



*"Por un Desarrollo Agrario  
Integral y Sostenible"*

# **UNIVERSIDAD NACIONAL AGRARIA**

## **FACULTAD DE AGRONOMÍA**

### **Trabajo de Tesis**

**Usos y aplicaciones de la teledetección para  
monitorización agrícola en Nicaragua con  
tres estudios de casos**

#### **Autores**

**Br. América Lucía Téllez Reyes**  
**Br. Guillermo Javier Ortega Flores**

#### **Asesores**

**Ing. Isidro Humberto Salinas Marcenaro**  
**Ing. José René Jarquín Díaz**

**Managua, Nicaragua**  
**Septiembre, 2021**



“Por un Desarrollo  
Agrario  
Integral y Sostenible”

# UNIVERSIDAD NACIONAL AGRARIA

## FACULTAD DE AGRONOMÍA

### Trabajo de Tesis

## Usos y aplicaciones de la teledetección para monitorización agrícola en Nicaragua con tres estudios de casos

### Autores

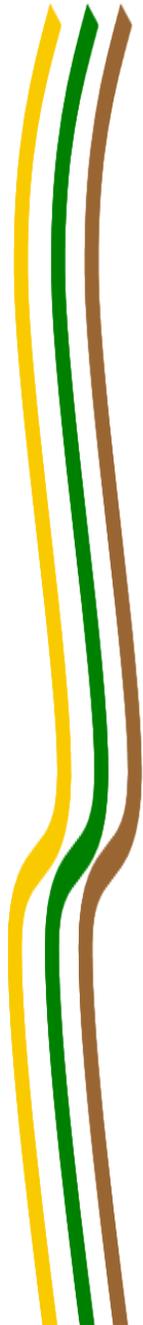
**Br. América Lucía Téllez Reyes**  
**Br. Guillermo Javier Ortega Flores**

### Asesores

**Ing. Isidro Humberto Salinas Marcenaro**  
**Ing. José René Jarquín Díaz**

Presentado a la consideración del honorable tribunal  
examinador como requisito final para optar al grado  
de Ingeniero Agrónomo

**Managua, Nicaragua**  
**Septiembre, 2021**



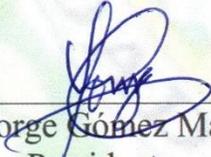
Hoja de aprobación del Tribunal Examinador

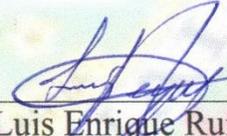
Este trabajo de graduación fue evaluado y aprobado por el honorable Tribunal Examinador designado por el Decanato de la Facultad de Agronomía como requisito final para optar al título profesional de:

*Ingeniero Agrónomo*

---

Miembros del Tribunal Examinador

  
MSc. Jorge Gómez Martínez  
Presidente

  
Ing. Luis Enrique Ruíz Obando  
Secretario

  
MSc. Gerardo Murillo Malespín  
Vocal

Lugar y Fecha: Sala Magna Facultad de Agronomía 29 de septiembre del 2021

## **DEDICATORIA**

A mis padres **Martha Lorena Reyes Hernández** y **Augusto César Téllez Martínez**, como los pilares fundamentales de mi vida, motores de mi motivación y la fuerza que me impulsa a ser cada día mejor.

A mi abuelo, **José Florencio Téllez Robles** (QEPD), quien fue una persona admirable, de corazón noble. Él quería que estudiara esta carrera y seguramente hoy estaría orgulloso de mí.

*Br. América Lucía Téllez Reyes*

## **DEDICATORIA**

A mi madre, Sra. **Blanca Clemencia Flores**, quien con su amor y dedicación siempre me motivó a seguir adelante y no rendirme y a quien más le debo ser una persona de bien. A ella, eternas gracias.

*Br. Guillermo Javier Ortega Flores*

## **AGRADECIMIENTO**

Agradezco principalmente a **Dios** por la vida y la sabiduría necesarias para culminar mi carrera profesional.

A mi amigo, Juan Manuel Rocha Medina, por ser una persona generosa y leal, que siempre me extendió su apoyo y solidaridad. De igual manera agradezco al vice ministro del Ministerio Agropecuario, Dr. Isidro Antonio Rivera Guadamuz por brindarme su confianza.

A nuestros asesores, por aceptar el reto de acompañarnos en este proceso y compartir sus conocimientos y experiencias, dedicando el tiempo necesario para ayudarnos construir este proyecto.

A mis compañeros y amigos de la universidad: Cristhel Marcela Suárez Villagra, Greyci Aracelly Blandón Díaz, Jessenia del Carmen Torres Soza, Marilena del Carmen Gutiérrez Rivas, Francisco Javier Talavera Gutiérrez, Jonny Alberto Muñoz Romero, Nelson Vásquez Peña, grandes personas que me apoyaron siempre con sus consejos y su amistad.

A mis compañeros de trabajo en el Ministerio Agropecuario: Bayardo Efraín Flores Espinoza, Olga Carolina Cuaresma Estrada, Elmer Valle Silva, Yader Noel Moreno, Julio César Gago Medal.

A la Unión Nacional de Agricultores y Ganaderos (UNAG) junto al Programa Campesino a Campesino, ya que, gracias a esta organización, recibí seminarios y participé en diferentes capacitaciones que despertaron en mí, el interés por estudiar la carrera de Agronomía.

Y especialmente agradezco a la Universidad Nacional Agraria por haber contribuido a mi formación y permitirme adquirir conocimientos científicos que me serán útiles durante toda mi vida.

*Br. América Lucía Téllez Reyes*

## AGRADECIMIENTO

Agradezco primero a Dios Dador de vida y sabiduría.

A nuestros asesores, ya que con su sabiduría y dedicación nos guiaron desde el inicio hasta el final de este proyecto y siempre mostraron empatía y disposición para ayudarnos.

A mi amigo Juan Manuel Rocha Medina, a quien conocí cuando cursábamos segundo año de la carrera y siempre me demostró su apoyo y confianza de la manera más noble y sincera, así mismo, agradezco el apoyo del vice ministro del Ministerio Agropecuario, Dr. Isidro Antonio Rivera Guadamuz de quien fue la idea del tema que se aborda en este estudio.

A mi padre (QEPD), César Guillermo Lacayo Dávila, sus consejos siempre calaron en mí. A mis hermanos Yader Alberto Ortega Flores, Mariela Nohemí Ortega Flores y Wilberth Daniel Dávila Flores, quien participó activamente en este trabajo brindándonos sus valiosas opiniones, a mi cuñado Marlon Antonio Gaitán y a mi sobrina Esperanza Nahomi Gaitán.

A mis compañeros de estudios que fueron ejemplo y motivo de ánimo durante mi preparación: Lía Rocha Palacios, Nelson Vásquez Peña, Nelson Martínez, Jhonny Muñoz Romero, Mery Ríos, Kevin Larios, Tania Valle, Virginia Lezama, Marylena Gutiérrez, Jairo Calderón, Juan Carlos Sánchez, Waldir Escoto, Francisco Javier Talavera, Greyci Blandón y Cristhel Suárez.

Al Ministerio Agropecuario (MAG) por permitirme formar parte de su equipo de trabajo que labora en pro de alcanzar de la soberanía alimentaria del país y donde he tenido la oportunidad de desarrollarme profesionalmente creciendo en conocimiento. A mis compañeros de trabajo del Ministerio Agropecuario: Julio César Gago Medal, Darwin Ariel Zeledón, Yader Noel Moreno, Elmer Valle Silva, Francisco Javier Fonseca, Ulises Osorio, Alberto González, Raúl Duriez, Bayardo Flores Espinoza y María Teresa Aráuz Rueda.

A la Universidad Nacional Agraria por permitirme alcanzar el desarrollo profesional en esta maravillosa profesión que es la agronomía y a las personas que me motivaron a emprender esta carrera de mi vida: Walter Rafael Castillo Mejía, Héctor Gaitán Averruz y a mi amiga Eveling Mazariegos Solís, sus valiosos consejos siempre fueron de gran utilidad.

*Br. Guillermo Javier Ortega Flores*

## ÍNDICE DE CONTENIDO

SECCIÓN	PÁGINA
<b>DEDICATORIA</b>	<b>i</b>
<b>AGRADECIMIENTO</b>	<b>ii</b>
<b>ÍNDICE DE CUADROS</b>	<b>iii</b>
<b>ÍNDICE DE FIGURAS</b>	<b>iv</b>
<b>ÍNDICE DE ANEXOS</b>	<b>vi</b>
<b>RESUMEN</b>	<b>vii</b>
<b>ABSTRACT</b>	<b>viii</b>
<b>I. INTRODUCCIÓN</b>	<b>1</b>
<b>II. OBJETIVOS</b>	<b>3</b>
2.1 Objetivo general	3
2.2 Objetivos específicos	3
<b>III. MARCO DE REFERENCIA</b>	<b>4</b>
3.1 Conceptos clave	4
3.2 Clasificación de los satélites	7
3.2.1 De acuerdo con su órbita	7
3.2.2 De acuerdo con sus sensores	7
3.3 Principales satélites de observación terrestre	8
3.3.1 MODIS	8
3.3.2 Landsat	9
3.3.3 Copernicus y la constelación Sentinel	9
3.4 Principales características de las imágenes	10
3.5 Principales herramientas para el procesamiento de datos espaciales	11
3.6 Monitorización de los Objetivos de Desarrollo Sostenible (ODS)	12
3.7 La importancia de la teledetección en la agenda para 2030	13
3.8 Aplicaciones de la teledetección en el sector agrícola	14
<b>IV. MATERIALES Y MÉTODOS</b>	<b>16</b>
4.1 Ubicación de los estudios	16
4.1.1 El Valle Sébaco	16
4.1.2 La Reserva de Biósfera Bosawás	17
4.1.3 El Departamento de Chinandega	19
4.2 Diseño metodológico	20

4.2.1	Primer estudio de caso	20
4.2.2	Segundo estudio de caso	22
4.2.3	Tercer estudio de caso	23
4.3	VARIABLES EVALUADAS	23
4.3.1	Primer estudio	24
4.3.2	Segundo estudio	24
4.3.3	Tercer estudio	24
4.4	Recolección de datos	25
4.5	Análisis de datos	28
4.5.1	Primer estudio	28
4.5.2	Segundo estudio	32
4.5.3	Tercer estudio	37
<b>V.</b>	<b>RESULTADOS Y DISCUSIÓN</b>	<b>44</b>
5.1	Primer estudio de caso	44
5.1.1	Dinámica ocupacional de la vegetación bajo riego en el Valle de Sébaco	44
5.1.2	Distribución de los cuatro tipos de cobertura terrestres	45
5.2	Segundo estudio de caso	46
5.2.1	Dinámica evolutiva de cobertura boscosa y agropecuaria	46
5.2.2	Análisis cuantitativo de las áreas con bosque y/o agropecuarias	49
5.2.3	Estimación entre la pérdida de bosques y la expansión agropecuaria	50
5.2.4	Estimación del momento en que coincidirán ambas superficie	51
5.3	Tercer estudio de caso	54
5.3.1	Mapeo de la cobertura y uso del suelo del departamento de Chinandega	54
5.3.2	Distribución de los tipos de cobertura en el departamento de Chinandega	57
<b>VI.</b>	<b>CONCLUSIONES</b>	<b>59</b>
<b>VII.</b>	<b>RECOMENDACIONES</b>	<b>60</b>
<b>VIII.</b>	<b>LITERATURA CITADA</b>	<b>61</b>
<b>IX.</b>	<b>ANEXOS</b>	<b>68</b>

