



Organización de las Naciones
Unidas para la Alimentación
y la Agricultura




**Instituto Nacional de
Conservación Forestal**
Gobierno de la República



PROTOCOLO METODOLÓGICO

Mapa de Cobertura y Uso de la Tierra, Honduras 2024



AUTORIDAD NACIONAL

Luis Edgardo Soliz Lobo
Director Ejecutivo del ICF

COORDINACIÓN GENERAL TÉCNICA

Manuel Enrique Erazo
Jefe del Centro de Información y Patrimonio Forestal (CIPF)
Karol Berenice Lara
Coordinadora Unidad de Monitoreo Forestal /CIPF

EQUIPO CONSULTOR EXPERTO NACIONAL

Klaus Wiese
Consultor y asesor principal

ESPECIALISTA TÉCNICOS

Daryl Medina
Sub coordinador
José Cáceres
Especialista teledetección
Antonio Carías
Especialista teledetección
Kevin Irías
Técnico SIG
Mario René López
Técnico SIG
Maynor Josué Díaz
Técnico SIG

COORDINACIÓN FAO

Fabio Casco
Enlace FAO
Amy Lazo
Enlace FAO

COORDINACIÓN ADMINISTRATIVA


José David Pastrana
Coordinador General OCP
Victoria Trujillo
Oficial de Formulación de Proyectos OCP

EQUIPO TÉCNICO UNIDAD DE MONITOREO FORESTAL

Luis Alfredo López
Técnico Unidad de Monitoreo Forestal
Marlon Alexander Díaz
Técnico Unidad de Monitoreo Forestal
Teresa de Jesús Gómez
Técnico Unidad de Monitoreo Forestal
Luis Alonso Fuentes
Técnico Unidad de Monitoreo Forestal

EQUIPO DE COLECTA DE DATOS DE ENTRENAMIENTO

Frayh Jonnatan Mejía Izaguirre
Región Forestal Pacífico
Darwin Gregorio Funez Bautista
Región Forestal del Valle de Aguán
Axel Ricardo Cardona
Programa Nacional de Reforestación
Matías José Girón Sagastume
Departamento de Protección Forestal
Julissa Beatriz Perdomo
Departamento de Protección Forestal
Sheila Lizeth Nuñez Ruiz
Región Forestal Pacífico
Aida Mariel Hernández Vásquez
Región Forestal Comayagua
Allan Bladimir Palacios Rodríguez
Región Forestal Noreste de Olancho
Marlon Calderón
Unidad Gestión Forestal Cambio Climático
Zeuxis Vladimir Fajardo
Departamento de Salud y Sanidad Forestal



EQUIPO TÉCNICO VALIDADOR DEL MAPA

Edwin Vega

Región Forestal Atlántida

Melissa Juárez

*Región Forestal Biosfera del Río
Plátano*

Juan Carlos Hernández

Región Forestal Comayagua

Santos Javier Lazo

Región Forestal El Paraíso

Darwin Hernández

*Región Forestal Francisco
Morazán*

Martha Medrano

Región Forestal Islas de la Bahía

Jayson Calderón

Región Forestal La Mosquita

Chelsea Montoya

*Región Forestal Noreste de
Olancho*

Wilson Morales

Región Forestal Noroccidente

Marlon Javier Peña

Región Forestal Occidente

Daniel Sandres

Región Forestal Olancho

Samantha Castillo

Región Forestal Pacífico

Osman Andino

Región Forestal Santa Bárbara

Carlos Samir Reyes

Región Forestal Valle de Aguán

Juan Javier Cano

Región Forestal Yoro

EQUIPO DE PRODUCCIÓN Y DISEÑO COMUNICACIONAL

Pamela Quiñonez

Coordinadora

Carlos Velásquez

Dirección de arte

Juan Carlos Rojas

Diseñador gráfico

Danny Flores

Productor audiovisual

1. INTRODUCCIÓN

El proyecto "Construcción del Mapa de Cobertura Forestal y Uso de la Tierra de Honduras 2024" surge en respuesta a la necesidad crítica de contar con datos geospaciales actualizados y precisos para la gestión sostenible de los recursos naturales del país. A lo largo de las últimas décadas, Honduras ha implementado diversos estudios y proyectos que han contribuido significativamente a la clasificación y monitoreo del uso del suelo y la cobertura forestal. Sin embargo, la rápida evolución de los patrones de uso del suelo, así como los desafíos ambientales contemporáneos, requieren herramientas de monitoreo más avanzadas y actualizadas.

El Instituto Nacional de Conservación y Desarrollo Forestal, Áreas Protegidas y Vida Silvestre (ICF), en coordinación con la Organización de las Naciones Unidas para la Agricultura y la Alimentación (FAO), ha emprendido este proyecto con el objetivo de desarrollar un mapa integral y detallado que refleje la situación actual de la cobertura forestal y los usos del suelo en Honduras. Este esfuerzo es crucial para cumplir con los compromisos internacionales del país en materia de cambio climático, conservación de la biodiversidad y desarrollo sostenible, tal como lo estipulan las Metas de Aichi para la Biodiversidad y el Acuerdo de París.

La metodología emplea técnicas avanzadas de teledetección y sistemas de información geográfica (SIG) para procesar imágenes satelitales ópticas y de radar, así como datos complementarios. Estas metodologías permitirán una clasificación precisa y actualizada de las diversas categorías de uso del suelo, proporcionando una herramienta esencial para la planificación estratégica, la formulación de políticas y la toma de decisiones informadas.

Además, se ha integrado la experiencia y conocimiento del personal técnico del ICF y otras instituciones involucradas, asegurando que el mapa no solo cumpla con los más altos estándares técnicos, sino que también refleje las particularidades locales y regionales. La capacitación y fortalecimiento de capacidades técnicas de los profesionales involucrados, así como la modernización de las infraestructuras necesarias, garantizarán la sostenibilidad del proyecto a largo plazo.

Este mapa no solo permitirá un monitoreo más eficaz de los cambios en la cobertura forestal y el uso del suelo, sino que también fortalecerá la transparencia y rendición de cuentas de Honduras en foros internacionales. La creación del Mapa de Cobertura Forestal y Uso de la Tierra 2024 es un paso fundamental hacia una gestión ambiental más sostenible y responsable, que beneficiará a las generaciones presentes y futuras.

El presente documento contiene una descripción de la metodología empleada en el proceso de edición y diseño del mapa nacional de cobertura y uso forestal de Honduras para el año 2024. Esta guía metodológica detalla el uso de imágenes satelitales de los sensores Sentinel-1 y Sentinel-2 del Programa Copernicus, así como la integración de datos auxiliares y el cálculo de índices espectrales. Además, se describe el entrenamiento del modelo de clasificación utilizando el algoritmo Random Forest. Este documento servirá como referencia para posteriores estudios y elaboración de mapas en Honduras y otras regiones de Centroamérica y el Caribe, proporcionando un marco conceptual sólido y técnicas avanzadas para la clasificación de la cobertura y uso del suelo.



2. ANTECEDENTES

Honduras ha llevado a cabo varios estudios y proyectos relacionados con la clasificación y monitoreo del uso del suelo y la cobertura forestal en el país.

1979

Estudio de cobertura vegetal y uso del suelo de Honduras, estableció una clasificación basada en la presencia o ausencia de vegetación arbórea y herbácea, agua y áreas urbanas.

1995

Se utilizó información de imágenes de satélite para actualizar y mejorar la clasificación anterior. Este estudio utilizó una clasificación de cuatro categorías: bosque, tierra agrícola, áreas urbanas y otros usos del suelo.

2002

Se llevó a cabo el proyecto Monitoreo de los Cambios de la Cobertura Forestal en Honduras, que utilizó imágenes de satélite para evaluar la tasa de deforestación y degradación forestal en el país. El proyecto se centró en tres áreas piloto y utilizó una metodología que permitió la identificación de cambios en la cobertura forestal y su relación con la actividad humana.

2014

Nuevo mapa de cobertura y uso del suelo que fue producido utilizando imágenes satelitales RapidEye y técnicas de teledetección. El mapa se elaboró para actualizar la información sobre la distribución espacial de la cobertura y uso del suelo en el país. La clasificación se realizó mediante el uso de un sistema de información geográfica y técnicas de aprendizaje automático. Para este mapa se consideraron 26 clases de cobertura y usos de la tierra siendo 8 correspondiente a bosques.

2018

Se elaboró utilizando imágenes satelitales Sentinel-2 y técnicas de teledetección. El mapa se produjo como parte del proyecto "Monitoreo de la Cobertura Forestal en Honduras" de la Organización de las Naciones Unidas para la Agricultura y la Alimentación (FAO). El objetivo del proyecto fue proporcionar información actualizada sobre la distribución espacial de la cobertura y uso del suelo en Honduras. La clasificación se realizó utilizando un algoritmo de clasificación de objetos basado en el análisis de características espectrales y espaciales. Este mapa consideró 35 clases de cobertura y usos de la tierra, siendo 8 de bosque.

3. JUSTIFICACIÓN

El cambio climático se ha convertido en el mayor desafío ambiental del siglo XXI. En respuesta a esta problemática global, Honduras, junto con 196 países, es miembro de la Convención Marco de las Naciones Unidas sobre el Cambio Climático (CMNUCC), comprometiéndose a llevar a cabo acciones para contrarrestar sus efectos.

Los bosques desempeñan un papel crucial en la mitigación del cambio climático, ya que son el único medio eficiente para reducir las emisiones de carbono. Sin embargo, actualmente contribuyen a casi un sexto de las emisiones de carbono mundial debido a la deforestación, la explotación excesiva y la degradación. A pesar de esto, los bosques tienen el potencial de absorber hasta un décimo de las emisiones mundiales de carbono previstas para la primera mitad de este siglo, almacenando carbono en su biomasa, suelos y productos (FAO, 2020).

La representación gráfica y espacial de la cobertura forestal y el uso de la tierra a través de mapas es una herramienta esencial para la planificación, gestión y toma de decisiones en el marco del manejo forestal sostenible. Estos mapas son fundamentales para comprender las características biofísicas y ecosistémicas, y para impulsar decisiones técnicas y políticas en el uso del suelo a nivel nacional, regional y local.

El Mapa de Cobertura Forestal y Uso de la Tierra 2024 es una actualización del mapa generado en 2018 y servirá como herramienta base para la planificación territorial y la toma de decisiones en el ordenamiento forestal. Este mapa es esencial para los tomadores de decisiones y apoyará el manejo sostenible de los bosques, el control de plagas e incendios forestales, la regularización forestal, los planes de ordenamiento y la gestión de cuencas hidrográficas. Además, contribuirá a las estadísticas generadas por el Instituto de Conservación Forestal y otras instituciones del sector forestal.



4. OBJETIVOS


● Objetivo General

Generar un mapa de cobertura forestal y usos de la tierra para el año 2024, utilizando imágenes satelitales del programa Copernicus y datos complementarios, empleando herramientas y técnicas de arquitectura abierta mediante teledetección y manejo de información geográfica.

● Objetivos Específicos

- Identificar y describir las clases de cobertura y uso del suelo a ser clasificadas con base a lineamientos de la Unidad de Monitoreo Forestal del ICF.
- Implementar técnicas avanzadas de teledetección para obtener y procesar imágenes satelitales, ópticas y de radar, representativas para el año 2024.
- Calcular y analizar índices espectrales y datos auxiliares que aporten información para la clasificación de las categorías del mapa de cobertura forestal y usos del suelo para facilitar la diferenciación de coberturas.
- Entrenar un modelo de clasificación supervisada, a partir de las variables seleccionadas, utilizando el algoritmo Random Forest para la elaboración del Mapa Forestal 2024.
- Validar la precisión y robustez de la clasificación mediante técnicas de evaluación cruzada.





