



**Modelamiento de las alturas del dosel de los manglares en la Provincia de El Oro,
empleando datos SAR y LiDAR en un algoritmo de Inteligencia Artificial**

Asimbaya Socasi, Katty Vanessa

Departamento de Ciencias de la Tierra y de la Construcción

Carrera de Ingeniería Geográfica y del Medio Ambiente

Trabajo de titulación, previo a la obtención del título de Ingeniera Geógrafa y del
Medio Ambiente

PhD. Padilla Almeida, Oswaldo Vinicio

31 de agosto del 2023

TESIS ASIMBAYA KATTY.pdf

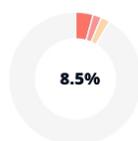
Scan details

Scan time:
August 16th, 2023 at 13:55 UTC

Total Pages:
89

Total Words:
22153

Plagiarism Detection



| Types of plagiarism | | Words |
|---------------------|------|-------|
| Identical | 4.3% | 944 |
| Minor Changes | 2% | 453 |
| Paraphrased | 2.2% | 483 |
| Omitted Words | 0% | 0 |

AI Content Detection



Text coverage
 AI text
 Human text

Plagiarism Results: (113)



OSWALDO VINICIO
PADILLA ALMEIDA

CARACTERIZACIÓN DE LAS CONDICIONES DEL PÁRA... **1.1%**

<http://repositorio.puce.edu.ec/bitstream/handle/22000/1528...>

estudiante

FACULTAD DE CIENCIAS HUMANAS ESCUELA DE CIENCIAS GEOGRÁFICAS
CARRERA DE CIENCIAS GEOGRÁFICAS Y MEDIO AMBIENTE DISERTACIÓN...

PLAN-DE-MANEJO-JOVENES-DEL-MANGLAR-25-02-20... **0.9%**

<https://proyectomarinocostero.com.ec/wp-content/uploads/...>

Martha Sánchez T.

MANEJO INTEGRADO DE ESPACIOS MARINOS Y COSTEROS DE ALTO VALOR
PARA LA BIODIVERSIDAD EN EL ECUADOR CONTINENTAL PLAN DE MANEJO...

capituloIIPropuestaAplicacionCOT.docx **0.8%**

<https://info.napo.gob.ec/wp-content/uploads/2022/07/capitu...>

[image:] ZONIFICACIÓN ECOLÓGICA ECONÓMICA DE LA PROVINCIA DE NAPO
Índice 1.Introducción 2.Marco Conceptual 3.Objetivos...



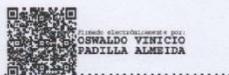
Departamento de Ciencias de la Tierra y de la Construcción
Carrera de Ingeniería Geográfica y del Medio Ambiente

Certificación

Certifico que el trabajo de titulación: **“Modelamiento de las alturas del dosel de los manglares en la Provincia de El Oro, empleando datos SAR y LIDAR en un algoritmo de Inteligencia Artificial”** fue realizado por la señorita Asimbaya Socasi Katty Vanessa; el mismo que cumple con los requisitos legales, teóricos, científicos, técnicos y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, además fue revisado y analizado en su totalidad por la herramienta de prevención y/o verificación de similitud de contenidos; razón por la cual me permito acreditar y autorizar para que se lo sustente públicamente.

Sangolquí, 31 de agosto del 2023

Firma:



PhD. Oswaldo Vinicio Padilla Almeida

C. C.: 1709776650



Departamento de Ciencias de la Tierra y de la Construcción

Carrera de Ingeniería Geográfica y del Medio Ambiente

Responsabilidad de Autoría

Yo, **Asimbaya Socasi Katty Vanessa**, con cédula de ciudadanía n° 1724688716, declaro que el contenido, ideas y criterios del trabajo de titulación: **“Modelamiento de las alturas del dosel de los manglares en la Provincia de El Oro, empleando datos SAR y LiDAR en un algoritmo de Inteligencia Artificial”** es de mi autoría y responsabilidad, cumpliendo con los requisitos legales, teóricos, científicos, técnicos, y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, respetando los derechos intelectuales de terceros y referenciando las citas bibliográficas.

Sangolquí, 31 de agosto del 2023

.....
Asimbaya Socasi Katty Vanessa

C.C.: 1724688716



Departamento de Ciencias de la Tierra y de la Construcción

Carrera de Ingeniería Geográfica y del Medio Ambiente

Autorización de Publicación

Yo **Asimbaya Socasi Katty Vanessa**, con cédula de ciudadanía n°1724688716, autorizo a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de titulación: **“Modelamiento de las alturas del dosel de los manglares en la Provincia de El Oro, empleando datos SAR y LiDAR en un algoritmo de Inteligencia Artificial”** en el Repositorio Institucional, cuyo contenido, ideas y criterios son de mi responsabilidad.

Sangolquí, 31 de agosto del 2023

.....
Asimbaya Socasi Katty Vanessa

C.C.: 1724688716

Dedicatoria

A mi dulce madre Julia y hermano Mateo, quienes han estado a mi lado en todo momento apoyándome con su cálido amor.

A mi abuelo Miguel, quien ha sido como un padre para mí y ha guiado cada etapa de mi vida con sus sabias palabras.

A Andrés, mi compañero de vida quien siempre me inspira a ser una mejor persona.

A mis tías Aidé y Elvia, quienes a pesar de la distancia me han brindado su inmenso cariño y apoyo.

Agradecimiento

A mi madre Julia, por todo su amor, paciencia y apoyo en mis años de preparación académica.

A mi abuela Diocelina y abuelo Miguel, por todos sus consejos de vida que atesoro.

A mis tías, Elvia y Aidé quienes estuvieron pendientes de mí en mis años de estudio.

A mis amigos Valeria, Andy, Estefanía, Mabel, Brayan y Anthony, por todas las experiencias que compartimos juntos dentro y fuera de las aulas.

A Jonathan Panimboza y Adrián Rodríguez, por su acompañamiento en el desarrollo de este proyecto.

Al Ing. Oswaldo Padilla Ph.D., por su calidez, confianza y acompañamiento en el desarrollo de la presente investigación.

Al Ing. Eduardo Kirby, MSc., por su guía y recomendaciones para que este proyecto se realizara con éxito.

A mi querida Universidad de las Fuerzas Armadas-ESPE, en especial al departamento de Ciencias de la Tierra y la Construcción, en donde tuve la maravillosa oportunidad de conocer a mis profesores, quienes no solo compartieron conocimientos relacionados al campo profesional sino también experiencias, consejos y reflexiones para hacer de nosotros mejores seres humanos.

Índice de contenido

| | |
|--------------------------------------|----|
| Resumen..... | 17 |
| Abstract..... | 18 |
| Capítulo I: Aspectos generales..... | 19 |
| Antecedentes..... | 19 |
| Planteamiento del problema..... | 22 |
| Justificación e importancia..... | 24 |
| Descripción del área de estudio..... | 26 |
| Objetivos..... | 27 |
| Objetivo General..... | 27 |
| Objetivos Específicos..... | 28 |
| Metas..... | 28 |
| Capítulo II: Marco teórico..... | 29 |
| Teledetección..... | 29 |
| Sensor activo..... | 29 |
| Sensor pasivo..... | 30 |
| Radiación electromagnética..... | 30 |
| Espectro electromagnético..... | 31 |
| Imagen satelital..... | 32 |
| Resolución espacial..... | 32 |
| Resolución espectral..... | 32 |
| Resolución radiométrica..... | 32 |

| | |
|--|----|
| Resolución temporal..... | 33 |
| Mosaico de imágenes satelitales | 33 |
| Sistema RADAR | 33 |
| Bandas de los sistemas RADAR | 34 |
| Radares de Imágenes..... | 34 |
| Ecuación del Sistema Radar | 35 |
| Amplitud | 36 |
| Fase..... | 36 |
| Speckle o ruido en las imágenes de RADAR..... | 36 |
| Retrodispersión | 37 |
| Coeficiente de retrodispersión | 37 |
| Mecanismos de retrodispersión..... | 38 |
| Polarización..... | 39 |
| Sistema de Radar de Apertura Sintética SAR..... | 40 |
| Geometría de adquisición SAR | 42 |
| Efectos geométricos que se producen en una imagen de SAR | 42 |
| Resoluciones de las imágenes SAR | 44 |
| Tecnología LiDAR..... | 45 |
| Nube de puntos..... | 46 |
| Tecnología LiDAR Satelital | 47 |
| Google Earth Engine | 47 |

| | |
|---|----|
| | 10 |
| Satélite Sentinel-1 | 48 |
| Modos de adquisición | 49 |
| Niveles de procesamiento de los datos de Sentinel-1 | 51 |
| Preprocesamiento de imágenes Sentinel-1 en GEE..... | 52 |
| Misión GEDI..... | 53 |
| Funcionamiento de GEDI | 53 |
| Productos de datos de GEDI..... | 54 |
| Inteligencia Artificial..... | 55 |
| Aprendizaje automático | 56 |
| Random Forest | 57 |
| Tecnologías de teledetección activas para inventarios de recursos naturales | 58 |
| Bosques de manglares | 59 |
| Mecanismos de dispersión en los manglares | 60 |
| Media aritmética..... | 60 |
| Muestreo aleatorio simple | 60 |
| Base Legal | 61 |
| Constitución de la República del Ecuador..... | 61 |
| Código Orgánico del Ambiente..... | 62 |
| Código Orgánico de Ordenamiento Territorial, Autonomía y Descentralización..... | 64 |
| Código orgánico de la Economía Social de los Conocimientos e Innovación..... | 65 |
| Ley de Seguridad Pública y del Estado..... | 65 |

| | |
|--|----|
| | 11 |
| Capítulo III: Metodología..... | 66 |
| Fase de obtención de los datos | 68 |
| Determinación del área de estudio..... | 68 |
| Recopilación y filtrado de datos..... | 68 |
| Preprocesamiento de datos..... | 71 |
| Generación del mosaico de datos SAR Sentinel-1 para el año 2021 | 71 |
| Eliminación de ruido o “speckle” en el mosaico de datos SAR Sentinel-1 | 72 |
| Definición de máscaras para el análisis del modelamiento | 72 |
| Definición de máscaras para el mosaico Sentinel-1 2021 | 74 |
| Normalización de los datos SAR | 74 |
| Generación del mosaico de datos LiDAR de la misión GEDI..... | 75 |
| Definición de máscaras para el Mosaico LiDAR de GEDI 2021 | 76 |
| Corrección de alturas respecto al nivel medio del mar | 76 |
| Depuración manual de datos LiDAR | 77 |
| Procesamiento de los datos | 77 |
| Definición de muestras de datos de entrenamiento y prueba | 77 |
| Ejecución de la regresión del algoritmo Random Forest | 78 |
| Validación de los resultados y obtención de los resultados | 79 |
| Evaluación de la precisión de los modelamientos | 79 |
| Generación del aplicativo web de visualización de resultados en GEE | 79 |

| | |
|---|-----|
| Generación de la guía para la gestión ambiental de los bosques de manglar ubicados en la cuenca hidrográfica del Río Pagua en base a los resultados obtenidos del aplicativo web..... | 83 |
| Capítulo IV: Resultados | 84 |
| Resultados de los códigos fuentes utilizados en el presente proyecto | 84 |
| Resultados de la recopilación y filtrado de datos SAR de la misión Sentinel-1 | 84 |
| Resultados de la recopilación y filtrado de datos LiDAR de GEDI..... | 86 |
| Resultados de la generación del mosaico Sentinel-1 para el año 2021 | 87 |
| Resultados de la eliminación de “speckle” en el mosaico de datos SAR Sentinel-1 | 89 |
| Resultados de la definición de máscaras para Mosaico Sentinel 1 2021 | 90 |
| Resultados de la normalización de los datos SAR Sentinel-1..... | 90 |
| Resultados de la generación del mosaico de datos LiDAR GEDI para el año 2021 | 91 |
| Resultado de la corrección de alturas respecto al nivel medio del mar | 92 |
| Resultado de la depuración de datos LiDAR | 93 |
| Resultados de la definición de muestras de datos de entrenamiento y prueba | 96 |
| Resultados de la ejecución de regresión del algoritmo de regresión Random Forest | 100 |
| Resultados de la evaluación de la precisión de los modelos de alturas del dosel | 106 |
| Resultados de la generación del aplicativo web de visualización de resultados en GEE . | 107 |
| Capítulo V: Conclusiones y Recomendaciones | 110 |
| Conclusiones | 110 |
| Recomendaciones..... | 111 |
| Bibliografía | 113 |

Índice de tablas

| | |
|--|-----|
| Tabla 1 Bandas RADAR..... | 34 |
| Tabla 2 Características de filtrado para los datos de Sentinel-1..... | 69 |
| Tabla 3 Características de filtrado para los datos GEDI | 70 |
| Tabla 4 Archivos vectoriales utilizados en el presente proyecto..... | 71 |
| Tabla 5 Datos de entrada correspondientes a las alturas LiDAR que ingresaron en el algoritmo RF..... | 80 |
| Tabla 6 Imágenes SAR recopiladas para el proyecto | 85 |
| Tabla 7 Imágenes LiDAR recopiladas para el proyecto | 86 |
| Tabla 8 Grupos de entrenamiento y validación de alturas LiDAR correspondientes a la Máscara 1 | 97 |
| Tabla 9 Grupos de entrenamiento y validación de alturas LiDAR correspondientes a la Máscara 2 | 98 |
| Tabla 10 Descripción de los modelos de altura del dosel generados a partir de la Máscara 1 | 100 |
| Tabla 11 Descripción de los modelos de altura del dosel generados a partir de la Máscara 2 | 103 |
| Tabla 12 Resultados de RMSE obtenidos para los modelos de alturas del dosel de los manglares | 106 |

Índice de Figuras

| | |
|---|----|
| Figura 1 Árbol de problemas | 24 |
| Figura 2 Ubicación del área de estudio | 27 |
| Figura 3 Diagrama de una onda electromagnética | 30 |
| Figura 4 Espectro electromagnético | 31 |
| Figura 5 Imagen Satelital que presenta ruido o speckle | 37 |
| Figura 6 Mecanismos de dispersión | 39 |
| Figura 7 Tipos de polarización | 40 |
| Figura 8 Efecto geométrico de escorzo | 43 |
| Figura 9 Efecto geométrico de inversión por relieve | 43 |
| Figura 10 Efecto geométrico de sombras | 44 |
| Figura 11 Modos de adquisición de Sentinel-1 | 49 |
| Figura 12 Forma de onda GEDI | 54 |
| Figura 13 Metodología general del proyecto | 67 |
| Figura 14 Máscara 1 definida para el estudio | 73 |
| Figura 15 Máscara 2 definida para el estudio | 73 |
| Figura 16 Representación del boceto de una parte del panel de capas del geovisor del proyecto | 82 |
| Figura 17 Mosaico de Imágenes Sentinel-1 | 87 |
| Figura 18 Bandas de polarización que conforman el Mosaico Sentinel-1 2021 | 88 |
| Figura 19 Representación del Mosaico SAR 2021 después de la eliminación de moteado..... | 89 |
| Figura 20 Máscaras definidas para el Mosaico Sentinel-1 | 90 |
| Figura 21 Mosaico Sentinel-1 corregido de moteado, normalizados | 91 |
| Figura 22 Mosaico LiDAR de GEDI 2021 obtenido en GEE | 91 |
| Figura 23 Transformación del mosaico LiDAR GEDI 2021 a cobertura vectorial | 92 |
| Figura 24 Representación de los puntos LiDAR ubicados en el océano | 93 |

| | |
|---|-----|
| Figura 26 Corrección de las alturas LiDAR respecto al nivel empleando la calculadora de campos del Software QGIS | 93 |
| Figura 26 Alturas LiDAR depuradas para la Máscara 1 | 94 |
| Figura 27 Histograma de la distribución de alturas LiDAR definidas para la Máscara 1 | 95 |
| Figura 28 Alturas LiDAR depuradas para la Máscara 2 | 95 |
| Figura 29 Histograma de la distribución de alturas LiDAR definidas para la Máscara 2 | 96 |
| Figura 30 Representación de los puntos de entrenamiento y validación (80 VS 20) para la Máscara 1 | 97 |
| Figura 31 Representación de los puntos de entrenamiento y validación (90 VS 10) para la Máscara 1 | 98 |
| Figura 32 Representación de los puntos de entrenamiento y validación (80 VS 20) para la Máscara 2 | 99 |
| Figura 33 Representación de los puntos de entrenamiento y validación (90 VS 10) para la Máscara 2 | 99 |
| Figura 34 Modelo 1 de las alturas del dosel de los manglares para la provincia de El Oro 2021 | 101 |
| Figura 35 Modelo 2 de las alturas del dosel de los manglares para la provincia de El Oro 2021 | 101 |
| Figura 36 Modelo 3 de las alturas del dosel de los manglares para la provincia de El Oro 2021 | 102 |
| Figura 37 Modelo 4 de las alturas del dosel de los manglares para la provincia de El Oro 2021 | 102 |
| Figura 38 Modelo 5 de las alturas del dosel de los manglares para la provincia de El Oro 2021 | 104 |
| Figura 39 Modelo 6 de las alturas del dosel de los manglares para la provincia de El Oro 2021 | 104 |

| | |
|---|-----|
| Figura 40 Modelo 7 de las alturas del dosel de los manglares para la provincia de El Oro 2021 | 105 |
| Figura 41 Modelo 8 de las alturas del dosel de los manglares para la provincia de El Oro 2021 | 105 |
| Figura 42 Geovisor de representación de datos de entrada así como de resultados de la investigación | 108 |
| Figura 43 Código QR de acceso al aplicativo web | 109 |

Resumen

La teledetección es una herramienta poderosa ampliamente utilizada para cartografiar y monitorear recursos naturales. En la investigación se estudió el potencial de combinar datos de Radar de Apertura Sintética (retrodispersión) de Imágenes Sentinel-1 con mediciones LiDAR (alturas en metros) de GEDI para la estimación de las alturas del dosel de los bosques de manglar en la provincia de El Oro para el año 2021. Se aplicó el algoritmo de aprendizaje automático, Random Forest (RF) para regresión dentro del entorno computación Google Earth Engine (GEE). Este se entrenó en base a dos grupos de alturas, el primero con el 90% destinado a entrenamiento dejando los 10% para validación, y el segundo con 80% para entrenamiento y 20% para validación. Se generaron dos máscaras, una que contenía información adyacente a la cobertura de manglar y otra que solo incluía a esta. Se determinó que los modelos con los RMSE más bajos, correspondientes a 2.86 metros generado en torno a la máscara 1 y 3.93 metros para la máscara 2 son aplicables efectivamente para la escala de 1: 25 000, mas esta escala solo se puede garantizar a lo largo de las pistas por donde el satélite GEDI adquiere los datos, es decir es relativa ya que existe la incertidumbre de que se alcance esta precisión en las coberturas totales de los modelos por lo que se abre paso a más estudios en donde se puedan corroborar estos resultados. Esta investigación demostró el potencial que tiene GEE para procesar datos de diferentes satélites, herramienta con la cual se puede llevar acabo más estudios relacionados a los parámetros biofísicos de los manglares.

Palabras claves: Radar de Apertura Sintética, Random Forest, dosel de los manglares.

Abstract

Remote sensing is a powerful and widely used tool for mapping and monitoring natural resources. This research investigated the potential of combining Synthetic Aperture Radar (SAR) data from Sentinel-1 images with Light Detection and Ranging (LiDAR) measurements (in meters) from GEDI for estimating canopy heights of mangrove forests in the El Oro province for the year 2021. The machine learning algorithm, Random Forest (RF), was applied within the Google Earth Engine (GEE) computing environment. It was trained using two height datasets, with the first allocated 90% for training and 10% for validation, and the second with 80% for training and 20% for validation. Two masks were generated, one containing information adjacent to the mangrove coverage and another that included only the mangrove area. It was determined that models with the lowest Root Mean Square Error (RMSE), which were 2.86 meters for Mask 1 and 3.93 meters for Mask 2, were effectively applicable at the 1:25,000 scale. However, this scale can only be guaranteed along the satellite GEDI data acquisition tracks, making it relative due to uncertainty regarding achieving this level of precision across the total model coverage. This opens the door to further studies to corroborate these results. This research demonstrated the potential that GEE has for processing data from different satellites, a tool with which further studies related to the biophysical parameters of mangroves can be conducted.

Keywords: Synthetic Aperture Radar, Random Forest, mangrove canopy.

Capítulo I: Aspectos generales

En el siguiente capítulo, se abordan los aspectos generales del presente proyecto titulado "Modelamiento de las alturas del dosel de los manglares en la Provincia de El Oro, empleando datos SAR y LiDAR en un algoritmo de Inteligencia Artificial". Se proporciona información bibliográfica relevante sobre estudios similares y se plantea el problema a abordar, justificando su importancia, así como los objetivos y metas de la investigación.

Antecedentes

En las últimas décadas las técnicas geoespaciales han tomado un papel relevante en la adquisición de información de diferentes recursos de la tierra. El contar con información de herramientas avanzadas como la teledetección satelital, GPS y los sistemas de información geográfica, le han proporcionado a la población nuevas dimensiones para monitorear y administrar los recursos de la tierra (Baker et al., 2015). Uno de los ejemplos claros de estudios de recursos naturales son los manglares, ecosistemas marino-costeros de gran relevancia para el mundo, ya que se constituyen como la base de la seguridad alimentaria de miles de personas cuyos medios de vida dependen de los bienes y servicios ecosistémicos que proveen (Moreno et al., 2015), además de jugar un papel fundamental en las estrategias de adaptación al cambio climático, ya que poseen la mayor densidad total de carbono de todos los bosques en la Tierra (Kauffman et al., 2020).

Debido al complicado acceso a los bosques de manglares, los instrumentos de teledetección se han utilizado ampliamente de manera eficaz para caracterizar, cartografiar y monitorearlos a lo largo de su rango geográfico (Lucas et al., 2017). Conforme al desarrollo de la tecnología de observación de la Tierra, los estudios actualmente no solo se limitan a mapear su extensión y distribución, sino que se han sumado varios temas, tales como la caracterización de los procesos ecosistémicos que se desarrollan en ellos y la recuperación de información de parámetros biofísicos en tres dimensiones (Wang et al., 2019). Adicionalmente, fusionar imágenes de diferentes sensores se ha convertido en una técnica útil que permite la

combinación de información referente a las propiedades de la tierra proveniente de sensores que operan con principios físicos fundamentalmente diferentes (Ghorbanian et al., 2021).

Existen un elevado número de aportes respecto al conocimiento de la distribución de los manglares alrededor del mundo, uno de los más significativos, es la plataforma Global Mangrove Watch (GMW), una iniciativa de la Agencia de Exploración Aeroespacial de Japón (JAXA), cuyo objetivo es proporcionar información geoespacial sobre la extensión de los manglares a nivel mundial (Bunting et al., 2018). Para dicho proyecto se buscó inicialmente establecer un mapa de referencia de los manglares para el año 2010 mediante el empleo de un modelo de aprendizaje automático Random Forest (RF), con el cual se combinó datos de los satélites Landsat 5 y Landsat 7, y datos del Radar de Apertura Sintética de banda L ALOS PALSAR, posteriormente los cambios dentro y fuera de esa línea base de estudio se derivaron a estudios entre los años 1996 y 2016 (Bunting et al., 2018).

Respecto a estudios estructurales de los bosques de manglares, centrándose en la altura del dosel de los árboles ya que es uno de los parámetros más importantes debido a su relación con otros aspectos como la biomasa aérea, la densidad de las reservas de carbono, la complejidad vertical del dosel y la calidad del hábitat (Li et al., 2020), se han generado diversos resultados combinando imágenes de radar de apertura sintética (SAR), imágenes ópticas de alta resolución e imágenes de detección y alcance de luz (LiDAR) (Lagomasino et al., 2016). En 2006, Simard et al. utilizaron datos de la misión SRTM de la NASA calibrados con datos de LiDAR aerotransportado, estimando la altura media de los manglares del Parque Nacional Everglades, con 2,0 m de error de raíz cuadrada media (RMSE) y posteriormente la cantidad de biomasa a través de una ecuación alométrica lineal usando las alturas estimadas y la biomasa estudiada en campo.

Lucas et al. (2020), realizaron un análisis multitemporal para la caracterización estructural de los manglares en la Reserva Forestal de Manglares de Matang en Malasia a lo largo del tiempo (1988-2016), en el cual se obtuvieron modelos de altura del dosel utilizando

diferentes técnicas como la interferometría SAR (ALOS), estereofotogrametría satelital (WorldView-2) y modelos digitales de elevación de SRTM y Tandem-X, que luego fueron calibradas con modelos generados a través de fotogrametría con drones (Lucas et al., 2020).

En el ámbito regional, refiriéndose a investigaciones relacionados al estudio de los parámetros estructurales de los manglares, se evidencia el trabajo de Simard et al. (2008), quienes desarrollaron una investigación para medir la altura de los manglares y la biomasa aérea de Ciénaga Grande de Santa Marta (CGSM) en Colombia, empleando datos de elevación SRTM (Shuttle Radar Topography Mission), formas de onda ICESat/GLAS (Ice, Cloud, and Land Elevation Satellite/Geoscience Laser Altimeter System) y datos tomados en campo. Compararon métodos de estimación de altura basados en centroides de forma de onda y el perfil de altura del dosel (CHP) concluyendo que el método de estimación de altura basado en centroides mostró valores de RMSE más bajos, una vez obtenido el modelo de alturas, este fue usado para estimar la distribución de biomasa en el área de estudio (Simard et al., 2008). En otro estudio realizado en una formación de manglar en Guaratiba, Río de Janeiro - Brasil, se demostró la utilidad de los drones para generar modelos digitales de elevación cuando no se puede contar con datos de LiDAR, obteniéndose un modelo de altura de la vegetación restando el Modelo Digital de Superficie (DSM) y el Modelo Digital del Terreno (DTM) con una precisión menor a un metro (Boa Morte et al., 2020).

En cuanto al Ecuador se han llevado a cabo una serie de proyectos de investigación relacionados principalmente a valoraciones económicas y estudios multitemporales para analizar la cobertura de los bosques de manglar (Morocho et al., 2022). Respecto a estudios en donde intervienen parámetros estructurales se evidencia el trabajo de Hamilton et al., (2017), quienes combinaron las mediciones de campo del diámetro de árboles de manglar, la distribución de las especies de mangle y la densidad de árboles de mangle para calcular el almacenamiento de carbono en los manglares en el norte del Ecuador, concluyeron que los modelos latitudinales básicos de carbono que obtuvieron tienen comportamientos similares a

modelos alométricos basados en especie. De la consulta bibliográfica realizada, se puede concluir que en el país no se han realizado investigaciones que profundicen en temas relacionados a la estructura del manglar.