---

## ÍNDICE DE CUADROS

<b>CUADRO</b>		<b>PÁGINA</b>
1.	Principales características de los satélites utilizados en este documento	8
2.	Repertorio Landsat	9
3.	Definición de las categorías para la reclasificación del NDVI en Sentinel 2 para el Valle de Sébaco	31
4.	Definición de las categorías para la reclasificación del NDVI de MODIS	33
5.	Características de las bandas espectrales de Sentinel 2	38
6.	Índices añadidos a la imagen Sentinel 2 de Chinandega	39
7.	Categorías y tipos de cobertura para cada clase de cobertura	39
8.	Distribución de las áreas agropecuarias y forestales con datos MODIS (columna 3 y 4 respectivamente) vs pérdida anual de bosque mediante Global Forest Change	53

## ÍNDICE DE FIGURAS

<b>FIGURA</b>		<b>PÁGINA</b>
1.	Ubicación del Valle de Sébaco	16
2.	Ubicación de la Reserva de Biosfera Bosawás	17
3.	Ubicación del departamento Chinandega	19
4.	Diagrama de trabajo del primer estudio de caso	21
5.	Diagrama de trabajo del segundo estudio de caso	22
6.	Diagrama de trabajo del tercer estudio de caso	23
7.	Imágenes Sentinel 2 del valle de Sébaco a color natural	25
8.	Imagen MODIS de la región de Bosawás a color natural	26
9.	Imagen Sentinel 2 del departamento de Chinandega a color natural	27
10.	Monobanda del NDVI en escala de grises	28
11.	Índices NDVI 2017 a 2021 con una rampa de 5 colores	29
12.	NDVI multitemporal elaborado con datos del 2019, 2020 y 2021	30
13.	Muestreo de valores de pixel en QGIS	33
14.	Script para la elaboración del mosaico de Landsat libre de nubes	35
15.	Esquema simple del proceso de clasificación automatizada	37
16.	Cantidad y distribución de las geometrías de entrenamiento	41
17.	El aprendizaje automático representado como una caja negra	42
18.	Nube de puntos para la extracción de los valores de la clasificación automatizada en QGIS para el departamento de Chinandega	43
19.	Serie temporal de la distribución espacial de los valores del NDVI	44
20.	Distribución espacio-temporal de los tipos de cobertura en el Valle de Sébaco	45

21.	Serie temporal del avance de la frontera agropecuaria de acuerdo con reclasificación del NDVI MODIS, 2001 a 2020	47
22.	Mosaico libre de nubes de Landsat 7 y de Landsat 8	48
23.	Dinámica de la frontera agropecuaria y áreas de bosques, período 2001 - 2020	49
24.	Correlación entre el área agropecuaria y el área de bosques	50
25.	Relación de las áreas forestales y agropecuarias en función del tiempo	51
26.	Mapa temático obtenido mediante el algoritmo Random forest a partir de imagen Sentinel 2 del 10 de febrero del 2021	54
27.	Filtro con superficies de agua; humedal; zonas de cultivos, áreas de bosques, rastrojo y zonas urbanas	56
28.	Distribución de las superficies de los tipos de cobertura y usos del suelo en el departamento de Chinandega, 10/02/2021	57

---

## ÍNDICE DE ANEXOS

ANEXO		PÁGINA
1.	Especificaciones técnicas de las computadoras utilizadas	69
2.	Longitud de onda y campo electromagnético	70
3.	El espectro electromagnético	70
4.	Ejemplo de diferentes tipos de resolución espacial	71
5.	Ejemplo de cómo se expresan los niveles radiométricos de los píxeles	71
6.	Logos de los principales componentes de ArcGIS	71
7.	Interfaz de trabajo de QGIS	72
8.	Entorno de desarrollo interactivo de Earth Engine	72
9.	Imágenes Sentinel 2 del valle de Sébaco a pseudo color natural	73
10.	Distribución espacio-temporal de los tipos de cobertura terrestre Valle de Sébaco de acuerdo con el NDVI	73
11.	Ráster clasificado (izquierda) y archivo vectorial (derecha)	73
12.	Interfaz de descarga de Global Forest Change	74
13.	Delimitación de los datos de la pérdida anual de bosques de GFC	75
14.	Tendencia proyectada de la dinámica espacio-temporal de la vegetación en la Reserva de Bosawás	76
15.	Distribución de los diferentes tipos de cobertura terrestre en el departamento de Chinandega	76
16.	Firmas espectrales obtenidas de los tipos de cobertura terrestre del departamento de Chinandega a partir de las 10 bandas de Sentinel 2	77
17.	Firmas espectrales del departamento de Chinandega con la adición de 7 índices espectrales	77

## RESUMEN

En los últimos años, la teledetección está asumiendo un papel cada vez más importante para el monitoreo agrícola. Teniendo en cuenta la escala, se puede recurrir a imágenes de baja, media y alta resolución. Las imágenes de media resolución Sentinel 2 y Landsat 8 han mostrado ser de gran utilidad para investigaciones a nivel de parcela, municipio y departamento, mientras que las imágenes de baja resolución MODIS han mostrado ser efectivas a escalas más grandes, por ejemplo, a nivel de país, continente o global. La integración de herramientas para el procesamiento de estos productos, contribuye a generar diagnósticos sobre el estado de la agricultura con altos niveles de precisión. El objetivo principal de este documento es mostrar el potencial que ofrece la teledetección para la investigación agronómica a diferentes escalas, para ello se realizaron los siguientes tres estudios de casos: (1) En el Valle de Sébaco, una región de más de 18 mil ha de suelos fértiles y donde se produce principalmente arroz y hortalizas, se detectó un incremento en las superficies cultivadas en época de riego del 9 % durante el período 2017 a 2021. De los 5 años analizados, solo 2019 presentó un leve descenso, -1.5 % con respecto a 2018; (2) Se midió el avance de la frontera agropecuaria en los 7 municipios que rodean la Reserva de Biosfera Bosawás (2.26 millones de ha), los datos obtenidos de MODIS mostraron una reducción de 382,353 ha de superficie boscosa, en cambio la frontera agropecuaria presentó un incremento de 386,216 ha. Los resultados se validaron mediante la aplicación Global Forest Change, que mostró una reducción de las áreas boscosas de 381,205 ha; (3) En el departamento de Chinandega se realizó una clasificación automática sobre una superficie de más de 500 mil ha, que se destaca por la abundante producción de cultivos como caña de azúcar, maní, soya, ajonjolí, sorgo, musáceas y maíz. Además, cuenta con importantes zonas de humedales y áreas de extracción de sal y áreas boscosas. Se mapearon 9 tipos de cobertura y usos del suelo con una precisión de 92.13 %.

**Palabras clave:** Imagen satelital, “Big Data”, aprendizaje automático, algoritmos de clasificación, índices espectrales, NDVI, firmas espectrales.

## ABSTRACT

In recent years, remote sensing is assuming an increasingly important role for agricultural monitoring. Taking into account the scale, low, medium and high-resolution images can be used. Medium-resolution Sentinel 2 and Landsat 8 images have been shown to be very useful for investigations at the parcel, municipality, and department level, while low-resolution MODIS images have been shown to be effective at larger scales, for example, at the level of country, continent or global. The integration of tools for the processing of these products contributes to generating diagnoses on the state of agriculture with high levels of precision. The main objective of this document is to show the potential that remote sensing offers for agronomic research at different scales, for which the following three case studies were carried out: (1) In the Sébaco Valley, a region with more than 18 thousand ha of fertile soils and where rice and vegetables are mainly produced, an increase in the cultivated areas during the irrigation season of 9% was detected during the period 2017 to 2021. Of the 5 years analyzed, only 2019 presented a slight decrease, -1.5% compared to 2018; (2) The advance of the agricultural frontier was measured in the 7 municipalities that surround the Bosawás Biosphere Reserve (2.26 million ha), the data obtained from MODIS showed a reduction of 382,353 ha of wooded area, whereas the agricultural frontier presented an increase of 386,216 ha. The results were validated through the Global Forest Change application, which showed a reduction in forested areas of 381,205 ha; (3) In the department of Chinandega, an automatic classification was carried out on an area of more than 500 thousand ha, which stands out for the abundant production of crops such as sugar cane, peanuts, soybeans, sesame, sorghum, musaceae and corn. In addition, it has important wetland areas and salt extraction areas and wooded areas. 9 types of cover and land uses were mapped with an accuracy of 92.13%.

**Keywords:** Satelital image, “Big Data”, machine learning, classification algorithms, spectral indices, NDVI, spectral signatures.

## I. INTRODUCCIÓN

En los últimos años se está hablando mucho sobre la agricultura de precisión como una alternativa para combatir los efectos negativos que el cambio climático ejerce sobre los sistemas agrarios (Instituto Internacional de Investigación sobre Políticas Alimentarias [IFPRI], 2009). El propósito de este tipo de agricultura es optimizar los recursos basándose en información obtenida a través de mediciones de la superficie agrícola, para ello se vale de satélites, drones u otros medios electrónicos que permitan obtener datos de los cultivos (García y Flego, 2008).

Aunque la orientación a este tipo de agricultura requiere de tecnología especializada para la obtención de información, se puede acceder a ella de manera confiable recurriendo a la teledetección, esta disciplina abarca dos componentes principales: los sensores remotos y los Sistemas de Información Geográfica (SIG) (Organización de las Naciones Unidas para la Agricultura y la Alimentación [FAO, por sus siglas en inglés], 2009).

El objetivo de la teledetección es la obtención de imágenes de la superficie terrestre con el fin de recolectar datos que aporten información sobre el estado de los ecosistemas (Instituto Interamericano de Cooperación para la Agricultura [IICA], 2014). Algunos ejemplos de datos que se pueden obtener a través de teledetección son: estados de la vegetación, deforestación, tipos de cultivos, masas de agua, humedad del suelo, variables meteorológicas, entre otros.

Sin embargo, para explotar esta riqueza de datos se requiere de los SIG, los cuales están constituidos por un conjunto de herramientas para la recopilación, procesamiento e interpretación de la información, entre los que se incluyen, GPS, software como QGIS, LEOWorks, SNAP y plataformas online como Google Earth Engine, entre otros, que junto a los datos satelitales se encuentran accesibles de forma completamente gratuita en internet.