5. MATERIALES Y MÉTODOS

Para la elaboración del Mapa de Cobertura Forestal y Uso del Suelo de Honduras 2024, se adoptó una metodología basada en cuatro principios fundamentales.

1

Se utilizaron datos de libre acceso, específicamente imágenes de los satélites Sentinel-1 y Sentinel-2 del programa Copernicus.

2

Se integró la información generada internamente por el Instituto de Conservación Forestal (ICF), promoviendo la transversalidad de las acciones institucionales .

3

Se implementaron tecnologías y aplicaciones avanzadas que aseguran la solidez del procedimiento y permiten el desarrollo continuo del mapa a lo largo del tiempo

4

Se priorizó la precisión de los resultados mediante evaluaciones sistemáticas basadas en datos empíricos, facilitando el aprendizaje a partir de experiencias previas y asegurando la comparabilidad de los mapas en distintos momentos temporales

A continuación, se detalla el desarrollo metodológico aplicado en la generación del Mapa de Cobertura Forestal y Uso del Suelo de Honduras.


Para cuantificar y delimitar el área ocupada por las distintas categorías de Cobertura Forestal y Uso del Suelo en Honduras 2024, se empleó un modelo de predicción espacial estructurado en varios componentes clave (Figura 1). En primer lugar, se utilizaron datos ópticos y de radar provenientes de las imágenes satelitales de Sentinel-2 y Sentinel-1. Las imágenes de Sentinel-2 proporcionaron información multiespectral detallada, incluyendo bandas e índices espectrales como NDVI, EVI, SAVI, entre otros. Las imágenes de radar de Sentinel-1 GRD, en polarizaciones VV y VH, tanto en órbitas ascendentes como descendentes, ofrecieron datos adicionales sobre la estructura y humedad del suelo.

Adicionalmente, se incorporaron datos auxiliares del modelo digital de elevación SRTM, incluyendo la elevación y la pendiente del terreno, para enriquecer el modelo y optimizar la clasificación. Luego, se utilizaron datos de campo que permitan caracterizar y clasificar con precisión las distintas categorías presentes en el territorio para generar los puntos de entrenamiento. Posteriormente, se aplicaron algoritmos de clasificación avanzados que permitieron procesar la información de manera eficiente y precisa el entrenamiento del modelo de clasificación, mediante la hiperparametrización, el ajuste del modelo.

Posteriormente, se realizó una evaluación en la que, si el modelo necesita mejoras, se aplica un proceso de Fine-Tuning antes de repetir el entrenamiento, en cambio, si el rendimiento es satisfactorio, se procedió a la validación utilizando puntos de validación independientes del entrenamiento. Finalmente, se llevó a cabo una validación rigurosa del modelo utilizando puntos de validación para evaluar la precisión y fiabilidad de los resultados obtenidos.




5.1. ESQUEMA METODOLÓGICO



5.2 ÁREA DE ESTUDIO

El área de estudio del proyecto abarca todo el territorio de Honduras, que tiene una extensión aproximada de 112,777 km² y presenta una gran diversidad de paisajes y ecosistemas. Para mejorar la precisión en la clasificación del uso y cobertura del suelo, el análisis se realizó a nivel de las Regiones Forestales definidas por el ICF (Figura 2). Esta subdivisión permite entrenar modelos de clasificación que se ajusten mejor a las características ambientales y de uso del suelo de cada región, optimizando así la representatividad y exactitud de los resultados.



Con el fin de ser eficaz y eficiente en la ejecución de las actividades que por ley le competen, el ICF se ha dividido administrativamente a nivel nacional en quince regiones forestales (ICF, 2024), cómo se muestra en la Tabla 1

Nombre de Región Forestal	Código	Ubicación Oficina Regional
Atlántida	AT	La Ceiba
Comayagua	CO	La Paz
El paraíso	EP	Danlí
Francisco Morazán	FM	Comayagüela
La Mosquitia	LM	Puerto Lempira
Noreste de Olancho	NE	Gualaco
Noroccidente	NO	San Pedro Sula
Occidente	OC	Santa Rosa de Copán
Olancho	OL	Juticalpa
Pacífico	PC	Marcovia
Biósfera del Río Plátano	LB	Culmí
Yoro	YO	Yoro
Santa Bárbara	SB	Santa Bárbara
Valle de Aguan	VA	Olanchito
Islas de la Bahía	IB	Roatan



5.3 DEFINICIÓN DE CLASES

Se identificaron 23 categorías a ser incluidas en el mapa, agrupadas en seis macro-categorías:

- **Tierras Forestales:** Abarca diversos tipos de bosques que se distinguen por su composición y características estacionales. Incluye el Bosque Latifoliado Siempre Verde, caracterizado por árboles de hojas anchas que permanecen verdes todo el año; el Bosque de Conífera, dominado por coníferas; el Bosque Mixto, que combina elementos de bosques latifoliados y de coníferas; el Bosque Latifoliado Deciduo, cuyos árboles pierden sus hojas en una temporada específica; y el Bosque Mangle, típico de zonas costeras inundables.
- **Tierras de Cultivos** Esta categoría agrupa diferentes tipos de cultivos agrícolas. Incluye los Cultivos de Ciclo Corto, que completan su ciclo productivo en un periodo breve; la Musácea, que abarca plantaciones como el plátano y la banana; la Caña de Azúcar, un cultivo tropical perenne; el Café, cultivado en arbustos; los Frutales, que incluyen una variedad de árboles frutales; y la Palma Africana, utilizada principalmente para la producción de aceite; Arrozales abarca los terrenos destinados a la producción arroz.
- **Pastizales:** Estos incluyen áreas donde predominan las hierbas y arbustos bajos. La Vegetación Arbustiva/Matorral consiste en áreas con vegetación baja y densa; los Pastizales son áreas dominadas por pasto; y la Sabana de Bosque de Pino combina pastizales con presencia de pinos dispersos.
- **Humedales:** Esta categoría comprende áreas con alta humedad y presencia de agua. Incluye Humedales con Vegetación, que son áreas inundables con vegetación específica; Cuerpos de Agua, que abarcan lagos, ríos y otros cuerpos de agua; y Camaroneras/Salineras, que son áreas utilizadas para la acuicultura y la producción de sal; Marismas humedales planos y periódicamente inundados, ubicados principalmente en las zonas costeras y estuarinas del Atlántico y Pacífico.
- **Asentamiento** :Incluye áreas urbanizadas y desarrolladas, donde se encuentran viviendas, infraestructuras y otras construcciones humanas.
- **Otras Tierras:**Esta categoría agrupa diversas áreas que no encajan en las anteriores. Incluye Suelo, que son áreas de tierra desnuda; Playa, que abarca las zonas costeras arenosas; y Bancos de Arena que hace referencia a la acumulación de este material en zonas de riberas.



El listado de las categorías con su respectivo código de identificación se presenta en la Tabla 2.

Tabla 2. Categorías del mapa de cobertura forestal y uso de la tierra.

MACROCATEGORÍAS	CATEGORÍA	CÓDIGO
Tierras Forestales	Bosque Latifoliado Siempre Verde	FLAT
	Bosque de Conífera	FCON
	Bosque Mixto	FMIX
	Bosque Latifoliado Deciduo	FDEC
	Bosque Mangle	FMAN
Tierras de Cultivos	Cultivos de Ciclo corto	CCOR
	Musácea	CMUS
	Caña de Azúcar	CAZU
	Café	CCAF
	Frutales	CFRU
	Palma Africana	CAFR
	Arrozales	Arroz
Pastizales	Vegetación Arbustiva/Matorral	PARBM
	Pastizales	PPAS
	Sabana de bosque de pino	PSABP
Humedales	Humedales Vegetación	HVEG
	Cuerpos de Agua	HCAGU
	Camaroneras/Salinerías	HCAMS
	Marismas	MARSM
Asentamientos	Tejido Urbano Continuo	A
Otras tierras	Suelo	OSUE
	Playa	OPLA
	Bancos De Arena	BA



5.4 ÁREA DE ESTUDIO

El proceso de clasificación del Mapa de Cobertura Forestal y Uso de la Tierra de Honduras 2024 se fundamenta en una base de datos de entrenamiento robusta, levantada por el personal técnico de las regionales del ICF. Este grupo de profesionales seleccionados por la Institución poseen un profundo conocimiento sobre la distribución y comportamiento geográfico de las 23 clases de cobertura definidas, lo que les convierte en actores clave para la recolección de datos de referencia mediante el conocimiento en campo de las muestras generadas. Su experiencia en el reconocimiento de patrones de vegetación y uso del suelo dentro de sus regiones garantiza una selección precisa de las áreas de entrenamiento, proporcionando insumos confiables para la calibración del modelo de clasificación (Foody, 2002).

Para asegurar la calidad y representatividad de los datos, se establecieron criterios específicos en la selección de las áreas de entrenamiento. Se consideró que cada clase de cobertura contara con una cantidad de muestras homogéneas para todas las clases, permitiendo una representación equilibrada de las categorías de uso y cobertura del suelo. Además, se tomaron en cuenta la variabilidad espectral de cada clase y las condiciones geográficas en las que se presentan, con el fin de capturar la mayor diversidad posible de respuestas espectrales y retrodispersión dentro de cada categoría (Belgiu y Drăguț, 2016). Este enfoque garantiza que el modelo de predicción pueda diferenciar correctamente entre clases similares y mejorar su capacidad de generalización.

La base de datos de entrenamiento, generada por los técnicos de ICF, se construyó a partir de la interpretación de imágenes satelitales y datos auxiliares. Se diseñó un esquema de muestreo que incluye tanto áreas homogéneas como transicionales, asegurando que el modelo pueda capturar las diferencias espectrales dentro de cada clase. Estos datos fueron utilizados en el entrenamiento del algoritmo de clasificación, optimizando su desempeño en la predicción espacial de las categorías seleccionadas (Mather y Koch, 2011). La combinación de conocimiento experto en campo y métodos de teledetección garantiza una clasificación precisa y adaptada a las características del territorio hondureño.




5.5 SELECCIÓN DE IMÁGENES SATELITALES

Para la clasificación de las coberturas se utilizaron imágenes Sentinel-1 y Sentinel-2.

5.4.1 SENTINEL - 1

Las imágenes de Sentinel-1, parte del programa Copernicus de la Agencia Espacial Europea (ESA), son capturadas mediante tecnología radar de apertura sintética (SAR). Estas imágenes se caracterizan por su capacidad de adquisición independiente de las condiciones meteorológicas y de iluminación (ESA's Radar Observatory Mission for GMES Operational Services, 2012), lo que permite obtener datos tanto de día como de noche y en presencia de nubes. Sentinel-1 opera en la banda C (5.4 GHz) y ofrece productos de alta resolución con una resolución espacial de 10 metros. Las imágenes se adquieren en modos de polarización VV y VH (Figura 2), y pueden ser procesadas para corregir distorsiones radiométricas y geométricas, así como para reducir el moteado (Speckle). Sus principales aplicaciones incluyen la detección de cambios en la superficie terrestre, el monitoreo de cuerpos de agua, la evaluación de riesgos por desastres naturales y el seguimiento de la cobertura forestal y uso del suelo, gracias a su capacidad para penetrar la vegetación y captar información estructural del terreno.



(a) Sentinel-1 VV	(b) Sentinel-1 VH
Figura 3. Combinaciones simples de Sentinel-1	



Se recopiló todas las imágenes disponibles del año 2024 para las plataformas Sentinel-1. El procesamiento de estas imágenes incluyó la aplicación de un filtro speckle y la corrección de pendiente.

La misión Sentinel-1 proporciona datos de un radar de apertura sintética con capacidad de obtención de imágenes diurnas y nocturnas en diferentes condiciones meteorológicas (Sentinel-1 SAR GRD, 2025) estos datos recogen información de la retrodispersión de la superficie de la tierra y son de mucha utilidad para separar diferentes usos del suelo y coberturas vegetales (Craig Dobson et al., 1995).