Planteamiento del problema

Los bosques de manglares son ecosistemas altamente productivos, con características que los hacen estructural y funcionalmente únicos (Alongi, 2002), se constituyen como puntos calientes de biodiversidad, que proporcionan a las comunidades que los rodean una amplia gama de servicios económicos y ecológicos (Kuenzer et al., 2011). A pesar de los bien documentados beneficios económicos, ecológicos, y sociales, los bosques de manglares continúan sufriendo altas tasas de degradación y destrucción, principalmente a causa de las fuertes presiones demográficas y de desarrollo como la agricultura, acuicultura, turismo, desarrollo urbano y sobreexplotación (Giri et al., 2008) (Figura 1).

Estudios señalan que la pérdida de la extensión de los bosques de manglares a nivel mundial fue del 20% al 35% entre los años 1960 y 2010 (Polidoro et al., 2010), donde las tasas más altas de destrucción y degradación se presentaron en países en desarrollo, los cuales albergan al 90% del total de bosques de manglares (Duke et al., 2007). El Ecuador perdió aproximadamente un 22.5% de la superficie de bosques de manglares principalmente por la expansión de la acuicultura del camarón, de 1969 a 2014 pasando de 202 695 hectáreas a 157 000 hectáreas (Ministerio del Ambiente del Ecuador, 2014). Con respecto a la provincia del Oro, se estima que originalmente la cobertura de manglares ocupaba 35 144 hectáreas, habiéndose reducido, para el año 2006, a 16 152 hectáreas, lo que equivale a una pérdida del 56,2% (Rodríguez, 2018).

Aunque las estrategias planteadas por el Ministerio del Ambiente, Agua y Transición Ecológica (MAATE) han evidenciado un ligero balance positivo de recuperación de los bosques de manglares con un total de 164 520 hectáreas a nivel nacional para el año 2018, el desarrollo de la camaronicultura continúa generando una serie de problemas que no permiten el uso

sostenible de los manglares (Morocho et al., 2022). En ese sentido, encaminado a fortalecer las acciones de protección de estos preciados ecosistemas, en el año 2019 se puso en marcha el Plan Nacional para la Conservación de Manglares del Ecuador Continental (2019-2030), en el cual se mencionan una serie de acciones prioritarias a ejecutar, entre las cuales se tiene planificado realizar estudios de extensión y análisis multitemporales de los cambios en la superficie de los manglares (Carvajal & Santillán, 2019), sin tomar en cuenta ningún tipo de estudios de parámetros estructurales. Sin embargo, diferentes autores sugieren incluir estos tipos de estudios, principalmente de la altura del dosel, ya que permite determinar la salud de los bosques, estimar la biomasa, cuantificar el carbono almacenado y monitorear su desarrollo, con lo que se puede llevar un mejor seguimiento de estos ecosistemas, encaminados a la conservación y al uso sostenible de sus recursos (de Souza-Pereira et al., 2016; Feldpausch et al., 2012; Riel et al., 2018).

Por lo tanto, en la presente investigación se propone una metodología para modelar la altura del dosel de los bosques de manglar, empleando datos LiDAR y de imágenes SAR, en un algoritmo de inteligencia artificial Random Forest, con el fin de proporcionar a las autoridades competentes, comunidad científica y académica entre otros, resultados que sirvan de base para diferentes estudios que permitan conocer a más detalle el estado de estos bosques, considerando que mientras no se tomen las medidas necesarias para un estudio más profundo de estos ecosistemas, todos los bienes y servicios ecosistémicos que ofrecen disminuirán o se perderán para siempre (Duke et al., 2007), teniendo como consecuencias la pérdida de flujos de nutrientes, la productividad y la biodiversidad de las especies, así como la disminución de los productos forestales y pesqueros de las que dependen miles de familias para su sustento y economía, así mismo no preservar estos bosques puede causar emisiones de carbono considerables y, por lo tanto, acelerar el cambio climático (Sandilyan & Kathiresan, 2012).

Figura 1*Árbol de problemas*

Nota. La figura representa las causas y consecuencias de la degradación de los ecosistemas de manglares.

Justificación e importancia

El Ecuador es considerado como uno de los países con mayor biodiversidad del planeta, no solo se limita al número de especies por unidad de área, sino también a los distintos tipos de ambientes naturales y ecosistemas que existen. Esto se debe a varios factores, como la presencia de la Cordillera de los Andes que atraviesa el país de norte a sur, dado origen a diversos pisos altitudinales, con variados micro-climas y tipos de suelos, así como a las corrientes marinas que dividen la costa ecuatoriana en una zona seca al sur y húmeda al norte en donde se desarrollan ecosistemas con una flora y fauna adaptada a dichas condiciones, tales como los ecosistemas de manglares (Bravo, 2014).

Los manglares son considerados como uno de los ecosistemas más importantes y productivos del planeta, gracias a los cuales 100 millones de personas que viven en un radio de 10 km a su alrededor, se benefician de forma permanente de un amplia variedad de bienes y

servicios ecosistémicos tales como: brindar recursos renovables (madera, peces, crustáceos), servir de viveros para una multitud de especies de importancia ecológica y comercial, ser un medio eficaz de protección de la costa y del mantenimiento del equilibrio ecológico y la biodiversidad, así como secuestrar y almacenar una alta cantidad de carbono (UNEP, 2014).

En el país los bosques de manglares se distribuyen a lo largo de la costa desde la provincia de Esmeraldas al norte hasta la provincia de El Oro en el sur, donde miles de personas que habitan en las comunidades costeras dependen de los manglares como su principal fuente de ingreso, siendo el turismo, la pesca y acuicultura las actividades económicas que principalmente desarrollan (Ministerio del Ambiente del Ecuador, 2017).

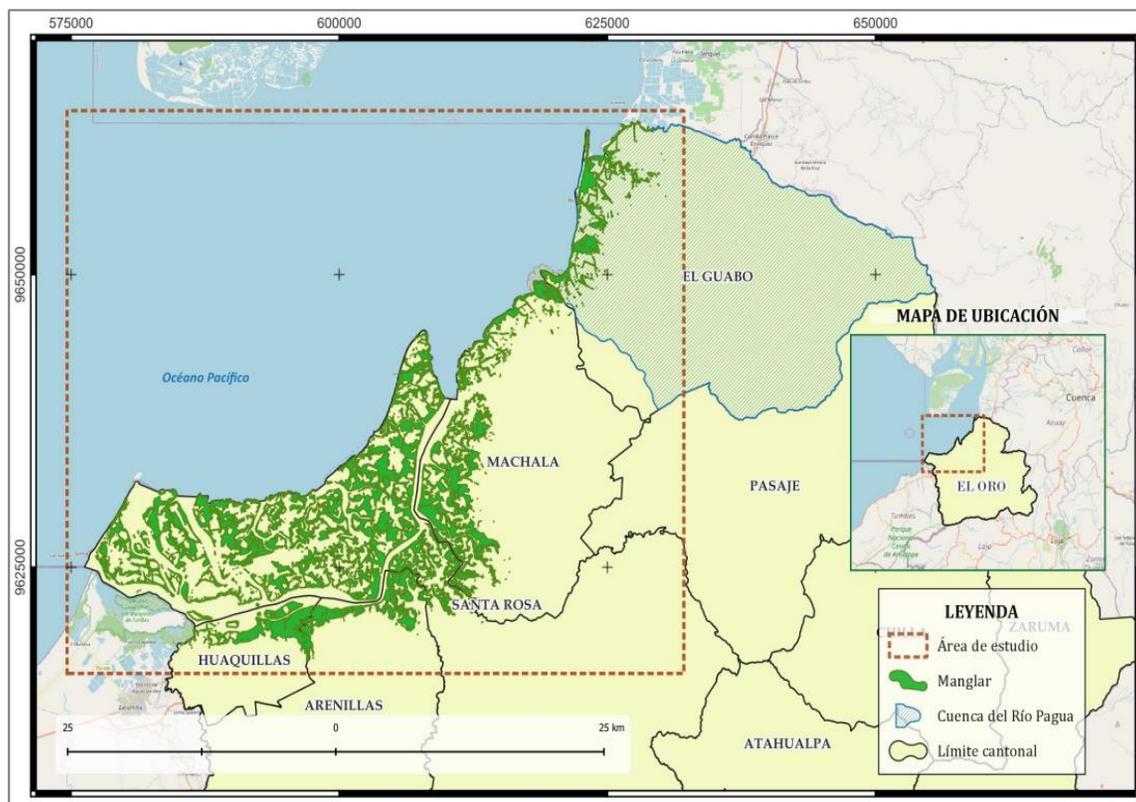
Debido a la alta relevancia ecológica y económica de los manglares, hoy en día existe una demanda urgente de medidas de conservación y restauración, que implican la generación de información actualizada sobre las condiciones en que se encuentran los ecosistemas de manglares (Kuenzer et al., 2011). El presente estudio busca contribuir a las estrategias de conservación de los manglares en el país, mediante un modelo de las alturas del dosel de los manglares de la provincia de El Oro para el año 2021, que le permita a los tomadores de decisiones (MAATE, GAD provincial, GAD cantonales, GAD parroquiales, supervisores de las concesiones forestales de manglares, encargados de áreas protegidas, entre otros) contar con información base para investigaciones relacionadas a la altura del dosel como: crecimiento forestal, biomasa, cuantificación de almacenamiento de carbono y salud de los manglares (Riel et al., 2018), evitando los costos asociados al trabajo de campo.

El proyecto, al estar encaminado a la conservación de los bosques de manglares, se alinea a los esfuerzos para lograr los Objetivos de Desarrollo Sostenible de las Naciones Unidas, como el Objetivo 14 (Vida debajo del agua), que fomenta el uso sostenible de los recursos costeros y marinos y el Objetivo 13 (Acción por el Clima), debido a que la altura del dosel es un parámetro fundamental para las estimaciones de secuestro y almacenamiento de carbono (Friess et al., 2019).

Adicionalmente esta investigación se alinea con el Objetivo 11 del Eje de Transición Ecológica contenido en el Plan Nacional de Desarrollo (2021-2025), el cual se refiere a conservar, restaurar, proteger y hacer un uso sostenible de los recursos naturales, con especial énfasis al espacio marino-costero (Secretaría Nacional de Planificación, 2021). Se vincula a los lineamientos establecidos en el Plan de Ordenamiento del Espacio Marino Costero (2017 – 2030) que consiste en conservar y recuperar los humedales costeros y los manglares, con sus zonas de amortiguamiento delimitadas por el Ministerio del Ambiente y Agua (Secretaría Técnica Planifica Ecuador, 2020). Así mismo, se alinea con las políticas públicas locales a ejecutarse en el Plan de Desarrollo y Ordenamiento Territorial de la provincia de El Oro, que busca recuperar el patrimonio natural particularmente los bosques generadores de agua y el ecosistema manglar, así como fomentar la recuperación del manglar para la conservación de la biodiversidad en la zona (GAD El Oro, 2015).

Descripción del área de estudio

El área de estudio considerada en el proyecto corresponde a la provincia de El Oro, ubicada en el extremo sur occidental del Ecuador, misma que posee una superficie de 5.791,85 Km², cubriendo gran parte las estribaciones de la Cordillera Occidental de los Andes, así como zona costera y en su minoría, zona insular (Figura 2) (GAD El Oro, 2015). La provincia posee cinco cantones costeros: Huaquillas, Arenillas, Santa Rosa, Machala, El Guabo. Donde la cobertura de bosques de manglar que se expande sobre estos cinco cantones representa aproximadamente al 4% del total de la superficie de la provincia (Rodríguez, 2018). Adicionalmente, se ha seleccionado el área de la cuenca hidrográfica del Río Pagua contenida en el cantón el Guabo, para la elaboración de una guía para la gestión ambiental de los bosques de manglar.

Figura 2*Ubicación del área de estudio*

Nota. Elaborado a partir de Información pública del Sistema Nacional de Información (SNI) y de datos obtenidos de la plataforma Global Mangrove Watch (GMW).

Objetivos

Objetivo General

Modelar las alturas del dosel de los manglares en la provincia de El Oro para el año 2021, empleando datos LIDAR y SAR en un algoritmo de Inteligencia Artificial dentro del entorno de computación en la nube Google Earth Engine (GEE), con el fin de apoyar a la gestión de conservación del ecosistema manglar en el Ecuador.

Objetivos Específicos

- Aplicar el algoritmo de regresión Random Forest usando los datos de altura LiDAR y retrodispersión SAR para generar un modelo de alturas del dosel de los manglares en la provincia del Oro, para el año 2021.
- Validar estadísticamente el modelo de alturas del dosel de los manglares con datos de prueba de la misión LiDAR GEDI, con el fin de evaluar la calidad del modelo.
- Desarrollar una aplicación web de visualización del estudio en la plataforma GEE como apoyo a las estrategias de conservación de los ecosistemas marino-costeros del país.
- Generar una guía para la gestión ambiental de los bosques de manglar ubicados en la cuenca hidrográfica del Río Pagua en base a los resultados obtenidos del aplicativo web.

Metas

- Mosaico de imágenes SAR Sentinel-1 para el área de estudio.
- Modelo de alturas a escala 1:25 000.
- Conjunto de datos de entrenamiento.
- Conjunto de datos de prueba.
- Código fuente de la aplicación.
- Aplicación web para la visualización de resultados, con las opciones habilitadas de exportación y descarga de los datos de entrada empleados en el estudio.
- Guía para la gestión ambiental de los bosques de manglares ubicados en la cuenca hidrográfica del Río Pagua, cantón El Guabo en base a los resultados obtenidos del modelamiento de las alturas del dosel.

Capítulo II: Marco teórico

En este capítulo se describe la base teórica en la que se basa el presente proyecto. Se incluyen los fundamentos conceptuales acerca de los datos de Radar de Apertura Sintética (SAR) y de los datos de Detección y Medición de la Luz (LiDAR), así como las características de los satélites de los que fueron obtenidos. De igual modo se presenta bibliografía sobre la importancia ecológica de los manglares y los desafíos asociados a su monitoreo. Asimismo, se detallan conceptos acerca de la Inteligencia Artificial y la plataforma empleada para el desarrollo de este proyecto, Google Earth Engine.

Teledetección

La teledetección es un procedimiento o técnica de adquisición de información de un objeto sin tener contacto físico con él. Dichas técnicas se basan en que sensores miden el flujo energético de un objeto, que puede ser emitido por el mismo o proceder de otro cuerpo y haber sido reflejada. Se presentan dos categorías de teledetección (Figura 3), cuando un sensor mide la energía emitida naturalmente y la luz del sol es la principal fuente de energía utilizada, se trata de teledetección pasiva, por otro lado, cuando un sensor genera su fuente de energía electromagnética para iluminar el objetivo y registra la radiación retrodispersada del objetivo, se trata de teledetección activa (Segado, 1996).

Para Chuvieco (2008), los elementos de la teledetección corresponden: (1) fuente de energía, (2) cubierta terrestre, (3) sistema sensor, (4) sistema de recepción-comercialización, (5) intérprete y (6) usuario final.

Sensor activo

Un sensor activo es aquel que proporciona su propia fuente de energía para la iluminación, emitiendo una radiación dirigida hacia el objetivo a investigar, en donde la radiación reflejada por ese objetivo es detectada y medida por el sensor. Gracias a que no requieren de la energía de factores externos, estos sensores tienen la capacidad de obtener mediciones en cualquier momento, independientemente de la hora del día o la estación. Entre

los sensores activos más utilizados se incluyen: Radio Detection and Ranging (RADAR), Light Detection And Ranging (LiDAR) y Sound Navigation Ranging (SONAR) (Muñoz & Pérez, 2006).

Sensor pasivo

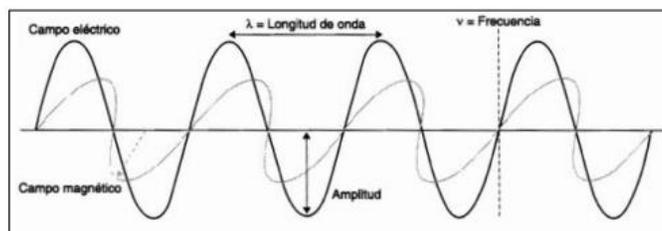
Un sensor pasivo es aquel que no sede energía propia al objeto o superficie investigada, solo detectan la radiación electromagnética reflejada o emitida naturalmente por un objeto. La fuente de radiación más común está representada por la luz solar reflejada, que representa una parte de la radiación electromagnética emitida por el sol. Los ejemplos de sensores pasivos incluyen varios tipos de radiómetros o espectrómetros, que operan principalmente en las partes visible, infrarroja, infrarroja cercana, infrarroja térmica y microondas del espectro electromagnético (EarthData NASA, 2021).

Radiación electromagnética

La radiación electromagnética es un fenómeno que toma la forma de ondas de energía que se propagan a sí mismas a medida que viaja a través del espacio, consta de componentes de campo eléctrico y magnético, que toman como flujo la velocidad de la luz (Figura 3). Las ondas de energía oscilan en fases perpendiculares entre sí y perpendiculares a la dirección de propagación de la energía, observándose que cuanto mayor sea la longitud de onda implicada, menor será la frecuencia y la energía (Chuvieco, 2008).

Figura 3

Diagrama de una onda electromagnética



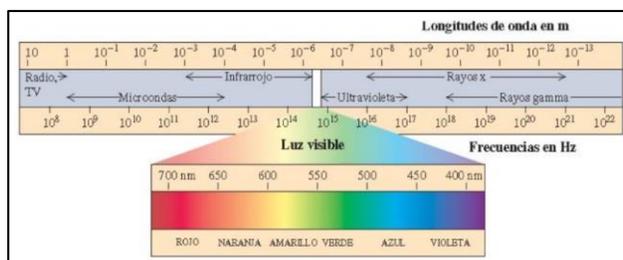
Nota. Tomado de *Teledetección Espacial*, por Chuvieco, 2008.

Espectro electromagnético

El espectro electromagnético es un término colectivo que se refiere a todo el rango y alcance de las frecuencias de la radiación electromagnética. El comportamiento de la radiación depende de su longitud de onda y es inversamente proporcional a la frecuencia y longitud de onda, es decir, las frecuencias más altas tienen longitudes de onda más cortas y viceversa (Haldar, 2018). La radiación electromagnética se clasifica en varios tipos según la frecuencia de su onda (en orden decreciente de frecuencia y creciente de longitud de onda) en: radiación gamma, radiación de rayos X, radiación ultravioleta, radiación visible, radiación IR, radiación de microondas y ondas de radio, como se observa en la figura 4.

Figura 4

Espectro electromagnético



Nota. Tomado de *Principios de teledetección*, por Mignone & Barnes, 2012.

Para Reuter (2009), las divisiones del espectro electromagnético pueden ser arbitrarias. Según su criterio las bandas de interés empleada en estudios de teledetección corresponden a:

- ultravioleta fotográfica, con longitudes de onda entre 0.3 y 0.4 micrómetros
- visible, con longitudes de onda entre 0.4 y 0.7 μm
- infrarroja cercana con longitudes de onda entre 0.7 y 3 μm
- infrarroja media, con longitudes de onda entre 3 μm y 8 μm
- infrarroja lejana (térmica), con longitudes de onda desde 8 hasta 1000 μm
- microonda, con longitudes de onda entre 1 milímetro y 100 centímetros

Imagen satelital

Las imágenes satelitales son imágenes de la Tierra capturadas mediante satélites, corresponden a una matriz bidimensional de píxeles, en donde cada píxel tiene un valor de intensidad y una dirección de ubicación. La intensidad de un píxel se registra como un número digital, que almacena un número finito de bits (dígitos binarios). El número de bits determina la resolución radiométrica de la imagen. Por otro lado, la dirección de un píxel se denota por sus coordenadas de fila y columna en la imagen bidimensional, existiendo una correspondencia de uno a uno entre la dirección de columna y fila de un píxel y las coordenadas geográficas (p. ej., longitud, latitud) de la ubicación de la imagen (Laituri, 2018) .

Resolución espacial

La resolución espacial se refiere a la medida del tamaño o área de la dimensión más pequeña en la superficie de la Tierra sobre la cual el sensor puede realizar una medición independiente. Se expresa por el tamaño del píxel en el suelo en metros (Gupta & Follette, 2018).

Resolución espectral

La resolución espectral se refiere a la capacidad de un sensor satelital para medir longitudes de onda específicas del espectro electromagnético. Cuanto más fina sea la resolución espectral, más estrecho será el rango de longitud de onda para un canal o banda en particular (Gupta & Follette, 2018).

Resolución radiométrica

La resolución radiométrica se refiere al número de valores posibles del archivo de datos en cada banda (indicado por el número de bits en los que se divide la energía registrada). Se refiere también a la capacidad de un sensor para detectar diferencias en la magnitud de la energía (Gupta & Follette, 2018).

Resolución temporal

La resolución temporal se refiere a la frecuencia o período de revisita o retorno con la que un satélite puede proporcionar observaciones de una misma área en la Tierra también a la capacidad de un sensor para detectar diferencias en la magnitud de la energía (Gupta & Follette, 2018).

Mosaico de imágenes satelitales

Un mosaico de imágenes satelitales es la combinación de varias imágenes individuales capturadas por satélites en órbita alrededor de la Tierra para crear una imagen compuesta más grande y continua de una determinada área geográfica. El proceso de creación de un mosaico de imágenes satelitales implica alinear, ajustar y combinar las imágenes individuales para formar una única imagen compuesta (IIAP, 2014). Los mosaicos de imágenes satelitales se utilizan en diversas aplicaciones, como la cartografía, la monitorización del cambio del uso del suelo, la planificación urbana, el seguimiento de fenómenos naturales, la gestión de recursos naturales y el estudio del medio ambiente (IIAP, 2014).

Sistema RADAR

RADAR es el acrónimo de Radio Detection and Ranging. Los sistemas RADAR son sensores activos que proporcionan su propia fuente de energía electromagnética por lo que pueden adquirir imágenes de la Tierra en todas las condiciones climáticas, en cualquier momento, de día o de noche. Consiste fundamentalmente de un transmisor, un receptor, una antena y un sistema electrónico para procesar y registrar los datos (Richards, 2009).

El proceso consiste en que el sensor de radar emite radiación de microondas en una serie de pulsos desde una antena, mirando oblicuamente a la superficie perpendicular a la dirección del movimiento, una vez que la energía alcanza el objetivo, parte de la energía se refleja hacia el sensor. La radiación de microondas retrodispersada es detectada, medida y cronometrada. El tiempo requerido para que la energía viaje al objetivo y regrese al sensor determina la distancia o el alcance al objetivo. Al registrar el rango y la magnitud de la energía

reflejada por todos los objetivos a medida que pasa el sistema, se puede producir una imagen bidimensional de la superficie (Richards, 2009).

Bandas de los sistemas RADAR

Los sistemas RADAR operan en la porción del espectro electromagnético de las microondas, más allá de las regiones visible e infrarrojo térmico, como se puede ver en la Tabla 1. Las ondas con mayor longitud de onda tienen mayor penetración en la vegetación y el suelo (Podest, 2015).

Tabla 1

Bandas RADAR

| Banda | Longitud de onda (λ), cm | Frecuencia (ν), GHz (10^9 ciclos. Seg⁻¹) |
|--------------------|--|--|
| Ka (0.86 cm) | 0.8 – 1.1 | 40.0 – 26.5 |
| K | 1.1 – 1.7 | 26.5 – 18.00 |
| Ku | 1.7 – 2.4 | 18.00 – 12.5 |
| X (3.0 cm, 3.2 cm) | 2.4 – 3.8 | 12.5- 8.00 |
| C (3.60 cm) | 3.8 - 7.5 | 8.0 – 4.00 |
| S | 7.5 -15 | 4.0 -2.0 |
| L (23.5 cm, 25 cm) | 15.0 – 30.0 | 2.0 – 1.0 |
| P (68 cm) | 30.0 – 100.0 | 1.0 - 3.0 |

Nota. Las longitudes de ondas más frecuentemente usadas en radar se encuentran en paréntesis. Tomado de *Conceptos Básicos del Radar de Apertura Sintética*, por Podest, 2015.

Radares de Imágenes

Los sistemas radar son empleados en diversos propósitos tales como radares de observación meteorológicas y radares de imágenes. Los radares de imágenes se ubican en

plataformas móviles, lo que les permite adquirir imágenes en dos dimensiones de una escena de la superficie terrestre (Guerrero & Hernández, 2017).

Entre los tipos de radar de imágenes se tienen los SLAR (Sidelooking Airborne Radar), con los que se puede obtener imágenes con una resolución alta en rango y una resolución angular adecuada; los SAR (Radar de Apertura Sintética) que emplean algoritmos de procesamiento avanzados para aumentar la resolución azimutal del radar y poder recibir más información de los objetos en la superficie; los ISAR (Radar de Apertura Sintética Inversa) que producen imágenes de coherencia con alta resolución en rango y además puede capturar datos acerca del movimiento relativo de un objetivo (Guerrero & Hernández, 2017).

Ecuación del Sistema Radar

La formulación del sistema de Radar se establece en función de la potencia del Radar, esto implica la emisión de impulsos electromagnéticos en las longitudes de onda correspondientes a las señales de microondas, dirigidos hacia un objetivo en la superficie terrestre. Posteriormente se capta la señal reflejada por el sensor, permitiendo la medición de la intensidad y el retardo temporal de dicha señal con respecto al sensor. También, la ganancia de la antena y la distancia de cobertura del Radar influyen en el proceso (Richards, 2009).

La ecuación de la potencia radar se define mediante la siguiente ecuación (Richards, 2009):

$$P_R = P_T(\sigma^0) \frac{G^2 \lambda^2}{(4\pi)^2 R^4} \quad (1)$$

Donde:

P_R =Potencia recibida

P_T =Potencia transmitida

σ^0 =Coeficiente de dispersión

G =Ganancia de la antena

λ = Longitud de onda de pulso

R=Altura del satélite

A=Resolución de la celda de la imagen

Amplitud

La amplitud en las imágenes corresponde a la intensidad de la onda electromagnética reflejada. Se relaciona con las características de forma, orientación y propiedades eléctricas de los elementos en la superficie terrestre. Esta amplitud permite diferenciar la luminosidad y la intensidad de la superficie o elementos en el terreno (Richards, 2009).

Fase

La fase corresponde al cambio temporal en una señal de radar reflejada en comparación con la señal emitida. Este aspecto indica la variación de tiempo entre el pulso original de radar transmitido y la señal reflejada que retorna al radar. Dentro de una imagen SAR, la fase se emplea para establecer la ubicación relativa de los puntos en la representación visual (Richards, 2009).