Con la democratización de los datos espaciales, se han desarrollado investigaciones que han contribuido al desarrollo económico y social de los países que han sabido aprovechar estos recursos. De acuerdo a Goodchild *et al.*, (2012) tratando sobre el proyecto *Earth Engine* de Google, desde principios del 2000, el mundo ha entrado a una nueva era de información digital sobre la tierra. Los autores expresan lo siguiente:

El suministro de información geográfica a partir de sensores terrestres y satelitales se ha expandido rápidamente, lo que fomenta la creencia en un nuevo [...] paradigma o "Big Data" [...] que enfatiza la colaboración internacional, el análisis intensivo de datos, la computación masiva de recursos y visualización de alta gama. (p. 3)

Actualmente existen conjuntos de datos satelitales que datan de 1972 y que están disponibles en la plataforma Google Earth Engine, a los que se puede acceder de manera gratuita, pero, además, la plataforma también brinda los medios necesarios para poder procesar estos datos de forma masiva, sin importar el tipo de computador con que se cuente (Gorelick *et al.*, 2017) (Anexo 1).

Mediante este trabajo se pretende fomentar el uso de la teledetección como herramienta para la investigación en el campo agronómico. Para ello, se realizaron tres estudios de casos relacionados con la agricultura en los territorios de Chinandega, Matagalpa y los municipios que rodean la Reserva de Biósfera Bosawás. A través de ellos, se determinó la dinámica espacio-temporal de la superficie agrícola durante el ciclo de riego en el Valle de Sébaco para el período 2017-2021, se estimó el avance de la frontera agropecuaria hacia la Reserva de Biósfera Bosawás para el período 2001-2020 y se realizó un mapeo y estimación de la cobertura y usos del suelo en el departamento de Chinandega durante el mes de febrero 2021.

## **II. OBJETIVOS**

### **2.1 Objetivo general**

Demostrar los usos y aplicaciones que ofrece la teledetección para la monitorización agrícola en Nicaragua, mediante tres estudios de caso

### **2.2 Objetivos específicos**

1. Evaluar la dinámica espacial y temporal de la vegetación, en época de riego, en el Valle de Sébaco, Matagalpa durante el período 2017 – 2021.
2. Estimar el avance de la frontera agropecuaria en los municipios que comparten la Reserva de Biósfera Bosawás durante el período 2001 – 2020.
3. Mapear la cobertura y usos del suelo en el departamento de Chinandega, para el mes de febrero de 2021.

### III. MARCO DE REFERENCIA

#### 3.1 Conceptos clave

**Teledetección:** Mide la energía que emanan los objetos en la superficie terrestre, si la fuente de energía es el sol, entonces se llama teledetección pasiva u óptica. “Si la energía no es emitida por el sol, sino por el propio satélite, entonces se llama teledetección activa o de radar” (Bravo, 2017, p. 7). Cada una aporta información sobre distintos temas que influyen directa o indirectamente sobre los sistemas agrarios, por ejemplo, erosión, comportamiento de la vegetación, variables climáticas, por mencionar algunos.

**Sistemas de Información Geográfica (SIG):** “Es un conjunto de hardware, software, datos geográficos y personal capacitado; organizados para capturar, almacenar, consultar, analizar y presentar todo tipo de información que pueda tener una referencia geográfica” (Puerta *et al.*, 2011, p. 8). Mediante los SIG de escritorio se gestionan los datos, estos pueden estar presentados en forma de ‘ráster’ (imágenes, ortofotos) o de vectores (puntos, líneas y polígonos) llamados comúnmente “shape”.

**Satélites de observación terrestre:** Son utilizados para medir variables relacionadas con los ecosistemas terrestres y marítimos, como estados de la vegetación, temperaturas atmosféricas y oceánicas, humedad del suelo, precipitaciones, contaminantes atmosféricos, topografía, entre otros. Según la Agencia Espacial Europea (ESA, por sus siglas en inglés, 2011), “estos se pueden clasificar según la órbita que describen, la carga útil que llevan a bordo y las características de las imágenes que generan. Todos esos parámetros se definen al principio de la misión según la aplicación que se vaya a dar al satélite.” (ESA, 2011 p. 1.)

**Sensores satelitales:** Son dispositivos electrónicos acoplados al satélite, encargados de capturar la energía que emiten los elementos de la superficie terrestre para luego transformarlas a imágenes. Se prefiere usar el término “sensor” y no cámara, porque a diferencia de una cámara que solo puede captar las características visibles al ojo, el sensor es capaz de capturar información que el ojo no puede ver, como la energía infrarroja y térmica (ESA, 2014).

**Radiación Electromagnética:** Cuando un cuerpo se encuentra a elevadas temperaturas está irradiando energía. El científico alemán Heinrich Hertz a mediados del siglo XIX demostró que la energía es una partícula sin masa que viaja en formas de onda a través de un campo eléctrico y otro magnético perpendiculares entre sí (Stern, 2001). De esta manera se explica cómo la superficie terrestre es capaz de reflejar la radiación en una proporción relativa para cada tipo de cobertura terrestre. La proporción de energía que regresa al espacio es capturada por los sensores de los satélites (Anexo 2).

**Longitud de onda ( $\lambda$ ):** La radiación electromagnética se divide en subunidades llamadas longitudes de onda (Anexo 3). Por lo general, se miden en micrómetros ( $\mu\text{m}$ ) o nanómetros (nm). Las principales longitudes de onda que se estudian en la agricultura son las pertenecientes al rango del espectro visible e infrarrojo (Solomon *et al.*, 2013). Sin embargo, para estudios en los que se analiza la rugosidad del terreno y su estructura tridimensional, se utilizan las microondas. De acuerdo a Pérez *et al.*, (2020) las longitudes de onda se clasifican en:

Rayos Gamma: 0.1 – 1 nm;

Rayos X: 1 – 10 nm;

Ultravioleta: 10 – 100 nm;

Visible (rojo, verde y azul, RGB): 0.4 – 0.7  $\mu\text{m}$ ;

Infrarrojo cercano (Near Infrared o NIR): 0.7 – 1.3  $\mu\text{m}$ ;

Infrarrojo de onda corta (Short wave infrared o SWIR): 1.3 – 8  $\mu\text{m}$ ;

Infrarrojo térmico (Thermal infrared o TIR): 8 – 100  $\mu\text{m}$ ;

Microondas: 1 mm - 1 m;

Ondas de Radio y TV: 1 - 1,000 m.

**Bandas espectrales:** Es la capacidad del satélite para capturar información en las diferentes regiones del espectro electromagnético (Artola, 2013). Las bandas o canales espectrales son las que almacenan los datos de la energía que emiten los objetos en la tierra. El conjunto de bandas conforma la imagen satelital, se puede acceder a estas de manera gratuita a través de plataformas online.

**Firmas espectrales:** Cuando la energía electromagnética interactúa con los elementos de la superficie terrestre, parte de ésta es absorbida por los objetos, otra dispersada (atraviesa al objeto) y una tercera parte es reflejada o irradiada hacia el espacio, donde es captada por los sensores de los satélites y almacenada en las bandas espectrales. La proporción en que cada objeto refleja la energía se conoce como firma espectral, curva de reflectancia o comportamiento espectral. (IICA, 2014) (Anexo 16).

**Índices espectrales:** Son imágenes sintéticas de una sola banda o monobanda que se obtienen a través de la relación entre dos o más bandas de la imagen original, a través de un procedimiento algebraico. Estos índices se utilizan comúnmente para medir características específicas de la superficie terrestre, como vegetación, agua, incendios, áreas urbanas, entre otros. Entre los índices más utilizados se encuentran los “índices de diferencia normalizada”.

**Composición analítica de bandas:** Los programas y plataformas de teledetección poseen una herramienta conocida como filtro RGB (*Red Green Blue*) que permite el análisis visual de los elementos de la superficie terrestre en diferentes tonalidades. Con este filtro se pueden realizar combinaciones de colores que resalten detalladamente elementos específicos de la superficie terrestre, ya que con él es posible “teñir” con colores característicos la energía que el ojo no es capaz de detectar a simple vista, por ejemplo, la energía infrarroja que emanan muchos cuerpos terrestres (Anexo 9).

## 3.2 Clasificación de los satélites

### 3.2.1 De acuerdo con su órbita

**Geoestacionaria:** Corresponde a satélites que orbitan a una altura aproximada de 36,000 km, principalmente del tipo meteorológico. Como ventaja, al mantenerse alejados del ecuador terrestre pueden tomar imágenes diariamente de todo el planeta, pero presentan el inconveniente de que esa enorme distancia reduce la resolución o nitidez de la imagen (Pérez *et al.*, 2020).

**Heliosincrónica:** Las orbitas de estos satélites se efectúan a una altura entre los 600 y 800 km, éstos pasan de cerca por los polos, por lo que a veces a este tipo de órbita se le llama “cuasipolar”. Mientras el satélite avanza en su órbita y la Tierra gira sobre su eje, éste captura la energía en franjas y al cabo de varias vueltas cubre por completo el globo terrestre. Como ventaja ofrecen buena resolución espacial, pero tardan varios días en volver a pasar por el mismo lugar (Pérez *et al.*, 2020).

### 3.2.2 De acuerdo con sus sensores

**Pasivos:** Actúan de manera pasiva captando energía ajena a ellos, esta puede provenir del sol o también de los propios objetos que emanan energía (vegetación, masas de agua, desiertos, estructuras antropogénicas). Esta energía es reflejada total o parcialmente desde la superficie terrestre y llega al sensor, donde es capturada en las bandas o canales espectrales de acuerdo a la longitud de onda (IICA, 2014). A estos satélites también se les denomina satélites ópticos.

**Activos:** Emiten su propia energía hacia la tierra, donde esta interactúa con la superficie y regresa al sensor para ser tratada. Ejemplo de esta situación la encontramos en los satélites de RADAR (*Radio Detection And Ranging*) y LiDAR (*Light Detection And Ranging*), comunes para el modelado 3D y análisis de la rugosidad del terreno (IICA, 2014). Una de las ventajas de este tipo de sensores es que, al trabajar con longitudes de onda largas, pertenecientes a las microondas, tienen la capacidad de atravesar las nubes, por lo que pueden trabajar casi bajo cualquier condición meteorológica (Podest, 2018).

### 3.3 Principales satélites de observación terrestre

Los satélites de observación se utilizan para medir variables relacionadas con los ecosistemas terrestres y marítimos. Gracias a los datos que aportan, es posible gestionar los recursos naturales de una manera más sostenible, ya que las mediciones que llevan a cabo contribuyen a generar información sobre problemáticas que inciden directamente sobre los ecosistemas. En el cuadro 1 se presentan algunos de estos satélites y sus principales características.