Se utilizó la colección de imágenes del año 2024 del catálogo de Google Earth Engine (Gorelick et al., 2017). Estas imágenes fueron procesadas para eliminar el ruido térmico, calibrar radiométricamente y corregir topográficamente usando el modelo SRTM. De la colección se utilizó las siguientes variables :

- Polarización simple VV orbita ascendente y descendente (decibeles)
- Polarización simple VH orbita ascendente y descendente (decibeles)

Posteriormente se procedió al cálculo de estadísticos derivados de la colección de imágenes RADAR del año 2024 para obtener valores de coberturas. Esta metodología permite diferenciar los estadios de crecimiento de cultivos, pastizales y otras formaciones vegetales (Song y Wang, 2019). Para el análisis se utilizaron varios estadísticos de la serie temporal de las imágenes Sentinel-1, correspondientes a las dos polarizaciones sencillas disponibles de este sensor.

- Mediana de colección RADAR polarización VV con orbitas ascendente y descendente para el 2024 (decibeles).
- Mediana de colección RADAR polarización VH con orbitas ascendente y descendente para el 2024 (decibeles).
- Desviación Estándar de colección RADAR polarización VV con orbitas ascendente y descendente para el 2024 (decibeles).
- Desviación Estándar de colección RADAR polarización VH con orbitas ascendente y descendente para el 2024 (decibeles).
- Ratios de doble polarización (VH / VV) para con orbitas ascendente y descendente para el 2024 (decibeles).




5.4.2 SENTINEL - 2

Las imágenes Sentinel-2 forman parte del programa Copernicus de la Agencia Espacial Europea (ESA) y están diseñadas para la observación terrestre, con aplicaciones en el monitoreo de la vegetación, el uso del suelo y los recursos hídricos. El sistema consta de dos satélites, Sentinel-2A y Sentinel-2B, que capturan datos en 13 bandas espectrales que abarcan desde el visible hasta el infrarrojo de onda corta (SWIR), con resoluciones espaciales de 10, 20 y 60 metros, dependiendo de la banda. Su resolución temporal es de aproximadamente 5 días, gracias a la constelación de dos satélites (Sentinel-2A y Sentinel-2B) que orbitan con un desfase de 180 grados entre sí, lo que permite un monitoreo frecuente de los cambios en la superficie terrestre.

Gracias a su alta resolución espectral y temporal, las imágenes Sentinel-2 son ampliamente utilizadas en aplicaciones como la clasificación de cobertura del suelo, la detección de cambios, la agricultura de precisión y el monitoreo de la calidad del agua, proporcionando información detallada y accesible para la gestión ambiental y territorial (Drusch et al., 2012; European Space Agency [ESA], 2023).

Para poder generar imágenes que correspondan a espacios de tiempo específicos se crea una herramienta para hacer compuestos temporales que selecciona el mejor pixel posible de toda la serie de tiempo para el año 2024 (Figura 3).



De las bandas disponibles para las imágenes Sentinel-2, se seleccionaron las correspondientes al espectro visible (azul (B2), verde (B3) y rojo (B4)), el infrarrojo (rededge 1-3 (B5, B6 y B7) y el infrarrojo de cercano (B8)) y datos sobre infrarrojo de onda corta (B11 y B12) (ESA, 2023). estas imágenes fueron recolectadas usando la plataforma de computación en la nube Google Earth Engine (Gorelick et al., 2017).

Se uso la colección harmonizada de imágenes que poseen corrección topográfica y atmosférica, a esta se aplicó finalmente un filtro de nubes y sombras.



5.6 ÍNDICES ESPECTRALES

Los índices espectrales ayudan a resaltar las características de las cubiertas en la superficie terrestre, se generan a partir de la interacción de los diferentes espectros de la luz (Chuvieco-Salinero, 2006).

Usando como base valor de la mediana de la colección Sentinel-2 para el año 2024, se calculó diferentes índices espectrales conocidos por su utilidad para separar diferentes coberturas vegetales. Los índices espectrales empleados incluyen:

1. Índice de Vegetación de Diferencia Normalizada (NDVI), que se calcula mediante la siguiente fórmula:

$$NDVI = \frac{NIR - RED}{NIR + RED}$$

donde NIR es la reflectancia en el infrarrojo cercano y RED es la reflectancia en la banda roja. Este índice permite evaluar la densidad y vigor de la vegetación (Rouse et al., 1974).

2. Índice de Construcción de Diferencia Normalizada (NDBI), que resalta áreas urbanizadas y se calcula como:

$$NDBI = \frac{SWIR - NIR}{SWIR + NIR}$$

donde SWIR es la reflectancia en el infrarrojo de onda corta y NIR la reflectancia en el infrarrojo cercano (Zha et al., 2003).

3. Índice de Vegetación Mejorado (EVI) corrige efectos atmosféricos y de fondo del suelo, proporcionando mayor sensibilidad en áreas de alta biomasa. Se define como:

$$EVI = G * \frac{NIR - RED}{NIR + C1 * RED - C2 * BLUE + L}$$

donde G es un factor de ganancia igual a 2.5, C1 y C2 son coeficientes de corrección atmosférica iguales a 6 y 7.5 respectivamente, L es un factor de corrección del suelo igual a 1, y BLUE representa la reflectancia en la banda azul (A. Huete et al., 1994)



4. Índice de Vegetación Ajustado al Suelo (SAVI) se calcula como:

$$SAVI = \frac{NIR - RED}{NIR + RED + L} * (1 + L)$$

donde L es un factor de ajuste del suelo, útil en zonas áridas o semiáridas (A.R Huete, 1988).

5. Índice de Vegetación de Diferencia Normalizada del Verde (GNDVI) se define como:

$$GNDVI = \frac{NIR - GREEN}{NIR + GREEN}$$

donde GREEN representa la reflectancia en la banda verde. Este índice mejora la evaluación de la actividad fotosintética y la clorofila (Gitelson et al., 1996).

6. Índice de Diferencia Normalizada del Agua (NDWI) se calcula como:

$$NDWI = \frac{GREEN - NIR}{GREEN + NIR}$$

Este índice se utiliza para resaltar cuerpos de agua y minimizar la influencia de la vegetación y el suelo (McFeeters, 1996).

7. Índice Modificado de Diferencia Normalizada del Agua (MNDWI) se define como:

$$MNDWI = \frac{GREEN - SWIR}{GREEN + SWIR}$$

Este índice mejora la detección de cuerpos de agua al sustituir el NIR por el SWIR (Xu, 2006).

8. Índice de Área Quemada Normalizado (NBR), se calcula mediante la fórmula:

$$NBR = \frac{NIR - SWIR}{NIR + SWIR}$$

Se emplea para identificar áreas afectadas por incendios forestales (Key y Benson, 2006).

9. Índices de Vegetación de Diferencia Normalizada en el Rojo Extendido (NDRE1 y NDRE2) se calculan como:

$$NDRE = \frac{NIR - RedEdge}{NIR + RedEdge}$$

donde RedEdge representa las bandas del borde rojo, utilizadas para mejorar la detección de estrés en la vegetación y facilitar el monitoreo agrícola (Gitelson et al., 1996).

5.7 DATOS AUXILIARES

Los modelos de elevación y las pendientes son variables auxiliares fundamentales en los algoritmos de aprendizaje de máquina para la clasificación de coberturas del suelo, ya que proporcionan información clave sobre la distribución altitudinal y la morfología del terreno, lo que influye directamente en la presencia y transición de diferentes clases de cobertura. La incorporación de estas variables permite mejorar la precisión de los modelos, especialmente en áreas montañosas donde los patrones espectrales pueden ser similares pero diferenciables en función de la altitud y la inclinación del terreno (Rodríguez-Galiano et al., 2012). Estudios previos han demostrado que el uso combinado de datos ópticos y radar con información topográfica mejora significativamente la capacidad de discriminación de coberturas como bosques, cultivos y áreas urbanas, al capturar variaciones que no son evidentes solo a partir de la reflectancia espectral (Kennedy et al., 2010). Además, la pendiente es una variable crucial para la clasificación de áreas agrícolas, ya que ciertas prácticas agrícolas están restringidas a terrenos con inclinaciones específicas, lo que contribuye a una mejor delimitación de clases en modelos de clasificación basados en árboles de decisión y algoritmos de ensamble como Random Forest y Gradient Boosting (Hansen et al., 2013).

Para la obtención de las elevaciones se utilizó el Modelo Digital de Elevación (MDE) del Shuttle Radar Topography Mission (SRTM) el cual proporciona datos de elevación con una resolución espacial de 30 metros a nivel global. Este modelo fue generado a partir de imágenes de radar interferométrico adquiridas durante la misión SRTM en el año 2000, la cual utilizó un radar de apertura sintética (SAR) a bordo del transbordador espacial Endeavour de la NASA. El MDE del SRTM ha sido ampliamente utilizado en estudios geoespaciales debido a su alta precisión y cobertura global, permitiendo aplicaciones en cartografía, modelado hidrológico, análisis de pendientes y aspectos topográficos, así como en la clasificación de coberturas del suelo al integrarse como una variable auxiliar en algoritmos de aprendizaje de máquina. Su disponibilidad gratuita y correcciones posteriores han mejorado la calidad del producto, facilitando su uso en diversas disciplinas científicas y en la planificación territorial (Farr et al., 2007).

A partir del DEM se calcula la pendiente del terreno, la cual muestra la inclinación de la superficie terrestre. Este es un dato clave para análisis como la erosión del suelo, el flujo de agua o la distribución de la vegetación. En áreas de alta pendiente, la vegetación puede ser diferente que, en áreas planas, ya que la escorrentía y la capacidad de retención de agua varían.



5.8. VARIABLES PREDICTORAS

Para entrenar el modelo de clasificación de coberturas del suelo, se integraron datos multiespectrales, radar y topográficos provenientes de Sentinel-1, Sentinel-2 y el Modelo Digital de Elevación (MDE) del SRTM. En total, se utilizaron 32 variables predictoras, incluyendo bandas espectrales de Sentinel-2, índices espectrales derivados, bandas de retrodispersión de Sentinel-1, estadísticas de textura radar, así como datos de elevación y pendiente. La combinación de estas fuentes de información permitió capturar la variabilidad espectral y estructural del paisaje, mejorando la discriminación entre clases de cobertura y uso del suelo. Los datos fueron organizados en una pila de imágenes (stack), donde cada variable representa una dimensión en el espacio de características utilizado para entrenar el modelo de clasificación. Este enfoque ha demostrado ser efectivo para la clasificación de coberturas del suelo al manejar grandes volúmenes de datos y reducir la sensibilidad al ruido, optimizando la precisión del mapa resultante (Belgiu y Drăguț, 2016). La integración de múltiples variables permite al modelo aprender patrones complejos en la distribución espacial de las coberturas, generando un producto cartográfico detallado y representativo del territorio hondureño.


5.9. MODELO DE PREDICCIÓN ESPACIAL

Existen diferentes metodologías para la clasificación de coberturas vegetales, entre las que podemos contar métodos 1) paramétricos y no paramétricos, 2) análogos (foto interpretación y delimitación manual) y digitales (usando algoritmos de agrupación). Los métodos digitales de clasificación pueden ser agrupados en: automáticos, supervisados y semi-supervisados (Chuvieco-Salinero, 2006).

La clasificación de la cobertura y uso del suelo 2024 se realizó mediante algoritmos de aprendizaje de máquinas, específicamente con un modelo de clasificación supervisada basado en Random Forest. El conjunto de datos de entrenamiento se extrae de la pila de imágenes utilizando los puntos de entrenamiento definidos previamente. El clasificador se entrena con estos datos para aprender a diferenciar entre las distintas clases de cobertura del suelo.