Speckle o ruido en las imágenes de RADAR

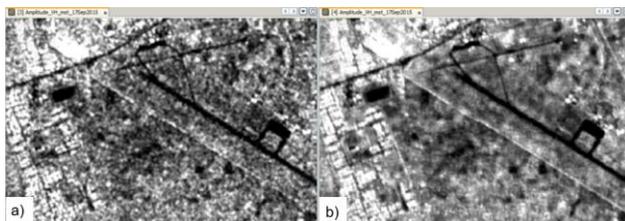
El "speckle" en las imágenes de radar es un tipo de ruido que se produce debido a la naturaleza coherente de la señal de radar y la interferencia constructiva y destructiva de las ondas electromagnéticas. Es un patrón granular y aleatorio que aparece en las imágenes de radar, similar al ruido granular en una imagen fotográfica (Figura 5). El speckle en las imágenes de radar puede afectar la calidad y la interpretación de los datos, ya que puede ocultar detalles importantes y dificultar la detección de objetos o cambios sutiles en la superficie terrestre. Además, puede influir en la precisión de las mediciones cuantitativas, como la estimación de la altura del terreno o el cálculo de volúmenes (Tarazona, 2020).

Para reducir o eliminar el efecto del speckle en las imágenes de radar, se utilizan diversas técnicas de filtrado y procesamiento de imágenes con los cuales se busca preservar las características importantes de la imagen mientras reducen el ruido speckle, mejorando así

la calidad y utilidad de las imágenes de radar para diversas aplicaciones, como la cartografía, la agricultura, la monitorización ambiental y otras (Tarazona, 2020).

Figura 5

Imagen Satelital que presenta ruido o speckle



Nota. En a) se observa una imagen satelital en crudo, mientras que en b) se muestra la misma imagen satelital a la que se le aplicó un filtro de corrección de denominado Lee Sigma. Tomado de *Tratamiento del ruido Speckle en las imágenes RADAR* por Tarazona, 2020.

Retrodispersión

La retrodispersión o backscattering es la porción de la señal de radar saliente que el objetivo redirige directamente hacia el sistema radar. Esta porción de la señal, generalmente mira hacia los lados en diferentes ángulos de incidencia que dependen en gran medida de las características los objetos. La medida normalizada del retorno del radar desde un objetivo distribuido se llama coeficiente de retrodispersión (Pourshamsi y otros, 2021).

Coeficiente de retrodispersión

El coeficiente de retrodispersión del radar (σ_0) es la señal reflejada de vuelta al sensor por los elementos de dispersión de una escena iluminada, y proporciona información sobre los parámetros de la superficie, como la forma geométrica, las propiedades dieléctricas del objetivo y la rugosidad. La información de retrodispersión está influenciada por diferentes parámetros del radar, como la polarización, el ángulo de incidencia y la frecuencia de la radiación incidente. Se puede calcular el coeficiente de retrodispersión (σ_0) en dB para todas las polarizaciones disponibles usando la siguiente fórmula (Pourshamsi y otros, 2021):

$$\sigma_0(\text{dB}) = 10 * \log_{10}(|\text{backscatter}|) \quad (2)$$

Donde:

backscatter = Valores crudos de retrodispersión

$\sigma_0(\text{dB})$ = Valores de retrodispersión transformados en decibeles

Mecanismos de retrodispersión

La retrodispersión para un área de objeto de estudio, en una longitud de onda particular cambia según una variedad de condiciones, como la polarización de los pulsos SAR, los ángulos de observación, el tamaño físico de los dispersores en el área objetivo o sus propiedades dieléctricas (Meyer, 2019).

Una escena natural se compone de la combinación de cuatro tipos de dispersores (Figura 6): dispersores de superficie lisa o espejo, dispersores de superficie rugosa, dispersores de doble rebote y dispersores de volumen (Meyer, 2019).

Dispersión espejo o especular. Ocurre cuando una onda choca con una superficie lisa y plana que se refleja en una dirección específica y predecible, de acuerdo con la ley de reflexión. La mayor parte de la energía incidente es reflejada en la dirección opuesta al radar y por estas áreas aparecen oscuras. Como ejemplo se tienen a los cuerpos de agua, superficies metálicas pulidas (Meyer, 2019).

Dispersión de superficie áspera. Se refiere al fenómeno de la reflexión de una onda electromagnética en una superficie rugosa o áspera, donde la dirección de la reflexión no sigue la ley de reflexión especular. Para este tipo de dispersión se tienen como ejemplo los campos con poca vegetación y suelos desnudos (Meyer, 2019).

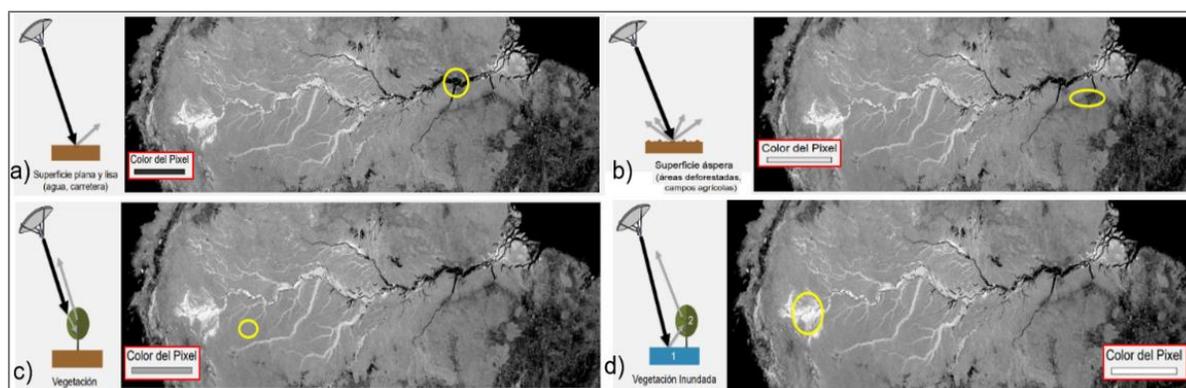
Dispersión por volumen. La dispersión de volumen se produce cuando las ondas electromagnéticas son dispersadas en todas las direcciones por un objeto que tiene dimensiones comparables a la longitud de onda del radar. Esto significa que la dispersión no se produce solo en la superficie del objeto, sino que también se produce dentro del objeto. Como ejemplo de este tipo de dispersión se tiene a las cubiertas vegetales en donde a medida que

las señales rebotan múltiples veces se propagan a través de la estructura de la vegetación (Meyer, 2019).

Dispersión por doble rebote. Se produce cuando las ondas electromagnéticas rebotan en dos superficies antes de ser detectadas por el radar. Este tipo de dispersión es común en superficies como edificios, troncos de árboles, postes de luz, y otras estructuras (Meyer, 2019).

Figura 6

Mecanismos de dispersión



Nota. En la imagen se visualiza un mosaico de Radar de SMAP de la Cuenca Amazónica Abr. 2015 (L-band, HH, 3 km) en donde se presentan los cuatro tipos de mecanismos de dispersión: a) Dispersión especular, b) Dispersión de superficie áspera, c) Dispersión por volumen, d) Dispersión por doble rebote. Tomado de *Conceptos Básicos del Radar de Apertura Sintética*, por Podest, 2015.

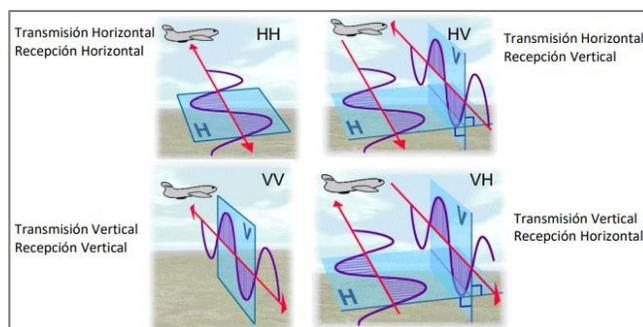
Polarización

La polarización se refiere a la orientación del plano en el que oscila la onda electromagnética transmitida. Si bien la orientación puede ocurrir en cualquier ángulo, los sensores SAR generalmente transmiten con polarización lineal. La ventaja de los sensores de radar es que la polarización de la señal se puede controlar con precisión tanto en la transmisión como en la recepción. La polarización horizontal (de izquierda a derecha) se indica con la letra H y la polarización vertical (arriba y abajo) se indica con V (Meyer, 2019).

Las señales emitidas en polarización vertical (V) y recibidas en polarización horizontal (H) estarían indicadas por un VH. Alternativamente, una señal que fue emitida en horizontal (H) y recibida en horizontal (H) sería indicada por HH, y así sucesivamente. Los radares de imágenes pueden tener diferentes configuraciones de polarización. Un sistema de polarización única, o "single-pol", transmite y recibe una polarización única, generalmente en la misma dirección, lo que da como resultado un generador de imágenes horizontal-horizontal (HH) o vertical-vertical (VV). Un sistema de polarización dual, o "pol dual", puede transmitir en una polarización, pero recibir en dos, lo que da como resultado imágenes HH y HV o VH y VV (Figura 7) (Cherrington y otros, 2019).

Figura 7

Tipos de polarización



Nota. Tomado de *Spaceborne Synthetic Aperture Radar – Principles, Data Access, and Basic Processing Techniques. SAR Handbook: Comprehensive Methodologies for Forest Monitoring and Biomass Estimation*, por Meyer, 2019.

Sistema de Radar de Apertura Sintética SAR

Un Sistema de Radar de Apertura Sintética (SAR) es una tecnología que emplea señales radar y procedimientos coherentes de procesamiento de señales para adquirir imágenes minuciosas de la superficie terrestre en diversas situaciones. Tiene una geometría de imagen lateral y se basan en un radar pulsado instalado en una plataforma con movimiento hacia adelante (Moreira y otros, 2013).

El sistema de radar transmite pulsos electromagnéticos de alta potencia y recibe los ecos de la señal retrodispersada de forma secuencial. Los valores típicos para la frecuencia de repetición de pulso oscilan entre unos pocos cientos y unos pocos miles de Hertz para sistemas aerotransportados y espaciales, respectivamente. El pulso transmitido interactúa con la superficie de la Tierra y solo una parte de él se retrodispersa a la antena receptora, que puede ser la misma que la antena transmisora (para un radar monoestático) o una diferente (para un radar bi- o multi-estático). La amplitud y fase de la señal retrodispersada depende de las propiedades físicas (es decir, geometría, aspereza) y eléctricas (es decir, permitividad) del objeto de la imagen (Moreira y otros, 2013).

Un sistema SAR almacena información de los ecos reflejados después de interactuar con la Tierra. La sumatoria coherente de dichos ecos permite la síntesis de una apertura virtual de longitud mucho mayor a la real, es decir se combina una secuencia de adquisiciones de una antena más corta para simular una antena mucho más grande, proporcionando así datos de mayor resolución. Los ecos recibidos son digitalizados, almacenados y posteriormente procesados para construir un mapa de reflectancias, la cual consiste en una gráfica 2D. Donde la reflectancia de un píxel es igual al coeficiente de retrodispersión promedio del píxel por el área del píxel (Zozaya, 2016).

La formación de la imagen SAR implica utilizar las señales reflejadas capturadas por el sensor mientras interactúan con la superficie. Estas señales son sometidas a procesamiento en el satélite, lo que resulta en la creación de números complejos en cada píxel de la imagen. En esta representación, la parte real se denota como "I" y la parte imaginaria como "Q". En términos de la señal, "A" representa la amplitud y " ϕ " simboliza la fase medida (Iqbal, 2014).

Las siguientes ecuaciones representan los datos complejos de los datos SAR:

$$I = A \cos(\phi) \quad (3)$$

$$Q = A \sin(\phi) \quad (4)$$

Con lo anterior establecido se puede despejar la información de la amplitud, fase e intensidad de cada celda de la imagen, por medio de la siguiente ecuación:

$$\phi = \arctan(Q/I) \quad (5)$$

$$\text{Intensidad} = I^2 + Q^2 \quad (6)$$

$$\text{Amplitud} = \sqrt{I^2 + Q^2} \quad (7)$$

Geometría de adquisición SAR

La geometría de adquisición en imágenes SAR se distingue de la que se observa en otros sistemas de teledetección convencionales, como las imágenes fotográficas o escáner. Esta distinción se origina en la naturaleza del radar, que mide distancias en lugar de ángulos. Así una imagen obtenida mediante SAR se presenta comúnmente en dos variantes de productos: ground range detected (GRD) y single look complex (SLC). Los productos GRD se generan mediante un proceso de promedio para formar una imagen multifacética que se proyecta sobre el rango de suelo, empleando un modelo basado en el elipsoide terrestre. Una imagen GRD se almacena en forma de una matriz de valores numéricos reales, donde cada píxel contiene la información sobre la amplitud de la señal de retrodispersión medida. Los productos SLC son imágenes que se encuentran en el plano de imagen de la adquisición de datos, conocido como el plano de rango de inclinación. Una imagen SLC se guarda como una matriz de valores complejos, en la que cada píxel tiene un valor complejo que refleja tanto la amplitud como la fase de la señal de retrodispersión registrada (Battula & Parayitam, 2021).

Efectos geométricos que se producen en una imagen de SAR

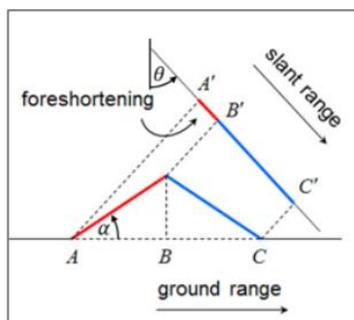
Debido a la disposición angular de observación que están presente en todos los sistemas de radar de imágenes, las inclinaciones del relieve y otras características del terreno causan alteraciones geométricas en los datos capturados por los SAR. Entre estas alteraciones, las más destacadas incluyen el escorzo, la superposición y la sombra.

Escorzo. Se refiere a la representación visual de la compresión de las áreas inclinadas hacia el sensor. Cuando se trata de superficies inclinadas en dirección opuesta al sensor, estas

parecen extenderse. Esto resulta en que las pendientes presentes en una imagen adquieran una tonalidad más luminosa, como se observa en la Figura 8.

Figura 8

Efecto geométrico de escorzo

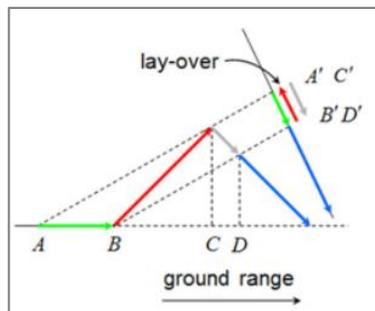


Nota. Tomado de *Spaceborne Synthetic Aperture Radar – Principles, Data Access, and Basic Processing Techniques. SAR Handbook: Comprehensive Methodologies for Forest Monitoring and Biomass Estimation*, por Meyer, 2019.

Inversión por relieve. Sucede cuando la energía reflejada en la parte superior de un objeto es captada antes que la proveniente de la parte inferior. En esta situación, al procesar la imagen, la porción superior del objeto aparecerá desplazada y colocada sobre su base. El efecto se puede ver en la Figura 9.

Figura 9

Efecto geométrico de inversión por relieve

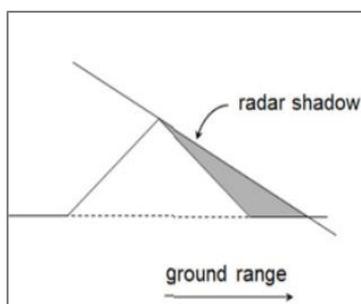


Nota. Tomado de *Spaceborne Synthetic Aperture Radar – Principles, Data Access, and Basic Processing Techniques. SAR Handbook: Comprehensive Methodologies for Forest Monitoring and Biomass Estimation*, por Meyer, 2019.

Sombras. Corresponden a áreas sin iluminación captadas por el sensor, donde, consecuentemente, no se encuentran registros de valores (Figura 10).

Figura 10

Efecto geométrico de sombras



Nota. Tomado de *Spaceborne Synthetic Aperture Radar – Principles, Data Access, and Basic Processing Techniques. SAR Handbook: Comprehensive Methodologies for Forest Monitoring and Biomass Estimation*, por Meyer, 2019.

Resoluciones de las imágenes SAR

La resolución espacial de un sistema SAR se descompone en dos componentes: la resolución en dirección de rango y la resolución en dirección de azimut. Ambas dimensiones están influenciadas por factores como la longitud de onda de la señal de radar, la apertura sintética y la geometría de la adquisición. Una mayor resolución espacial en ambas direcciones permite capturar detalles más pequeños en la imagen, lo que es esencial para aplicaciones que requieren una detección y análisis detallados de la superficie terrestre (Jensen, 2013).

Resolución en dirección de Rango o Alcance. La resolución en dirección de rango se refiere a la capacidad del sistema SAR para distinguir objetos a lo largo de la trayectoria de movimiento del satélite. Esta dimensión está relacionada con la longitud de onda de la señal de

radar emitida. Cuanto más corta sea la longitud de onda, mejor será la resolución en dirección de rango, lo que significa que se pueden identificar y separar objetos cercanos con mayor claridad. Este parámetro está en función de la longitud del pulso, la cual se determina al multiplicar la duración de la transmisión por la velocidad de la luz como se indica en la siguiente ecuación (Jensen, 2013).

$$R_r = \frac{\tau c}{2 \cos \gamma} \quad (8)$$

Donde:

R_r = Resolución de rango

c = Velocidad de la luz

τ = Duración de la transmisión del pulso

γ = Ángulo de depresión

Resolución en dirección de Azimut. Se refiere a la habilidad del sistema SAR para diferenciar objetos en la dirección que es perpendicular a la órbita del satélite. Este logro se alcanza mediante la mejora de la apertura sintética, una estrategia de procesamiento que fusiona varias observaciones obtenidas desde distintas ubicaciones con el propósito de conseguir una resolución superior en esta dimensión. La conexión entre la longitud de onda y la longitud de la antena para la descripción del concepto de resolución en azimut de un objeto observado mediante SAR se presenta en la siguiente ecuación (Jensen, 2013):

$$R_a = \frac{L}{2} \quad (9)$$

Donde:

R_a = Resolución de azimut

L = Longitud de la antena en dirección al azimut

Tecnología LiDAR

LiDAR es el acrónimo en inglés de Light Detection And Ranging, que en español se traduce como alcance y detección de luz, más conocido como registro mediante escáner laser

de barrido. Es una tecnología de detección remota activa similar al radar, pero utiliza pulsos de luz láser en lugar de ondas de radio para generar información espacial precisa sobre la forma y los componentes de la superficie de la Tierra (Dassot & Fournier, 2011).

Esta tecnología implica la emisión de pulsos láser desde un instrumento colocado en una plataforma hacia un objeto, las características más alejadas del sensor, interceptan y reflejan la energía del láser de regreso al sensor más tarde que las más cercanas siendo detectadas por el sensor óptico para posteriormente ser analizadas electrónicamente y obtener una medición de la intensidad de la luz reflejada y el tiempo de llegada en función de la distancia desde el sensor. Las longitudes de onda de los láseres usadas en LiDAR dependen de la aplicación y se extienden desde alrededor de 250 nm a 11 μm (Dassot & Fournier, 2011)

La fórmula que los analistas utilizan para calcular la distancia se da en la ecuación (Dassot & Fournier, 2011):

$$D = c * \left(\frac{\Delta T}{2}\right) \quad (10)$$

Donde:

D = La distancia del sensor al objeto

c = Velocidad de la luz

ΔT = Tiempo requerido por la luz para viajar

Nube de puntos

Un enfoque tradicional de teledetección con tecnología LiDAR emplea un láser, un sistema de GPS y una unidad de medición inercial (IMU) para calcular las altitudes de elementos en la superficie terrestre. A partir del LiDAR, se generan conjuntos de datos discretos en los que cada punto representa información de energía transmitida y reflejada de alta intensidad. Estos puntos discretos contienen coordenadas en los ejes x, y, y z para cada punto, y el valor z se utiliza para determinar la altitud. Un sistema convencional de Medición y Detección por Láser (LiDAR) emite rápidos pulsos de luz que rebotan en la superficie terrestre

y otros objetos, creando puntos de altitud o elevación en el sistema LiDAR (Salamanca J. , 2008).

Tecnología LiDAR Satelital

El LiDAR (Light Detection and Ranging) es una técnica de detección remota que emplea pulsos láser para medir distancias entre un sensor y objetos o superficies. Combinado con satélites, se denomina LiDAR por satélite. Montar sistemas LiDAR en plataformas espaciales como satélites implica llevar a cabo mediciones detalladas y precisas de la topografía y las características de la Tierra desde el espacio. Estos sistemas emiten pulsos de luz láser hacia la superficie terrestre y registran el tiempo que la luz tarda en rebotar y volver al sensor, permitiendo calcular con gran exactitud la distancia entre el satélite y la superficie. Mediante la combinación de múltiples mediciones, es posible generar un modelo tridimensional altamente preciso del terreno y las estructuras presentes en la superficie (Mehendale, 2020).

Google Earth Engine

Google Earth Engine (GEE) es una es una plataforma de procesamiento geoespacial basada en la nube para el monitoreo y análisis ambiental a gran escala que facilita el acceso a recursos informáticos de alto rendimiento para procesar conjuntos de datos geoespaciales muy grandes, sin tener que sufrir los problemas que implican las tecnologías de la información (TI) tradicionales (Tamiminia y otros, 2020).

La plataforma es de uso gratuito y proporciona el acceso a petabytes de datos de imágenes de más de 40 años y otros productos listos para usar con una aplicación web de exploración; procesamiento paralelo de alta velocidad y algoritmos de aprendizaje automático que utilizan la infraestructura informática de Google; cuenta con una biblioteca de interfaces de programación de aplicaciones (API) con entornos de desarrollo que admiten lenguajes de codificación populares, como JavaScript y Python (Tamiminia y otros, 2020).

A diferencia de la mayoría de los centros de supercomputación, GEE está diseñado para ayudar a los investigadores a difundir fácilmente sus resultados, ya que una vez que se ha desarrollado un algoritmo en GEE, los usuarios pueden producir productos de datos sistemáticos o implementar aplicaciones interactivas (Gorelick et al., 2017). GEE contiene datos de detección remota de Landsat, MODIS, radiómetro avanzado de muy alta resolución de la Administración Nacional Oceanográfica y Atmosférica (NOAA AVHRR), Sentinel 1, 2, 3 y 5-PAG, datos del Satélite de Observación Terrestre Avanzado (ALOS), entre otros. Además de la disponibilidad de un gran depósito de imágenes sin procesar de detección remota, los usuarios tienen acceso a imágenes preprocesadas, eliminadas de la nube y en mosaico en el catálogo de datos de GEE (Tamiminia y otros, 2020).

Satélite Sentinel-1

Sentinel-1 es una misión espacial financiada por la Unión Europea y llevada a cabo por la Agencia Espacial Europea (ESA) dentro del Programa Copernicus, se compone por un par de satélites en órbitas polares (Sentinel-1A lanzado en 2013 y Sentinel-1B lanzado en 2016), los cuales tienen cobertura mundial con revisita de 6 días para Europa y de 12 días para el resto del mundo. El sistema recopila imágenes de radar de apertura sintética (SAR) de banda C en una variedad de polarizaciones y resoluciones (Ustin & Middleton, 2021).

Los instrumentos SAR de banda C de Sentinel-1 admiten el funcionamiento en polarización simple (HH o VV) y polarización dual (HH+HV o VV+VH), implementados a través de una cadena de transmisión (conmutable a H o V) y dos cadenas de recepción paralelas para Polarización H y V. Los modos de adquisición se clasifican en cuatro: Stripmap (SM), Interferometric Wide Swath Mode (IW), Extra-Wide Swath (EW) y Wave (WV). Los modos SM, IW y EW están disponibles en polarización simple (HH o VV) o doble (HH+HV o VV+VH), mientras que el modo WV solo en polarización simple (HH o VV) (ESA, 2013). Entre las aplicaciones que admiten los productos de datos de la misión Sentinel-1 se incluyen (Ustin & Middleton, 2021) :

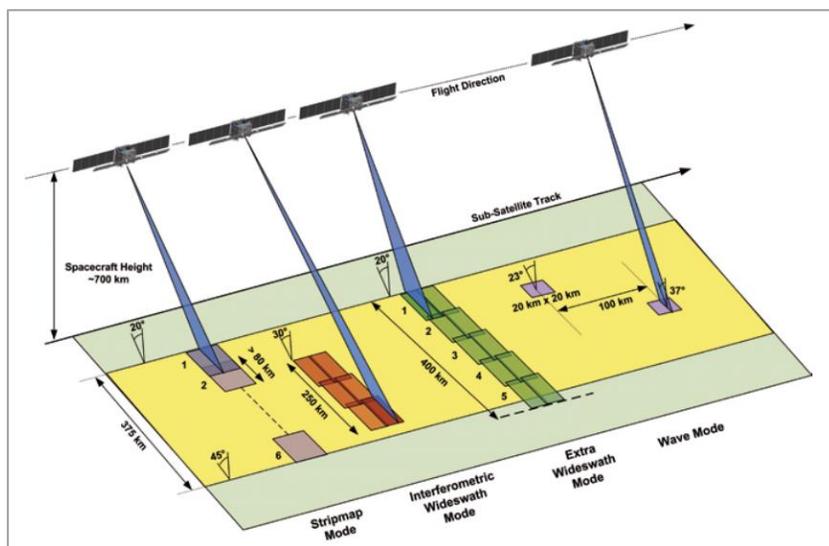
- Vigilancia de las zonas de hielo marino y el entorno ártico
- Vigilancia del medio marino
- Monitoreo de los riesgos de movimiento de la superficie terrestre
- Mapeo de superficies terrestres: bosque, agua y suelo, agricultura
- Mapeo en apoyo a la ayuda humanitaria en situaciones de crisis

Modos de adquisición

La misión Sentinel-1 opera en cuatro modos de adquisición exclusivos: Stripmap (SM), Interferometric Wide Swath Mode (IW), Extra-Wide Swath Mode (EW) y Wave Mode (WV), representados en la figura 11.

Figura 11

Modos de adquisición de Sentinel-1



Nota. Tomado de *Handbook Sentinel-1*, por ESA, 2013.

Strip Map (SM). El modo Strip Map (SM) denota que la imagen adquirida es la banda o franja de terreno recorrida por el instrumento con su antena, presenta una resolución espacial de 5 por 5 metros y una franja de 80 km. Ofrece productos de datos en polarización simple (HH o VV) o doble (HH + HV o VV + VH) y su uso se centra en monitorear islas pequeñas, así como

para la gestión de emergencias para eventos extraordinarios a pedido (Ustin & Middleton, 2021).