Cuadro 1. Principales características de los satélites utilizados en este documento

<b>Satélite sensor</b>	<b>Resolución espacial (m)<sup>1</sup></b>	<b>Resolución temporal<sup>2</sup></b>	<b>Resolución espectral<sup>3</sup></b>	<b>Cobertura histórica</b>
MODIS	250, 500 y 1,000	1 a 2 días	36	feb/2000 - actualidad
Landsat 7	15, 30 y 60	16 días	8	ene/1999 - actualidad
Landsat 8	15, 30, y 100	16 días	11	abr/2013 - actualidad
Sentinel 2	10, 20, 60	5 días	13	jun/2015 - actualidad

#### 3.3.1 MODIS

Con 36 bandas espectrales y una franja de barrido de 2,330 km, MODIS mapea el planeta completo en 1 o 2 días. Rastrea una amplia gama de signos vitales de la tierra, es adecuado para monitorear cambios a gran escala en la biósfera, mide la actividad fotosintética de las plantas terrestres y marinas, aporta valiosa información sobre la evapotranspiración utilizando la ecuación de Penman Monteith, proporciona datos de temperatura, observa cambios en las poblaciones de fitoplancton del Pacífico que pueden indicar el inicio de los fenómenos climáticos como El Niño y La Niña, mucho antes de su llegada (National Aeronautics and Space Administration [NASA, por sus siglas en inglés], s. f.).

<sup>1</sup> Dimensiones del pixel.

<sup>2</sup> Período de revisitas, lapso entre dos pasadas del satélite.

<sup>3</sup> Cantidad de bandas en las que opera el sensor.

### 3.3.2 Landsat

El programa espacial Landsat recibe su nombre de las abreviaturas LAND (tierra) y SAT (satélite), es una de las primeras misiones de observación terrestre, gestionada por la NASA y distribuido por la USGS (Matellanes, 22 de febrero del 2020). Durante más de 49 años, los satélites Landsat han adquirido imágenes de la Tierra, creando un catálogo de imágenes único en todo el mundo en cuanto a antigüedad, continuidad, cobertura mundial y detalle (Pérez *et al.*, 2020). Actualmente se encuentran operativos los sensores de Landsat 7 y 8 (Cuadro 2). El satélite Landsat 9 fue puesto en órbita el 27 de septiembre de 2021.

Cuadro 2. Repertorio Landsat

Satélite	Lanzamiento	Fin de operación
Landsat 1	Julio, 1972	Ene - 1978
Landsat 2	Enero, 1975	Feb - 1982
Landsat 3	Marzo, 1978	Mar - 1983
Landsat 4	Julio, 1982	Dic - 1993
Landsat 5	Enero, 1984	Ene - 2013
Landsat 6	Octubre, 1993	Lanzamiento fallido
Landsat 7	Enero, 1999	Actualidad
Landsat 8	Abril, 2013	Actualidad

Fuente: Matellanes, (22 de febrero del 2020).

### 3.3.3 Copernicus y la constelación Sentinel

Copernicus es actualmente el programa más ambicioso de observación terrestre encabezado por la Comisión Europea. Los Sentinels son una constelación de satélites desarrollados por la ESA que incluyen imágenes de radar de Sentinel 1, imágenes ópticas de Sentinel 2, datos oceánicos y terrestres para monitoreo climático procedentes de Sentinel 3, así como datos de calidad del aire de Sentinel 5P (ESA, 2016). La misión Sentinel 2, utilizada en este documento para dos de los tres estudios de caso, recopila imágenes multispectrales operando en 13 bandas, con una resolución de pixel de hasta 10 metros y un período de revisita de 5 días (ESA, 2015).

### 3.4 Principales características de las imágenes

Las imágenes satelitales son los principales insumos para el análisis remoto. Una imagen satelital es una base de datos que almacena la información de manera cuantitativa y la refleja de manera cualitativa en subunidades llamadas píxeles o pixeles. Las principales características de las imágenes ópticas están ligadas a su resolución, esta varía para cada satélite y se mide desde cuatro ángulos: espacial, temporal, espectral y radiométrica.

**Espacial:** Hace referencia al tamaño de los pixeles, ya que, a menor tamaño, mayor capacidad para discriminar los elementos de la superficie. Para los satélites geoestacionarios la resolución es menor que la de los heliosincrónicos (Anexo 4), en contraposición los geoestacionarios tienen una mejor resolución temporal. En la mayoría de los casos, los satélites ópticos que presentan baja resolución espacial son utilizados para estudios que cubren extensas superficies.

**Temporal:** Es el lapso que dura un satélite en volver a pasar por el mismo lugar, o el tiempo que tarda en cubrir el globo terrestre en su totalidad. Un ejemplo de este tipo de resolución se puede apreciar al comparar el satélite Landsat 8 que tarda 16 días en mapear todo el planeta mientras que Sentinel 2 lo hace en apenas 5 días. Como resultado, con Sentinel 2 se pueden obtener 6 imágenes mensuales, mientras que con Landsat 8 menos de dos.

**Espectral:** Es la capacidad que tienen los sensores para distinguir las diferentes longitudes de onda del espectro electromagnético y está relacionada a la cantidad de bandas con las que cuenta el sensor. En el caso de Sentinel 2 posee 13 bandas que le permite realizar estudios terrestres, de nubes y de aerosoles costeros, mientras que Sentinel 3 con sus 23 bandas, permite ampliar los estudios hacia los océanos.

**Radiométrica:** Está relacionada a la cantidad de tonalidades que pueden tomar los elementos en una imagen, se les llama comúnmente “niveles digitales” y están determinados por el número de bits que posee la imagen. Entre mayor sea el número de bits mayor será la capacidad del pixel para adquirir las diferentes tonalidades y por ende hacer una mejor diferenciación de los objetos de la superficie terrestre (Anexo 5). Para calcular los niveles digitales se utiliza la expresión:  $2^{\text{número de bits}}$ , donde 2 es una constante.

### 3.5 Principales herramientas para el procesamiento de datos espaciales

Actualmente, algunas de las principales herramientas para el procesamiento y análisis espacial de imágenes satelitales los constituyen programas como ArcGIS, QGIS, SNAP, LEOWorks, ENVI, Global Mapper, ERDAS Imagine, gvSIG y la propia plataforma Google Earth Engine. A continuación, se hace una breve descripción de algunos de estos.

**ArcGIS:** Es un paquete de software de análisis espacial y mapeo que el instituto Esri (*Environmental Systems Research Institute*), desde el año 1999, ha puesto al servicio de empresas, gobiernos y usuarios de todo el mundo bajo una licencia (ESRI.com, s. f.) (Anexo 6). Entre los principales servicios de ArcGIS encontramos:

**ArcMap:** Es el componente principal del conjunto de programas de ArcGIS, se utiliza principalmente para ver, editar, crear y analizar datos espaciales. ArcMap permite explorar datos dentro de un conjunto de datos, simbolizar características y crear mapas.

**ArcCatalog:** Proporciona una ventana de catálogo que se utiliza para organizar y administrar varios tipos de información geográfica para los demás componentes de ArcGIS.

**ArcScene:** Permite trabajar los datos en un entorno 3D. Ofrece información altitudinal, ya sea en base a datos recolectados en campo u obtenidos mediante drones o satélites.

**ArcGlobe:** Es una aplicación de visualización 3D que permite visualizar y analizar grandes cantidades de datos espaciales sobre una superficie de globo en su ubicación geodésica real.

**QGIS:** Lanzado en 2002 por la ONG *Open Source Geospatial Foundation* (OSGeo), es uno de los softwares de análisis y procesamiento geoespacial preferido por la mayoría de usuarios SIG, ya que es de código abierto y siendo un proyecto construido por voluntarios de diferentes profesiones en todo el mundo (QGIS.org, s.f.), contiene un amplio repertorio de herramientas y complementos diseñados para realizar análisis en diferentes temas de investigación (Anexo 7).

**Google Earth Engine:** No requiere la instalación de ningún programa, utiliza lenguaje de programación JavaScript, Python o R (Anexo 8). Está dedicada para el procesamiento, análisis y descarga de datos a escala masiva, incorpora las capacidades computacionales masivas de los servidores de Google para abordar una variedad de temas de alto impacto como deforestación, sequía, seguridad alimentaria y protección del medio ambiente (Gorelick *et al.*, 2017). Reúne un catálogo de imágenes de las principales misiones de observación terrestre y diariamente se actualiza sistematizando información de diferente naturaleza (Yang *et al.*, 2016).

**Global Forest Change:** Es una aplicación integrada a Google Earth Engine que permite medir la pérdida anual de la cobertura forestal global mediante datos procesados a partir de imágenes Landsat desde el año 2000 hasta la actualidad, actualizándose cada año. Con esta aplicación es posible obtener los productos procesados para extraer las bases de datos a nivel de extensas regiones que permiten medir la pérdida del bosque para cualquier región del mundo (Hansen *et al.*, 2013).

### **3.6 Monitorización de los Objetivos de Desarrollo Sostenible (ODS)**

En el año 2000, la Organización de las Naciones Unidas, hizo la declaración del milenio, la cual establecía como objeto reducir la pobreza y construir una serie de metas para el año 2015, denominadas Objetivos de Desarrollo del Milenio (ODM) (ONU, 2000). En 2012, en la conferencia sobre el Desarrollo Sostenible, se elaboró un documento que contenía indicaciones para la consecución de Objetivos de Desarrollo Sostenible (ODS) (ONU, 2012). Estos esfuerzos continuaron en septiembre de 2015 en la histórica cumbre del Desarrollo Sostenible, en la que se aprobó la Agenda 2030 que contiene los 17 Objetivos de Desarrollo Sostenible que hoy rigen los esfuerzos de los países para alcanzar un mundo sostenible para el año 2030 (ONU, 2018).

Uno de los ODS que está intrínsecamente relacionado con los profesionales y especialistas del sector agropecuario, es el Objetivo número 2: *Hambre cero*, el cual tiene como meta general “Reducir el hambre, fomentar la seguridad alimentaria y la mejora de la nutrición y promover la agricultura sostenible”. Este objetivo está vinculado sinérgicamente con el ODS número 15: *Vida de ecosistemas terrestres*, que establece como meta general “Gestionar sosteniblemente los bosques, luchar contra la desertificación, detener e invertir la degradación de las tierras y detener la pérdida de biodiversidad”.

Para asegurar la armonía entre estos dos objetivos y asegurar la sostenibilidad en los sistemas agrarios, se deben integrar criterios medioambientales al campo agrícola (Larragaña, 2016). La producción de alimentos debe realizarse procurando el equilibrio con la naturaleza, ya que la degradación del medioambiente supone un impacto directo en los sistemas de producción y por ende en la economía de la población que se dedica a la agricultura (Reardon & Vosty, 1995).

Para realizar una mejor gestión de la producción de alimentos sin interferir con los recursos naturales, es necesario monitorear el territorio de forma constante a través de una sólida base de información confiable con independencia de intereses comerciales y políticos, esta información solo la pueden proporcionar los satélites de observación terrestre a través de una visión desde las alturas (Euronews, 2016).

