		Project Code		Plot Number	
Field Date mmdyyy	/ /	Fire Date mmyyyy	/		
Plot Aspect		Plot % Slope		UTM Zone	
Plot Diameter Overstory		UTM E plot center		GPS Datum	
Plot Diameter Understory		UTM N plot center		GPS Error (m)	
Number of Plot Photos		Plot Photo IDs			

STRATA RATING FACTORS	BURN SEVERITY SCALE							FACTOR SCORES	
	No Effect	Low		Moderate		High			
	0.0	0.5	≤1.0	>1.0	2.0	>2.0	3.0		
A. SUBSTRATES									
% Pre-Fire Cover: Litter =		Duff =	Soil/Rock =	Pre-Fire Depth (inches): Litter =		Duff =	Fuel Bed =	Σ =	
Litter/Light Fuel Consumed	Unchanged	--	50% litter	--	100% litter	>80% light fuel	98% Light Fuel		
Duff	Unchanged	--	Light char	--	50% loss deep char	--	Consumed	N =	
Medium Fuel, 3-8 in.	Unchanged	--	20% consumed	--	40% consumed	--	>60% loss, deep ch		
Heavy Fuel, > 8 in.	Unchanged	--	10% loss	--	25% loss, deep char	--	>40% loss, deep ch	X =	
Soil & Rock Cover/Color	Unchanged	--	10% change	--	40% change	--	>80% change		
B. HERBS, LOW SHRUBS AND TREES LESS THAN 3 FEET (1 METER):									
Pre-Fire Cover =		% Enhanced Growth =							Σ =
% Foliage Altered (blk-brn)	Unchanged	--	30%	--	80%	95%	100% + branch loss		
Frequency % Living	100%	--	90%	--	50%	< 20%	None	N =	
Colonizers	Unchanged	--	Low	--	Moderate	High-Low	Low to None		
Spp. Comp. - Rel. Abund.	Unchanged	--	Little change	--	Moderate change	--	High change	X =	
C. TALL SHRUBS AND TREES 3 to 16 FEET (1 TO 5 METERS):									
Pre-Fire Cover =		% Enhanced Growth =							Σ =
% Foliage Altered (blk-brn)	0%	--	20%	--	60-90%	> 95%	Signifcnt branch loss		
Frequency % Living	100%	--	90%	--	30%	< 15%	< 1%	N =	
% Change in Cover	Unchanged	--	15%	--	70%	90%	100%		
Spp. Comp. - Rel. Abund.	Unchanged	--	Little change	--	Moderate change	--	High Change	X =	
D. INTERMEDIATE TREES (SUBCANOPY, POLE-SIZED TREES)									
Pre-Fire % Cover =		Pre-Fire Number Living =		Pre-Fire Number Dead =					Σ =
% Green (Unaltered)	100%	--	80%	--	40%	< 10%	None		
% Black (Torch)	None	--	5-20%	--	60%	> 85%	100% + branch loss	N =	
% Brown (Scorch/Girdle)	None	--	5-20%	--	40-80%	< 40 or > 80%	None due to torch		
% Canopy Mortality	None	--	15%	--	60%	80%	% 100	X =	
Char Height	None	--	1.5 m	--	2.8 m	--	> 5 m		
Post Fire: %Girdled =		%Felled =	%Tree Mortality =						
E. BIG TREES (UPPER CANOPY, DOMINANT, CODOMNANT TREES)									
Pre-Fire % Cover =		Pre-Fire Number Living =		Pre-Fire Number Dead =					Σ =
% Green (Unaltered)	100%	--	95%	--	50%	< 10%	None		
% Black (Torch)	None	--	5-10%	--	50%	> 80%	100% + branch loss	N =	
% Brown (Scorch/Girdle)	None	--	5-10%	--	30-70%	< 30 or > 70%	None due to torch		
% Canopy Mortality	None	--	10%	--	50%	70%	% 100	X =	
Char Height	None	--	1.8 m	--	4 m	--	> 7 m		
Post Fire: %Girdled =		%Felled =	%Tree Mortality =						
Community Notes/Comments:				CBI = Sum of Scores / N Rated:		Sum of Scores	N Rated	CBI	
				Understory (A+B+C)					
				Overstory (D+E)					
				Total Plot (A+B+C+D+E)					

Fuente: Tomado y adaptado de Key and Benson (2006).