Interferometric Wide Swath Mode (IW). Es el modo operativo principal sobre la Tierra, el cual adquiere datos con una franja de 250 km a una resolución espacial de 5 m por 20 m. Captura tres subfranjas utilizando la observación del terreno con barridos progresivos SAR (TOPSAR). Ofrece productos de datos en polarización simple (HH o VV) o doble (HH + HV o VV + VH) y es empleado en interferometría mediante sincronización de ráfagas (ESA, 2013).

Procesamiento TOPSAR. La técnica de observación del terreno con barridos progresivos SAR (TOPSAR) es una forma de imágenes ScanSAR, en la que los datos se adquieren en ráfagas, cambiando cíclicamente el haz de la antena entre varias subfranjas adyacentes. Las adquisiciones de TOPSAR pueden proporcionar anchos de barrido grandes y un rendimiento radiométrico mejorado al reducir el efecto festoneado. TOPSAR se utiliza en los modos Interferometric Wide Swath y Extra Wide Swath de SENTINEL-1 (Zan & Guarnieri, 2006).

Extra-Wide Swath Mode (EW). El modo EW adquiere datos en una franja de 400 km con una resolución espacial de 20 m por 40 m, empleando la técnica TOPSAR para adquirir datos sobre un área más amplia usando cinco sub-franjas. El modo EW está diseñado principalmente para su uso sobre hielo marino, zonas polares y ciertas áreas marítimas, en particular para hielo, monitoreo de derrames de petróleo y servicios de seguridad. Al igual que IW, el modo EW también se puede utilizar para interferometría (ESA, 2013).

Wave Mode (WV). Las adquisiciones de WV consisten en varias viñetas exclusivamente en polarización simple (VV o HH), donde cada viñeta se procesa como una imagen separada. Los productos pueden contener cualquier número de viñetas, lo que podría equivaler a una toma de datos completa. El modo de onda adquiere datos en viñetas de 20 km por 20 km, con una resolución espacial de 5 m por 5 m a lo largo de la órbita a intervalos de

100 km, que son adquiridos alternativamente en dos ángulos de incidencia diferentes. Se caracteriza por ser el modo operativo principal en mar abierto (ESA, 2013).

Niveles de procesamiento de los datos de Sentinel-1

Nivel 0. Los productos de nivel 0 de SAR corresponden a datos sin procesar, comprimidos y desenfocados, utilizado como base a partir de los cuales se fabrican los demás productos de alto nivel (nivel 1 y nivel 2). Están disponibles para los usuarios de datos solo para los modos SM, IW y EW e incluyen información acerca de la calibración interna, ruido, paquetes de fuente de eco y órbita (ESA, 2018).

Nivel 1. Los datos de nivel 1 son los productos generalmente disponibles destinados a la mayoría de los usuarios de datos. Estos se pueden procesar en productos Single Look Complex (SLC) y/o Ground Range Detected (GRD) (ESA, 2018).

Productos Single Look Complex (SLC). Estos productos consisten en datos SAR enfocados, que son georreferenciados usando los datos de órbita y actitud del satélite, además son corregidos por retardo bi-estático de azimut, patrón de antena de elevación y pérdida de dispersión de rango. Poseen una vista única en cada dimensión utilizando todo el ancho de banda de señal disponible y muestras complejas (reales e imaginarias) conservando la información de fase (ESA, 2018).

Productos Ground Range Detected (GRD). Estos productos consisten en datos SAR enfocados que han sido detectados, analizados y proyectados al rango terrestre utilizando el modelo de elipsoide terrestre WGS84. Los productos resultantes tienen píxeles de resolución aproximadamente cuadrada y un espaciado de píxeles cuadrados con moteado reducido a costa de una resolución geométrica reducida. Se presentan en tres resoluciones: Resolución completa (FR), alta resolución (HR) y resolución media (MR). La resolución depende de la cantidad de visualizaciones múltiples realizadas (ESA, 2018).

Nivel 2. Estos productos se derivan del Nivel-1 y son productos oceánicos (OCN) que son empleados para aplicaciones de viento, olas y corrientes, ya que contienen los siguientes componentes geofísicos derivados de los datos SAR: Campo de viento oceánico (OWI), Espectros Ocean Swell (OSW) y Velocidad radial superficial (RVL) (ESA, 2018).

Preprocesamiento de imágenes Sentinel-1 en GEE

En la plataforma de GEE, la colección de imágenes de la misión Sentinel-1, incluye escenas detectadas en el rango de tierra (GRD) de nivel 1 procesadas al coeficiente de retrodispersión (σ°) en decibelios (dB). El coeficiente de retrodispersión representa el área de retrodispersión del objetivo por unidad de superficie terrestre. Debido a que puede variar en varios órdenes de magnitud, se convierte a dB como $10 \cdot \log_{10} \sigma^\circ$. Para que los usuarios puedan acceder a datos con el coeficiente de retrodispersión en cada píxel de las imágenes, en la plataforma se realizaron los siguientes pasos de acuerdo al siguiente orden de preprocesamiento (GEE, 2018):

Aplicar archivo de órbita. Se actualizan los metadatos de órbita con un archivo de órbita restituido (o un archivo de órbita preciso si el restituido no está disponible).

Eliminación de ruido de borde GRD. Se elimina el ruido de baja intensidad y los datos no válidos en los bordes de la escena.

Eliminación de ruido térmico. Se elimina el ruido aditivo en las sub-franjas para ayudar a reducir las discontinuidades entre las sub-franjas para escenas en modos de adquisición de múltiples franjas.

Aplicación de valores de calibración radiométrica. Se calcula la intensidad de la retrodispersión utilizando los parámetros de calibración del sensor en los metadatos GRD.

Corrección del terreno (ortorrectificación). Se convierte datos de la geometría del rango del suelo, que no tiene en cuenta el terreno, a σ° utilizando el DEM de 30 metros SRTM o el DEM ASTER para latitudes altas (mayores de 60° o menores de -60°).

Misión GEDI

GED I es el acrónimo en inglés de Global Ecosystem Dynamics Investigation, que en español se traduce como Investigación de la Dinámica de los Ecosistemas Globales. Es una misión dirigida por la Universidad de Maryland en colaboración con el Centro de Vuelo Espacial Goddard de la Administración Nacional de Aeronáutica y el Espacio (NASA), que tiene como objetivo, caracterizar la estructura y la dinámica de los ecosistemas para permitir una cuantificación y comprensión radicalmente mejoradas del ciclo del carbono y la biodiversidad de la Tierra (Dubayah et al., 2020).

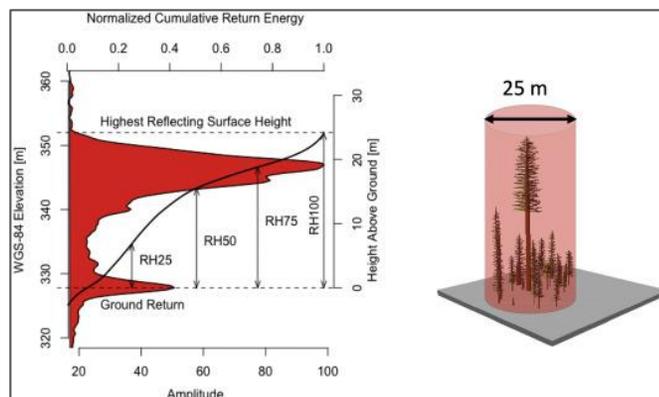
GED I se encuentra adjunta a la Estación Espacial Internacional (ISS), en donde realiza mediciones de día y de noche continuamente sobre las superficies terrestres de la Tierra entre los 51,6° N y 51,6° S de latitud, cubriendo los bosques tropicales y templados de la Tierra con la resolución más alta y el muestreo más denso de cualquier instrumento de detección de luz y alcance (LiDAR) (Dubayah et al., 2020). Fue lanzada en el año 2018 para una misión de dos años, ahora extendida hasta enero de 2023 (Duncanson y otros, 2022).

Funcionamiento de GEDI

GED I emplea un sistema de detección remota por láser cuyo único observable es la forma de onda LiDAR devuelta. Se dispara un pulso de energía láser de infrarrojo cercano hacia la superficie donde se refleja en hojas y ramas dentro de una huella de diámetro nominal de 25 m (Figura 12). A partir de dicha forma de onda, se derivan una variedad de métricas de forma de onda y de copa, como la altura de la copa, el perfil vertical de la copa, las métricas de energía de altura relativa (HR) y la elevación de la superficie topográfica. El instrumento GEDI consta de 3 láseres que se dividen y hacen difuminados, para producir 8 pistas de datos, separadas por unos 600 m a lo largo de la dirección de la pista de vuelo dentro de una franja de ~ 4,2 km. Cada haz consta de muestras de huella de ~25 m espaciadas aproximadamente cada 60 m a lo largo de la vía (Dubayah y otros, 2020).

Figura 12

Forma de onda GEDI



Nota: La forma de onda devuelta se procesa para encontrar topografía en tierra, altura del dosel y varias métricas de alturas relativas (HR). Tomado de *The Global Ecosystem Dynamics Investigation: High-resolution laser ranging of the Earth's forests and topography*, por Dubayah y otros, 2020.

Productos de datos de GEDI

Las formas de onda LiDAR cuantifican la distribución vertical de la vegetación al registrar la cantidad de energía láser reflejada por el material vegetal (tallos, ramas y hojas) a diferentes alturas sobre el suelo. El procesamiento de señales se utiliza para identificar el terreno dentro de la forma de onda. La distribución de la energía láser sobre el suelo se puede utilizar para determinar la altura y la densidad de los objetos (tallos, hojas y ramas) dentro de la huella. De las formas de onda GEDI, se pueden extraer cuatro niveles de datos que describen las características 3D de la Tierra (Beck y otros, 2021).

Nivel 1. Las formas de onda GEDI sin procesar recopiladas por el sistema GEDI se indican como L1A. Estas formas de onda se geolocalizan y posicionan correctamente en relación con el elipsoide de la Tierra después de los análisis orbitales y de orientación basados en la información del GPS y los rastreadores de estrellas de GEDI y se almacenan como datos

L1B, los cuales no se pueden emplear para identificar la altura del suelo o del dosel (Dubayah y otros, 2020).

Nivel 2. Las formas de onda se procesan para identificar la elevación del suelo, la altura superior del dosel y la altura relativa (métricas de RH) en el conjunto de datos L2A. En L2B, se calculan varias métricas del dosel, incluida la fracción de cobertura del dosel, el índice de área foliar total (LAI) y el perfil del follaje vertical, es decir, cómo varía el LAI con la altura desde la parte superior del dosel hasta el suelo identificado (Dubayah y otros, 2020).

Nivel 3. Los productos de nivel 3 se cuadrícula mediante la interpolación espacial de las estimaciones de la huella L2 de la topografía, la altura del dosel, la cobertura del dosel, la altura del dosel, el área foliar total, el perfil del follaje vertical y sus incertidumbres (Dubayah y otros, 2020).

Nivel 4. Los productos de nivel 4 son el nivel más alto de producto GEDI, representan la salida de los modelos y requieren la mayor parte del procesamiento posterior. Las métricas de huella derivadas de los productos de datos L2 se convierten en estimaciones de huella de biomasa forestal sobre la densidad de suelo (AGBD), utilizando ecuaciones de calibración (Dubayah y otros, 2020).

Inteligencia Artificial

La Inteligencia Artificial (IA), es un sistema informático que reproduce la cognición humana utilizando datos a los que se accede desde una variedad de fuentes o sistemas diferentes para tomar decisiones y aprender de los patrones resultantes. También se la considera como la capacidad de una computadora para reconocer patrones y tomar medidas en función de los datos disponibles y los modelos estadísticos (Hassani et al., 2020).

Según Boucher (2020), las tecnologías clave bajo el estandarte de la inteligencia artificial, se encuentran agrupado en tres secciones. La primera sección corresponde a primera ola, la cual describe las primeras técnicas de IA, la IA simbólica, que se refiere a los enfoques para desarrollar máquinas inteligentes mediante la codificación del conocimiento y la

experiencia de los expertos en conjuntos de reglas que la máquina puede ejecutar. La segunda sección corresponde a la ola dos, que comprende al aprendizaje automático e inteligencia artificial basada en datos, estas se refieren a una amplia gama de técnicas que automatizan el proceso de aprendizaje de algoritmos, los cuales generalmente mejoran entrenándose en datos, que en los últimos años han estado disponibles de forma masiva. La tercera sección comprende a las posibles oleadas futuras de la IA, tales como la IA especulativa, la Super Inteligencia Artificial (ASI) y la singularidad que se refiere al momento en el que la IA se vuelve suficientemente inteligente y autónoma para generar IA aún más inteligentes y autónomas, liberándose del control humano y embarcarse en un proceso de desarrollo fuera de control (Hassani et al., 2020).

Aprendizaje automático

El aprendizaje automático (AA) o en inglés Machine Learning (ML), es un subcampo de la inteligencia artificial, donde los sistemas tienen la capacidad de aprender a través de datos, estadísticas y prueba y error para optimizar procesos e innovar a un ritmo más rápido. Con el aprendizaje automático se busca encontrar la mejor representación de los datos de entrada para producir un conjunto de datos de salida válidos, es decir, se encuentran automáticamente las representaciones que convierten datos de entrada en representaciones mucho más útiles de los mismos para una tarea específica (Brown, 2021).

Según Pineda (2019), los algoritmos de ML se pueden clasificar de la siguiente manera:

Aprendizaje supervisado. Los algoritmos de ML generan una función que grafica los datos de entrada para apuntar a los datos de salida.

Aprendizaje no supervisado. No hay datos de salida de destino y el algoritmo ML simplemente modela un conjunto de datos de entrada, buscando agrupaciones en esos datos.

Aprendizaje semisupervisado. Corresponde a una combinación de los dos anteriores, donde los algoritmos de ML utilizan datos etiquetados y datos no etiquetados.

Aprendizaje por refuerzo. Los algoritmos de ML aprenden a través de su interacción en un entorno u obtiene retroalimentación sobre la precisión de su respuesta.

Aprendizaje inductivo. Se da cuando los algoritmos de ML aprenden, basándose en conocimientos previos, su propio sesgo inductivo.

Random Forest

Random Forest es algoritmo de aprendizaje automático que pertenece a la técnica de aprendizaje supervisado. Se emplea para problemas de clasificación y regresión en Machine Learning. Se basa en el concepto de aprendizaje conjunto, que es un proceso de combinación de múltiples clasificadores para resolver un problema complejo y mejorar el rendimiento del modelo. Random Forest es un clasificador que contiene una serie de árboles de decisión en varios subconjuntos del conjunto de datos dado y toma el promedio para mejorar la precisión predictiva de ese conjunto de datos. En lugar de depender de un árbol de decisión, el bosque aleatorio toma la predicción de cada árbol y, en función de los votos mayoritarios de las predicciones, predice el resultado final. El mayor número de árboles en el bosque conduce a una mayor precisión y evita el problema del sobreajuste (Mbaabu, 2020).

Regresión Random Forest. La Regresión Random Forest es un algoritmo de aprendizaje automático que combina el concepto de regresión con la técnica de Bosques Aleatorios (Random Forests). Es una variante del modelo Random Forest utilizada específicamente para tareas de regresión, donde el objetivo es predecir valores numéricos continuos en lugar de clasificar categorías. Un Random Forest es un conjunto de árboles de decisión, donde cada árbol se entrena con una muestra aleatoria del conjunto de datos original y realiza una predicción individual. Luego, las predicciones de todos los árboles se combinan mediante promedio o votación ponderada para obtener la predicción final (Cutler, 2010).

En la Regresión Random Forest, cada árbol se entrena utilizando un subconjunto de características seleccionadas al azar del conjunto de datos original. Durante la predicción, los

árboles ponderan sus predicciones basándose en su precisión y se combinan para generar una estimación final (Cutler, 2010).

Regresión Random Forest en GEE. En el contexto de Google Earth Engine (GEE), la regresión Random Forest (bosques aleatorios) es un algoritmo de aprendizaje automático utilizado para realizar análisis de regresión en datos geoespaciales. La implementación de la regresión Random Forest aprovecha la capacidad de procesamiento y almacenamiento de datos masivos de la plataforma. Permite aplicar este algoritmo a conjuntos de datos geoespaciales de gran escala y realizar análisis de regresión en múltiples variables de forma simultánea (Amat, 2020).

Tecnologías de teledetección activas para inventarios de recursos naturales

La teledetección ha evolucionado como una herramienta esencial en la gestión y monitoreo de los recursos naturales de nuestro planeta. Su capacidad para recopilar datos a gran escala y de manera no invasiva, es fundamental para la realización de inventarios de estos recursos, permitiendo así evaluar y planificar el uso sostenible de estos valiosos activos (Kellndorfer, 2019).

La tecnología RADAR, haciendo énfasis al radar de apertura sintética (SAR) se ha convertido en una tecnología clave en la teledetección de recursos naturales. La misión Sentinel-1 de la Agencia Espacial Europea utiliza esta tecnología para adquirir imágenes a través de las diversas condiciones climáticas y la oscuridad, lo que posibilita llevar a cabo estudios precisos y consistentes sin que estos se vean afectados por factores externos como los ambientales (Kellndorfer, 2019).

Por otro lado, LiDAR (Light Detection and Ranging) es otra tecnología líder en la realización de inventarios de recursos naturales. GEDI emite pulsos láser hacia la superficie terrestre y mide el tiempo de retorno de la señal, lo que resulta en la creación de modelos tridimensionales detallados del dosel forestal y la topografía (Simard et al., 2008).

Dentro del vasto espectro de recursos naturales, los manglares merecen una atención especial, ya que estos ecosistemas costeros son cruciales para la biodiversidad, la protección costera y la mitigación del cambio climático. Estos enfrentan amenazas significativas, desde la deforestación hasta la degradación del hábitat, es por eso que estas tecnologías desempeñar un papel crucial en su conservación y el monitoreo (Simard et al., 2008).

Bosques de manglares

Los bosques de manglares son unos de los ecosistemas más productivos en el mundo, estos prosperan dentro de la zona intermareal a lo largo de las costas de las regiones tropicales y subtropicales. Corresponden a una formación leñosa, densa, usualmente arbustiva o arborescente de 2 a 25 m de altura (Rzedowski, 2006). Ocupan ambientes terrestres y marinos, lo que les permite albergar una amplia gama de biodiversidad, que abarca desde organismos dentro del suelo hasta un gran número de especies de peces y especies terrestres, incluidos reptiles, mamíferos, aves e insectos. Los manglares brindan servicios directos e indirectos a las poblaciones locales que habitan la zona costera. Los principales beneficios incluyen la captura de sedimentos; la producción de nutrientes y materia orgánica a través de los detritos; un sumidero de carbono, nitrógeno y fósforo; mantener la calidad del agua; provisión de alimento y hábitat para la biodiversidad; y proporcionar protección costera contra tormentas y aumento del nivel del mar (Simard et al., 2008).

Los bosques de manglares se incluyeron en la estrategia de mitigación climática del Panel Intergubernamental sobre el Cambio Climático (IPCC) a través de los suplementos de humedales, debido a que estos aunque solo cubran una pequeña superficie terrestre (<1%), pueden ser responsables del 10% de exportación global de carbono a los océanos (Lucas y otros, 2014)

Mecanismos de dispersión en los manglares

El mecanismo de dispersión dominante en los manglares depende en gran medida de la estructura del dosel. Las tendencias en el volumen y las firmas de doble rebote varían mucho más que en otros tipos de bosques. En los manglares, la dispersión de volumen disminuye y la dispersión de doble rebote aumenta en copas de los árboles cerradas y abiertas, respectivamente (Simard et al., 2008).

Media aritmética

En el campo de la estadística, la media es una medida que se utiliza para identificar el valor promedio de un conjunto de datos. Es decir, es el punto intermedio o central que representa típicamente la distribución de los datos (Quevedo, 2011).

El cálculo de la media se realiza sumando todos los valores presentes en el conjunto de datos y luego dividiendo esta suma por el número total de observaciones. Esta operación permite obtener un valor que refleja de manera representativa el conjunto de datos, ya que toma en cuenta la contribución de cada observación en la formación del promedio (Quevedo, 2011).

$$\bar{X} = \frac{(X_1 + X_2 + X_3 + \dots + X_n)}{n} \quad (11)$$

Donde:

\bar{X} = media aritmética

X_n = cantidad finita de números

n= número de sumandos

Muestreo aleatorio simple

El muestreo aleatorio simple es un método utilizado en la estadística para seleccionar una muestra representativa de una población más grande. La idea detrás de este tipo de muestreo es que cada individuo en la población tenga la misma probabilidad de ser

seleccionado para formar parte de la muestra (Thomas, 2020). Para un muestreo aleatorio simple se puede utilizar la siguiente fórmula:

$$n = \frac{N \cdot \sigma^2 \cdot Z^2}{(N - 1) \cdot e^2 + \sigma^2 \cdot Z^2} \quad (12)$$

Donde:

σ = desviación estandar de la población

N =Tamaño de la población

Z = Valor obtenido de la distribución normal para un nivel de confianza del 95%

e =Límite aceptable del error muestral

n =Tamaño mínimo de la población objetivo esperado para un nivel de confianza del 95%

Base Legal

El presente proyecto se apoya en las normas legales presentes en la Constitución de la República del Ecuador, el Código Orgánico del Ambiente, el Código Orgánico de Ordenamiento Territorial, Autonomía y Descentralización, el Código orgánico de la Economía Social de los Conocimientos, Creatividad e Innovación y la Ley de Seguridad Pública y del Estado.

Constitución de la República del Ecuador

Artículo 14.- “Se reconoce el derecho de la población a vivir en un ambiente sano y ecológicamente equilibrado, que garantice la sostenibilidad y el buen vivir, Sumak Kawsay. Se declara de interés público la preservación del ambiente, la conservación de los ecosistemas, la biodiversidad y la integridad del patrimonio genético del país, la prevención del daño ambiental y la recuperación de los espacios naturales degradados.” (Constitución de la República del Ecuador, 2008).

Artículo 73.- “El Estado aplicará medidas de precaución y restricción para las actividades que puedan conducir a la extinción de especies, la destrucción de ecosistemas o la alteración permanente de los ciclos naturales” (Constitución de la República del Ecuador, 2008).

Artículo 400.- “El Estado ejercerá la soberanía sobre la biodiversidad, cuya administración y gestión se realizará con responsabilidad intergeneracional. Se declara de interés público la conservación de la biodiversidad y todos sus componentes, en particular la biodiversidad agrícola y silvestre y el patrimonio genético del país.” (Constitución de la República del Ecuador, 2008)

Artículo 406.- “El Estado regulará la conservación, manejo y uso sustentable, recuperación, y limitaciones de dominio de los ecosistemas frágiles y amenazados; entre otros, los páramos, humedales, bosques nublados, bosques tropicales secos y húmedos y manglares, ecosistemas marinos y marinos-costeros.” (Constitución de la República del Ecuador, 2008).

Código Orgánico del Ambiente

Artículo 29.- Regulación de la biodiversidad: “La biodiversidad es un recurso estratégico del Estado, que deberá incluirse en la planificación territorial nacional y de los gobiernos autónomos descentralizados como un elemento esencial para garantizar un desarrollo equitativo, solidario y con responsabilidad intergeneracional en los territorios.” (Código Orgánico del Ambiente, 2017)

Artículo 31.- De la conservación de la biodiversidad: “La conservación de la biodiversidad se realizará in situ o ex situ, en función de sus características ecológicas, niveles de endemismo, categoría de especies amenazadas de extinción, para salvaguardar el patrimonio biológico de la erosión genética, conforme a la política formulada por la Autoridad Ambiental Nacional.” (Código Orgánico del Ambiente, 2017)

Artículo 35.- De la protección de las especies de vida silvestre: “Para la protección de la vida silvestre, se establecen las siguientes condiciones a las personas naturales y jurídicas:

1. Conservar a las especies de vida silvestre en su hábitat natural prohibiendo su extracción, salvo las consideradas para la investigación, repoblación de especies con cualquier tipo de amenaza y las establecidas en este Código;

2. Reconocer el uso tradicional y el aprovechamiento de las especies de vida silvestre por motivos de subsistencia o por prácticas culturales medicinales;
3. Proteger todas las especies nativas de vida silvestre terrestres, marinas y acuáticas con especial preocupación por las especies endémicas, las amenazadas de extinción, las migratorias y las listadas por instrumentos internacionales ratificados por el Estado;
4. Proteger los hábitats, ecosistemas y áreas de importancia biológica, de los que dependen las especies de vida silvestre;
5. Coordinar acciones interinstitucionales para la conservación in situ de especies de vida silvestre que sean afectadas, o que puedan resultar afectadas por actividades antropogénicas;
6. Promover investigaciones sobre vida silvestre para difundir el bioconocimiento dentro del territorio nacional; y,
7. Otras que se determinen para el efecto.” (Código Orgánico del Ambiente, 2017)

Artículo 89.- Patrimonio Forestal Nacional: “La Autoridad Ambiental Nacional ejerce la rectoría, planificación, regulación, control y gestión del Patrimonio Forestal Nacional. El Patrimonio Forestal Nacional estará conformado por:

1. Los bosques naturales y tierras de aptitud forestal, incluyendo aquellas tierras que se mantienen bajo el dominio del Estado o que por cualquier título hayan ingresado al dominio público;
2. Las formas de vegetación no arbórea asociadas o no al bosque, como manglares, páramos, moretales y otros;
3. Bosques y Vegetación Protectores (BVP);
4. Los bosques intervenidos y secundarios; y,
5. Las tierras de restauración ecológica o protección.” (Código Orgánico del Ambiente, 2017)

Artículo 99.- Conservación de páramos, moretales y manglares: “Será de interés público la conservación, protección y restauración de los páramos, moretales y ecosistema de manglar. Se prohíbe su afectación, tala y cambio de uso de suelo, de conformidad con la ley. Las comunas, comunidades, pueblos, nacionalidades y colectivos participarán en el cuidado de estos ecosistemas y comunicarán a la autoridad competente cualquier violación o destrucción de los mismos.” (Código Orgánico del Ambiente, 2017)

Artículo 105.- Categorías para el ordenamiento territorial: “Con el fin de propender a la planificación territorial ordenada y a la conservación del patrimonio natural, las siguientes categorías deberán ser tomadas en cuenta e incorporadas obligatoriamente en los planes de ordenamiento territorial de los Gobiernos Autónomos Descentralizados:

1. Categorías de representación directa. Sistema Nacional de Áreas Protegidas, Bosques y Vegetación Protectores y las áreas especiales para la conservación de la biodiversidad;

2. Categoría de ecosistemas frágiles. Páramos, humedales, bosques nublados, bosques secos, bosques húmedos, manglares y moretales; y,

3. Categorías de ordenación. Los bosques naturales destinados a la conservación, producción forestal sostenible y restauración.