Random Forest es un algoritmo de aprendizaje automático basado en ensamblado de árboles de decisión (Figura 4), ampliamente utilizado en la clasificación de coberturas del suelo debido a su robustez y precisión. Este método combina múltiples árboles de decisión generados a partir de subconjuntos aleatorios de los datos de entrenamiento y de las variables predictoras, reduciendo así la varianza y mitigando el sobreajuste (Breiman, 2001). En el contexto de clasificación de coberturas del suelo, Random Forest utiliza características espectrales derivadas de imágenes satelitales, índices espectrales, datos contextuales y texturas para generar predicciones confiables de las distintas categorías de uso de la tierra. Su capacidad para manejar datos de alta dimensionalidad y variables correlacionadas lo hace especialmente adecuado para analizar imágenes multiespectrales y radar, como las obtenidas por Sentinel-1 y Sentinel-2. Además, el algoritmo permite la evaluación de la importancia de las variables, lo que facilita la interpretación de los factores más relevantes en la discriminación de las clases de cobertura. La combinación de múltiples modelos de clasificación en Random Forest mejora la generalización y permite obtener mapas temáticos de alta precisión, fundamentales para la toma de decisiones en la gestión territorial y ambiental.



La integración de los datos procesados y los resultados de la clasificación permitió la generación de un producto cartográfico detallado que representa la cobertura y uso del suelo en Honduras. Este producto es de gran utilidad para la toma de decisiones en la gestión territorial y la planificación ambiental del país.

Para la implementación del modelo de predicción, a partir de las variables predictoras seleccionadas, se desarrolló un código en Google Earth Engine que realiza la clasificación de coberturas mediante el algoritmo Random Forest. Este modelo utiliza 250 árboles de decisión para mejorar la precisión y reducir la variabilidad en los resultados. Posteriormente, con el fin de suavizar la clasificación y eliminar el ruido en los datos, se aplica un filtro de moda, que reasigna las categorías predominantes en ventanas de píxeles adyacentes, garantizando una representación espacialmente coherente.



5.10. EVALUACIÓN DEL MODELO DE PREDICCIÓN ESPACIAL

El proceso de evaluación del Mapa de Cobertura Forestal y Uso del Suelo para Honduras 2024 se fundamenta en el uso de técnicas estadísticas que permiten evaluar la precisión del modelo de clasificación. La metodología incluye la comparación entre los valores de clasificación generados por el modelo y un conjunto de datos de referencia obtenidos mediante muestreo en campo, independientes de las observaciones utilizadas en el entrenamiento. A partir de esta comparación, se genera una matriz de confusión que proporciona información detallada sobre la coincidencia entre las clases predichas y las reales, permitiendo evaluar el desempeño del modelo.

Para evaluar el modelo de predicción espacial, se aplicó un procedimiento de muestreo estratificado en el que el 80% de los datos de campo se utilizó para el entrenamiento del modelo y el 20% restante para la evaluación. Esta división se realizó de manera estratificada dentro de cada clase de cobertura del suelo, garantizando la independencia entre ambos conjuntos y minimizando el riesgo de sobreajuste. De esta manera, el modelo se enfrenta a datos no vistos durante la fase de validación, proporcionando una medida objetiva de su capacidad predictiva.

El proceso de división de datos fue implementado en R (Anexo I) mediante la biblioteca sf, asegurando que cada clase de cobertura estuviera representada en ambos conjuntos de datos. Posteriormente, se aplicaron métricas de evaluación basadas en índice kappa y matriz de confusión para cuantificar la precisión global, la exactitud por clase y la capacidad de generalización del modelo. Además, los datos fueron visualizados en un entorno interactivo mediante leaflet, lo que permitió verificar la distribución geográfica de los puntos de entrenamiento y validación, garantizando una cobertura espacial adecuada. Este enfoque optimiza la robustez del modelo y mejora la fiabilidad del producto cartográfico resultante.

La matriz de confusión es una herramienta estadística utilizada para evaluar la exactitud de los modelos de clasificación supervisada. Se organiza en una tabla de doble entrada donde las filas representan las clases reales y las columnas las clases predichas, permitiendo identificar la frecuencia de aciertos y errores en la clasificación. Este enfoque facilita la estimación de métricas de precisión y el análisis de patrones de error en el modelo (Congalton, 1991)


El índice Kappa es una medida estadística que evalúa la concordancia entre las clasificaciones obtenidas y las reales, ajustando la precisión observada en función de la probabilidad de coincidencia aleatoria. Su valor oscila entre -1 y 1, donde valores cercanos a 1 indican una alta concordancia, mientras que valores cercanos a 0 reflejan una coincidencia cercana al azar (Cohen, 1960). Este índice es ampliamente utilizado en estudios de teledetección y cartografía temática para evaluar la confiabilidad de mapas derivados de imágenes satelitales.



Para lograr esta validación se ha desarrollado un código en R (Anexo II) para evaluar la precisión de la clasificación mediante el análisis de una matriz de confusión, el cálculo de la precisión general y el índice Kappa. Este código implementa una aplicación web interactiva con Shiny para evaluar la precisión de un mapa de clasificación de cobertura y uso del suelo, permitiendo al usuario cargar un archivo TIFF con la clasificación y un archivo Shapefile con puntos de validación independientes. Una vez que los datos han sido cargados, el sistema extrae los valores de clasificación predichos del raster (TIFF) en las ubicaciones exactas de los puntos de validación y los compara con las clases reales proporcionadas en el Shapefile. Esta información se estructura en un dataframe, facilitando su análisis comparativo. Luego, la aplicación genera una matriz de confusión utilizando la función `confusionMatrix` del paquete `caret`, permitiendo evaluar la concordancia entre los valores predichos y reales. Además, se genera una versión de esta matriz con porcentajes normalizados por fila, y se calculan métricas clave como la precisión general del modelo, el índice Kappa, los intervalos de confianza, la precisión nula y el valor p, ofreciendo una visión detallada del desempeño del modelo de clasificación. Finalmente, todos estos resultados se presentan en una interfaz intuitiva con diferentes pestañas, donde el usuario puede visualizar la matriz de confusión en formato tabla, una versión mejorada con el paquete `GT`, la matriz con porcentajes normalizados y las métricas de precisión general, permitiendo una evaluación interactiva y en tiempo real de la calidad del modelo.

La evaluación del Mapa de Cobertura Forestal y Uso del Suelo para Honduras 2024 es un paso crucial para garantizar la precisión y fiabilidad del producto cartográfico. A través del uso de la matriz de confusión, el índice Kappa y los estadísticos de precisión, es posible evaluar la calidad del modelo de clasificación y detectar áreas susceptibles de mejora. La combinación de estos métodos proporciona una visión integral del desempeño del modelo, contribuyendo a la generación de información geoespacial de alta calidad para la toma de decisiones en la gestión territorial y ambiental.






6. RESULTADOS

6.1. DISTRIBUCIÓN DE DATOS DE ENTRENAMIENTO Y EVALUACIÓN


A partir de la base de datos de entrenamiento, generada por los técnicos de ICF, se realizó una separación del 80% de estos para el entrenamiento del modelo de predicción (Figura 6), mediante un muestreo estratificado por cada cobertura, asegurando su representatividad a lo largo de todas las clases.




Estos datos fueron generados para cada regional. La Figura 8 muestra la cantidad de muestras para entrenamiento por región forestal de ICF, esta distribución es representativa tanto del tamaño de la región forestal, cómo de la heterogeneidad de coberturas presentes dentro de esta.



El 20% restante de los datos recopilados por ICF, se utilizaron como observaciones independientes del entrenamiento para la evaluación del modelo de predicción espacial (Figura 8).



Esta selección estratificada se realizó manteniendo la significancia estadística de la proporción de muestras para cada una de las coberturas, a nivel de región forestal, cómo se muestra en la Figura 9.




El 20% restante de los datos recopilados por ICF, se utilizaron como observaciones independientes del entrenamiento para la evaluación del modelo de predicción espacial (Figura 8).




6.2. VARIABLES PREDICTORAS


A partir de las imágenes ópticas, de radar y datos auxiliares, se generaron 32 variables para entrenar el modelo de predicción espacial.










A partir de las imágenes Sentinel-1 se generaron 10 variables a partir de imágenes con polarización VV y VH. Estas fueron la mediana de la colección, desviación estándar y ratios de doble polarización en órbitas ascendente y descendente (Figura 10).










De las imágenes ópticas del Sentinel-2 se utilizaron las bandas B2, B3, B4, B5, B6, B7, B8, B11 y B12. También se calcularon los índices NDVI, NDBI, EVI, SAVI, GNDVI, NDWI, MNDWI, NBR, NDRE1 y NDRE2 (Figura 11), siendo un total de 19 variables derivadas de este producto.







Finalmente, como datos auxiliares, se extrajeron los datos de elevación a partir del DEM del SRTM, y se calculó la pendiente del terreno con estos datos (Figura 12)



6.3 PROPUESTA DE LEYENDA DEL MAPA

Para garantizar la compatibilidad y comparabilidad internacional del Mapa de Cobertura Forestal y Uso de la Tierra de Honduras 2024, se recomienda la adopción de una leyenda de colores estandarizada a nivel mundial. El uso de una clasificación homogénea facilita la integración de los datos nacionales con iniciativas globales de monitoreo ambiental, como el Global Forest Watch y los reportes de la FAO sobre evaluación de los recursos forestales mundiales. En este contexto, se sugiere que la leyenda de colores del mapa forestal de Honduras siga el esquema del Corine Land Cover (CLC), ampliamente utilizado en estudios de cobertura y uso del suelo. La estructura jerárquica del CLC y su codificación cromática permiten representar de manera clara y sistemática las distintas categorías de vegetación y uso de la tierra, optimizando la interpretación visual y la comparación con otros mapas nacionales y regionales.

El Corine Land Cover (CLC) utiliza una metodología jerárquica para la clasificación de coberturas del suelo, basada en un sistema de tres niveles que permite la diferenciación progresiva de las clases. En el primer nivel, se definen cinco categorías generales: tierras artificiales, tierras agrícolas, bosques y áreas naturales, humedales, y masas de agua. En el segundo y tercer nivel, estas clases se subdividen en categorías más específicas según características como el tipo de vegetación, el uso del suelo y la presencia de cuerpos de agua. La leyenda del CLC ha sido estandarizada con una paleta de colores específica para cada categoría, asegurando la coherencia visual en los mapas de cobertura a nivel europeo y facilitando la comparación de datos en distintos periodos de tiempo (Büttner et al., 2004).

En América Latina, diversas iniciativas han adoptado o armonizado la leyenda del Corine Land Cover para la cartografía de coberturas y usos del suelo. Por ejemplo, en México, el Instituto Nacional de Estadística y Geografía (INEGI) ha utilizado una adaptación de la leyenda del CLC en sus series de mapas de uso del suelo y vegetación, permitiendo una mejor integración con estándares internacionales (INEGI, 2016). En Colombia, el Instituto de Hidrología, Meteorología y Estudios Ambientales (IDEAM) ha implementado una clasificación basada en el CLC para la elaboración del mapa nacional de cobertura terrestre, lo que ha facilitado comparaciones con otros países y la evaluación de cambios en la superficie terrestre (IDEAM, 2018). De igual manera, en Brasil, el proyecto MapBiomás ha desarrollado un enfoque armonizado con la leyenda del CLC para generar mapas anuales de cobertura y uso del suelo, mejorando la disponibilidad de información para la gestión ambiental y el monitoreo del cambio climático (Souza et al., 2020).

A partir de esto, se llevó a cabo el análisis de las clases del CLC para identificar su correspondencia con la leyenda del mapa forestal, a partir del significado y sentido espectral y espacial de las coberturas, identificando el correspondiente código de color RGB y Hex para cada clase (Tabla 6).