### **3.7 La importancia de la teledetección en la agenda para 2030**

En la Agenda para 2030, la ONU establece que:

Ayudaremos a los países en desarrollo, [...], los países menos adelantados, [...], a fortalecer la capacidad de sus oficinas estadísticas y sus sistemas estadísticos para asegurar el acceso a datos de gran calidad, oportunos y fiables [...], para aprovechar una amplia gama de datos, incluidos los de observación de la tierra e información geoespacial, garantizando al mismo tiempo, que sean los propios países quienes se encarguen de apoyar y vigilar los progresos conseguidos. (ONU, 2015, pp. 12, 13 y 38)

Por lo tanto, al más alto nivel de las Naciones Unidas se reconoce la importancia de la información geoespacial para contribuir al alcance de los ODS. Sumado a esto, el acceso universal a internet, las nuevas técnicas computacionales, el almacenamiento en la nube y la disponibilidad de software libres, favorecen la accesibilidad a los datos de teledetección y aumentan su facilidad de gestión y administración, ya que en ocasiones pueden resultar grandes y complejos (Pérez *et al.*, 2020; Goodchild *et al.*, 2012; Gorelick *et al.*, 2017).

Entre las aplicaciones más utilizadas y necesarias de cara al asesoramiento agronómico utilizando técnicas de teledetección, se pueden mencionar, la interpretación fenológica y la clasificación de cultivos (Gastón, 2018). Casanova, (1992) enfatizó sobre la importancia de la teledetección como una disciplina, expresando lo siguiente:

Creemos que las universidades que no hayan previsto incluir esta materia, deberían reconsiderar su decisión, porque la teledetección es una herramienta de tal potencia y con tanto futuro en todos los campos, que cualquier alumno, sea cual sea su orientación, se podrá beneficiar con su aprendizaje. (p. 62)

### 3.8 Aplicaciones de la teledetección en el sector agrícola

El uso de la teledetección ha sido poco aprovechado en el país, particularmente en las ciencias agrarias, donde tiene diversas utilidades. El amplio rango de aplicaciones y usos que tienen estas herramientas abre paso para el desarrollo de nuevas estrategias dentro del sector agropecuario nacional, pues permite optimizar el aprovechamiento de los recursos naturales, humanos y económicos, realizar monitoreo permanente y casi en tiempo real de los sistemas agrarios, vigilar los cambios que se producen, detectar y evaluar afectaciones ante desastres naturales. A continuación, se describen algunos usos y aplicaciones que se le ha dado en diferentes países.

En un estudio realizado por Rivas *et al.*, (2011), en un contexto de agricultura de precisión y haciendo uso del NDVI (Índice de Vegetación de Diferencia Normalizado) obtenido a partir de imágenes del satélite Landsat 5, elaboraron un modelo estadístico para estimar el rendimiento de Trigo en el suroeste de Uruguay. Para ello tomaron muestras del rendimiento de 509 hectáreas cosechadas y mediante un modelo de regresión, las relacionaron con los valores del NDVI. Los resultados mostraron una relación directa entre los valores del NDVI y el rendimiento del cultivo, el error de la estimación fue del 12 %. De esta forma, demostraron la importancia de las imágenes satelitales para estimar la productividad a nivel de parcelas.

El NDVI es uno de los índices más utilizados para análisis agrícola, ya que permite medir el vigor de la vegetación, estimando la relación entre la energía que más absorbe la vegetación y la que más refleja, es decir, la energía infrarroja cercana (NIR) y la del visible rojo (RED), respectivamente y está determinado por la siguiente expresión:

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \text{ (Rouse et al., 1973), dónde:}$$

$\rho_{NIR}$ : Reflectancia de la energía infrarroja ( $\lambda$ : 0.8 - 0.9  $\mu$ ),

$\rho_{RED}$ : Reflectancia de la energía roja ( $\lambda$ : 0.6 - 0.7  $\mu$ ).

Este comportamiento de contrastes se traduce en el estado de la vegetación, pues un estrés hídrico o vegetación menos joven o enferma varía su pigmentación, afectando de manera directa los valores del NDVI. De esta manera, es posible medir el estado de los cultivos y determinar si se encuentran en un nivel óptimo de producción, o si, por el contrario, es necesario aplicar alguna enmienda para corregir las deficiencias.

Parente y Ferreira (2018), utilizando Google Earth Engine, realizaron una evaluación sobre la dinámica espacial y de ocupación de los pastizales brasileños de 2000 a 2016, a través de técnicas de clasificación automatizada con imágenes MODIS y Landsat 7 y 8. El mapeo reveló un aumento de aproximadamente 25 millones de hectáreas en el área de pastos del país durante el período analizado. En general, cerca del 80 % de este aumento sucedió en los primeros 6 años, reflejando además las zonas de mayor expansión de pastizales. Con este estudio se comprobó la efectividad de las imágenes MODIS, las cuales, a pesar de tener una resolución espacial baja, de 500 metros, están libres de nubes y tienen una buena secuencia temporal.

Loría (2018), a través del software de código libre QGIS y herramientas de clasificación supervisada, utilizó imágenes del satélite Landsat 8 y Sentinel 2 para identificar y estimar áreas cafetaleras en la provincia de San José en el sur de Costa Rica. De esta manera, la autora pudo elaborar un mapa con la caracterización de las áreas cafetaleras, además de generar información estadística sobre su distribución por municipio.

Por otra parte, Shelestov *et al.*, (2017), realizaron una clasificación supervisada sobre los diferentes cultivos en la región de Kiev en el norte de Ucrania con imágenes del satélite Landsat 8 y utilizando la plataforma Google Earth Engine. El propósito principal de esta investigación fue determinar cuál de los algoritmos de clasificación de Google Earth Engine, era el más efectivo para el mapeo de cultivos.

Las experiencias reportadas avalan el uso de los sensores remotos para el monitoreo en la agricultura (Villalobos *et al.*, 2009), demostrando que se pueden realizar investigaciones de gran calidad y con un elevado grado de precisión y rigor científico. Los esfuerzos enmarcados en la Agenda del Desarrollo Sostenible promovida por la ONU, la Unión Europea (UE) y agencias espaciales como la NASA y la ESA, ponen a la disposición de cualquier usuario con acceso a internet los datos recopilados por los satélites de forma completamente gratuita.

## IV. MATERIALES Y MÉTODOS

### 4.1 Ubicación de los estudios

#### 4.1.1 El Valle Sébaco

El Valle de Sébaco se ubica a 105 kilómetros al norte de la capital Managua. Es una llanura de aproximadamente 18 mil hectáreas de tierras agrícolas, forma parte de los municipios de Ciudad Darío, Sébaco y San Isidro, departamento de Matagalpa (Figura 1). Según datos consultados del Satélite Terraclimate para un período de 20 años (2001-2020) y tomando en cuenta solamente los meses de febrero y marzo, en esta región, la temperatura media nocturna es de 19 °C, mientras que la media diurna es de 32 °C y la evapotranspiración de Penman-Monteith es de 5 mm día<sup>-1</sup> (Abatzoglou *et al.*, 2018). El período analizado corresponde a los meses de la época seca en que se da la mayor producción de cultivos de riego, principalmente arroz y hortalizas.

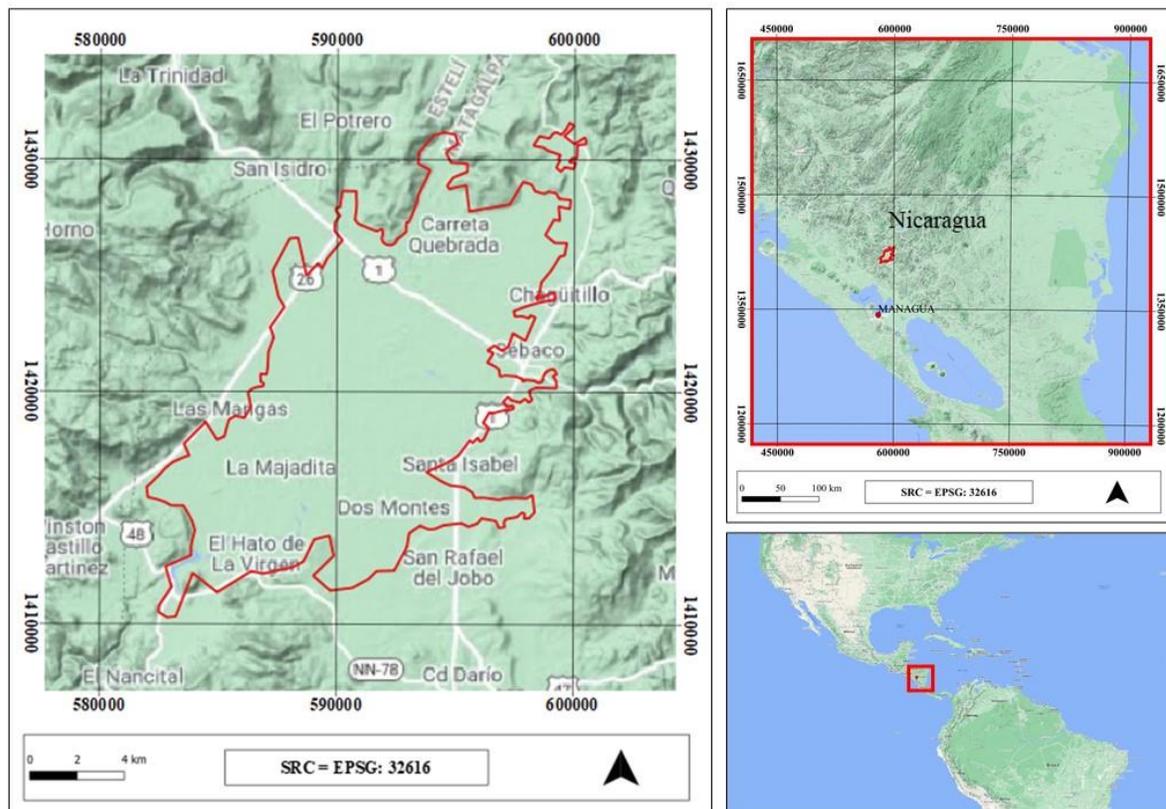


Figura 1. Ubicación del Valle de Sébaco.

#### 4.1.2 La Reserva de Biósfera Bosawás

La Reserva de Biósfera Bosawás se ubica en el departamento de Jinotega (frontera con Honduras) y la Región Autónoma de la Costa Caribe Norte (RACCN). Limita al norte y noroeste con la Reserva de Biósfera de Río Plátano y el Parque Nacional Patuca de Honduras, al este con los municipios de Waspán y Bonanza, al sur con los municipios de El Cuá, San José de Bocay, Waslala y Siuna y al oeste con el municipio Wiwilí de Jinotega. El área estimada para este estudio abarca siete municipios con una extensión de 2,257,165 hectáreas. La topografía del terreno es irregular, influenciada por cerros como el Kilambé, el macizo de Peñas Blancas y el cerro Saslaya con elevaciones por encima de los 1,500 m.s.n.m. (Figura 2).