La Autoridad Ambiental Nacional proveerá la información y guía metodológica para la determinación, identificación y mapeo de todas estas categorías, así como las respectivas limitaciones de uso de aprovechamiento o condiciones de manejo a las que quedan sujetas.” (Código Orgánico del Ambiente, 2017).

Código Orgánico de Ordenamiento Territorial, Autonomía y Descentralización

Artículo 140.- Ejercicio de la competencia de gestión de riesgos: “La gestión de riesgos que incluye las acciones de prevención, reacción, mitigación, reconstrucción y transferencia, para enfrentar todas las amenazas de origen natural o antrópico que afecten al territorio se

gestionarán de manera concurrente y de forma articulada por todos los niveles de gobierno de acuerdo con las políticas y los planes emitidos por el organismo nacional responsable, de acuerdo con la Constitución y la ley.

Los gobiernos autónomos descentralizados municipales adoptarán obligatoriamente normas técnicas para la prevención y gestión de riesgos en sus territorios con el propósito de proteger las personas, colectividades y la naturaleza, en sus procesos de ordenamiento territorial (...)” (Código Orgánico de Ordenamiento Territorial, Autonomía y Descentralización, 2016).

Código orgánico de la Economía Social de los Conocimientos e Innovación

Artículo 24.- “Los institutos públicos de investigación son entidades con autonomía administrativa y financiera los cuales tienen por objeto planificar, promover, coordinar, ejecutar e impulsar procesos de investigación científica, la generación de innovación, validación, difusión y transferencia de tecnologías.

Se garantiza el funcionamiento permanente de los institutos públicos de investigación relacionados a: salud pública, biodiversidad, investigación agropecuaria, pesca, geología, minería y metalurgia, eficiencia energética y energía renovable, oceanografía, estudio del espacio, estudio polar antártico, cartográfico y geografía, meteorología e hidrología, estadísticas y censos, patrimonio cultural y los demás que el Presidente de la República considere necesarios. (...)” (Código Orgánico de la Economía Social de los Conocimientos, Creatividad e Innovación, 2016)

Ley de Seguridad Pública y del Estado

Artículo 2.- “Se protegerá el patrimonio cultural, la diversidad biológica, los recursos genéticos, los recursos naturales, la calidad de vida ciudadana, la soberanía alimentaria.” (Ley de Seguridad Pública y del Estado, 2009)

Capítulo III: Metodología

En este capítulo, se describen los procesos metodológicos llevados a cabo para la generación de modelos de las alturas del dosel de los manglares a partir de datos de retrodispersión SAR de la misión Sentinel-1 y datos de alturas LiDAR de la misión GEDI para el año 2021 sobre un área definida en la provincia de El Oro.

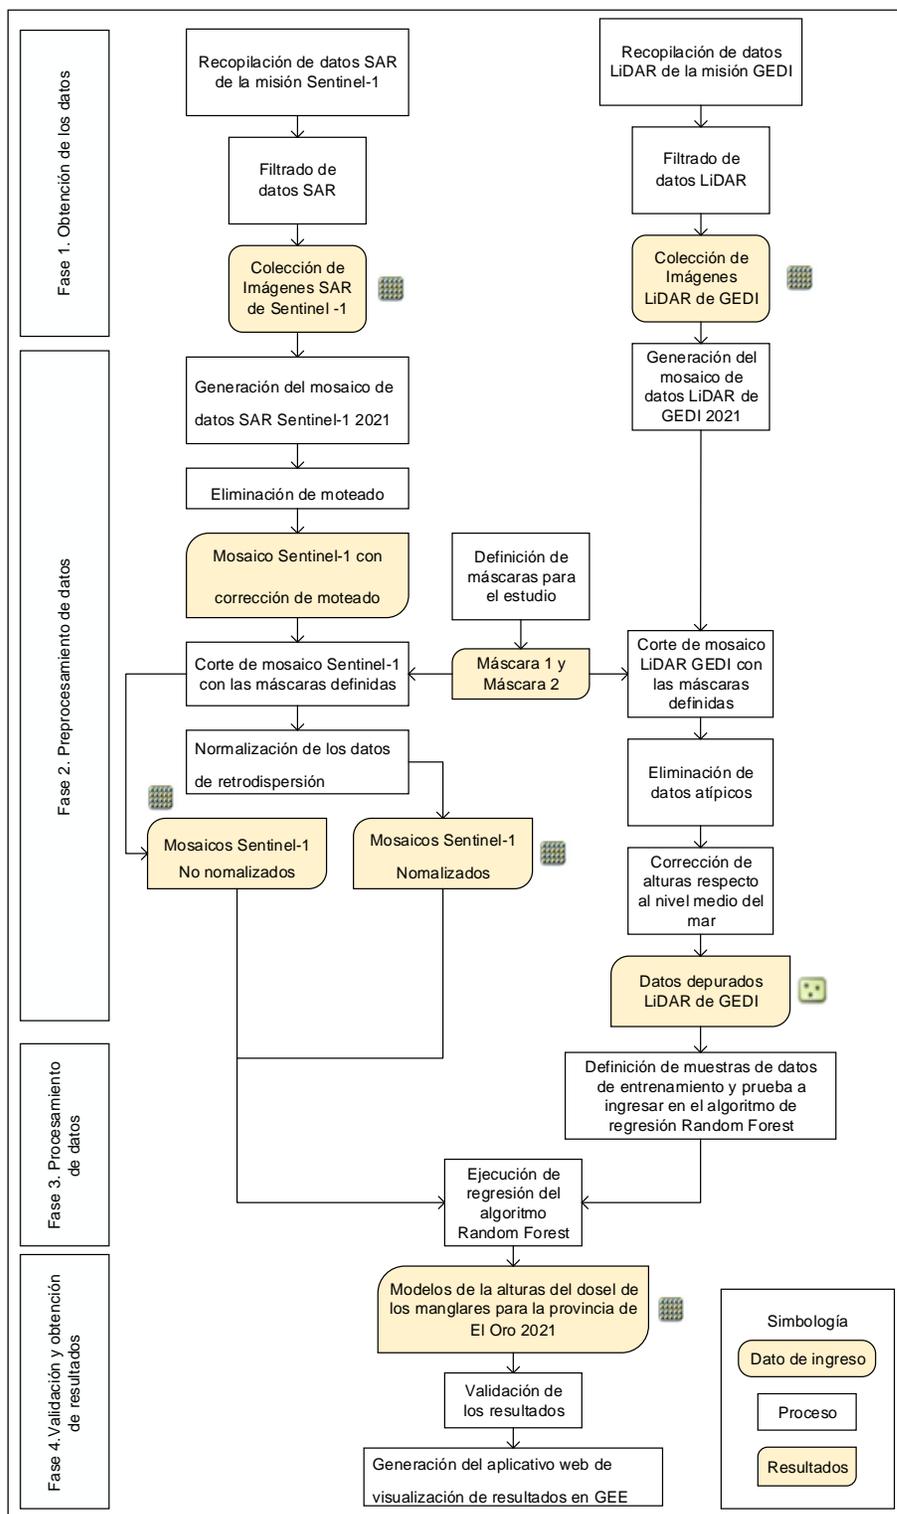
La metodología aplicada, se llevó a cabo principalmente en la plataforma GEE, en donde se realizaron procesos de recopilación de los datos y filtrados de los mismos, así como la generación de mosaicos anuales para cada fuente de datos. Así mismo fue necesario un proceso de depuración de la información de datos LiDAR, debido a que la validez de los resultados dependía en gran medida de la calidad de los datos utilizados. En la plataforma GEE se ejecutó el algoritmo de regresión Random Forest, con el cual se generó los modelos de alturas del dosel, mismos que fue evaluado con la medida del error cuadrático promedio entre las predicciones del modelo y los valores reales. Los resultados obtenidos se emplearon para la creación de un aplicativo web de visualización dentro del entorno de GEE.

Los aspectos fundamentales del desarrollo metodológico se detallan en la figura 13. El cual se compone de cuatro fases principales:

- Fase de obtención de datos (Fase 1)
- Fase de preprocesamiento (Fase 2)
- Fase de procesamiento (Fase 3)
- Fase de validación y obtención de resultados (Fase 4).

Figura 13

Metodología general del proyecto



Nota. Metodología general del proyecto para el modelamiento de las alturas del dosel de los manglares empleando datos SAR de Sentinel 1 y LiDAR de GEDI.

Fase de obtención de los datos

La fase de obtención de los datos se realizó a partir de procesos que se indican a continuación.

Determinación del área de estudio

En la determinación del área de estudio de la investigación se consideró que este abarcará toda la cobertura de bosques de manglar presentes en los cantones de la provincia de El Oro (Huaquillas, Arenillas, Santa Rosa, Machala, El Guabo), misma que se representa en la Figura 2 “Ubicación del área de estudio” en el Capítulo 1, sección “Descripción del área de estudio”. Así mismo dentro del entorno de GEE se codificó el siguiente link:

[kvasimbaya/área_estudio](#), el cual permite visualizar el área de estudio así como realizar la descarga del mismo en formato KML.

Recopilación y filtrado de datos

En el desarrollo de este proceso fue fundamental haber revisado toda la información teórica previamente acerca de conceptos básicos de imágenes satelitales, especificaciones de los datos SAR y LiDAR a emplear, así como requerimientos de las plataforma y software donde se llevará a cabo el procesamiento metodológico.

De acuerdo a la revisión de la información bibliográfica presente en el Capítulo 2, se determinaron las especificaciones requeridas para el filtrado de datos de las imágenes SAR y LiDAR, considerando varios parámetros, tales como temporalidad, modo de adquisición, niveles de producto, entre otros que se describen a continuación.

Recopilación y filtrado de datos SAR de la misión Sentinel-1

En la recopilación de datos SAR de la misión Sentinel-1 desde la nube de GEE, se empleó la colección de datos Sentinel-1 SAR GRD: C-band Synthetic Aperture Radar Ground

Range Detected, log scaling (Sentinel-1 SAR GRD: Rango de Tierra del Radar de Apertura Sintética de banda C Detectado, escala logarítmica), que como se mencionó en el Capítulo 2 “Preprocesamiento de Imágenes Sentinel-1 en la plataforma GEE”, contiene escenas S1 (GRD) calibradas y ortocorregidas, gracias al preprocesamiento realizado en la misma plataforma Earth Engine con la herramienta Sentinel-1 Toolbox.

Con el fin de obtener un conjunto homogéneo de datos para el año 2021, se filtró la información en base a parámetros como el modo de adquisición IW TOPSAR, el nivel de procesamiento GDR, polarización cruzada de doble banda, dirección de la órbita descendente. En la Tabla 2 se indican las características de filtrado para los datos SAR de la misión Sentinel-1 que fueron empleados. Su resultado se presenta en el Capítulo IV, sección “Resultados de la recopilación y filtrado de datos SAR de la misión Sentinel-1”.

Tabla 2

Características de filtrado para los datos de Sentinel-1

| Especificaciones | Descripción |
|-------------------------------|---|
| Fechas de captura | 01-01-2021 al 31-12-2021 |
| Modo de adquisición | Interferometric Wide Swath Mode (IW) TOPSAR |
| Nivel de procesamiento | Nivel 1 - Ground Range Detected (GRD) |
| Polarización | Dual VV y VH |
| Dirección | Descendente |
| Resolución geométrica | 5x 20 m |
| Sistema de Referencia | WGS 84 |

Nota. En la tabla se indican las especificaciones requeridas para la obtención de datos de radar de apertura sintética de las Imágenes Sentinel-1 dentro de la plataforma GEE.

Recopilación y filtrado de datos LiDAR de la misión GEDI

En la recopilación de datos LiDAR de la misión GEDI desde la nube de GEE, se empleó la colección de datos GEDI L2A Raster Canopy Top Height (Altura superior del dosel ráster GEDI L2A). Esta colección corresponde a una versión ráster del producto GEDI02_A original, donde las imágenes rasterizadas se organizan como compuestos mensuales de órbitas individuales en el mes correspondiente. De las 100 métricas de alturas relativas (RH) que componen principalmente la colección el producto de GEDI02_A, se decidió filtrar los datos considerando la altura relativa 99 (rh99), para evitar la incertidumbre de la relación señal-ruido en la parte superior del dosel. En la Tabla 3, se indican las características de filtrado para los datos LiDAR de la misión GEDI. Su resultado se presenta en el Capítulo IV, sección “Resultados de la recopilación y filtrado de datos LiDAR de GEDI”.

Tabla 3

Características de filtrado para los datos GEDI

| Especificación | Descripción |
|------------------------|--|
| Fechas de captura | 01-01-2021 al 31-12-2021 |
| Nivel de procesamiento | Nivel 2A Geolocated Elevation and Height Metrics Product |
| RH | rh99 |
| Resolución espacial | ~25 m |

Nota. En la tabla se indican las especificaciones requeridas para la obtención de datos LiDAR de GEDI dentro de la plataforma GEE.

Recopilación de información cartográfica adicional

A más de los datos SAR de la misión Sentinel-1 y LiDAR de la misión GEDI, se recopiló información cartográfica de la cobertura de manglar de la provincia de El Oro obtenidos de la Plataforma Global Mangrove Watch (GMW), así como de información complementaria que se indican en la Tabla 4.

Tabla 4

Archivos vectoriales utilizados en el presente proyecto

| Nombre | Escala | Tipo de dato | Fuente | Año |
|---------------------------------|---------------|---------------------|---------------|------------|
| gmw_v3_2020.shp | Global | vectorial polígono | GMW | 2020 |
| unidad_hidrica_N4_250k_2020.shp | 1: 250 000 | vectorial polígono | MAATE | 2020 |
| nxcantones.shp | 1: 50 000 | vectorial polígono | SNI | 2013 |

Nota. En la tabla se indican los insumos adquiridos de diferentes fuentes de información.

Preprocesamiento de datos

En esta parte de la metodología se hace referencia al preprocesamiento que se realizó a los conjuntos de datos previos a la ejecución del algoritmo de regresión Random Forest en la plataforma GEE, con el cuál se obtuvo el modelo de alturas del dosel para los manglares de la provincia de El Oro. En el desarrollo de esta fase fue necesario contar con previa información teórica presentada en el Capítulo 2 acerca de conceptos como mosaicos, filtro de moteado y normalización.

Generación del mosaico de datos SAR Sentinel-1 para el año 2021

En la generación del mosaico de datos SAR , se consideró a la media como medida de tendencia central con la cual fue posible promediar los valores de los píxeles de todas las imágenes empleadas para el año de estudio 2021. En la plataforma GEE se empleó la función “mosaic()”. Su resultado se presenta en el Capítulo IV, sección “Resultados de la generación del mosaico SAR Sentinel-1 año 2021”.

Eliminación de ruido o “speckle” en el mosaico de datos SAR Sentinel-1

El mosaico de imágenes Sentinel-1 identificado como *Mosaico_SAR_2021*, presentaba ruido multiplicativo denominado moteado o “speckle”, el cual se redujo en parte al emplear 17 imágenes Sentinel-1 adquiridas en diferentes momentos (Schwartz y otros, 2022). Con el fin de disminuir aún más el efecto de moteado se aplicó el filtro de media focal, un filtro clasificado como de paso bajo. Para el filtro se definió una ventana de filtrado o Kernel con radio de 1 pixel, por lo tanto, se consideró un área circular de influencia de 3x3 píxeles (1 píxel del centro y los 8 píxeles vecinos) para calcular el valor promedio del píxel central, generando así una imagen más suavizada identificada como *Mosaico_SAR_2021_smoothed*. Su resultado se presenta en el Capítulo IV, sección “Resultados de “speckle” en el mosaico de datos SAR Sentinel-1 para el año 2021”.

Definición de máscaras para el análisis del modelamiento

Dado que el objetivo principal de esta investigación era modelar la altura del dosel de los manglares de la provincia de El Oro, se consideraron dos máscaras específicas con la finalidad de analizar los modelos resultantes y seleccionar el más idónea.

La primera máscara, denominada “Máscara 1” (Figura 14), abarcó la extensión de manglares obtenidos del Global Mangrove Watch (GMW) y se amplió para incluir el área adyacente a los polígonos de los manglares, comprendiéndose la línea de costa, los esteros y superficie circundante. La definición de esta primera máscara permitió obtener un conjunto más amplio de datos de retrodispersión, con el objetivo de mejorar el proceso de entrenamiento del algoritmo de regresión Random Forest.

Figura 14

Máscara 1 definida para el estudio

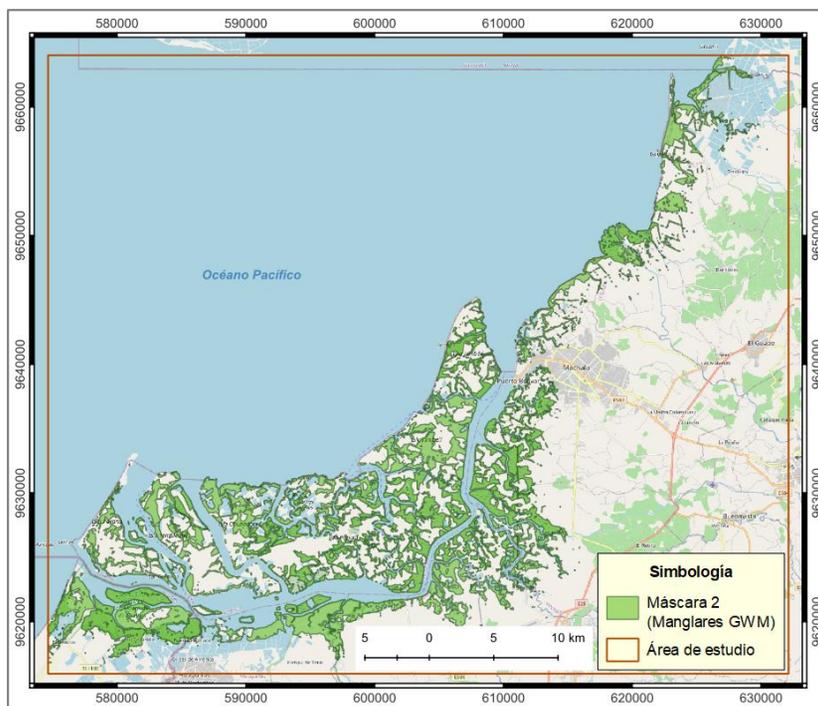


Nota. En la figura se indica la Máscara 1, misma que abarca más cobertura y por lo tanto más datos para entrenamiento del algoritmo de regresión Random Forest.

Por otro lado, la segunda máscara, denominada "Máscara 2", se restringió únicamente a los polígonos de los manglares, sin incluir el área adyacente. Esta estrategia de emplear dos máscaras diferentes permitió evaluar cómo la inclusión o exclusión del entorno circundante afectaba la precisión y eficacia del modelo de predicción de la altura del dosel de los manglares. Dichas máscaras se pueden visualizar en la Figura 15.

Figura 15

Máscara 2 definida para el estudio



Nota. En la figura se indica la Máscara 2, misma que abarca solo la cobertura de los bosques de manglar.

Definición de máscaras para el mosaico Sentinel-1 2021

Una vez definidas las máscaras se procedió a importarlas a GEE. El Mosaico_SAR_2021_smoothed, fue intersecado con las dos máscaras generándose dos capas identificadas como: “Mosaico_SAR_2021_mascara” y “Mosaico_SAR_2021_mangle”. Los resultados de este proceso se pueden ver en el Capítulo IV, “Resultados de la definición de máscaras para Mosaico Sentinel-1 2021”.

Normalización de los datos SAR

La normalización de datos de Sentinel-1 antes de ser utilizados en una regresión Random Forest no es estrictamente necesario, ya que este tipo de regresión se basa en árboles en los que un árbol divide cada nodo. Esta división no se ve afectada por las otras características del conjunto de datos por lo que los árboles de decisión permanecerán

constantes a la escala de las características y, por lo tanto, no requieren normalización (Narang, 2022).

Con la intención de evaluar si la normalización de los datos SAR tiene un impacto significativo en la precisión y capacidad predictiva del modelo para estimar las alturas del dosel de los manglares, se decidió también generar modelos de la altura del dosel con datos normalizados. Para esto se empleó la siguiente ecuación:

$$X_{\text{new}} = \frac{X}{X_{\text{max}}} \quad (13)$$

Donde:

X = Un valor del conjunto de datos

X max = El valor máximo del conjunto de datos

X new = Nuevo valor normalizado

Esta comparación proporcionó una comprensión más profunda sobre la influencia de la normalización en los resultados del modelamiento y permitió identificar cuál enfoque fue el más adecuado para el estudio de los manglares en cuestión.

El nombre identificador para el mosaico de datos SAR 2021 normalizado para la máscara 1 se definió como *Mosaico_SAR_2021_mascara_normalizado*, mientras que el mosaico de datos SAR 2021 normalizado para la máscara 2 correspondiente al raster que contiene los píxeles de intersección con el polígono de cobertura de manglar del GMW 2020 se definió como *Mosaico_SAR_2021_mangle_normalizado*. Los resultados se indican en el capítulo IV, “Resultados de la normalización de los mosaicos Sentinel 1”.

Generación del mosaico de datos LiDAR de la misión GEDI

En la generación del mosaico de LiDAR de los rásteres descritos en la Tabla 5 en GEE, se consideró a la media como medida de tendencia para obtener un resumen de cada uno de las celdas de las imágenes empleadas para el año de estudio 2021. El mosaico de datos LiDAR generado fue identificado como *Mosaico_GEDI_2021*. Su resultado se presenta en el

Capítulo IV, sección “Resultados de la generación del mosaico de datos LiDAR GEDI para el año 2021”.

Posteriormente se procedió a transformar dicho mosaico en una capa vectorial en donde se le asignó a cada centroide de las celdas, los valores de alturas LiDAR en metros correspondientes. La capa generada fue exportada en formato shape para la realizar el proceso de depuración de los datos en el software QGIS.

Definición de máscaras para el Mosaico LiDAR de GEDI 2021

Dado que se generaron dos mosaicos de datos SAR de Sentinel 1 en base a las Máscaras 1 y 2, también se generaron dos conjuntos de datos de alturas LiDAR correspondientes a las dos máscaras utilizadas. Los resultados de este proceso se pueden ver en el Capítulo IV, “Resultados de la definición de máscaras para Mosaico LiDAR GEDI 2021”.

Corrección de alturas respecto al nivel medio del mar

Los datos de altura LiDAR de GEDI se presentan como altitudes sobre el elipsoide WGS84, lo cual es útil en diversos contextos geodésicos y cartográficos, pero no reflejan directamente la elevación real con respecto al nivel medio del mar, lo que puede limitar su aplicación en varias situaciones prácticas.

Para evaluar de manera más precisa la elevación del dosel de los manglares en relación con el nivel del mar. Se realizó el proceso de corrección a partir la aplicación de la ecuación 12 del capítulo 2, "Muestreo aleatorio simple", con la cual se obtuvo una muestra aleatoria simple de los datos de altura de los puntos LiDAR medidos en el océano.

$$n = \frac{(6465) \cdot (0.5)^2 \cdot (1.96)^2}{(6465 - 1) \cdot (0.05)^2 + (0.5)^2 \cdot (1.96)^2}$$

$$n \approx 363$$

Posteriormente se obtuvo la media de ese conjunto de alturas resultantes del muestreo, con lo que se pudo ajustar todas las alturas para cada máscara respectiva restando la altura promedio calculada a cada altura LiDAR previo al proceso de depuración para su ingreso al

algoritmo Random Forest. El resultado de este proceso se encuentra en el Capítulo IV, sección “Resultado de la corrección de alturas respecto al nivel medio del mar”

Depuración manual de datos LiDAR

En este proceso de la metodología, se procedió a realizar una revisión de los mismos a fin de eliminar los datos atípicos que pudieron ser resultantes de errores en la medición, ruido en los datos o indicar características inusuales o extremas del terreno. Cabe mencionar que de no haber eliminado las alturas atípicas los resultados y conclusiones de la investigación pudieron haberse afectado significativamente. En este proceso se realizó una eliminación manual por medio de las herramientas del software QGIS: (1) edición y digitalización, (2) Seleccionar, (3) Eliminar.

El nombre identificador para los puntos de altura LiDAR de la máscara 1, se definió como *Alt_LiDAR_mascara1_depurado_1*, mientras que el identificador para los puntos de altura LiDAR de la máscara 2 se definió como *Alt_LiDAR_mascara2_depurado_1*.

Procesamiento de los datos

Esta parte de la metodología se enfoca en el procesamiento de los datos SAR de Sentinel-1 y datos LiDAR de GEDI recopilados. Consta de dos etapas cruciales: la validación cruzada, específicamente la definición de muestras de datos de entrenamiento y prueba a ingresar en el algoritmo de regresión Random Forest, y la ejecución de la regresión utilizando dicho algoritmo.

Definición de muestras de datos de entrenamiento y prueba

Para asegurar la fiabilidad y precisión del modelo de alturas del dosel de los manglares, se utilizó la validación cruzada como una técnica esencial. En este proceso metodológico de la investigación se trabajó con los datos ya depurados LiDAR de GEDI:

Alt_LiDAR_mascara1_depurado_1 y *Alt_LiDAR_mascara2_depurado_1*.

Mediante el uso del software QGIS, se agregó un campo denominado "Random" a la capa vectorial, donde se generaron números aleatorios en el rango de 0 a 1 para cada una de las alturas presentes en los datos. Estos números aleatorios permitieron segmentar las alturas en dos conjuntos: uno destinado al entrenamiento del modelo y otro a su posterior evaluación.

Se definieron dos grupos de datos con diferentes proporciones de entrenamiento y validación:

Grupo 1. En este grupo, el 80% de los datos se utilizó para entrenar el modelo de regresión Random Forest, y el 20% restante se reservó para evaluar el rendimiento del modelo.

Grupo 2. En este grupo, el 90% de los datos se utilizó para el entrenamiento del modelo, mientras que el 10% restante se reservó para la validación.

Ejecución de la regresión del algoritmo Random Forest

Para modelar las alturas del dosel de los manglares, se emplearon los datos previamente procesados de SAR y LiDAR, utilizando el algoritmo de regresión de Bosque Aleatorio, conocido como Random Forest (RF) en inglés.

Este algoritmo de Inteligencia Artificial fue la herramienta clave para combinar y procesar estos datos, ya que se basa en un enfoque de conjunto, donde se combinan múltiples árboles de decisión para obtener una predicción más robusta y precisa. Cada árbol de decisión se entrenó utilizando un subconjunto aleatorio de las muestras y predictores disponibles de alturas LiDAR definidos en el proceso anterior: 80% entrenamiento VS 20% validación y 90% entrenamiento VS 10% validación. El proceso de entrenamiento se realizó de manera independiente para cada árbol, y al final, se realiza una votación o promedio de las predicciones de todos los árboles para obtener la predicción final del modelo.