Código	Categoría Mapa Honduras	Categoría Corine Land Cover (CLC)	Color RGB	Color Hex	Mapa 2024 Hex
1	Bosque Latifoliado Siempre Verde	3.1.1. Bosques de frondosas	000, 255, 000	#00FF00	#006300
2	Bosque De Conífera	3.1.2. Bosques de coníferas	000, 230, 000	#00E600	#427d11
3	Bosque Mixto	3.1.3. Bosques mixtos	000, 204, 000	#00CC00	#4d5100
4	Bosque Latifoliado Deciduo	3.2.2. Vegetación esclerófila	204, 230, 000	#CCE600	#8ca038
5	Bosque De Mangle	4.2.1. Marismas salinas	204, 204, 255	#CCCCFF	#9f1fee
6	Cultivos De Ciclo Corto	2.4.1. Cultivos anuales asociados a cultivos permanentes	255, 200, 100	#FFC864	#ffc0cc
7	Musáceas	2.2.1. Viñedos	255, 215, 000	#FFD700	#004200
8	Caña De Azúcar	2.1.2. Cultivos herbáceos irrigados	255, 255, 000	#FFFF00	#851f4f
9	Café	2.2.4. Cultivos leñosos mixtos	230, 180, 080	#E6B450	#c58000
10	Frutales	2.2.2. Huertos frutales y frutos secos	255, 230, 128	#FFE680	#8775ad
11	Palma Africana	2.2.3. Olivares	210, 180, 140	#D2B48C	#33615f
12	Vegetación Arbustiva/Matorral	3.2.1. Matorrales	230, 204, 000	#E6CC00	#cccccc
13	Pastizales	2.3.1. Pastizales	255, 255, 128	#FFFF80	#f7f45a
14	Sabana De Bosque De Pino	3.2.3. Zonas de transición bosque-matorral	230, 230, 000	#E6E600	#f4f4db
15	Humedales Con Vegetación	4.1.1. Zonas pantanosas	204, 255, 204	#CCFFCC	#ffa600
16	Cuerpos De Agua	5.1.1. Cursos de agua	000, 000, 255	#0000FF	#0000ff
17	Camaroneras/Salineras	4.2.2. Salinas	220, 220, 220	#DCDCDC	#00006f
18	Tejido Urbano Continuo	1.1.1. Tejido urbano continuo	230, 000, 000	#E60000	#f60909
19	Suelo	3.3.3. Espacios naturales sin vegetación	200, 200, 200	#C8C8C8	#7f7f7f
20	Playa	3.3.1. Playas, dunas y arenales	255, 255, 190	#FFFFBE	#ffffff
21	Bancos De Arena	3.3.2. Rocas desnudas	190, 190, 190	#BEBEBE	#00ffff
22	Arrozales	2.1.3. Arrozales	230, 230, 000	#E6E600	#e88573
23	Marismas	4.2.3. Marismas intermareales	204, 230, 230	#CCE6E6	#8ca3ed



6.4. DISTRIBUCIÓN DE COBERTURA FORESTAL Y USOS DE LA TIERRA POR REGIÓN FORESTAL

A continuación, se presenta la distribución de las 23 coberturas forestales y usos de la tierra priorizados para Honduras 2024:

Distribución de Conberturas Forestales y
usos de la Tierra - ICF 2024



6.5. EVALUACIÓN DEL MODELO DE PREDICCIÓN


Después de obtener el modelo de predicción, a partir de las observaciones independientes al entrenamiento, se procedió a desarrollar la evaluación del modelo. En la Tabla 4 se presentan los estadísticos para cada región forestal.

Región forestal	Precisión	Kappa	p-valor significancia
Atlántida	0.94	0.94	0.00000
Biosfera del Río Plátano	0.94	0.93	0.00000
Comayagua	0.91	0.90	0.00000
El Paraíso	0.91	0.91	0.00000
Francisco Morazán	0.9	0.89	0.00000
Islas de la Bahía	0.92	0.91	0.00000
La Mosquitia	0.96	0.96	0.00000
Nor Occidente	0.95	0.95	0.00000
Occidente	0.92	0.91	0.00000
Olancho y Nor Este de Olancho	0.89	0.88	0.00000
Pacífico	0.96	0.95	0.00000
Santa Bárbara	0.88	0.86	0.00000
Valle del Aguan	0.91	0.90	0.00000
Yoro	0.89	0.88	0.00000

Finalmente, se presenta la tabla de precisión general (Tabla 5), la cual muestra la precisión total del modelo de predicción, el valor del índice Kappa obtenido el p-valor de a significancia.

Ubicación	Precisión	Kappa	p-valor significancia
Honduras	0.92	0.91	0.00000





7. CONCLUSIONES Y RECOMENDACIONES

1

La capacidad y alcance de ICF, a partir del personal técnico de sus regionales, han demostrado ser un recurso de alto valor en los ejercicios de generación de mapas de cobertura forestal, gracias a su conocimiento en la distribución y comportamiento de las distintas coberturas dentro de sus territorios.

2

La metodología empleada, que integra datos multiespectrales de Sentinel-2, imágenes de radar de Sentinel-1 y datos auxiliares de elevación y pendiente, ha demostrado ser efectiva para la clasificación precisa de la cobertura forestal y uso del suelo en Honduras. La combinación de estas fuentes de información ha permitido capturar la variabilidad espectral y estructural del paisaje, mejorando la discriminación entre clases de cobertura.

3

El uso del algoritmo Random Forest para la clasificación supervisada ha proporcionado resultados robustos y confiables. La evaluación del modelo mediante técnicas estadísticas, como la matriz de confusión y el índice Kappa, ha mostrado una alta precisión en la clasificación, lo que garantiza la fiabilidad del mapa de cobertura forestal y uso del suelo generado.

4

El Mapa de Cobertura Forestal y Uso de la Tierra 2024 es una herramienta esencial para la planificación y gestión sostenible de los recursos naturales en Honduras. Este mapa no solo facilita el monitoreo de los cambios en la cobertura forestal, sino que también apoya la toma de decisiones informadas en el manejo forestal, la conservación de la biodiversidad y la mitigación del

5

Es crucial continuar con la capacitación del personal técnico en el uso de herramientas de teledetección y sistemas de información geográfica (SIG). Fortalecer las capacidades técnicas de los profesionales involucrados garantizará la sostenibilidad del proyecto y la calidad de los datos generados.

8. BIBLIOGRAFÍA

- Belgiu, M. y Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24–31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Büttner, G., Feranec, J. y Jaffrain, G. (2004). Corine land cover update 2000: Technical guidelines. European Environment Agency.
- Chuvieco-Saliner, E. (2006). Teledetección ambiental: La observación de la Tierra desde el Espacio (2ª ed.). Ariel.
- Cohen, J. (1960). A Coefficient of Agreement for Nominal Scales. *Educational and Psychological Measurement*, 20(1), 37–46. <https://doi.org/10.1177/001316446002000104>
- Congalton, R. G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37(1), 35–46. [https://doi.org/10.1016/0034-4257\(91\)90048-B](https://doi.org/10.1016/0034-4257(91)90048-B)
- Craig Dobson, M., Ulaby, F. T. y Pierce, L. E. (1995). Land-cover classification and estimation of terrain attributes using synthetic aperture radar. *Remote Sensing of Environment*, 51(1), 199–214. [https://doi.org/10.1016/0034-4257\(94\)00075-X](https://doi.org/10.1016/0034-4257(94)00075-X)
- Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Isola, C., Laberinti, P., Martimort, P., Meygret, A., Spoto, F., Sy, O., Marchese, F. y Bargellini, P. (2012). Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services. *Remote Sensing of Environment*, 120, 25–36. <https://doi.org/10.1016/j.rse.2011.11.026>
- ESA's Radar Observatory Mission for GMES Operational Services. (2012). Sentinel-1. ESA SP-1322/1. https://sentinel.esa.int/documents/247904/349449/S1_SP-1322_1.pdf
- European Space Agency. (2023). Sentinel-2. <https://sentinel.esa.int/web/sentinel/missions/sentinel-2>
- FAO. (2020). Global Forest Resources Assessment 2020. FAO. <https://doi.org/10.4060/ca8753en>
- Farr, T. G., Rosen, P. A., Caro, E., Crippen, R., Duren, R., Hensley, S., Kobrick, M., Paller, M., Rodriguez, E., Roth, L., Seal, D., Shaffer, S., Shimada, J., Umland, J., Werner, M., Oskin, M., Burbank, D. y Alsdorf, D. (2007). The Shuttle Radar Topography Mission. *Reviews of Geophysics*, 45(2), Artículo 2005RG000183. <https://doi.org/10.1029/2005RG000183>
- Foody, G. M. (2002). Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 80(1), 185–201. [https://doi.org/10.1016/S0034-4257\(01\)00295-4](https://doi.org/10.1016/S0034-4257(01)00295-4)




- Belgiu, M. y Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of P*
- Gitelson, A. A., Kaufman, Y. J. y Merzlyak, M. N. (1996). Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sensing of Environment*, 58(3), 289–298. [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7)
- Gorelick, N., Hancher, M [Matt], Dixon, M., Ilyushchenko, S., Thau, D [David] y Moore, R [Rebecca] (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18–27. <https://doi.org/10.1016/j.rse.2017.06.031>
- Hansen, M. C., Potapov, P. V., Moore, R [R.], Hancher, M [M.], Turubanova, S. A., Tyukavina, A., Thau, D [D.], Stehman, S. V., Goetz, S. J., Loveland, T. R., Kommareddy, A., Egorov, A., Chini, L., Justice, C. O. y Townshend, J. R. G. (2013). High-resolution global maps of 21st-century forest cover change. *Science (New York, N.Y.)*, 342(6160), 850–853. <https://doi.org/10.1126/science.1244693>
- Huete, A [A.], Justice, C. y Liu, H. (1994). Development of vegetation and soil indices for MODIS-EOS. *Remote Sensing of Environment*, 49(3), 224–234. [https://doi.org/10.1016/0034-4257\(94\)90018-3](https://doi.org/10.1016/0034-4257(94)90018-3)
- Huete, A [A.R] (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295–309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- ICF. (2022). Anuario Estadístico Forestal de Honduras. https://icf.gob.hn/wp-content/uploads/2023/11/Anuario-estadistico-forestal-2022_.pdf
- IDEAM. (2018). Mapa nacional de coberturas de la tierra de Colombia. Instituto de Hidrología, Meteorología y Estudios Ambientales.
- INEGI. (2016). Conjunto de datos vectoriales de uso del suelo y vegetación, serie VI. Instituto Nacional de Estadística y Geografía.
- Kennedy, R. E., Yang, Z. y Cohen, W. B. (2010). Detecting trends in forest disturbance and recovery using yearly Landsat time series: 1. LandTrendr — Temporal segmentation algorithms. *Remote Sensing of Environment*, 114(12), 2897–2910. <https://doi.org/10.1016/j.rse.2010.07.008>
- Key, C. H. y Benson, N. C. (2006). Landscape Assessment: Ground measure of severity, the Composite Burn Index; and Remote sensing of severity, the Normalized Burn Ratio (núm. RMRS-GTR-164-CD: LA 1-51). <https://pubs.usgs.gov/publication/2002085>
- Mather, P. M. y Koch, M. (2011). *Computer Processing of Remotely-Sensed Images*. Wiley. <https://doi.org/10.1002/9780470666517>
- McFeeters, S. K. (1996). The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, 17(7), 1425–1432. <https://doi.org/10.1080/01431169608948714>
- Rodríguez-Galiano, V. F., Ghimire, B., Rogan, J., Chica-Olmo, M. y Rigol-Sánchez, J. P. (2012). An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67, 93–104. <https://doi.org/10.1016/j.isprsjprs.2011.11.002>
- Rouse, J. W., Haas, R. H., Schell, J. A. y Deering, D. W. (1974). Monitoring vegetation systems in the Great Plains with ERTS. *NASA Special Publication*, 351(309).
- Sentinel-1 SAR GRD. (2025). C-band Synthetic Aperture Radar Ground Range Detected, log scaling | Earth Engine Data Catalog. Google for Developers. https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S1_GRD
- Song, Y. y Wang, J. (2019). Mapping Winter Wheat Planting Area and Monitoring Its Phenology Using Sentinel-1 Backscatter Time Series. *Remote Sensing*, 11(4), 449. <https://doi.org/10.3390/rs11040449>
- Souza, C. M., Z. Shimbo, J., Rosa, M. R., Parente, L. L., A. Alencar, A., Rudorff, B. F. T., Hasenack, H., Matsumoto, M., G. Ferreira, L., Souza-Filho, P. W. M., Oliveira, S. W. de Rocha, W. F., Fonseca, A. V., Marques, C. B., Diniz, C. G., Costa, D., Monteiro, D., Rosa, E. R., Vélez-Martin, E., . . . Azevedo, T. (2020). Reconstructing Three Decades of Land Use and Land Cover Changes in Brazilian Biomes with Landsat Archive and Earth Engine. *Remote Sensing*, 12(17), 2735. <https://doi.org/10.3390/rs12172735>
- Xu, H. (2006). Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing*, 27(14), 3025–3033. <https://doi.org/10.1080/01431160600589179>
- Zha, Y., Gao, J. y Ni, S. (2003). Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *International Journal of Remote Sensing*, 24(3), 583–594. <https://doi.org/10.1080/01431160304987>