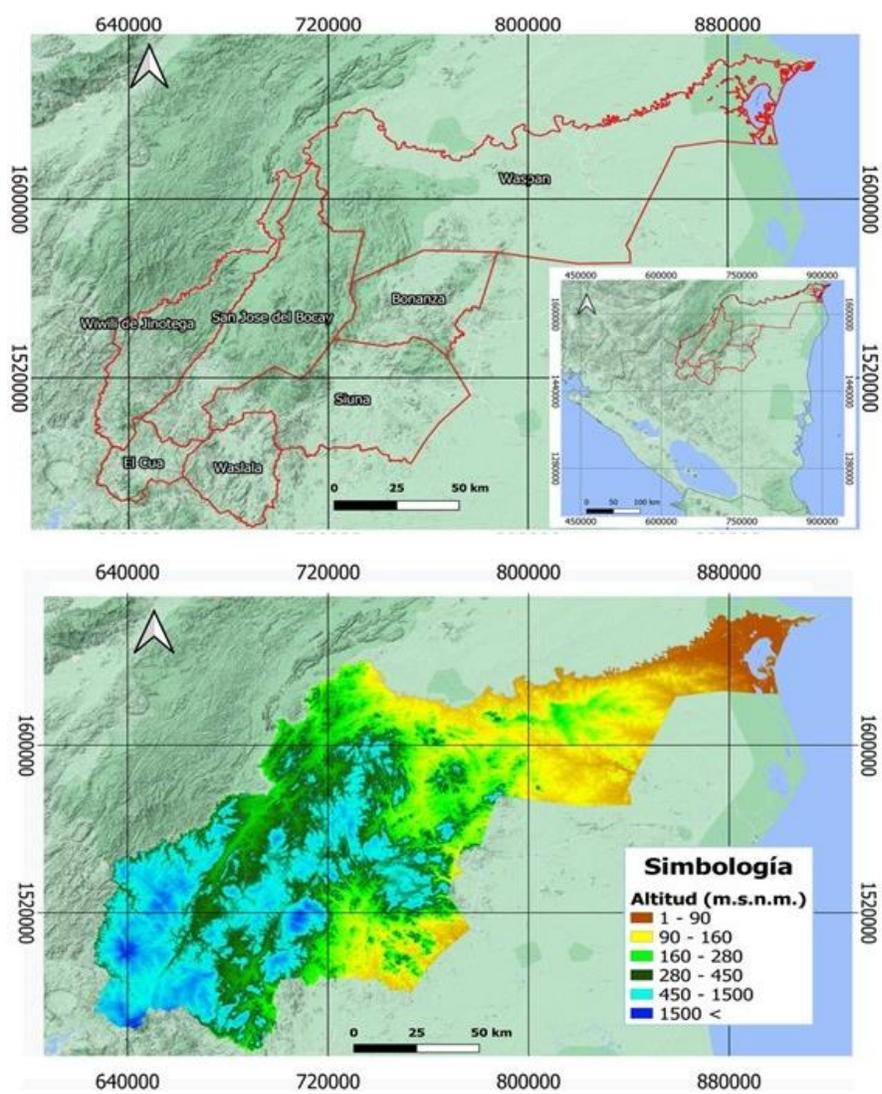


Figura 2. Ubicación de la Reserva de Biosfera Bosawás. (Fuente de datos: Farr et al., 2007).

La Reserva de Biósfera Bosawás es la mayor reserva forestal de Centroamérica, forma parte del Corredor Biológico Mesoamericano donde convergen flora y fauna de Norte y Suramérica y aunque la diversidad botánica es muy alta, se desconoce el número de especies. En cuanto a la fauna que posee, esta no ha sido lo suficientemente explorada, pero se han documentado avistamientos de varias especies en peligro de extinción (Maes *et al.*, 2006).

Fue declarada Reserva de Biósfera por la Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura (UNESCO) en 1997. Sin embargo, se encuentra en estado de degradación debido a que los habitantes de la zona recurren a prácticas perjudiciales al ambiente, además de la explotación por parte de empresas mineras y la incursión de invasores que se toman las tierras comercializándolas de forma ilegal y cometiendo tala indiscriminada de los bosques, aumentando la expansión de la frontera agropecuaria y la ganadería extensiva (Castro *et al.*, 2014).

### 4.1.3 El Departamento de Chinandega

Chinandega se localiza a 145 km al noroeste de la capital Managua, en la costa pacífica de Nicaragua, comparte frontera terrestre con Honduras y los departamentos de León, Estelí y Madriz. Sus suelos son considerados los más fértiles del país y esto se ve reflejado en una intensa actividad agrícola, donde predomina la siembra de ajonjolí, arroz, sorgo, soya, maní, maíz, frijol, caña de azúcar y banano.

Algunos de estos productos son para exportación, como es el caso del maní y el banano, otros como el maíz y el frijol son en su mayoría para consumo interno y la caña de azúcar sirve como materia prima para la producción de azúcar y licores. La actividad agrícola se ve beneficiada por dos estaciones climáticas bien demarcadas: seis meses de época seca y seis meses de época lluviosa (Instituto Nacional de Información de Desarrollo [INIDE], 2011). Además de la agricultura, también se da la producción pecuaria, como la pesca, la camaronicultura y la extracción de grandes cantidades de sal para consumo humano. El área delimitada para este estudio abarca una superficie de 5,123 km<sup>2</sup> (Figura 3).

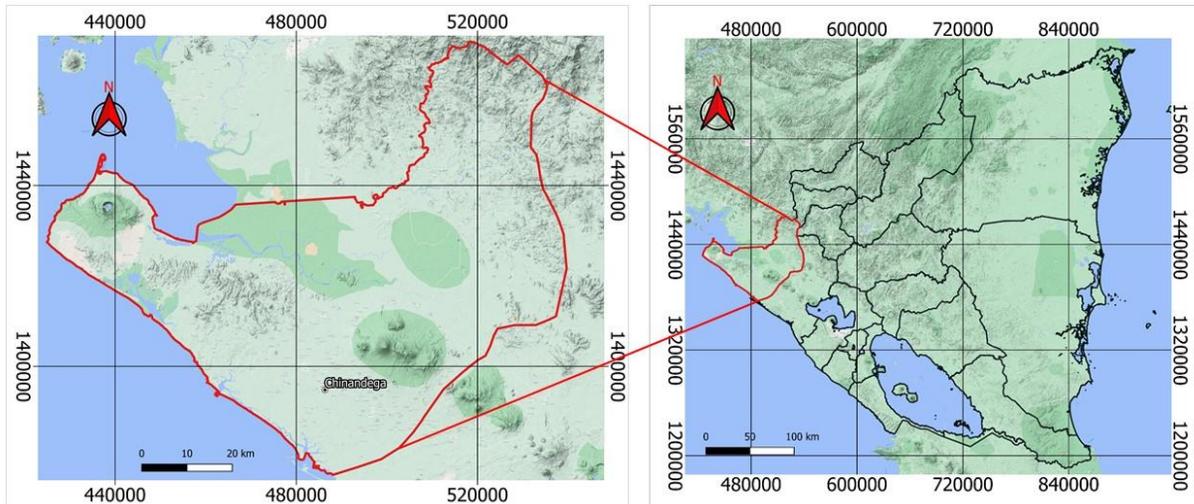


Figura 3. Ubicación del departamento Chinandega.

## 4.2 Diseño metodológico

El diseño metodológico de este estudio es no experimental, del tipo longitudinal con un enfoque mixto con un alcance correlacional, ya que se recabaron datos en diferentes puntos del tiempo, para realizar inferencias acerca de la evolución de los diferentes tipos de cobertura y usos de la tierra en las áreas de estudio en diferentes momentos, estos se relacionaron con las potenciales causas y efectos de estos cambios. Para análisis de los datos e información geoespacial los principales insumos fueron las imágenes satelitales y la cartografía de las zonas de estudio, esto se hizo principalmente a través de Google Earth Engine y QGIS. A continuación, se describe detalladamente el proceso metodológico de cada estudio de caso.

### 4.2.1 Primer estudio de caso: Evaluación espacio-temporal de las áreas cultivadas bajo riego en el Valle de Sébaco, período 2017 – 2021

Se utilizó la plataforma Google Earth Engine para acceder a las imágenes del satélite Sentinel 2, a las que se les calculó el NDVI para cada año analizado, 5 índices en total. El NDVI permite medir el vigor de la vegetación, estimando la relación entre la energía que más absorbe la vegetación y la que refleja mayormente, es decir, la energía infrarroja cercana (NIR) y la del visible rojo (RED), respectivamente y está determinado por la siguiente expresión:

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \text{ (Rouse et al., 1973), dónde:}$$

$\rho_{NIR}$ : Reflectancia de la energía infrarroja (banda 8 en Sentinel 2),

$\rho_{RED}$ : Reflectancia de la energía roja (banda 4 en Sentinel 2).

Con los datos del NDVI de 2019, 2020 y 2021 se elaboró un NDVI multitemporal que permitió identificar y delimitar las áreas que han mostrado actividad agrícola como mínimo en alguno de los últimos tres años. Una vez delimitados los NDVIs para cada año, fueron descargados a la computadora para que con QGIS se realizará la reclasificación de píxeles para la obtención de los mapas de la cobertura vegetal y la extracción de las bases de datos con la información de la distribución de cobertura vegetal para cada año (Figura 4).

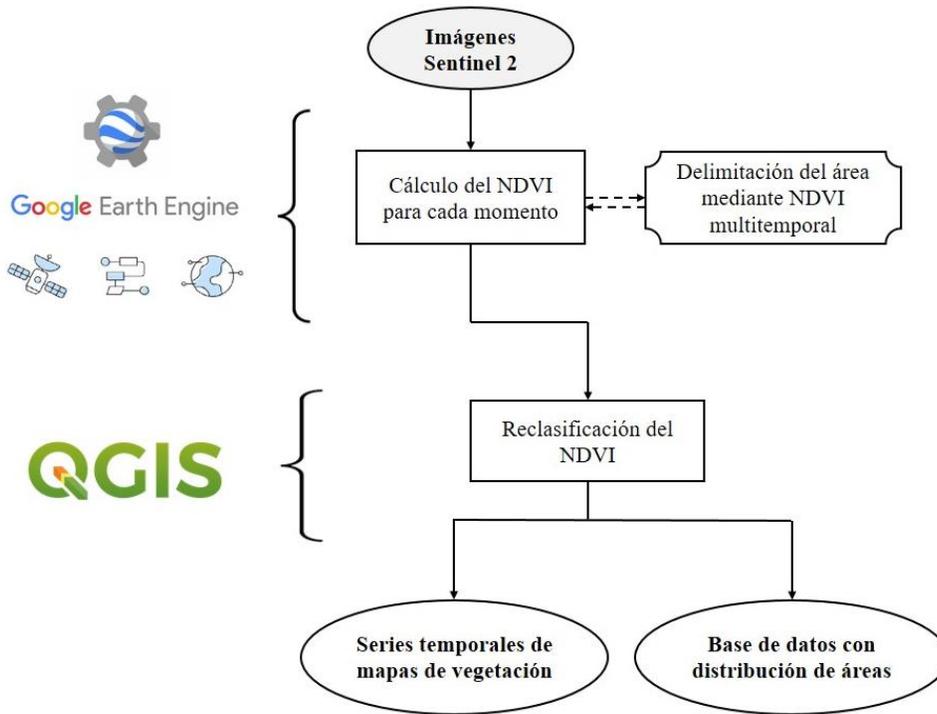


Figura 4. Diagrama de trabajo del primer estudio de caso.