En el entrenamiento del modelo, se definieron dos parámetros de RF: la cantidad de árboles para construir el "bosque" (ntree) y la cantidad de predictores considerados para cada nodo en los árboles (mtry), de la siguiente manera: se eligió 25 para ntree ya que no se notó

ninguna diferencia significativa en la precisión entre 25,50,100, mientras que el parámetro `mtry` se fijó en 2, luego de probar valores entre 2 a 4 y notar que no existía diferencia significativa en la precisión, además de con esto se consiguió un mejor equilibrio entre rendimiento y costo computacional.

La ejecución del algoritmo de regresión Random Forest en GEE, se realizó implementado la función de aprendizaje automático: `ee.Regression.randomForest ()`. El resultado de este proceso se encuentra en el Capítulo IV, sección “Resultado de la ejecución de regresión del algoritmo Random Forest”.

Validación de los resultados y obtención de los resultados

Esta parte de la metodología se enfocó en tres etapas: la evaluación de la precisión de los modelos, la creación del repositorio de datos dentro de GEE y la generación del aplicativo web de visualización de resultados del modelamiento de alturas en GEE.

Evaluación de la precisión de los modelamientos

Uno de los procesos más relevantes posteriores a la ejecución del algoritmo de regresión Random Forest empleada en el paso anterior, fue el enfoque de evaluación de las precisiones de los modelos generados, en este caso se evaluó los grupos destinados a la validación, empleando la métrica RMSE, o Root Mean Square Error (Error de la Raíz Cuadrada de la Media), que permitió medir la diferencia entre los valores reales de las alturas y las predicciones de los modelo, permitiendo así la cuantificación de la magnitud promedio de los errores. Se eligió el RMSE debido a que es ampliamente utilizado en la evaluación de modelos de regresión para medir la precisión y la calidad de las predicciones.

Generación del aplicativo web de visualización de resultados en GEE

GEE es una plataforma en la nube que permite a los usuarios acceder, analizar y visualizar grandes conjuntos de datos geoespaciales de forma rápida y eficiente. Entre los

elementos de su interfaz, en la pantalla de repositorios, se puede acceder a las opciones Scripts, Docs y Assets.

Se almacenó toda la información utilizada en el modelamiento, así como los diferentes modelos de altura del dosel obtenidos, en el área de "Assets" (Recursos). Los datos de entrada incluyeron las coberturas de los mosaicos Sentinel-1 correspondientes al año 2021, tanto para las máscaras 1 como para las máscaras 2. Para la máscara 1, se almacenaron los mosaicos "Mosaico_SAR_2021_mascara_1" y "Mosaico_SAR_2021_mascara_normalizado", mientras que para la máscara 2 se guardaron los mosaicos "Mosaico_SAR_2021_mangle" y "Mosaico_SAR_2021_mangle_normalizado". Asimismo, se incorporaron las alturas LiDAR de GEDI para el entrenamiento y validación del algoritmo Random Forest (Ver Tabla 5).

Tabla 5

Datos de entrada correspondientes a las alturas LiDAR que ingresaron en el algoritmo RF

| Grupos de entrenamiento y validación | Identificador |
|---|-------------------------------|
| Alturas correspondientes a la Máscara 1 | |
| 80% entrenamiento vs 20% validación | Alt_entrenamiento_masc1_80_20 |
| | Alt_validacion_masc1_80_20 |
| 90% entrenamiento vs 10% validación | Alt_entrenamiento_masc1_90_10 |
| | Alt_validacion_masc1_90_10 |
| Alturas correspondientes a la Máscara 2 | |
| 80% entrenamiento vs 20% validación | Alt_entrenamiento_masc2_80_20 |
| | Alt_validacion_masc2_80_20 |
| 90% entrenamiento vs 10% validación | Alt_entrenamiento_masc2_90_10 |
| | Alt_validacion_masc2_90_10 |

Nota. En la tabla se observan 4 grupos de entrenamiento y 4 grupos de validación de alturas LiDAR.

En relación a los modelos de altura del dosel obtenidos para la zona de estudio, también se almacenaron en el área de recursos los dos conjuntos de resultados correspondientes a las máscaras 1 y 2. Para la máscara 1, se obtuvieron los modelos "Mod_Alturas_Mascara_1" y "Mod_Alturas_Mascara_1_Normalizado". Mientras que, para la máscara 2, se generaron los modelos "Mod_Alturas_Mascara_2" y "Mod_Alturas_Mascara_2_Normalizado".

Es importante destacar que cada uno de estos archivos almacenados tenía habilitada la visualización para que todos los usuarios pudieran acceder y verlos al momento de ser publicados en el geovisor. Asegurando así que los resultados del modelamiento de alturas del dosel de los manglares fueran accesibles y compartidos de forma transparente con la comunidad de usuarios interesada en el tema.

Para la generación del aplicativo web, se importaron a la ventana de scripts, los archivos almacenados en la carpeta "Assets" (Recursos), ya que a más de crear un geovisor en el que se visualizara los resultados se buscaba mostrar los datos con los que se generaron los modelos.

Como segundo paso se estableció el mapa base, en el cual se habilitó el acceso a diversas funcionalidades, como el botón para visualizar en pantalla completa, la opción de desactivar capas, los controles de navegación zoom y pan para explorar el mapa, así como la opción para cambiar el mapa base de referencia. Para esto se empleó la función "ui.Map()".

En el tercer paso, se diseñó el panel de representación de las capas a visualizar, conocido como administrador de capas. Para esto se crearon los niveles que vinculan los títulos y las instrucciones mediante el uso de la función "ui.Label". Luego se implementaron selectores que permitieron elegir la capa que se deseaba visualizar en el mapa, estos selectores se obtuvieron mediante el uso de la función "ui.Select", proporcionando una forma sencilla de cambiar entre diferentes capas de datos. También se incorporaron botones para que mostraran los resultados deseados. Cada botón se asoció con una función específica que permitió la

visualización de los archivos seleccionados en el mapa base. Estos se crearon utilizando el comando "ui.Button".

Para unir los niveles, selectores y botones en una única estructura coherente, se empleó la función "ui.Panel". En la Figura 16, se presenta una parte del panel de capas elaborado para presentar los datos de entrada y resultados del proyecto.

Figura 16

Representación del boceto de una parte del panel de capas del geovisor del proyecto

PANEL DE CAPAS

DATOS DE ENTRADA AL ALGORITMO RF

MOSAICOS SAR SENTINEL1 (dB) 2021

MOSAICO_SAR_M1

Mostrar Descargar

Escoja un mosaico y presione mostrar o descargar

ALTURAS LiDAR GEDI (m) 2021

MASCARA 1

80 % Entrenamiento vs 20% Validación

Alturas_entrenamiento_M1 (80%)

Mostrar Descargar

Escoja una cobertura y presione mostrar o descargar

Nota. En la figura se visualiza parte del panel de capas del aplicativo web creado en GEE.

Para la publicación del geovisor, como una aplicación dentro del entorno de GEE, se siguieron los siguientes pasos:

- En el editor de códigos, se seleccionó el botón "Apps" con el fin de acceder al Administrador de Aplicaciones de GEE.
- Una vez en el Administrador de Aplicaciones, se seleccionó la opción de "New" o "Crear" para crear una nueva aplicación web.

- En la página de creación de aplicaciones, se configuraron los detalles de la aplicación tales como el nombre y descripción. El nombre definido fue: para este estudio fue “*Geovisor_Tesis_Asimbaya_Katty*”.
- Se estableció el código fuente obtenido del repositorio de datos.
- Después de configurada la aplicación, se seleccionó "Save" o "Guardar" para guardar los cambios y crear la aplicación.
- Posteriormente se dio clic en "Publish" o "Publicar" para hacer que la aplicación estuviese disponible para otros usuarios.
- Después de publicar la aplicación, se obtuvo un enlace único con el cuál otros usuarios podrán visualizar el aplicativo.

Generación de la guía para la gestión ambiental de los bosques de manglar ubicados en la cuenca hidrográfica del Río Pagua en base a los resultados obtenidos del aplicativo web.

En base a los resultados obtenidos, la guía para la gestión ambiental de los bosques de manglar de la Cuenca del Río Pagua, se presenta en el Anexo 1.

Capítulo IV: Resultados

En este capítulo se detallan los resultados obtenidos de las fases metodológicas de la investigación. Partiendo de las fases de preprocesamiento y procesamiento se presentan los datos resultantes de LiDAR provenientes de GEDI y los datos SAR de Sentinel-1, que se constituyeron como pilares fundamentales en el proceso de regresión. Así mismo, se plasman, los modelos de alturas del dosel de los manglares generados a partir de los conjuntos de entrada diseñados. Se analizaron los resultados en la etapa de validación, en donde se llevó a cabo una comparativa de los ocho modelos generados con el fin de identificar cuál de ellos ofreció un mejor rendimiento en términos de precisión y generalización. Concluyendo este capítulo, se presentan los resultados obtenidos a través de un aplicativo web de fácil acceso para el público en general.

Resultados de los códigos fuentes utilizados en el presente proyecto

Los códigos fuentes elaborados en la plataforma GEE, se encuentran completamente asequible a cualquier usuario mediante los siguientes links:

- Link para la acceder al código de obtención de los datos:

[kvasimbaya/obtención_y_preprocesamiento_de_datos](#)

- Link para acceder al código de las fases de procesamiento y validación:

[kvasimbaya/procesamiento_y_validación_de_datos](#)

- Link para acceder al código con el que fue elaborado el geovisor de resultados:

[kvasimbaya/geovisor_resultados](#)

Resultados de la recopilación y filtrado de datos SAR de la misión Sentinel-1

Del proceso de recopilación y filtrado de datos SAR de la misión Sentinel-1 se obtuvieron un total de 17 imágenes Sentinel-1, las cuales se indican en la Tabla 6.

Tabla 6*Imágenes SAR recopiladas para el proyecto*

| Id | Id en GEE | Fecha de la toma |
|-----------|---|-------------------------|
| 1 | COPERNICUS/S1_GRD/S1B_IW_GRDH_1SDV_20210510T110110_20210510T110135_026841_0334DC_37F4 | 2021-05-10 |
| 2 | COPERNICUS/S1_GRD/S1B_IW_GRDH_1SDV_20210522T110111_20210522T110136_027016_033A47_9D0A | 2021-05-22 |
| 3 | COPERNICUS/S1_GRD/S1B_IW_GRDH_1SDV_20210615T110112_20210615T110137_027366_0344BA_646F | 2021-06-15 |
| 4 | COPERNICUS/S1_GRD/S1B_IW_GRDH_1SDV_20210627T110113_20210627T110138_027541_0349A4_CB5F | 2021-06-27 |
| 5 | COPERNICUS/S1_GRD/S1B_IW_GRDH_1SDV_20210709T110113_20210709T110138_027716_034EC1_91BF | 2021-07-09 |
| 6 | COPERNICUS/S1_GRD/S1B_IW_GRDH_1SDV_20210721T110114_20210721T110139_027891_0353FC_6A17 | 2021-07-21 |
| 7 | COPERNICUS/S1_GRD/S1B_IW_GRDH_1SDV_20210802T110115_20210802T110140_028066_035919_700F | 2021-08-02 |
| 8 | COPERNICUS/S1_GRD/S1B_IW_GRDH_1SDV_20210814T110115_20210814T110140_028241_035E83_36A4 | 2021-08-14 |
| 9 | COPERNICUS/S1_GRD/S1B_IW_GRDH_1SDV_20210826T110116_20210826T110141_028416_0363F6_989F | 2021-08-26 |
| 10 | COPERNICUS/S1_GRD/S1B_IW_GRDH_1SDV_20210907T110117_20210907T110142_028591_036978_2A6B | 2021-09-07 |

| Id | Id en GEE | Fecha de la toma |
|-----------|---|-------------------------|
| 11 | COPERNICUS/S1_GRD/S1B_IW_GRDH_1SDV_20210919T110117_20210919T110142_028766_036ED6_2622 | 2021-09-19 |
| 12 | COPERNICUS/S1_GRD/S1B_IW_GRDH_1SDV_20211003T110117_20211013T110142_029116_037972_84FC | 2021-10-13 |
| 13 | COPERNICUS/S1_GRD/S1B_IW_GRDH_1SDV_20211025T110118_20211025T110143_029291_037EDF_9110 | 2021-10-25 |
| 14 | COPERNICUS/S1_GRD/S1B_IW_GRDH_1SDV_20211106T110117_20211106T110142_029466_038435_9951 | 2021-11-06 |
| 15 | COPERNICUS/S1_GRD/S1B_IW_GRDH_1SDV_20211118T110117_20211118T110142_029641_038997_976F | 2021-11-18 |
| 16 | COPERNICUS/S1_GRD/S1B_IW_GRDH_1SDV_20211130T110117_20211130T110142_029816_038F1C_1546 | 2021-11-30 |
| 17 | COPERNICUS/S1_GRD/S1B_IW_GRDH_1SDV_20211212T110116_20211212T110141_029991_03949E_1E40 | 2021-12-12 |

Nota. En la tabla se indican el identificador y la fecha de adquisición de las imágenes.

Resultados de la recopilación y filtrado de datos LiDAR de GEDI

Del proceso de filtrado de datos LiDAR, se obtuvieron un total de 12 imágenes rásteres correspondientes a cada uno de los meses del año 2021, las cuales se indican en la Tabla 7.

Tabla 7

Imágenes LiDAR recopiladas para el proyecto

| Id | Id en GEE | Fecha de la toma |
|-----------|--|-------------------------|
| 1 | LARSE/GEDI/GEDI02_A_002_MONTHLY/202101_084W_006S | 2021-01 |
| 2 | LARSE/GEDI/GEDI02_A_002_MONTHLY/202102_084W_006S | 2021-02 |

| Id | Id en GEE | Fecha de la toma |
|----|--|------------------|
| 3 | LARSE/GEDI/GEDI02_A_002_MONTHLY/202103_084W_006S | 2021-03 |
| 4 | LARSE/GEDI/GEDI02_A_002_MONTHLY/202104_084W_006S | 2021-04 |
| 5 | LARSE/GEDI/GEDI02_A_002_MONTHLY/202105_084W_006S | 2021-05 |
| 6 | LARSE/GEDI/GEDI02_A_002_MONTHLY/202106_084W_006S | 2021-06 |
| 7 | LARSE/GEDI/GEDI02_A_002_MONTHLY/202107_084W_006S | 2021-07 |
| 8 | LARSE/GEDI/GEDI02_A_002_MONTHLY/202108_084W_006S | 2021-08 |
| 9 | LARSE/GEDI/GEDI02_A_002_MONTHLY/202109_084W_006S | 2021-09 |
| 10 | LARSE/GEDI/GEDI02_A_002_MONTHLY/202110_084W_006S | 2021-10 |
| 11 | LARSE/GEDI/GEDI02_A_002_MONTHLY/202111_084W_006S | 2021-11 |
| 12 | LARSE/GEDI/GEDI02_A_002_MONTHLY/202112_084W_006S | 2021-12 |

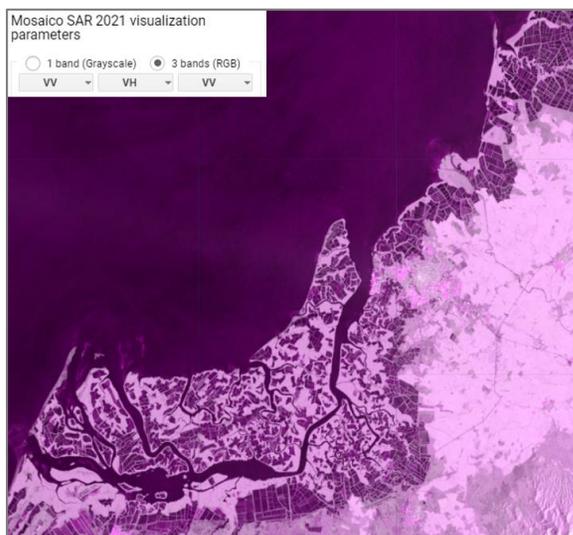
Nota. En la tabla se indican el identificador y la fecha de adquisición de las imágenes.

Resultados de la generación del mosaico Sentinel-1 para el año 2021

En la Figura 17 se visualiza el Mosaico Sentinel-1 2021, generado a partir de las imágenes recopiladas en la Tabla 6 “Imágenes SAR recopiladas para el proyecto”

Figura 17

Mosaico de Imágenes Sentinel-1

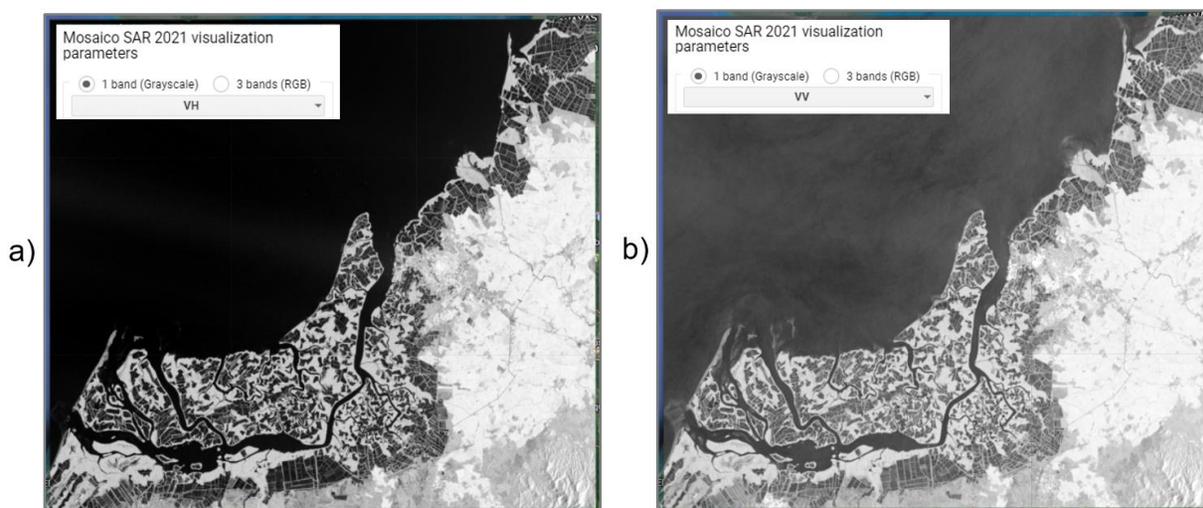


Nota. El mosaico SAR 2021, se visualiza en falso color en donde al canal rojo se le asignó la banda de polarización VV, al canal verde la banda VH y al canal azul, la banda VV. Este resultado se obtuvo en la plataforma de computación en la nube GEE.

El mosaico al estar compuesto por las bandas de polarización VV (polarización vertical-vertical) y VH (polarización vertical-horizontal), permitió obtener una visión más completa y detallada de la zona de estudio. En la Figura 18, se observa por separado las dos bandas de polarización VV y VH que conforman el Mosaico Sentinel-1 2021. Se puede observar como el agua del océano, los estuarios, así como las granjas acuáticas se presentan con intensidades más oscuras en ambas bandas debido a que el agua tiende a reflejar la energía del radar lejos del sensor, lo que significa que la retrodispersión es baja. Por otro lado, la vegetación incluyéndose los manglares, presenta una retrodispersión moderada ya que estos tienen una estructura compleja con árboles altos, raíces y vegetación densa. Las superficies urbanas se presentan con intensidades más brillantes ya que generan altas retrodispersiones de la energía del radar.

Figura 18

Bandas de polarización que conforman el Mosaico Sentinel-1 2021



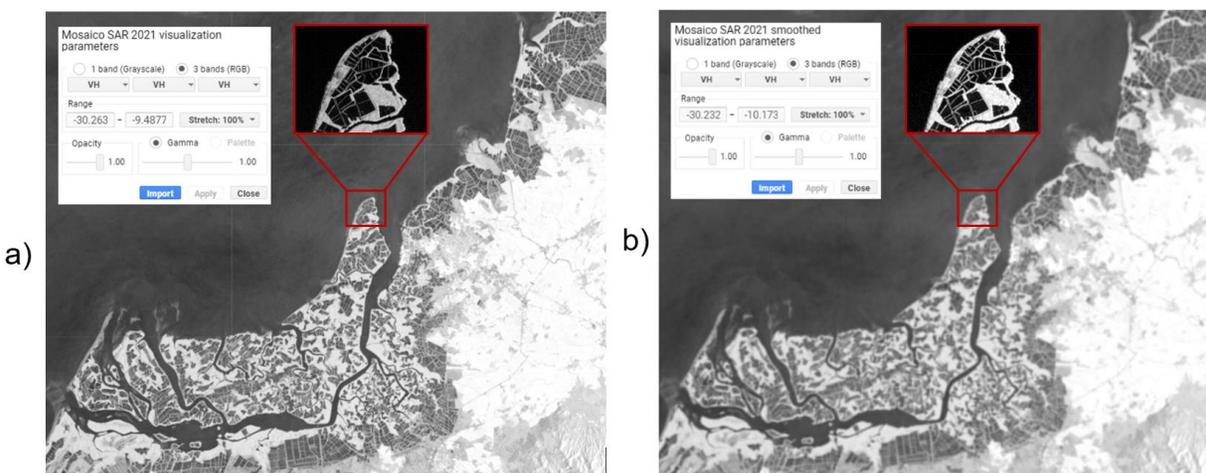
Nota. En a) se observa la banda de polarización Vertical-Horizontal mientras que en b) se observa la banda de polarización Vertical-Vertical. Los resultados se obtuvieron a través de la plataforma de computación en la nube GEE.

Resultados de la eliminación de “speckle” en el mosaico de datos SAR Sentinel-1

Dado que corregir el moteado en las imágenes SAR era esencial para mejorar la calidad de los datos. Se aplicó un filtro de media focal definido a partir de una ventana de filtrado o Kernel con un radio de 1 píxel. El mosaico generado a partir de este proceso se presenta en la Figura 19, mismo que fue denominado como Mosaico SAR_2021_smoothed. Este proceso permitió obtener una imagen más suavizada y libre de moteado, lo que facilitó realizar un análisis más preciso y detallado de diferentes características geográficas presentes en el área de estudio.

Figura 19

Representación del Mosaico SAR 2021 después de la eliminación de moteado



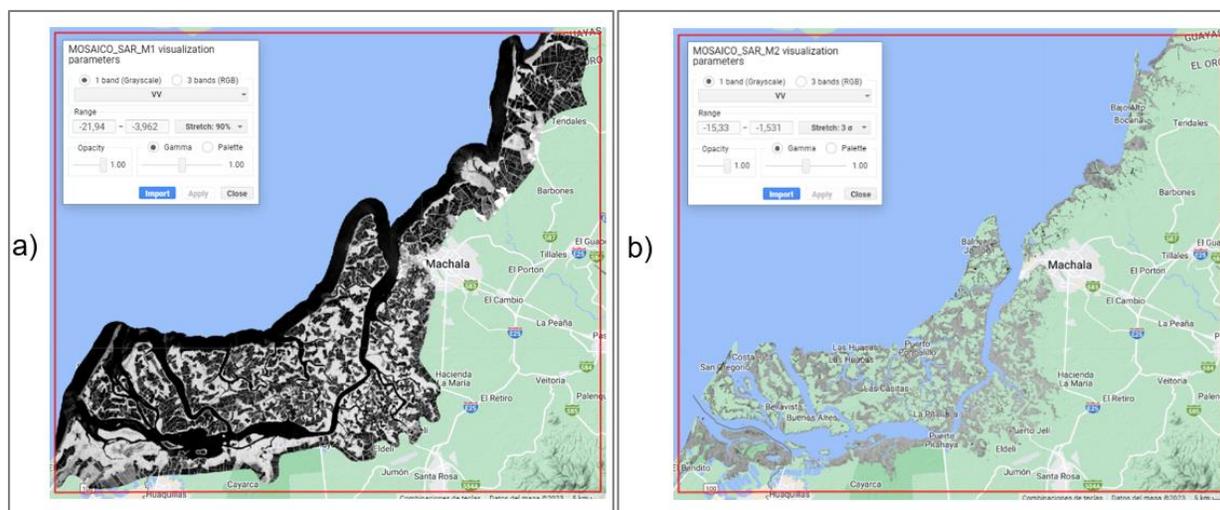
Nota. En a) se visualiza el Mosaico SAR 2021 mismo que no presenta corrección de moteado, por otro lado, en b) se observa el Mosaico SAR 2021 posterior a la corrección del moteado. Los productos se obtuvieron en la plataforma de computación en la nube GEE.

Resultados de la definición de máscaras para Mosaico Sentinel 1 2021

Posterior a la corrección del moteado en el mosaico Sentinel-1 para el año 2021, se generaron las dos máscaras específicas, las cuales se visualizan en la Figura 20. Como se mencionó anteriormente la "Máscara 1", abarcó la extensión de manglares obtenidos del Global Mangrove Watch (GMW) y así como el área circundante, mientras que la "Máscara 2", se restringió únicamente a los polígonos de los manglares, sin incluir el área adyacente. El incluir este proceso de análisis como se presentará más adelante permitió mostrar que la precisión del modelo de predicción de la altura del dosel de los manglares dependía en parte a la selección de la máscara utilizada.

Figura 20

Máscaras definidas para el Mosaico Sentinel-1



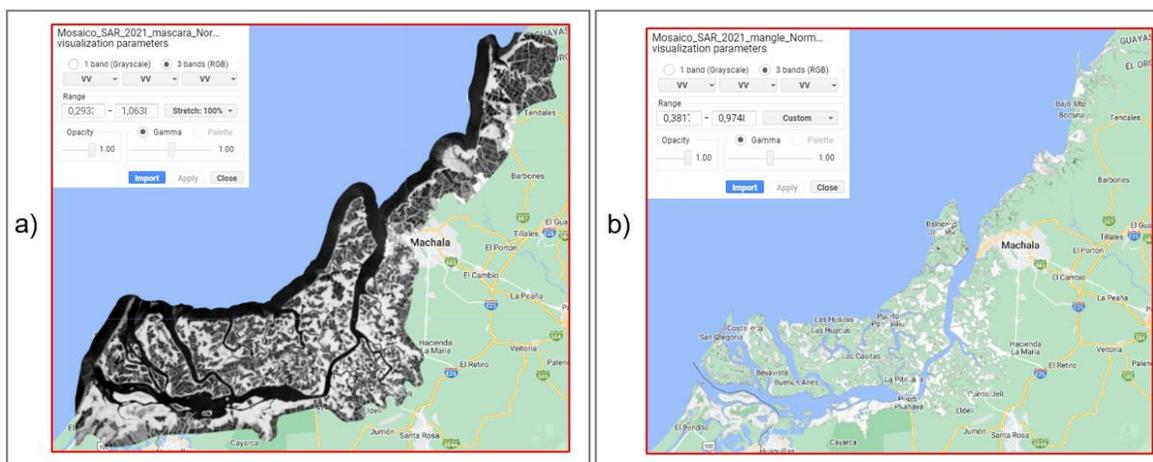
Nota. En a) se presenta el corte del Mosaico SAR_2021_smoothed con la "Máscara 1", mientras que en b) se presenta el corte con la "Máscara 2".