9. ANEXOS



MAPA DE COBERTURA FORESTAL Y USO DE LA TIERRA, REPÚBLICA DE HONDURAS 2024



Localización Regional

Los límites políticos administrativos de Honduras y límites fronterizos con los países vecinos (El Salvador, Nicaragua y Guatemala) se han incluido en esta información territorial (SINTI). La inclusión de los mismos se ha realizado exclusivamente para relacionarlos con los elementos cartográficos presentados en este mapa.

Los resultados obtenidos para la cobertura forestal y uso de la tierra en Honduras corresponden al año 2024, considerando los datos de los censos de bosques y uso de la tierra realizados en los años 2014, 2018, 2022 y 2024. Los datos de los censos de bosques y uso de la tierra corresponden al año 2024.

Todos los derechos de producción del presente mapa corresponden al Instituto Nacional de Conservación y Desarrollo Forestal, Áreas Protegidas y Vida Silvestre.

Nota:

UNIDAD DE MONITOREO FORESTAL: CENTRO DE INVESTIGACIÓN Y PATRIMONIO FORESTAL (CIPF) AÑO 2025

Elaborado por:

Descripción Cartográfica:

PROYECCIÓN: Universal Transversal Mercator

DATUM: WGS84

ZONA: 16N

UNIDAD DE MEDICIÓN: Metros

FORMATO: Shapefile, Raster

TABLA DE ATRIBUTOS: UTM-8

TOPOLOGÍA: Puntos, Polígonos, Líneas

Porcentaje de Cobertura

No Bosque 48.4%

Bosque 51.6%

Precisión


Exactitud 92%

Error 8%

Instituto Nacional de Conservación y Desarrollo Forestal, Áreas Protegidas y Vida Silvestre – ICF

Link de Descarga: <https://geoportal.icf.gob.hn/geoportal/main>





Anexo I: Proceso de estratificación de datos, 80 % de entrenamiento y 20 % de evaluación.

05/17/2024 Open in Browser Publish

Análisis de Clasificación - Mapa Forestal y de Uso de la Tierra 2024

Cargar archivo TIFF de clasificación

ClasificacionSB_3X3_24_03_2025.tif

Upload complete

Cargar puntos de evaluación (SHP)

4 files

Upload complete

Procesar Datos

Matriz de Confusión Tabla Matriz de Confusión Matriz de Confusión con Porcentajes Precisión General

	Bosque Latifoliado Siempre Verde	Bosque De Conifera	Bosque Mixto	Bosque Latifoliado Deciduo	Bosque De Mangle	Cultivos De Ciclo Corto	Musáceas	Caña De Azúcar	Café	Frutales	F Afr
Bosque Latifoliado Siempre Verde	486	10	8	5	0	0	0	0	44	0	
Bosque De Conifera	2	164	4	4	0	0	0	0	0	0	
Bosque Mixto	0	0	54	2	0	0	0	0	0	0	
Bosque Latifoliado Deciduo	6	5	6	147	0	0	0	0	0	0	
Bosque De Mangle	0	0	0	0	0	0	0	0	0	0	
Cultivos De Ciclo Corto	0	0	0	0	0	74	0	0	0	0	
Musáceas	0	0	0	0	0	0	0	0	0	0	
Caña De Azúcar	0	0	0	0	0	0	0	15	0	0	
Café	24	0	1	2	0	0	0	0	331	0	
Frutales	0	0	0	0	0	0	0	0	0	0	
Palma Africana	0	0	0	0	0	0	0	0	0	0	
Vegetación Arbustiva/Matorral	4	3	1	7	0	0	0	0	3	0	
Pastizales	0	10	0	4	0	31	0	2	3	0	
Sabana De Bosque de Pino	0	0	0	0	0	0	0	0	0	0	
Humedales Con Vegetación	0	0	0	0	0	0	0	0	0	0	

Anexo II: Generación de matriz de evaluación.



ANEXO III. Código en Google Earth Engine para aplicar la metodología desarrollada para el modelo de predicción espacial de cobertura

```
1. //////////////////////////////////////
2. //Código de clasificación Cobertura Forestal y Uso del la Tierra Honduras 2024
3. // Unidad de Monitoreo Forestal - ICF - Honduras
4. //////////////////////////////////////
5.
6.
7. // 1. Definir Zona de Interés
8. var ext = Regional.geometry().bounds();
9.
10. //////////////////////////////////////
11. // 2. Datos
12.
13. //////////////////////////////////////
14. // 2.1 Sentinel 1
15.
16. // Establecer si necesitamos filtro speckle, es una función que consume recursos
17. // computacionales y no mejora en gran medida los resultados de clasificación
18.
19. var speckleFilter = false;
20.
21. // Definir si se debe realizar la corrección de pendiente radiométrica
22. var slopeCorrection = true;
23.
24. // Definir el modelo de elevación que se utilizará en la corrección de pendiente
    radiométrica
25. var glob = ee.Image("USGS/GTOPO30").rename('elevation')
26. var srtm = ee.Image('USGS/SRTMGL1_003').rename('elevation')
27. var elev = srtm.unmask(glob).unmask(0);
28.
29. // Definir período de tiempo - año 2024
30. var startDate = '2024-01-01';
31. var endDate = '2025-01-01';
32.
33. // Sentinel 1 Funciones de procesamiento
34.
35. // Convertir a DB
36. function toDB(img) {
37.   return ee.Image(ee.Image(img).log10().multiply(10.0).copyProperties(img));
38. }
39. // Sigma Lee filter
40. // El filtro de moteado RL de
    https://code.earthengine.google.com/2ef38463ebaf5ae133a478f173fd0ab5
41. // por Guido Lemoine
42. function RefinedLee(img) {
43.   // la imagen debe estar en unidades naturales, es decir, ¡no en dB!
44.   // definir kernels de 3x3
45.   var weights3 = ee.List.repeat(ee.List.repeat(1,3),3);
46.   var kernel3 = ee.Kernel.fixed(3,3, weights3, 1, 1, false);
47.
48.   var mean3 = img.reduceNeighborhood(ee.Reducer.mean(), kernel3);
49.   var variance3 = img.reduceNeighborhood(ee.Reducer.variance(), kernel3);
50.
51.   // Usar muestras con ventanas de 3x3 dentro de ventanas de 7x7 para to
    determinar gardientes y direcciones
```



```

52. var sample_weights = ee.List([[0,0,0,0,0,0,0], [0,1,0,1,0,1,0],[0,0,0,0,0,0,0], [0,1,0,1,0,1,0],
[0,0,0,0,0,0,0], [0,1,0,1,0,1,0],[0,0,0,0,0,0,0]]);
53.
54. var sample_kernel = ee.Kernel.fixed(7,7, sample_weights, 3,3, false);
55.
56. // Calcular media y varianza de las ventanas de muestreo y almacenar como 9 bandas
57. var sample_mean = mean3.neighborhoodToBands(sample_kernel);
58. var sample_var = variance3.neighborhoodToBands(sample_kernel);
59.
60. // Determinar 4 gradientes para las ventanas muestreadas
61. var gradients = sample_mean.select(1).subtract(sample_mean.select(7)).abs();
62. gradients =
gradients.addBands(sample_mean.select(6).subtract(sample_mean.select(2)).abs());
63. gradients =
gradients.addBands(sample_mean.select(3).subtract(sample_mean.select(5)).abs());
64. gradients =
gradients.addBands(sample_mean.select(0).subtract(sample_mean.select(8)).abs());
65.
66. // Y encontrar la gradiente máxima dentro de la gradiente de bandas
67. var max_gradient = gradients.reduce(ee.Reducer.max());
68.
69. // Crea una máscara para los píxeles de banda que tienen el gradiente máximo
70. var gradmask = gradients.eq(max_gradient);
71.
72. // Bandas de máscara de gradiente duplicadas: cada gradiente representa 2
direcciones
73. gradmask = gradmask.addBands(gradmask);
74.
75. // Determinar las 8 direcciones
76. var directions =
sample_mean.select(1).subtract(sample_mean.select(4)).gt(sample_mean.select(4).subtract(
sample_mean.select(7))).multiply(1);
77. directions =
directions.addBands(sample_mean.select(6).subtract(sample_mean.select(4)).gt(sample_m
ean.select(4).subtract(sample_mean.select(2))).multiply(2));
78. directions =
directions.addBands(sample_mean.select(3).subtract(sample_mean.select(4)).gt(sample_m
ean.select(4).subtract(sample_mean.select(5))).multiply(3));
79. directions =
directions.addBands(sample_mean.select(0).subtract(sample_mean.select(4)).gt(sample_m
ean.select(4).subtract(sample_mean.select(8))).multiply(4));
80. // Los siguientes 4 son los no() de los 4 anteriores
81. directions = directions.addBands(directions.select(0).not().multiply(5));
82. directions = directions.addBands(directions.select(1).not().multiply(6));
83. directions = directions.addBands(directions.select(2).not().multiply(7));
84. directions = directions.addBands(directions.select(3).not().multiply(8));
85.
86. // Enmascarar todos los valores que no sean del 1 al 8
87. directions = directions.updateMask(gradmask);
88.
89. // "colapsar" la pila en una imagen de banda única (debido al enmascaramiento, cada
píxel tiene solo un valor (1-8) en su banda direccional y está marcado de otra manera)
90. directions = directions.reduce(ee.Reducer.sum());
91.
92. //var pal = ['ffffff','ff0000','ffff00','00ff00','00ffff','0000ff','ff00ff','000000'];
93. //Map.addLayer(directions.reduce(ee.Reducer.sum()), {min:1, max:8, palette: pal},
'Directions', false);
94.
95. var sample_stats = sample_var.divide(sample_mean.multiply(sample_mean));
96.
97. // Calcular localNoiseVariance