Los resultados obtenidos corresponden a un mapa de vegetación para cada uno de los años analizados, es decir, 5 mapas en total. Además, la obtención de una base de datos a partir de cada mapa, que recopila la distribución superficial de cada una de las coberturas terrestres, en ellos se muestra la distribución de las superficies de agua, suelo desnudo, vegetación medianamente sana y vegetación muy sana.

#### 4.2.2 Segundo estudio de caso: Avance de la frontera agropecuaria en los municipios que rodean la Reserva de Biósfera Bosawás, período 2001 – 2020

Con la plataforma Google Earth Engine se accedió a imágenes del sensor MODIS, a las que se les calculó la mediana del NDVI para cada año, de 2001 a 2020. El área de estudio fue delimitada a través de la capa de límites municipales de la FAO, (2015). Además, se recurrió a imágenes de Landsat 7 y Landsat 8 para obtener una visualización con mayor nitidez de las zonas deforestadas. Posteriormente los NDVIs delimitados fueron descargados a la computadora y así con QGIS, mediante reclasificación de píxeles, se obtuvieron mapas de la cobertura vegetal y una base de datos con la información de la distribución de la vegetación por año (Figura 5).

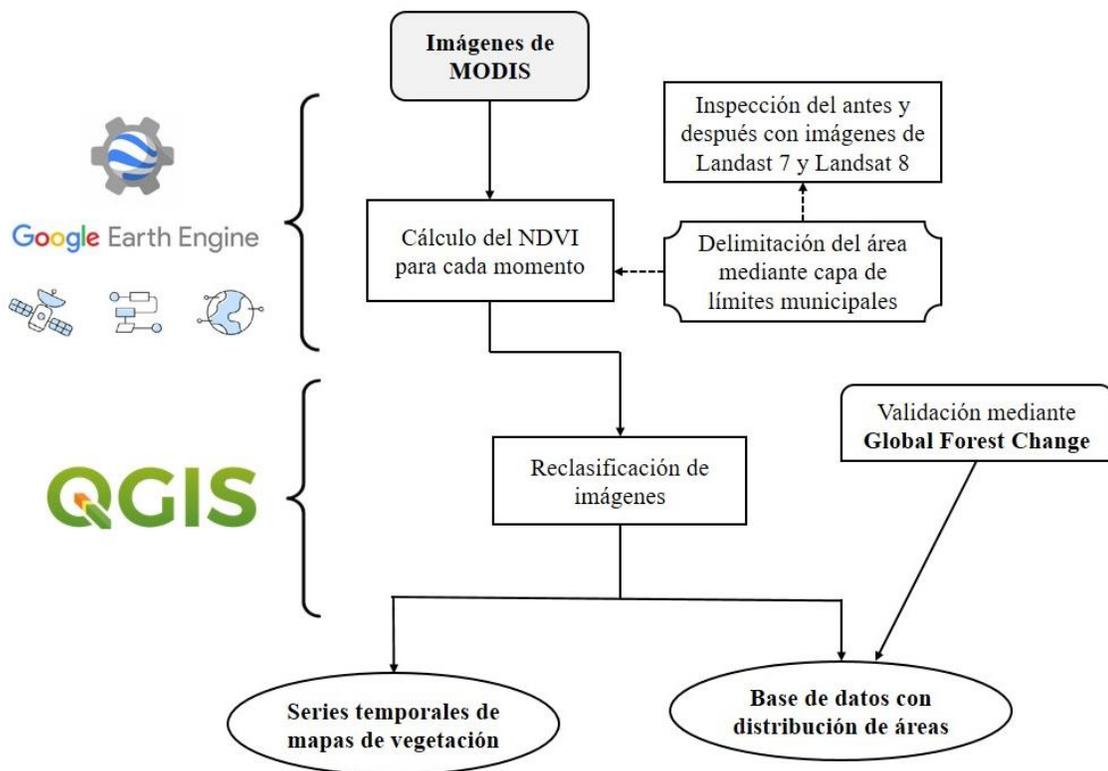


Figura 5. Diagrama de trabajo del segundo estudio de caso.

Los resultados de este estudio permiten observar mediante una serie temporal de mapas, la dinámica que ha presentado la frontera agrícola, así como de las áreas de los bosques en la Reserva de Bosawás durante el período 2001 - 2020. Mientras que la base de datos permite la cuantificación de las pérdidas de bosque y ganancia de superficies agropecuarias para cada uno de los años analizados.

### 4.2.3 Tercer estudio de caso: Mapeo de la cobertura y usos del suelo en el departamento de Chinandega mediante clasificación automatizada, utilizando Google Earth Engine

Para el mapeo del departamento de Chinandega, se utilizó la plataforma Google Earth Engine, con la cual, mediante el algoritmo de aprendizaje automático *Random forest*, se elaboró una clasificación de la imagen Sentinel 2 con la adición de 7 índices espectrales derivados de la misma, 17 bandas en total. Utilizando geometrías de entrenamiento, se muestrearon las firmas espectrales de los nueve principales tipos de cobertura superficial del departamento. Con estas firmas, se entrenó al algoritmo para que realizará la clasificación de la cobertura de todo el departamento. Finalmente, el modelo fue validado a través de puntos de muestreo utilizando el software QGIS y el complemento *Point Sampling Tool* (Figura 6).

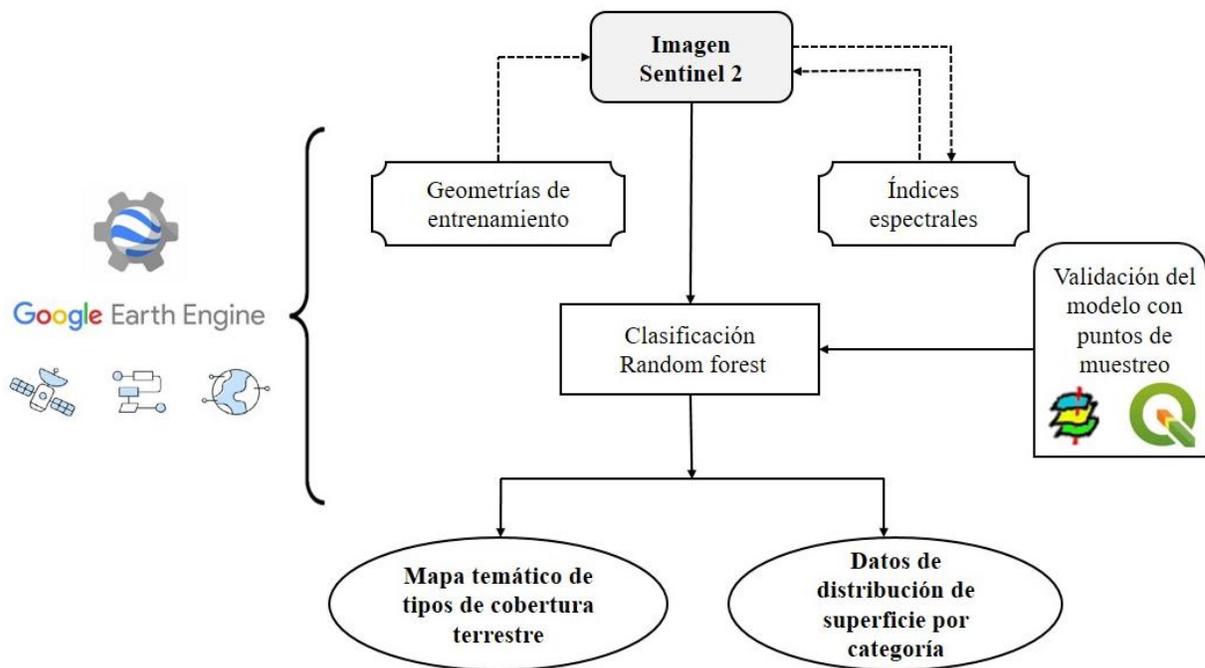


Figura 6. Diagrama de trabajo del tercer estudio de caso.

Los resultados de este estudio corresponden a un mapa de cobertura y usos del suelo del departamento de Chinandega más una base de datos con el inventario en superficie de cada una de las categorías generadas. Estos productos están actualizados al momento de la captura de la imagen, es decir, 10 de febrero del 2021.

### **4.3 Variables evaluadas**

#### **4.3.1 Primer estudio**

- Superficie cultivada (ha) en época de riego durante los meses de febrero a marzo, en la región de El Valle de Sébaco durante el período 2017 a 2021.

#### **4.3.2 Segundo estudio**

- Incremento de la superficie agropecuaria en los siete municipios que rodean la Reserva de Biósfera Bosawás durante el período 2001 a 2020.
- Pérdidas de las áreas boscosas en los siete municipios que rodean la Reserva de Biósfera Bosawás durante el período 2001 a 2020.
- Relación entre la pérdida de áreas boscosas y el aumento de las áreas agropecuarias.
- Estimación del momento en que las áreas agropecuarias se interceptan con las áreas boscosas en igualdad de superficies.

#### **4.3.3 Tercer estudio**

Mapeo y cuantificación de los usos de la tierra en el departamento de Chinandega, según la siguiente clasificación:

- Área urbana
- Suelo desnudo
- Salinera
- Superficies de agua
- Humedal
- Tacotal
- Foresta
- Cultivos y pastos
- Rastrojo

#### 4.4 Recolección de datos

##### Selección de imagen Sentinel 2 del Valle de Sébaco

Haciendo uso de Google Earth Engine, se seleccionaron 5 imágenes del satélite Sentinel 2 correspondientes a los años 2017 a 2021. Los parámetros de selección se definieron de acuerdo al momento de la captura y el porcentaje de nubes. Las capturas corresponden a los meses de febrero y marzo, ya que en este momento las áreas cultivadas bajo riego están próximas al período de cosecha. El máximo porcentaje de nubes permitido fue de 5 %, sin embargo, el área de análisis se encontró libre de estas. En la figura 7 se presentan las imágenes seleccionadas.