Resultados de la normalización de los datos SAR Sentinel-1

En la Figura 21, se visualizan las máscaras Mosaico_SAR_2021_mascara_normalizado y Mosaico_SAR_2021_mangle_normalizado. La normalización aseguró que todas las características (retrodispersión) tengan la misma escala o rango.

Figura 21

Mosaico Sentinel-1 corregido de moteado, normalizados



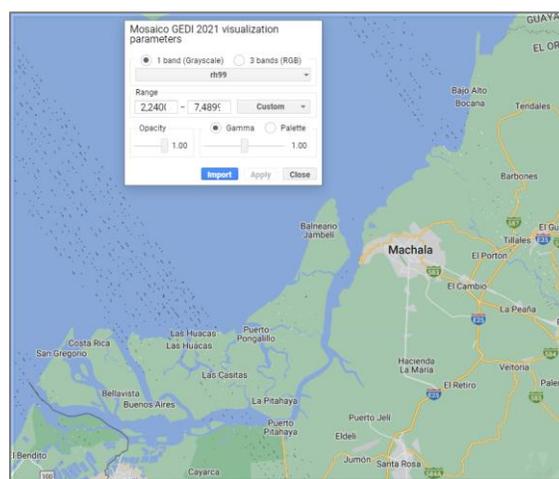
Nota. En a) se presenta el MOSAICO_SAR_M1 normalizado, mientras que en b) se presenta el MOSAICO_SAR_M2 normalizado.

Resultados de la generación del mosaico de datos LiDAR GEDI para el año 2021

Como resultado de este proceso, en la Figura 22 se visualiza el mosaico de datos LiDAR GEDI para el año 2021, generado a partir de las 12 imágenes ráster correspondientes a cada uno de los meses del año 2021.

Figura 22

Mosaico LiDAR de GEDI 2021 obtenido en GEE

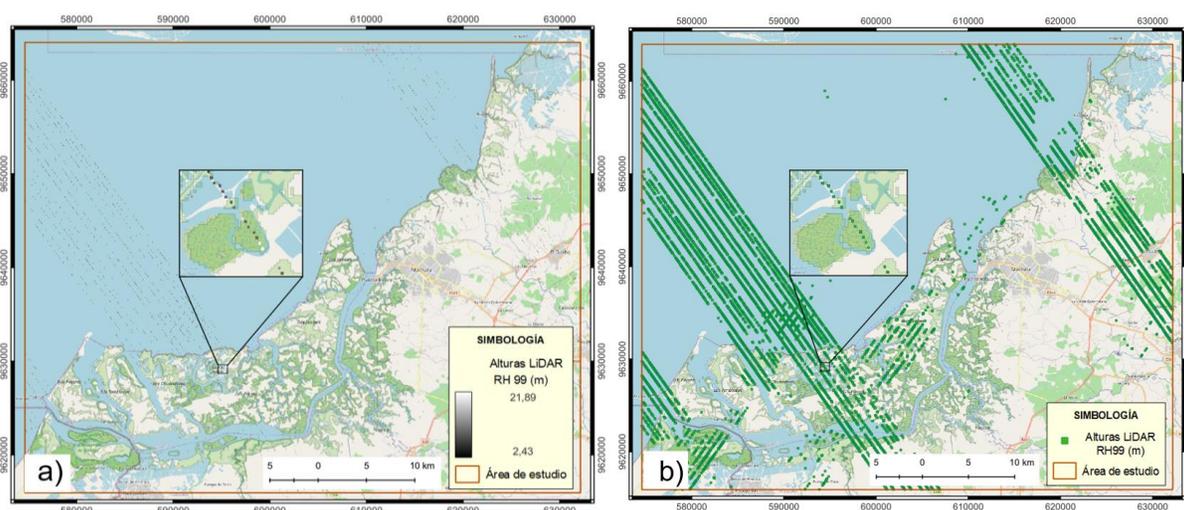


Nota. Este resultado se obtuvo desde la plataforma de computación en la nube GEE.

Con la finalidad de tener un manejo más detallado y específico de los datos LiDAR, se procedió a transformar el mosaico LiDAR de GEDI 2021 a un archivo vectorial. En la Figura 23 se observa el resultado de la transformación del raster al vector, en donde cada centroide de las celdas del mosaico contiene la información acerca de la ubicación precisa y así como las alturas LiDAR en metros.

Figura 23

Transformación del mosaico LiDAR GEDI 2021 a cobertura vectorial



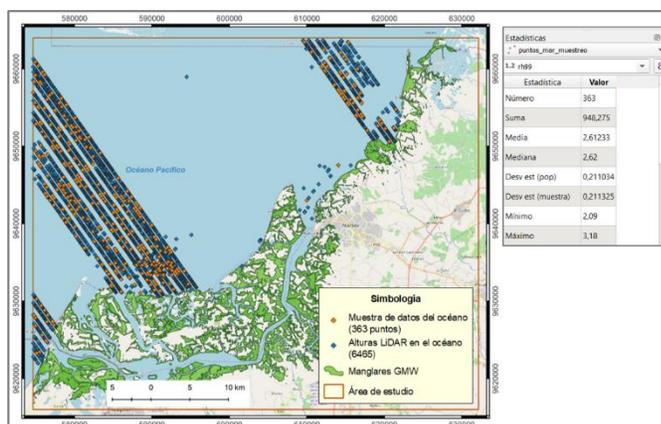
Nota. En a) se observa el mosaico LiDAR GEDI 2021 en formato TIFF, en b) se observa una capa vector de las alturas LiDAR GEDI, correspondiente a los puntos centroides de las celdas de la capa raster del mosaico original.

Resultado de la corrección de alturas respecto al nivel medio del mar

Del muestreo aleatorio simple se determinó un total de 363 puntos LiDAR, con los cuales se calculó una altura promedio de 2,61233 metros (Figura 24). Posteriormente en QGIS, haciendo uso de la calculadora de campo se procedió a restar esta altura promedio a cada una de las alturas LiDAR logrando de esta manera que fueran corregidas con respecto al nivel medio del mar (Figura 25).

Figura 24

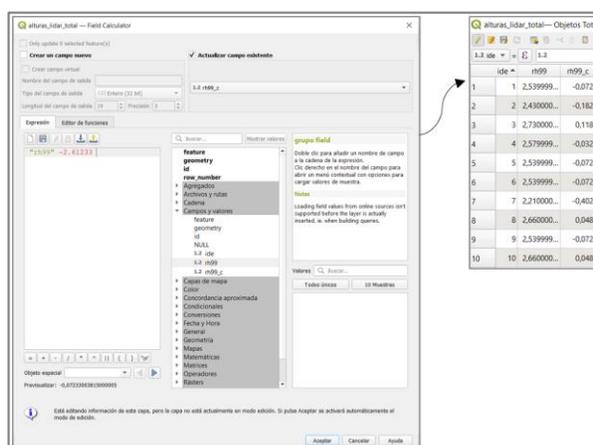
Representación de los puntos LiDAR ubicados en el océano



Nota. En la figura se observa lo datos empleados para el muestreo aleatorio simple de datos LiDAR.

Figura 25

Corrección de las alturas LiDAR respecto al nivel empleando la calculadora de campos del Software QGIS



Nota. En la figura se indica la calculadora de campos en el software QGIS, en donde se aplicó la corrección respecto al nivel medio del mar.

Resultado de la depuración de datos LiDAR

El proceso de depuración de datos LiDAR realizado antes de ingresar al algoritmo Random Forest fue esencial para garantizar la calidad y confiabilidad de los datos utilizados en

el análisis. A través de este proceso, se revisaron y eliminaron los datos atípicos que podrían haber resultado de errores de medición, ruido en los datos o características inusuales o extremas del terreno. En la Figura 26, se muestra las alturas LiDAR depuradas para la Máscara 1. La cobertura resultante contenía 2326 puntos de datos de las alturas en metros que posteriormente fueron empleados en la definición de muestras de datos de entrenamiento y prueba a ingresar en el algoritmo de regresión Random Forest.

Figura 26

Alturas LiDAR depuradas para la Máscara 1



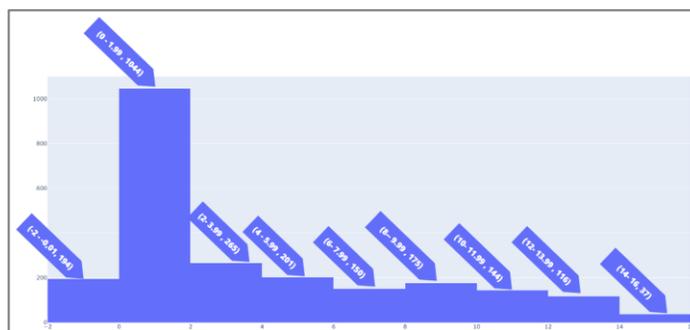
Nota. En la figura se indica las alturas LiDAR en metros que se ubican sobre los manglares, océano, estero y otras coberturas adyacentes.

Adicionalmente en la Figura 27, se visualiza un histograma de datos vectoriales generados en el software QGIS. En este se observan con más detalle la distribución de alturas indicándose el número de puntos contenidos en cierto rango de altura. Se puede analizar que para la Máscara 1, el 8.34% de los datos de altura se encuentran en un rango de -2 a -0.01 metros, el 44.88% en un rango de 0 a 1.99 metros, el 11.39% en un rango de 2.00 a 3.99 metros, el 8.64% en un rango de 4.00 a 5.99 metros, el 6.44% en un rango de 6.00 a 7.99

metros, el 7.52% en un rango de 8.00 a 9.99 metros y el 12.75% a alturas entre un rango de 10 a 15 metros.

Figura 27

Histograma de la distribución de alturas LiDAR definidas para la Máscara 1

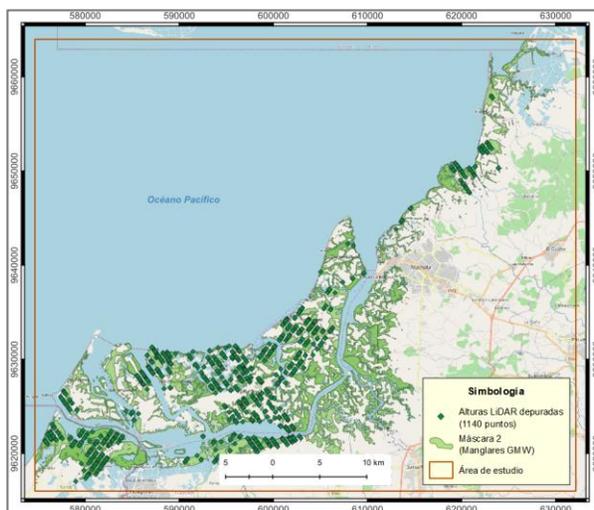


Nota. Obtenido por medio de la herramienta de gráficos del software QGIS.

En la Figura 28, se muestra las alturas LiDAR depuradas para la Máscara 2. La cobertura resultante contenía 1140 puntos con datos de la altura en metros que posteriormente fueron empleados en la definición de muestras de datos de entrenamiento y prueba a ingresar en el algoritmo de regresión Random Forest.

Figura 28

Alturas LiDAR depuradas para la Máscara 2

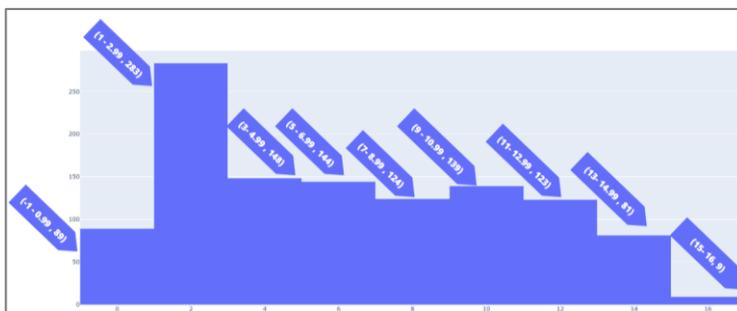


Nota. En la figura se indica las alturas LiDAR en metros que se ubican únicamente sobre la cobertura de manglar.

En la Figura 29, se visualiza un histograma de datos vectoriales en donde se detalla la distribución de alturas presentándose también el número de puntos contenidos en cierto rango de altura. Se puede analizar que para la Máscara 2, el 7.80% de los datos de altura se encuentran en un rango de -1 a 0.99 metros, el 24.82% en un rango de 1 a 2.99 metros, el 12.99% en un rango de 3.00 a 4.99 metros, el 12.63% en un rango de 5.00 a 6.99 metros, el 10.88% en un rango de 7.00 a 8.99 metros, el 12.19% en un rango de 9.00 a 10.99 metros y el 18.68% correspondía a alturas en un rango de 11 a 15 metros.

Figura 29

Histograma de la distribución de alturas LiDAR definidas para la Máscara 2



Nota. Obtenido por medio de la herramienta de gráficos del software QGIS.

Resultados de la definición de muestras de datos de entrenamiento y prueba

Dado que se implementó la técnica de validación cruzada para garantizar la confiabilidad y precisión del modelo de alturas del dosel de los manglares, partiendo de los conjuntos de datos ya depurados de LiDAR: "Alt_LiDAR_mascara1_depurado_1" y "Alt_LiDAR_mascara2_depurado_1". Se obtuvieron como resultados cuatro grupos de datos, dos grupos correspondieron a la Máscara 1 mientras que los dos restantes correspondían a la Máscara 2. En la Tabla 8 se puede observar los grupos de entrenamiento y validación definidos para la Máscara 1.

Tabla 8

Grupos de entrenamiento y validación de alturas LiDAR correspondientes a la Máscara 1

| Nombre | Grupos de entrenamiento y validación | Identificador | Cantidad de huellas |
|---------|--------------------------------------|-------------------------------|---------------------|
| Grupo A | 80% entrenamiento vs | Alt_entrenamiento_masc1_80_20 | 1854 |
| | 20% validación | Alt_validacion_masc1_80_20 | 472 |
| Grupo B | 90% entrenamiento vs | Alt_entrenamiento_masc1_90_10 | 2087 |
| | 10% validación | Alt_validacion_masc1_90_10 | 239 |

Nota. En la tabla se indica la cantidad de puntos LiDAR definidos para cada grupo a entrenar y validar en el algoritmo RF con la Máscara 1.

En la Figura 30, se visualiza el Grupo A, que corresponde al conjunto inicial de datos LiDAR empleado tanto para el entrenamiento y prueba dentro del algoritmo RF. Este grupo se compuso por 1854 puntos para entrenamiento y por 472 puntos para la validación.

Figura 30

Representación de los puntos de entrenamiento y validación (80 VS 20) para la Máscara 1



En la Figura 31, se representa el Grupo B, que corresponde al segundo conjunto de datos LiDAR empleado tanto para el entrenamiento como para la prueba dentro del algoritmo

de regresión RF para la Máscara 1. Este grupo se compuso por 2087 puntos para entrenamiento y por 239 puntos para la validación.

Figura 31

Representación de los puntos de entrenamiento y validación (90 VS 10) para la Máscara 1



En la Tabla 9 se visualizan los grupos de entrenamiento y validación definidos para la Máscara 2.

Tabla 9

Grupos de entrenamiento y validación de alturas LiDAR correspondientes a la Máscara 2

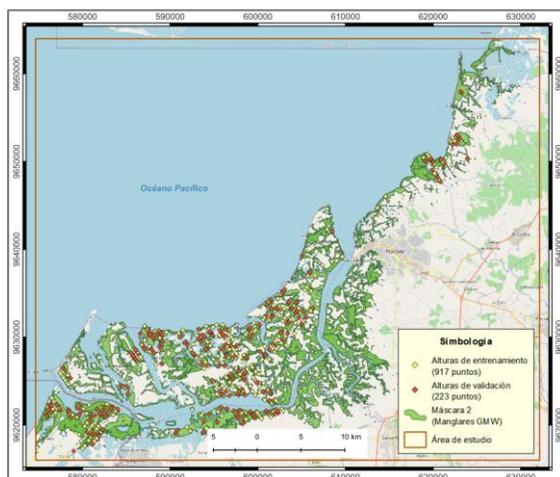
| Nombre | Grupos de entrenamiento y validación | Identificador | Cantidad de huellas |
|---|--------------------------------------|-------------------------------|---------------------|
| Alturas correspondientes a la Máscara 2 | | | |
| Grupo C | 80% entrenamiento vs | Alt_entrenamiento_masc2_80_20 | 917 |
| | 20% validación | Alt_validacion_masc2_80_20 | 223 |
| Grupo D | 90% entrenamiento vs | Alt_entrenamiento_masc2_90_10 | 1034 |
| | 10% validación | Alt_validacion_masc2_90_10 | 106 |

En la Figura 32, se visualiza el Grupo C, que corresponde al primer conjunto de datos LiDAR empleado tanto para el entrenamiento como para la prueba dentro del algoritmo de

regresión RF, para la Máscara 2. Este grupo se compuso por 917 puntos para entrenamiento y por 223 puntos para la validación.

Figura 32

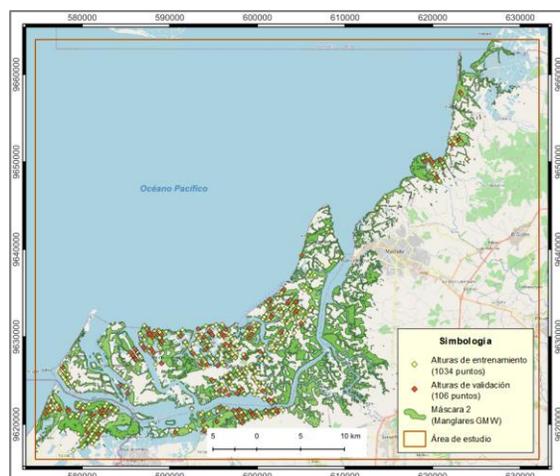
Representación de los puntos de entrenamiento y validación (80 VS 20) para la Máscara 2



Por otro lado, en la Figura 33, se visualiza el Grupo D. Este grupo se compuso por 1034 puntos para entrenamiento y por 106 puntos para la validación.

Figura 33

Representación de los puntos de entrenamiento y validación (90 VS 10) para la Máscara 2



Resultados de la ejecución de regresión del algoritmo de regresión Random Forest

En este apartado se presentan los resultados correspondientes a las predicciones de las alturas del dosel de los manglares generadas por los modelos de Inteligencia Artificial Random Forest. En la Tabla 10 se describen los cuatro modelos generados a partir de la Máscara 1.

Tabla 10

Descripción de los modelos de altura del dosel generados a partir de la Máscara 1

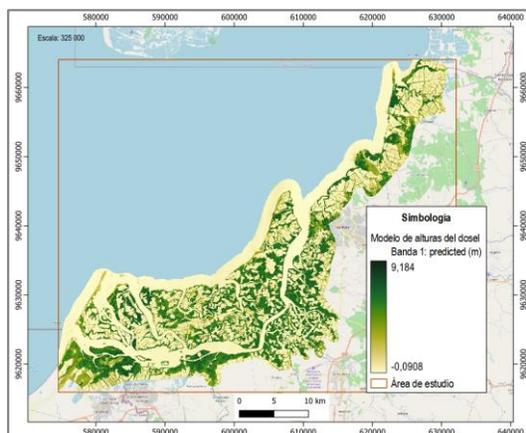
| Máscara empleada | Id | Datos de entrada |
|------------------|----------|--|
| MÁSCARA 1 | MODELO 1 | Grupo A de alturas LiDAR (80% entrenamiento vs 20% validación) y MOSAICO_SAR_M1 |
| | MODELO 2 | Grupo B de alturas LiDAR (90% entrenamiento vs 10% validación) y MOSAICO_SAR_M1 |
| | MODELO 3 | Grupo A de alturas LiDAR (80% entrenamiento vs 20% validación) y MOSAICO_SAR_M1_NORMALIZADO |
| | MODELO 4 | Grupo B de alturas LiDAR (90% entrenamiento vs 10% validación) y MOSAICO_SAR_M1_NORMALIZADO |

Nota. En la tabla se observa los datos de entradas SAR y LiDAR que ingresaron en el algoritmo de regresión RF en GEE, para generar los modelos derivados de la máscara 1.

En la Figura 34, se visualiza el primer modelo de predicción de las alturas del dosel de los manglares para la provincia de El Oro. Para el modelo se emplearon como datos de entrada las alturas del Grupo A y el Mosaico de datos de retrodispersión de Sentinel-1 sin normalizar.

Figura 34

Modelo 1 de las alturas del dosel de los manglares para la provincia de El Oro 2021

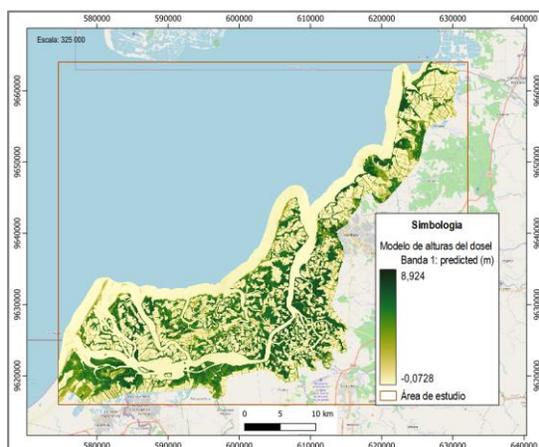


Nota. Se observa que en el modelo la altura mínima es de -0.09 metros y la altura máxima es de 9.184 metros.

En la Figura 35, se visualiza el Modelo 2 de predicción de las alturas del dosel de los manglares. Para dicho modelo se emplearon como datos de entrada las alturas del Grupo B y el Mosaico de datos de retrodispersión de Sentinel-1 sin normalizar.

Figura 35

Modelo 2 de las alturas del dosel de los manglares para la provincia de El Oro 2021

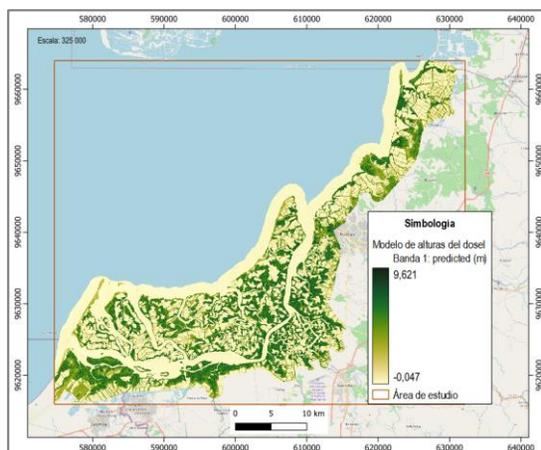


Nota. Se observa que en el modelo la altura mínima es de -0.07 metros y la altura máxima es de 8.92 metros.

En la Figura 36, se visualiza el Modelo 3. Se emplearon como datos de entrada las alturas del Grupo A y el Mosaico de datos de retrodispersión de Sentinel-1 normalizado.

Figura 36

Modelo 3 de las alturas del dosel de los manglares para la provincia de El Oro 2021

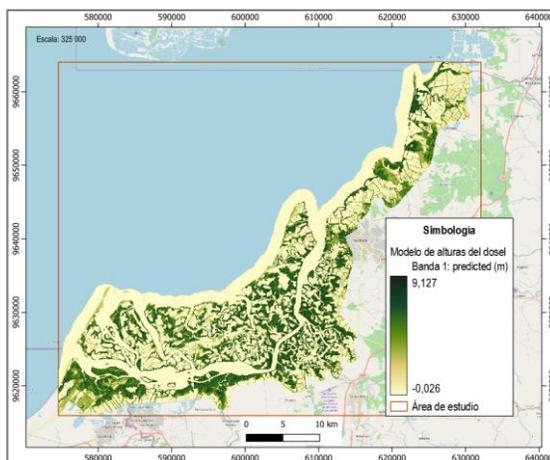


Nota. Se observa que en el modelo la altura mínima es de -0.04 metros y la altura máxima es de 9.62 metros.

En la Figura 37, se visualiza el Modelo 4. Se emplearon como datos de entrada las alturas del Grupo B y el Mosaico de datos de retrodispersión de Sentinel-1 normalizado.

Figura 37

Modelo 4 de las alturas del dosel de los manglares para la provincia de El Oro 2021



Nota. Se observa que en el modelo la altura mínima es de -0.026 metros y la altura máxima es de 9.127 metros.

En la Tabla 11 se describen los cuatro modelos generados a partir de la Máscara 2, la cual se definió con el objetivo de analizar el rendimiento de los modelos y cuales tendrían un menor error en su precisión. Al igual que con las alturas que se intersecaban con la máscara 1, las alturas que se estaban contenidas en la máscara 2, fueron divididas en dos grupos de entrenamiento.

Tabla 11

Descripción de los modelos de altura del dosel generados a partir de la Máscara 2

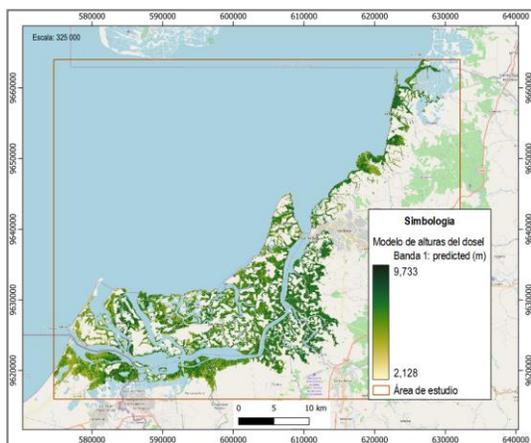
| Máscara empleada | Id | Datos de entrada |
|-----------------------------|-------------|---|
| MÁSCARA 2 | MODELO 5 | Grupo C de alturas LiDAR (80% entrenamiento vs 20% validación) y MOSAICO_SAR_M2 |
| | MODELO 6 | Grupo D de alturas LiDAR (90% entrenamiento vs 10% validación) y MOSAICO_SAR_M2 |
| | MODELO 7 | Grupo C de alturas LiDAR (80% entrenamiento vs 20% validación) y MOSAICO_SAR_M2_NORMALIZADO |
| | MODELO 8 | Grupo D de alturas LiDAR (90% entrenamiento vs 10% validación) y MOSAICO_SAR_M2_NORMALIZADO |

Nota. En la tabla se observa los datos de entradas SAR y LiDAR que ingresaron en el algoritmo de regresión RF en GEE, para generar los modelos derivados de la máscara 2.