```




```

98. var sigmaV =
sample_stats.toArray().arraySort().arraySlice(0,0,5).arrayReduce(ee.Reducer.mean(), [0]);
99.
100. // Configurar los núcleos 7*7 para las estadísticas direccionales
101. var rect_weights =
ee.List.repeat(ee.List.repeat(0,7),3).cat(ee.List.repeat(ee.List.repeat(1,7),4));
102.
103. var diag_weights = ee.List([[1,0,0,0,0,0,0], [1,1,0,0,0,0,0], [1,1,1,0,0,0,0],
104. [1,1,1,1,0,0,0], [1,1,1,1,1,0,0], [1,1,1,1,1,1,0], [1,1,1,1,1,1,1]]);
105.
106. var rect_kernel = ee.Kernel.fixed(7,7, rect_weights, 3, 3, false);
107. var diag_kernel = ee.Kernel.fixed(7,7, diag_weights, 3, 3, false);
108.
109. // Cree pilas para la media y la varianza utilizando los núcleos originales. Enmascare
con la dirección relevante. var dir_mean = img.reduceNeighborhood(ee.Reducer.mean(),
rect_kernel).updateMask(directions.eq(1));
110. var dir_var = img.reduceNeighborhood(ee.Reducer.variance(),
rect_kernel).updateMask(directions.eq(1));
111.
112. dir_mean = dir_mean.addBands(img.reduceNeighborhood(ee.Reducer.mean(),
diag_kernel).updateMask(directions.eq(2)));
113. dir_var = dir_var.addBands(img.reduceNeighborhood(ee.Reducer.variance(),
diag_kernel).updateMask(directions.eq(2)));
114.
115. // y agrega las bandas para los núcleos rotados
116. for (var i=1; i<4; i++) {
117. dir_mean = dir_mean.addBands(img.reduceNeighborhood(ee.Reducer.mean(),
rect_kernel.rotate(i)).updateMask(directions.eq(2*i+1)));
118. dir_var = dir_var.addBands(img.reduceNeighborhood(ee.Reducer.variance(),
rect_kernel.rotate(i)).updateMask(directions.eq(2*i+1)));
119. dir_mean = dir_mean.addBands(img.reduceNeighborhood(ee.Reducer.mean(),
diag_kernel.rotate(i)).updateMask(directions.eq(2*i+2)));
120. dir_var = dir_var.addBands(img.reduceNeighborhood(ee.Reducer.variance(),
diag_kernel.rotate(i)).updateMask(directions.eq(2*i+2)));
121. }
122.
123. // "colapsar" la pila en una imagen de banda única (debido al enmascaramiento, cada
píxel tiene solo un valor en su banda direccional y, de lo contrario, está enmascarado)
124. dir_mean = dir_mean.reduce(ee.Reducer.sum());
125. dir_var = dir_var.reduce(ee.Reducer.sum());
126.
127. // A finalmente generar el valor filtrado
128. var varX =
dir_var.subtract(dir_mean.multiply(dir_mean).multiply(sigmaV)).divide(sigmaV.add(1.0));
129.
130. var b = varX.divide(dir_var);
131.
132. var result = dir_mean.add(b.multiply(img.subtract(dir_mean)));
133. return ee.Image(result.arrayFlatten(['sum'])).copyProperties(img, ['system:time_start']);
134. }
135.
136. // Función para encapsular todo lo anterior en uno
137. var cleanS1 = function(img){
138. var imgOut = ee.Image(RefinedLee(img.select(0)))
139. return imgOut
140. }
141.
142.
143. // Función de corrección para la corrección de pendiente radiométrica en una

```



```

144. // Colección de imágenes Sentinel-1
145. // https://github.com/ESA-PhiLab/radiometric-slope-correction/tree/master/javascript
146. var slope_correction = function (collection,
147.     options
148. ) {
149.
150.     // set defaults if undefined options
151.     options = options || {};
152.     var model = options.model || 'volume';
153.     var elevation = options.elevation || ee.Image('USGS/SRTMGL1_003');
154.     var buffer = options.buffer || 0;
155.
156.     // Necesitamos una imagen de 90 grados en radianes para un par de cálculos
157.     var ninetyRad = ee.Image.constant(90).multiply(Math.PI/180);
158.
159.     // Modelo volumétrico Hoekman 1990
160.     function _volume_model(theta_iRad, alpha_rRad) {
161.
162.         var nominator = (ninetyRad.subtract(theta_iRad).add(alpha_rRad)).tan();
163.         var denominator = (ninetyRad.subtract(theta_iRad)).tan();
164.         return nominator.divide(denominator);
165.     }
166.
167.     // modelo de superficie Ulander et al. 1996
168.     function _surface_model(theta_iRad, alpha_rRad, alpha_azRad) {
169.
170.         var nominator = (ninetyRad.subtract(theta_iRad)).cos();
171.         var denominator = alpha_azRad.cos()
172.             .multiply((ninetyRad.subtract(theta_iRad).add(alpha_rRad)).cos());
173.         return nominator.divide(denominator);
174.     }
175.
176.     // Función buffer
177.     function _erode(img, distance) {
178.
179.         var d = (img.not().unmask(1)
180.             .fastDistanceTransform(30).sqrt()
181.             .multiply(ee.Image.pixelArea().sqrt()));
182.
183.         return img.updateMask(d.gt(distance));
184.     }
185.
186.     // calcular máscaras
187.     function _masking(alpha_rRad, theta_iRad, proj, buffer) {
188.
189.         // escala, donde pendiente > ángulo de visión del radar
190.         var layover = alpha_rRad.lt(theta_iRad).rename('layover');
191.
192.         // sombra
193.         var shadow =
194.             alpha_rRad.gt(ee.Image.constant(-1).multiply(ninetyRad.subtract(theta_iRad))).rename('shadow');
195.
196.         // combinar escala y sombra
197.         var mask = layover.and(shadow);
198.
199.         // añadir buffer a la máscara final
200.         if (buffer > 0)
201.             mask = _erode(mask, buffer);
202.
203.         return mask.rename('no_data_mask');

```




```

144. // Colección de imágenes Sentinel-1
145. // https://github.com/ESA-PhiLab/radiometric-slope-correction/tree/master/javascript
146. var slope_correction = function (collection,
147.                                options
148.                                ){
149.
150.    // set defaults if undefined options
151.    options = options || {};
152.    var model = options.model || 'volume';
153.    var elevation = options.elevation || ee.Image('USGS/SRTMGL1_003');
154.    var buffer = options.buffer || 0;
155.
156.    // Necesitamos una imagen de 90 grados en radianes para un par de cálculos
157.    var ninetyRad = ee.Image.constant(90).multiply(Math.PI/180);
158.
159.    // Modelo volumétrico Hoekman 1990
160.    function _volume_model(theta_iRad, alpha_rRad){
161.
162.        var nominator = (ninetyRad.subtract(theta_iRad).add(alpha_rRad)).tan();
163.        var denominator = (ninetyRad.subtract(theta_iRad)).tan();
164.        return nominator.divide(denominator);
165.    }
166.
167.    // modelo de superficie Ulander et al. 1996
168.    function _surface_model(theta_iRad, alpha_rRad, alpha_azRad){
169.
170.        var nominator = (ninetyRad.subtract(theta_iRad)).cos();
171.        var denominator = alpha_azRad.cos()
172.        .multiply((ninetyRad.subtract(theta_iRad).add(alpha_rRad)).cos());
173.        return nominator.divide(denominator);
174.    }
175.
176.    // Función buffer
177.    function _erode(img, distance) {
178.
179.        var d = (img.not().unmask(1)
180.        .fastDistanceTransform(30).sqrt()
181.        .multiply(ee.Image.pixelArea().sqrt()));
182.
183.        return img.updateMask(d.gt(distance));
184.    }
185.
186.    // calcular máscaras
187.    function _masking(alpha_rRad, theta_iRad, proj, buffer){
188.
189.    // escala, donde pendiente > ángulo de visión del radar
190.        var layover = alpha_rRad.lt(theta_iRad).rename('layover');
191.
192.    // sombra
193.        var shadow =
194.        alpha_rRad.gt(ee.Image.constant(-1).multiply(ninetyRad.subtract(theta_iRad))).rename('shadow');
195.
196.    // combinar escala y sombra
197.        var mask = layover.and(shadow);
198.
199.    // añadir buffer a la máscara final
200.        if (buffer > 0)
201.            mask = _erode(mask, buffer);
202.        return mask.rename('no_data_mask');

```



```

203. }
204.
205. function _correct(image){
206.
207. // obtener la geometría y proyección de la imagen
208.     var geom = image.geometry();
209.     var proj = image.select(1).projection();
210.
211. // obtener el ángulo de dirección de la mirada
212.     var heading = (ee.Terrain.aspect(
213.         image.select('angle')).reduceRegion(ee.Reducer.mean(), geom, 1000).get('aspect')
214.     );
215.
216. // geometria Radar
217.     var theta_iRad = image.select('angle').multiply(Math.PI/180).clip(geom);
218.     var phi_iRad = ee.Image.constant(heading).multiply(Math.PI/180);
219.
220. // Geometria del terreno
221.     var alpha_sRad = ee.Terrain.slope(elevation).select('slope')
222.         .multiply(Math.PI/180).setDefaultProjection(proj).clip(geom);
223.     var phi_sRad = ee.Terrain.aspect(elevation).select('aspect')
224.         .multiply(Math.PI/180).setDefaultProjection(proj).clip(geom);
225.
226.     // Modelo geometria
227.
228.     //reducir a 3 ángulos
229.     var phi_rRad = phi_iRad.subtract(phi_sRad);
230.
231.     // pendiente en el rango
232.     var alpha_rRad = (alpha_sRad.tan().multiply(phi_rRad.cos())).atan();
233.
234.     // pendiente de stepness en acimut
235.     var alpha_azRad = (alpha_sRad.tan().multiply(phi_rRad.sin())).atan();
236.
237.     // Gamma_nought
238.     var gamma0 = image.divide(theta_iRad.cos());
239.
240.     // modelos
241.     if (model == 'volume')
242.         var corrModel = _volume_model(theta_iRad, alpha_rRad);
243.
244.     if (model == 'surface')
245.         var corrModel = _surface_model(theta_iRad, alpha_rRad, alpha_azRad);
246.
247.     if (model == 'direct')
248.         var corrModel = _direct_model(theta_iRad, alpha_rRad, alpha_azRad);
249.
250.     // aplicar modelo para derivar gamma0_flat
251.     var gamma0_flat = gamma0.divide(corrModel);
252.     gamma0_flat = gamma0_flat.where(gamma0_flat.lte(0), image)
253.
254.     // obtener Layover/Shadow mask
255.     var mask = _masking(alpha_rRad, theta_iRad, proj, buffer);
256.
257.     //gamma_flat y mascara
258.     return gamma0_flat.copyProperties(image);
259.
260.
261. }
262.