En la Figura 38, se visualiza el Modelo 5. Se emplearon como datos de entrada las alturas del Grupo C y el Mosaico de datos de retrodispersión de Sentinel-1 sin normalizar.

Figura 38

Modelo 5 de las alturas del dosel de los manglares para la provincia de El Oro 2021

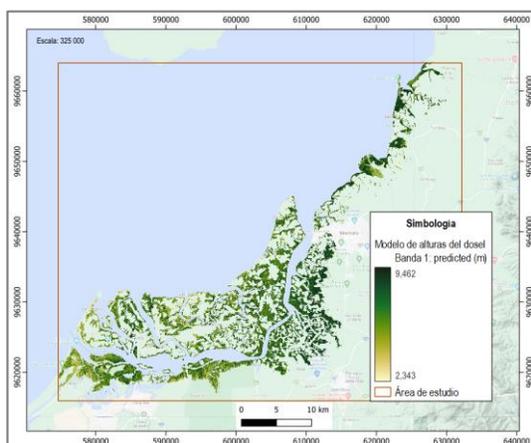


Nota. Se observa que en el modelo la altura mínima es de 2.12 metros y la altura máxima es de 9.733 metros.

En la Figura 39, se visualiza el Modelo 6 de predicción de las alturas del dosel de los manglares para la provincia de El Oro. Para dicho modelo se emplearon como datos de entrada las alturas del Grupo D y el Mosaico de datos de retrodispersión de Sentinel-1 sin normalizar.

Figura 39

Modelo 6 de las alturas del dosel de los manglares para la provincia de El Oro 2021

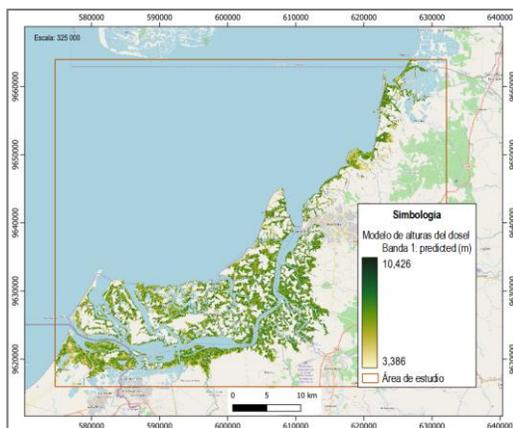


Nota. Se observa que en el modelo la altura mínima es de 2.34 metros y la altura máxima es de 9.462 metros.

En la Figura 40, se visualiza el Modelo 7 de predicción de las alturas del dosel de los manglares para la provincia de El Oro. Para dicho modelo se emplearon como datos de entrada las alturas del Grupo C y el Mosaico de datos de retrodispersión de Sentinel-1 normalizado.

Figura 40

Modelo 7 de las alturas del dosel de los manglares para la provincia de El Oro 2021

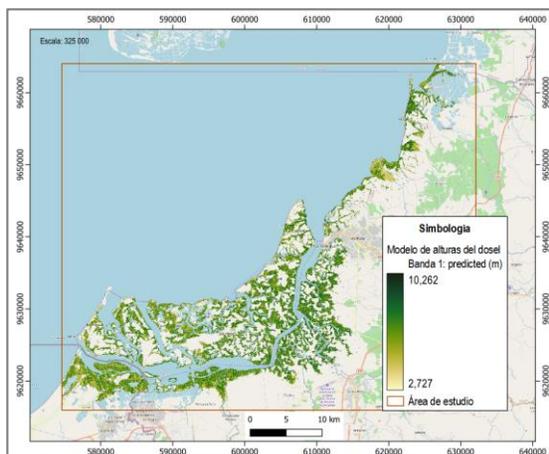


Nota. En el modelo la altura mínima fue de 3.84 metros y la altura máxima es de 10.42 metros.

En la Figura 41, se visualiza el Modelo 8 de predicción de las alturas del dosel de los manglares para la provincia de El Oro. Para dicho modelo se emplearon como datos de entrada las alturas del Grupo D y el Mosaico de datos de retrodispersión de Sentinel-1 normalizado.

Figura 41

Modelo 8 de las alturas del dosel de los manglares para la provincia de El Oro 2021



Nota. En este modelo la altura mínima fue de 2.72 metros y la altura máxima fue de 10.26 metros.

Resultados de la evaluación de la precisión de los modelos de alturas del dosel

En la Tabla 12, se visualizan los RMSE obtenidos entre las alturas de predicción y validación de los 8 modelos obtenidos.

Tabla 12

Resultados de RMSE obtenidos para los modelos de alturas del dosel de los manglares

| Modelo ID | Conjunto de datos | RMSE metros | Tiempo de procesamiento |
|------------------|---|--------------------|--------------------------------|
| Modelo 1 | Grupo A de alturas LiDAR (80% entrenamiento vs 20% validación) y MOSAICO_SAR_M1 Sin Normalizar | 3,003 | 13.27 segundos |
| Modelo 2 | Grupo B de alturas LiDAR (90% entrenamiento vs 10% validación) y MOSAICO_SAR_M1 Sin Normalizar | 2,863 | 12.99 segundos |
| Modelo 3 | Grupo A de alturas LiDAR (80% entrenamiento vs 20% validación) y MOSAICO_SAR_M1 Normalizado | 3,0164 | 12.05 segundos |
| Modelo 4 | Grupo B de alturas LiDAR (90% entrenamiento vs 10% validación) y MOSAICO_SAR_M1 Normalizado | 2,999 | 11.55 segundos |
| Modelo 5 | Grupo C de alturas LiDAR (80% entrenamiento vs 20% validación) y MOSAICO_SAR_M2 Sin Normalizar | 3,933 | 8.46 segundos |

| Modelo ID | Conjunto de datos | RMSE metros | Tiempo de procesamiento |
|-----------|---|-------------|-------------------------|
| Modelo 6 | Grupo D de alturas LiDAR (90% entrenamiento vs 10% validación) y MOSAICO_SAR_M2 Sin Normalizar | 3,935 | 8.39 segundos |
| Modelo 7 | Grupo C de alturas LiDAR (80% entrenamiento vs 20% validación) y MOSAICO_SAR_M2 Normalizado | 3,993 | 7.70 segundos |
| Modelo 8 | Grupo D de alturas LiDAR (90% entrenamiento vs 10% validación) y MOSAICO_SAR_M2 Normalizado | 3,974 | 8.89 segundos |

Nota. En la tabla se indican los resultados de RMSE generados para cada modelo además se indica el tiempo de procesamiento en la plataforma GEE.

Dado que un RMSE más bajo indica un mejor ajuste a los datos reales, se analiza que el Modelo 2 derivado de la Máscara 1, presentó un RMSE bajo de 2.863 metros. Por otro lado, de los modelos derivados de la Máscara 2, el Modelo 5 presentó un RMSE bajo de 3.933 metros. Comparando los mismos grupos de entrenamiento de alturas LiDAR con coberturas de datos SAR normalizados y no normalizados, se obtuvo que para los modelos generados a partir de la Máscara 1, la diferencia de RMSE respecto a los Modelo 1 y 3, fue de -0,0136 m; respecto a los Modelos 2 y 4 fue de -0,136 m. Respecto a los modelos generados a partir de la Máscara 2, la diferencia de RMSE para los Modelos 5 y 7, fue de -0,06 m; para los Modelos 6 y 8 por otro lado la diferencia fue de -0,039 m. Respecto al tiempo de ejecución ningún proceso de generación de los 8 modelos resultantes, sobrepasó los 13 segundos.

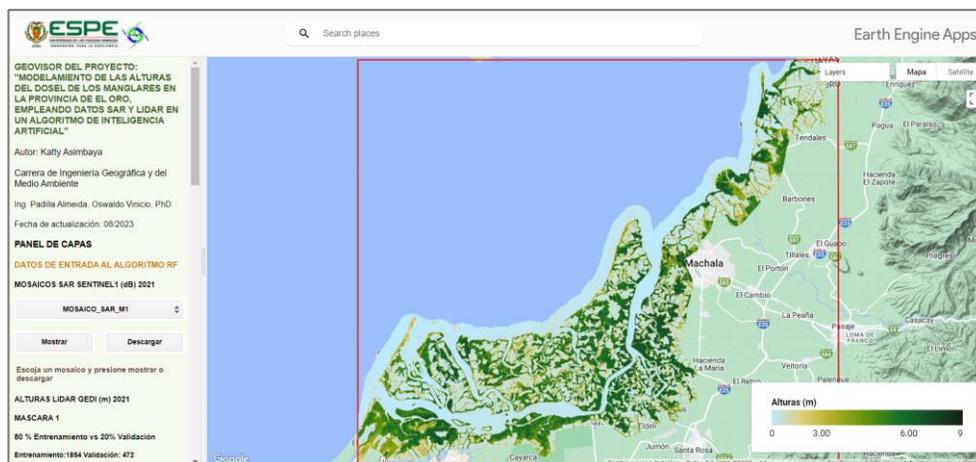
Resultados de la generación del aplicativo web de visualización de resultados en GEE

El geovisor generado mediante el aplicativo de Earth Engine Apps, presenta en su panel de capas los datos de entrada LiDAR y los datos de retrodispersión SAR que se emplearon en

el algoritmo de inteligencia artificial Random Forest. En la sección de resultados se presentan los modelos de altura del dosel de los manglares para el año 2021 de la provincia de El Oro tanto para la Máscara 1 y Máscara 2 definidas en la investigación (Ver Figura 42). Todo el contenido presentado en el geovisor está accesible, permitiendo a cualquier usuario visualizar o descargar tanto los datos iniciales como los modelos obtenidos en el estudio. El link de acceso al geovisor se lo realiza por medio del siguiente enlace: <https://tesis-kvasimbaya.projects.earthengine.app/view/geovisor-tesis-katty-asimbaya>

Figura 42

Geovisor de representación de datos de entrada así como de resultados de la investigación



Nota. En la figura se observa una captura de imagen del geovisor de resultados en donde se indica el valor de las alturas del dosel para el modelo 2.

Adicionalmente en Figura 43, se visualiza un código QR, para que cualquier usuario con un celular inteligente pueda acceder al aplicativo web, escaneándolo.

Figura 43

Código QR de acceso al aplicativo web



Nota. En la figura se presenta el código QR con el cual se puede acceder al aplicativo web en GEE, sin la necesidad de tener una cuenta registrada en la plataforma.

Capítulo V: Conclusiones y Recomendaciones

Conclusiones

En la presente investigación se logró la aplicación exitosa del algoritmo de regresión Random Forest utilizando datos de altura LiDAR y retrodispersión SAR Sentinel -1, con lo cual se generaron 8 modelos de alturas del dosel de los manglares en la provincia del Oro, para el año 2021.

Se concluye que la normalización apenas tuvo un impacto significativo en el rendimiento de los modelos. Esto se evidenció en los Modelos 1 y 3, donde se utilizaron conjuntos de entrenamiento y validación idénticos (90% entrenamiento y 10% validación), pero con Mosaicos SAR Sentinel-1 diferentes: uno normalizado y otro sin normalizar. En esta comparación, se calculó una diferencia de tan solo $-0,0128$ m en términos de RMSE. Una situación similar se presentó entre los Modelos 2 y 4. En este caso, también se utilizaron los mismos grupos de entrenamiento y validación (90% entrenamiento y 10% validación) pero con distintos mosaicos: uno normalizado y otro sin normalizar. La diferencia en los valores de RMSE entre estos dos modelos fue de $-0,136$ m.

En relación a los modelos generados a partir de la Máscara 2, los Modelos 5 y 7 los cuales emplearon los mismos conjuntos de datos de entrenamiento y validación (80% entrenamiento vs 20% validación), se observó una diferencia de $-0,06$ m en términos de RMSE, lo que subraya la consistencia entre ellos.

Con referencia a los Modelos 6 y 8, que compartieron un grupo de entrenamiento y validación idéntico, pero usaron rasters distintos, uno normalizado y otro sin normalizar, se constató que la disparidad en RMSE entre ellos se redujo a escasamente $-0,039$ m. Este estrecho margen demuestra la influencia mínima de la normalización en el rendimiento de estos modelos.

Las precisiones del Modelo 2 (2,863 metros) y del Modelo 5 (3,933 metros) correspondientes a los modelos con los RMSE más bajos son aplicables para la escala relativa

de 1: 25 000, mas no se puede garantizar que todo el modelo alcance esta precisión debido a la falta de datos de entrenamiento y validación a lo ancho de las pistas de datos que están separadas por 600 metros.

Se logró el desarrollo de una aplicación web utilizando la plataforma Google Earth Engine (GEE), la cual brinda a los usuarios la oportunidad de visualizar y descargar los datos de entrada así como resultados de la investigación. Su funcionalidad ofrece apoyo crucial a las estrategias de conservación de los ecosistemas marino-costeros del país al brindando una herramienta efectiva para analizar y comprender el modelo de alturas del dosel de los manglares.

En conjunto, estos logros resaltan la relevancia de la investigación en el campo de la conservación marino-costera y su capacidad para proporcionar herramientas y conocimientos prácticos para la toma de decisiones informadas y efectivas en la gestión ambiental.

Recomendaciones

Se recomienda para obtener un mejor rendimiento en los modelos de alturas del dosel de los manglares, recopilar más datos de entrenamiento y validación de alturas LiDAR, debido a que cuantos más datos se tenga, más información podrán los modelos Random Forest aprender para hacer predicciones más precisas.

Con la finalidad de corroborar los resultados obtenidos en la investigación, se recomienda tomar muestras de altura del dosel de los manglares en campo y verificarlas con los modelos propuestos.

A los profesionales en el ámbito de la geografía, se les recomienda a adquirir destrezas en programación, con el objetivo de ampliar la capacidad para llevar a cabo investigaciones vinculadas a la conservación ambiental. Mediante el dominio de estas habilidades técnicas, se abre la oportunidad de contribuir de manera significativa a la sociedad, ofreciendo conocimientos respaldados por datos y decisiones que fomenten la sostenibilidad en la salvaguardia de los ecosistemas.

Se recomienda también el desarrollo de Apps en GEE, para la presentación de resultados de investigaciones, ya que es una alternativa gratuita y en línea que ofrece un amplio alcance a tomadores de decisiones, comunidad académica y público en general de manera eficiente.

Bibliografía

- Amat, J. (2020). *Árboles de decisión, random forest, gradient boosting y C5*. https://rstudio-pubs-static.s3.amazonaws.com/255596_70d1823f6a214d58970f39af709dad37.html
- Battula , B., & Parayitam, S. (2021). Classification of Synthetic Aperture Radar-Ground Range Detected Image Using Advanced Convolution Neural Networks. *Remote Sensing in Earth Systems Sciences*, 4, 13–29. <https://doi.org/https://doi.org/10.1007/s41976-020-00042-x>
- Beck, J., Wirt, B., Armston, J., Hofton, M., Luthcke, S., & Tang, H. (2021). *GLOBAL Ecosystem Dynamics Investigation (GEDI) Level 2 User Guide*. https://lpdaac.usgs.gov/documents/998/GEDI02_UserGuide_V21.pdf
- Brinkmann, S. (2022). *GISGeography*. Fast Inverse Distance Weighting (IDW) Interpolation with Rcpp: <https://gisgeography.com/inverse-distance-weighting-idw-interpolation/>
- Brown, S. (2021). *Management Sloan School*. Machine learning, explained: <https://mitsloan.mit.edu/ideas-made-to-matter/machine-learning-explained>
- Bunting, P., Rosenqvist, A., Hilarides, L., Lucas, R., Thomas , N., Tadono , T., . . . Murray, N. (2022). Global Mangrove Extent Change 1996–2020: Global Mangrove Watch Version 3.0. *Remote Sens*, 14(15), 3657. <https://doi.org/https://doi.org/10.3390/rs14153657>
- Cherrington, E., Bahadur, R., Herndon, K., & Africa, I. (2019). *THE SAR HANDBOOK Comprehensive Methodologies for Forest Monitoring and Biomass Estimation*. SERVIR Global Science Coordination Ofce National Space Science and Technology Center. <https://doi.org/10.25966/nr2c-s697>
- Chuvieco, E. (2008). *Teledetección Espacial. La observación de la Tierra desde el Espacio (Tercera ed.)*. . Barcelona: Ariel.
- Cutler, A. (2010). *Random Forests for Regression and Classification*. Classification and Regression Trees: usu.edu/math/adele/randomforests/ovronnaz.pdf

- Dassot, M., & Fournier, M. (2011). The use of terrestrial LiDAR technology in forest science: application fields, benefits and challenges. *Annals of Forest Science*, 68, 959–974. <https://doi.org/https://doi.org/10.1007/s13595-011-0102-2>
- Dubayah, R., Blair, J., Goetz, S., Fatoyinbo, L., Hansen, M., & Healey, S. (2020). The Global Ecosystem Dynamics Investigation: High-resolution laser ranging of the Earth's forests and topography. *Science of Remote Sensing*, 1, 100002. <https://doi.org/https://doi.org/10.1016/j.srs.2020.100002>
- Duncanson, L., Kellner, J., Armston, J., Dubayah, R., Minor, D., Hancock, S., Patterson, P. (2022). Aboveground biomass density models for NASA's Global Ecosystem Dynamics Investigation (GEDI). *Remote Sensing of Environment*, 270, 112845. <https://doi.org/https://doi.org/10.1016/j.rse.2021.112845>.
- EarthData NASA. (2021). *¿Qué es la teledetección? Datos terrestres:* <https://earthdata.nasa.gov/learn/backgrounders/remote-sensing>
- ESA. (2013). *Handbook Sentinel-1*. https://sentinel.esa.int/documents/247904/349449/s1_sp-1322_1.pdf
- ESA. (2018). *Product Types and Processing Levels*. Copernicus: <https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-1-sar/product-types-processing-levels>
- ESRI. (2010). *Arc GIS Desktop*. What is a mosaic?: <https://desktop.arcgis.com/en/arcmap/latest/manage-data/raster-and-images/what-is-a-mosaic.htm>
- GEE. (2018). *Earth Engine Data Catalog*. Sentinel-1 Preprocessing: https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S1_GRD
- 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. <https://doi.org/https://doi.org/10.1016/j.rse.2017.06.031>

- Guerrero, C., & Hernández, P. (2017). *Determinación de un modelo digital de elevación a partir de imágenes de radar Sentinel-1 usando interferometría SAR*. Universidad Distrital Francisco José de Caldas, Bogotá.
- Gupta, P., & Follette, M. (2018). *Satellite Remote Sensing of Dust, Fires, Smoke, and Air Quality*. *Fundamentals of Satellite Remote Sensing*: https://appliedsciences.nasa.gov/sites/default/files/D1P3_Fundamentals.pdf
- Haldar, S. (2018). Photogeology, Remote Sensing, and Geographic Information System in Mineral . *Elsevier*, 3, 47-68. <https://doi.org/https://doi.org/10.1016/b978-0-12->
- IIAP. (2014). *BIODAMAZ*. Manual para la elaboración de mosaicos de imágenes de satélite Landsat TM para la selva baja peruana: <https://docplayer.es/22988154-Manual-para-la-elaboracion-de-mosaicos-de-imagenes-de-satelite-landsat-tm-para-la-selva-baja-peruana-documento-tecnico-no-03.html>
- Iqbal, A. (2014). *Capital University of Science & Technology*. Radar Signal Processing: https://abrarhashmi.files.wordpress.com/2017/02/lect_8_radar_equation1.pdf
- Jakob, J., & Yunjin, K. (2013). Synthetic Aperture Radar. *Encyclopedia of Physical Science and Technology (Third Edition)*, 451-465. <https://doi.org/doi.org/10.1016/B0-12-227410-5/00901-7>
- Jensen, J. (2013). *emote Sensing of the Environment : An Earth Resource Perspective (Segunda ed.)*. Londres: Pearson New International Edition.
- Kellndorfer, J. (2019). *SAR Handbook: Comprehensive Methodologies for Forest Monitoring and Biomass Estimation*. Using SAR Data for Mapping Deforestation and Forest Degradation: <https://gis1.servirglobal.net/TrainingMaterials/SAR/Ch3-Content.pdf>
- Laituri, M. (2018). *The conversation*. Satellite imagery is revolutionizing the world. But should we always trust what we see?: <https://theconversation.com/satellite-imagery-is-revolutionizing-the-world-but-should-we-always-trust-what-we-see-95201>

- Lucas, R., Rebelo, L., Rosenqvist, A., Shimada, M., & Hilarides, L. (2014). Contribution of L-band SAR to systematic global mangrove monitoring . *Marine and Freshwater Research*, 65(7), 589–603. <https://doi.org/http://doi.org/10.1071/MF13177>
- Mbaabu, O. (2020). *EngEd Community*. Introduction to Random Forest in Machine Learning: <https://www.section.io/engineering-education/introduction-to-random-forest-in-machine-learning/#:-:text=A%20random%20forest%20is%20a%20machine%20learning%20tech,consists%20of%20many%20decision%20trees>.
- Mehendale, N. (2020). Review on Lidar Technology. *SSRN Electron. J*, 9. <https://doi.org/http://dx.doi.org/10.2139/ssrn.3604309>
- Meyer, F. (2019). *Spaceborne Synthetic Aperture Radar – Principles, Data Access, and Basic Processing Techniques*. *SAR Handbook: Comprehensive Methodologies for Forest Monitoring and Biomass Estimation*. Eds. Flores, A., Herndon, K., Thapa, R., Cherrington, E. NASA. . <https://doi.org/10.25966/ez4f-mg98>
- Mignone , C., & Barnes, R. (2012). *El espectro electromagnético*. Revista Europea para profesores en Ciencias: www.scienceinschool.org/es/article/2012/em-3-es/
- Moreira, A., Prats, P., Younis, M., Krieger, G., & Hajnsek, I. (2013). *IEE Geoscience and remote sensing magazine*. A Tutorial on Synthetic Aperture Radar: <https://core.ac.uk/download/pdf/31005519.pdf>
- Narang, M. (2022). *Shiksha Online*. When Should We perform feature scaling?: <https://www.shiksha.com/online-courses/articles/normalization-and-standardization/>
- NASA. (2018). *GED I ECOSYSTEM LIDAR*. Applications-Forest Management and Carbon Cycling: <https://gedi.umd.edu/applications/forest-management-and-carbon-cycling/>
- National Oceanic and Atmospheric Administration. (n.d.). *What is lidar?* Lidar-Light Detection and Ranging: <https://oceanservice.noaa.gov/facts/lidar.html>

- Podest, E. (2015). *Conceptos Básicos del Radar de Apertura Sintética*. Applied Remote Sensing Training: <https://appliedsciences.nasa.gov/sites/default/files/Session1-SAR-Spanish.pdf>
- Pourshamsi, M., Xia, J., Yokoya, N., García, M., Lavallo, M., Pottier, E., & Balzter, H. (2021). Tropical forest canopy height estimation from combined polarimetric SAR and LiDAR using machine-learning. *ISPRS Journal of Photogrammetry and Remote Sensing*, 172, 79-94. <https://doi.org/10.1016/j.isprsjprs.2020.11.008>
- Quevedo, F. (2011). *MEDWAVE*. Measures of central tendency and dispersion: <https://www.medwave.cl/series/MBE04/4934.html>
- Reuter, F. (2009). *Principios de teledetección*. Facultad de Ciencias Forestales de la Universidad Nacional de Santiago del Estero.
- Richards, J. (2009). *Remote Sensing with Imaging Radar*. ANU College of Engineering and Computer Science The Australian National University. <https://doi.org/10.1007/978-3-642-02020-9>
- Rzedowski, J. (2006). *Vegetación de México* (Primera ed.). Limusa, S. A.
- Salamanca, J. (2008). *Ingeniería*. LIDAR, una tecnología de última generación, para planeación y desarrollo urbano: <https://revistas.udistrital.edu.co/index.php/reving/article/download/2090/2751?inline=1>
- Salamanca, J., & Pérez, J. (2008). LIDAR, una tecnología de última generación, para planeación y desarrollo urbano. *Ingeniería*, 13(1), 67-76. <https://doi.org/0121-750X>
- Sarría, F. (2015). *Fundamentos de teledetección*. Radar: <https://www.um.es/geograf/sigmur/sigpdf/temario.pdf>
- Schwartz, M., Ciais, p., Ottlé, C., De Truchis, A., Vega, C., & Fayad, I. (2022). High-resolution canopy height map in the Landes forest (France) based on GEDI, Sentinel-1, and Sentinel-2 data with a deep learning approach. *ArXiv*, 12(10). <https://doi.org/10.48550/arXiv.2212.10265>

- Segado, F. (1996). *Principios de teledetección (II, Vol. 1)*. Servicio de Publicaciones.
- Solórzano, J., & Perilla, G. (2022). *Cómo usar Google Earth Engine y no fallar en el intento*. Bogotá: Instituto de Investigación de Recursos Biológicos Alexander Von Humboldt.
- Tamiminia, H., Salehi, B., Mahdianpari, M., Quackenbush, L., & Adeli, S. (2020). Google Earth Engine for geo-big data applications: A meta-analysis and systematic review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 164, 152-170.
<https://doi.org/https://doi.org/10.1016/j.isprsjprs.2020.04.001>
- Tarazona, Y. (2020). *APROGIS*. Tratamiento del ruido Speckle en las imágenes RADAR: Filtros simples y Multi-temporales: <https://aprogis.com/blogs/tratamiento-del-ruido-speckle-en-las-imagenes-radar-filtros-simples-y-multi-temporales>
- Thomas, L. (2020). *Scribbr*. Simple Random Sampling | Definition, Steps & Examples: <https://www.scribbr.com/methodology/simple-random-sampling/>
- USGS. (2018). *Global Ecosystem Dynamics Investigation (GEDI)*. <https://www.earthdata.nasa.gov/sensors/gedi>
- Ustin, S., & Middleton, E. (2021). Current and near-term advances in Earth observation for ecological applications. *Ecological Processes*, 10(1).
<https://doi.org/https://doi.org/10.1186/s13717-020-00255-4>
- Valchavov, I. (2021). *365 DataScience*. Obtaining Standard Normal Distribution Step-By-Step: <https://365datascience.com/tutorials/statistics-tutorials/standardization/>
- Zan, D., & Guarnieri, A. (2006). Terrain Observation by Progressive Scans. *Geoscience and Remote Sensing*, 44(9), 2352-2360. <https://doi.org/doi:10.1109/TGRS.2006.873853>
- Zozaya, A. (2016). *Revista INGENIERÍA UC*. Radares de apertura sintética: procedimiento de diseño: <https://www.redalyc.org/pdf/707/70746634002.pdf>