```



```

263. // Ejecutar la función de corrección y devolver la colección corregida
264. return collection.map(_correct);
265.
266. };
267.
268.
269.
270. // Función para generar una pila de imágenes S1 para AOI
271. function getSARstack(aoi){
272.
273.   var s1 = ee.ImageCollection('COPERNICUS/S1_GRD_FLOAT')
274.     .filterBounds(aoi)
275.     .filterDate(startDate, endDate)
276.     .filterMetadata('resolution_meters', 'equals', 10)
277.     .filter(ee.Filter.eq('instrumentMode', 'IW'));
278.
279.   if (slopeCorrection){
280.     s1 = slope_correction(
281.       s1,
282.       {'model': 'volume', // Modelo de corrección: volumen recomendado para la
        clasificación de la cobertura del suelo   'elevation': elev, // Modelo de elevación
283.       'buffer': 0 // buffer en metros
284.     );
285.   }
286. }
287.
288. var asc = s1.filter(ee.Filter.eq('orbitProperties_pass', 'ASCENDING'));
289. var desc = s1.filter(ee.Filter.eq('orbitProperties_pass', 'DESCENDING'));
290.
291. var asc_vv = asc
292.   .filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VV'))
293.   .select(['VV', 'angle']);
294. var asc_vh = asc
295.   .filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VH'))
296.   .select(['VH', 'angle']);
297.
298. var desc_vv = desc
299.   .filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VV'))
300.   .select(['VV', 'angle']);
301. var desc_vh = desc
302.   .filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VH'))
303.   .select(['VH', 'angle']);
304.
305. if (speckleFilter){
306.
307.   asc_vv = asc_vv.map(cleanS1);
308.   asc_vh = asc_vh.map(cleanS1);
309.   desc_vv = desc_vv.map(cleanS1);
310.   desc_vh = desc_vh.map(cleanS1);
311.
312. }
313.
314. var stack = asc_vh.select(0).median().rename('asc_vh_median')
315.   .addBands(asc_vv.select(0).median().rename('asc_vv_median'))
316.   .addBands(desc_vv.select(0).median().rename('desc_vv_median'))
317.   .addBands(desc_vh.select(0).median().rename('desc_vh_median'))
318.
319.   .addBands(desc_vh.select(0).median().divide(desc_vv.select(0).median()).rename('desc_dpol
   _median'))

```




```

319.
.addBands(asc_vh.select(0).median().divide(asc_vv.select(0).median()).rename('asc_dpol_m
edian'))
320. .addBands(asc_vv.select(0).reduce(ee.Reducer.stdDev()).rename('asc_vv_stdDev'))
321. .addBands(asc_vh.select(0).reduce(ee.Reducer.stdDev()).rename('asc_vh_stdDev'))
322. .addBands(desc_vv.select(0).reduce(ee.Reducer.stdDev()).rename('desc_vv_stdDev'))
323. .addBands(desc_vh.select(0).reduce(ee.Reducer.stdDev()).rename('desc_vh_stdDev'))
324.
325.
326. // Convertir DB
327. stack = toDB(stack)
328. // Multiplique por 1000 y convierta a número entero para reducir el tamaño de los
archivos al exportar
329. stack = stack.multiply(1000).round().int()
330.
331. return stack
332. }
333.
334. // Consigue stack de Sentinel 1
335. var S1Stack = getSARstack(Regional);
336.
337. //////////////////////////////////////
338. // 2.2 Sentinel 2
339.
340. // Función de enmascaramiento de nubes y sombras para Sentinel-2
341. function maskCloudsS2(image) {
342.   var cloudProbThreshold = 40;
343.   var qa60 = image.select('QA60').bitwiseAnd(1 << 10).eq(0);
344.   var cloudProbability = image.select('MSK_CLDPRB').lte(cloudProbThreshold);
345.   var scl = image.select('SCL');
346.   var sclMask = scl.neq(3).and(scl.neq(8));
347.   return image.updateMask(qa60).updateMask(cloudProbability).updateMask(sclMask);
348. }
349.
350. // Colección imágenes Sentinel 2 para
351. var sen2 =
ee.ImageCollection('COPERNICUS/S2_SR_HARMONIZED')//COPERNICUS/S2_HARMONIZED
352.   .filterDate(startDate, endDate)
353.   .filterBounds(ext)
354.   .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE', 60))
355.   .map(maskCloudsS2);
356. var sen2Median = sen2.median().clip(Regional);
357.
358. // Índices Espectrales Sentinel-2
359. //NDVI
360. var S2ndvi = sen2Median.normalizedDifference(['B8', 'B4']).rename("S2ndvi").float();
361.
362. //NDBI
363. var S2ndbi = sen2Median.normalizedDifference(['B11', 'B8']).rename("S2ndbi").float();
364.
365. // EVI
366. var S2evi = sen2Median.expression(
367.   '2.5 * ((NIR - RED) / (NIR + 6 * RED - 7.5 * BLUE + 1))', {
368.     'NIR': sen2Median.select('B8'),
369.     'RED': sen2Median.select('B4'),
370.     'BLUE': sen2Median.select('B2')
371.   }
372. ).rename("S2evi").float();
373.
374. // SAVI
375. var S2savi = sen2Median.expression(
376.   '(1.5 * (NIR - RED)) / (NIR + RED + 0.5)', {

```



```

377. 'NIR': sen2Median.select('B8'),
378. 'RED': sen2Median.select('B4')
379. }
380. ).rename("S2savi").float();
381.
382. // GNDVI
383. var S2gndvi = sen2Median.normalizedDifference(['B8', 'B3']).rename("S2gndvi").float();
384.
385. // NDWI
386. var S2ndwi = sen2Median.normalizedDifference(['B3', 'B8']).rename("S2ndwi").float();
387.
388. // MNDWI
389. var S2mndwi = sen2Median.normalizedDifference(['B3',
'B11']).rename("S2mndwi").float();
390.
391. // NBR
392. var S2nbr = sen2Median.normalizedDifference(['B8', 'B12']).rename("S2nbr").float();
393.
394. // NDRE1
395. var S2ndre1 = sen2Median.normalizedDifference(['B8A', 'B5']).rename("S2ndre1").float();
396.
397. // NDRE2
398. var S2ndre2 = sen2Median.normalizedDifference(['B8A', 'B6']).rename("S2ndre2").float();
399.
400.
401. // 2.3 Datos Auxiliares
402.
403. // Modelo Digital de Elevaciones y Pendiente
404. var SRTM = ee.Image("USGS/SRTMGL1_003").clip(ext).float();
405. var Slope = ee.Terrain.slope(SRTM).float();
406.
407.
408. // Stack de Datos Auxiliares
409. var AuxiliarStack = SRTM //
410. .addBands(Slope)
411.
412. // 3. Unir todos los datos
413.
414.
415. // Combinar todas las en un Stack
416. var Ladrillo = sen2Median.select(['B2',"B3","B4","B5","B6","B7","B8","B9","B11","B12"])
417. .addBands(S2ndvi)
418. .addBands(S2ndbi)
419. .addBands(S2evi)
420. .addBands(S2savi)
421. .addBands(S2gndvi)
422. .addBands(S2ndwi)
423. .addBands(S2mndwi)
424. .addBands(S2nbr)
425. .addBands(S2ndre1)
426. .addBands(S2ndre2)
427. .addBands(S1Stack)
428. .addBands(AuxiliarStack);
429.
430.
431. // Nombres de variables en stack
432. var Ladrillo_bands = Ladrillo.bandNames();
433.
434. // 4. Entrenamiento de Modelo de Predicción para Uso del Suelo

```



```

377. 'NIR': sen2Median.select('B8'),
378. 'RED': sen2Median.select('B4')
379. }
380. ).rename("S2savi").float();
381.
382. // GNDVI
383. var S2gndvi = sen2Median.normalizedDifference(['B8', 'B3']).rename("S2gndvi").float();
384.
385. // NDWI
386. var S2ndwi = sen2Median.normalizedDifference(['B3', 'B8']).rename("S2ndwi").float();
387.
388. // MNDWI
389. var S2mndwi = sen2Median.normalizedDifference(['B3',
'B11']).rename("S2mndwi").float();
390.
391. // NBR
392. var S2nbr = sen2Median.normalizedDifference(['B8', 'B12']).rename("S2nbr").float();
393.
394. // NDRE1
395. var S2ndre1 = sen2Median.normalizedDifference(['B8A', 'B5']).rename("S2ndre1").float();
396.
397. // NDRE2
398. var S2ndre2 = sen2Median.normalizedDifference(['B8A', 'B6']).rename("S2ndre2").float();
399.
400.
401. // 2.3 Datos Auxiliares
402.
403. // Modelo Digital de Elevaciones y Pendiente
404. var SRTM = ee.Image("USGS/SRTMGL1_003").clip(ext).float();
405. var Slope = ee.Terrain.slope(SRTM).float();
406.
407.
408. // Stack de Datos Auxiliares
409. var AuxiliarStack = SRTM //
410. .addBands(Slope)
411.
412. // 3. Unir todos los datos
413.
414.
415. // Combinar todas las en un Stack
416. var Ladrillo = sen2Median.select(['B2',"B3","B4","B5","B6","B7","B8","B9","B11","B12"])
417. .addBands(S2ndvi)
418. .addBands(S2ndbi)
419. .addBands(S2evi)
420. .addBands(S2savi)
421. .addBands(S2gndvi)
422. .addBands(S2ndwi)
423. .addBands(S2mndwi)
424. .addBands(S2nbr)
425. .addBands(S2ndre1)
426. .addBands(S2ndre2)
427. .addBands(S1Stack)
428. .addBands(AuxiliarStack);
429.
430.
431. // Nombres de variables en stack
432. var Ladrillo_bands = Ladrillo.bandNames();
433.
434. // 4. Entrenamiento de Modelo de Predicción para Uso del Suelo

```




```

436.
437.
438.
439. // Agregar campo con valor aleatorio para muestras y usarlos para separar 80%
entrenamiento and 20% evaluación
440. var trainingSample = Muestras;
441.
442.
443. // Muestras de valores de bandas de Ladrillo para entrenamiento y evaluación
444. var training = Ladrillo.sampleRegions({
445.   collection: trainingSample,
446.   properties: ['CODIGO_NUM'],
447.   scale: 10,
448.   tileScale: 2
449. });
450.
451. // Entrenar el clasificador Random Forest
452. var rfClassifier = ee.Classifier.smileRandomForest({
453.   numberOfTrees: 250,
454.   variablesPerSplit: 15,
455.   minLeafPopulation: 1
456. }).train({
457.   features: training,
458.   classProperty: 'CODIGO_NUM',
459.   inputProperties: Ladrillo.bandNames()
460. });
461.
462. ///////////////////////////////////////////////////
463. // 5. Clasificación de la Imagen Completa
464.
465. // Función para clasificar cada Tile Individualmente
466. function classifyTile(tile) {
467.   return Ladrillo.clip(tile).classify(rfClassifier);
468. }
469.
470. // Crear una cuadrícula de mosaicos sobre extHN y clasificar cada uno
471. var tiles = ext.coveringGrid(ee.Projection('EPSG:4326').atScale(10000));
472. var classifiedTiles = tiles.map(classifyTile);
473.
474. // Combinar todos los Tiles Clasificados
475. var classificationRF = ee.ImageCollection(classifiedTiles).mosaic();
476.
477. ///////////////////////////////////////////////////
478. // 6. Exportar la Clasificación Final
479.
480. // Export the classified image to Google Drive
481. Export.image.toDrive({
482.   image: classificationRF.clip(ext),
483.   description: 'ClasificacionNorOccidente',
484.   folder: 'LULC_HN2024',
485.   scale: 10,
486.   maxPixels: 1e13,
487.   fileFormat: 'GeoTIFF'
488. });
489.
490. // Aplicar filtro de mayoría para suavizar el resultado de la clasificación
491. var kernel = ee.Kernel.square({radius: 1}); // 3x3 kernel
492. var smoothedImage = classificationRF.clip(ext).focal_mode({kernel: kernel});
493.
494. // Exportar clasificación suavizada a Google Drive

```



```
495. Export.image.toDrive({
496.  image: smoothedImage,
497.  description: 'Clasificación_3x3_NorOccidente',
498.  folder: 'LULC_HN2024',
499.  scale: 10,
500.  maxPixels: 1e13,
501.  fileFormat: 'GeoTIFF'
502. });
503.
504. // Aplicar filtro de mayoría para suavizar el resultado de la clasificación
505. var kernel2 = ee.Kernel.square({radius: 2}); // 5x5 kernel
506. var smoothedImage2 = classificationRF.clip(ext).focal_mode({kernel: kernel2});
507.
508. // Exportar clasificación suavizada a Google Drive
509. Export.image.toDrive({
510.  image: smoothedImage2,
511.  description: 'Clasificación_5x5_NorOccidente',
512.  folder: 'LULC_HN2024',
513.  scale: 10,
514.  maxPixels: 1e13,
515.  fileFormat: 'GeoTIFF'
516. });
517.
```





HONDURAS
GOBIERNO DE LA REPÚBLICA