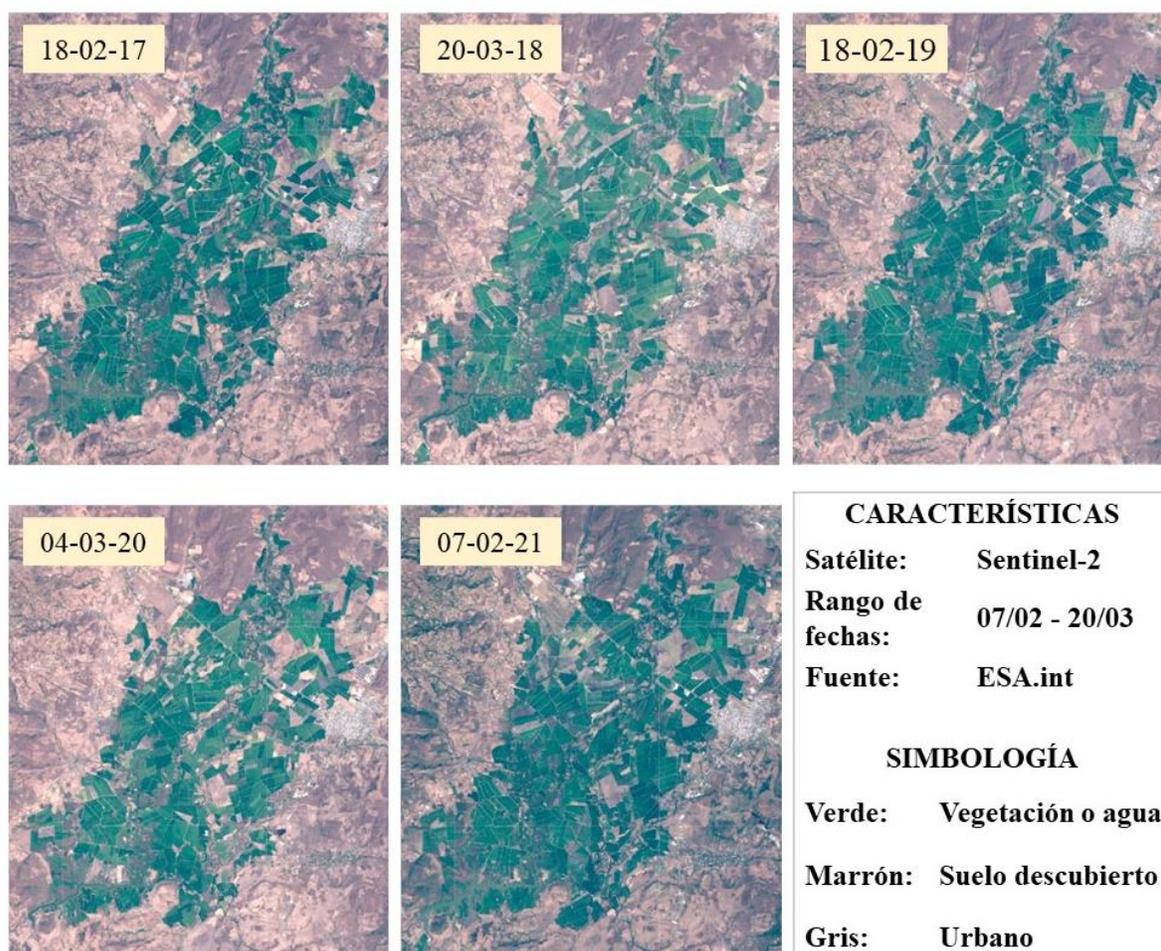


Figura 7. Imágenes Sentinel 2 a color natural (bandas: 4-3-2).

## Selección de imágenes MODIS del área donde se ubica la Reserva de Biosfera de Bosawás

Mediante Google Earth Engine se accedió al producto del sensor MODIS-MCD43A4-V6 del satélite Terra de la NASA y distribuido por la USGS<sup>4</sup>. El sensor recopila casi a diario datos de la superficie terrestre y los hace disponibles en un período de 16 días a través de un mosaico libre de nubes. Con estos datos se generó una imagen mediana por año, solicitando una colección de imágenes y aplicándoles la función “*median()*” la cual selecciona el pixel con el valor mediano del conjunto de datos. El motivo para trabajar con la mediana y no con la media, es que en la mediana se ve menos influenciada por la presencia de valores atípicos.

Utilizando la capa de límites administrativos de la FAO, (2015) se delimitó el área de estudio correspondiente a los 7 municipios que rodean la Reserva de Biósfera Bosawás. En la figura 8 se presenta una imagen MODIS a color natural correspondiente al área de estudio. La imagen de muestra corresponde a la mediana del año 2019, el tono verde oscuro muestra las áreas boscosas, mientras que el verde pálido muestra áreas de vegetación de porte bajo (cultivos, pastos, arbustos), las zonas marrones corresponden a zonas con ausencia de vegetación.



Figura 8. Imagen MODIS a color natural (bandas: 1-4-3).

---

<sup>4</sup> <https://lpdaac.usgs.gov/data/get-started-data/collection-overview/missions/modis-overview/>

### Selección de la imagen Sentinel 2 del departamento de Chinandega

La imagen proviene del satélite Sentinel 2, fue capturada el 10 de febrero de 2021. Se seleccionó de este mes, ya que en este momento se encuentra presente una diversa variedad de cultivos bajo riego, mientras que la vegetación natural herbácea tiende a disminuir. La imagen posee 3 % de cobertura de nubes, pero estas se ubicaban fuera del área de estudio. La imagen se delimitó mediante un polígono dibujado a mano y siguiendo los trazos del mapa base de Google (figura 3). Además, debido a que la imagen estaba fragmentada en 3 teselas, se realizó una unión de éstas para obtener un mosaico que abarcara al departamento en su totalidad (Figura 9).



Figura 9. Imagen Sentinel 2 del departamento de Chinandega, tomada el 10 de febrero del 2021 en una composición a color natural (bandas: 4-3-2).

## 4.5 Análisis de datos

### 4.5.1 Primer estudio

#### *Elaboración del Índice de Vegetación de Diferencia Normalizada (NDVI)*

El NDVI es uno de los indicadores más utilizados en estudios de vegetación. Este se determinó para cada año mediante la siguiente expresión:

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \quad (\text{Rouse } et \text{ al.}, 1973), \text{ donde:}$$

$\rho_{NIR}$ : en Sentinel 2 la banda 8

$\rho_{RED}$ : en Sentinel 2 la banda 4

Google Earth Engine cuenta con la función “*normalizedDifference()*”, la cual ejecuta el algoritmo que permite la obtención del NDVI. Los valores del índice son adimensionales y originalmente vienen representados en escalas de grises, sus valores oscilan entre -1 y 1. En la figura 10 se observa un NDVI en donde las zonas más brillantes o claras con valores cercanos a +1 corresponden a zonas con vegetación sana y vigorosa, tonos intermedios cercanos a 0 revelan escasez de vegetación o suelo desnudo, mientras que valores negativos cercanos a -1 corresponden a masas de agua, suelo desnudo, rocas y área urbana.



Figura 10. Monobanda del NDVI en escala de grises.

Para mejorar la visualización de los elementos de la superficie, a cada NDVI se le asignó una rampa de cinco tonalidades, como se aprecia en la figura 11. Con esta visualización, se hacen más distinguibles las zonas con vegetación. Sin embargo, los valores siguen manteniendo un carácter continuo en el que los colores se difuminan en dependencia de los valores del NDVI, para mejorar la visualización y facilitar la extracción de la información, los datos fueron discretizados en cuatro categorías (Cuadro 3).

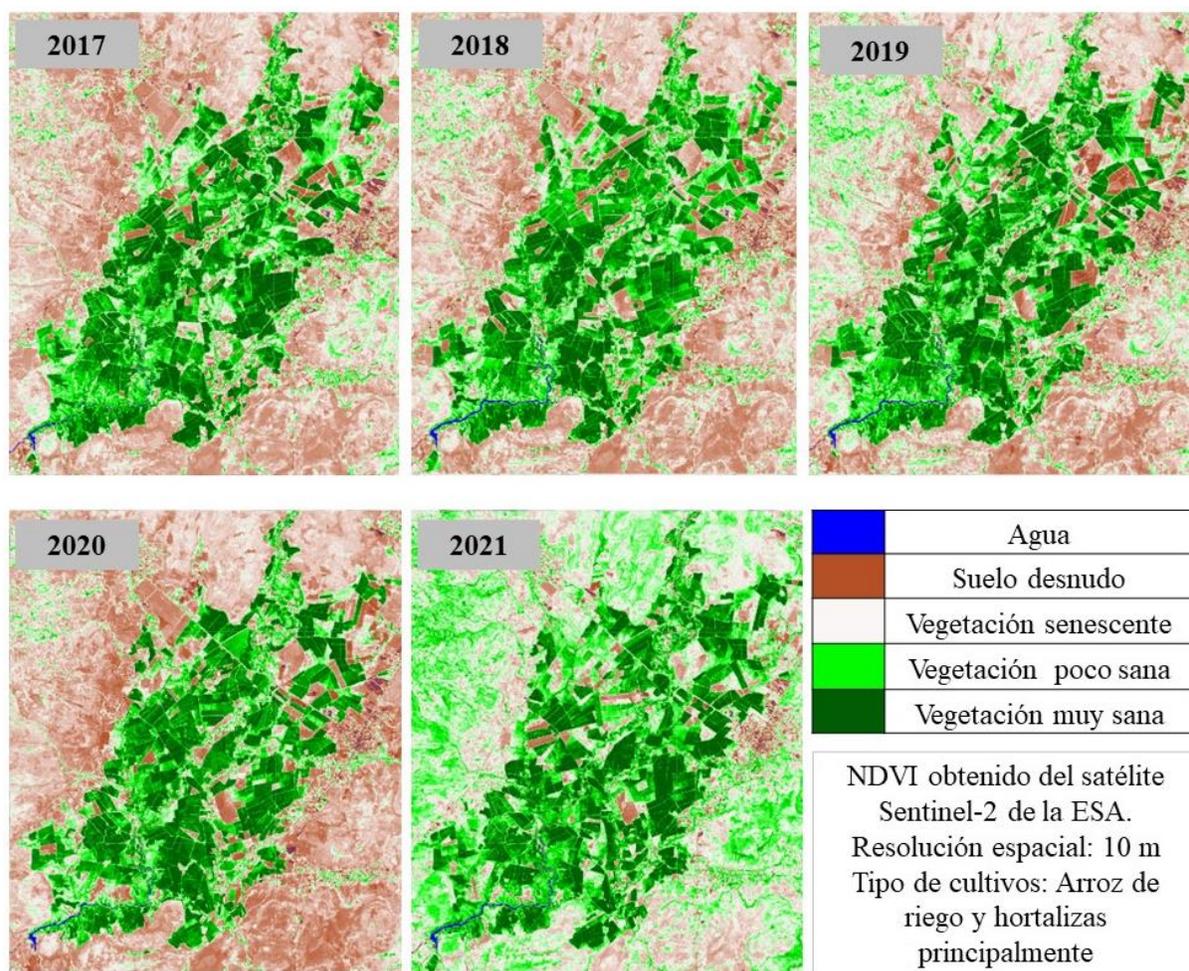


Figura 11. Índices NDVI's 2017 a 2021 representados en una rampa de 5 colores.

Para delimitar el área agrícola, se utilizó el filtro RGB y los NDVI's de 2019, 2020 y 2021, con los cuales se elaboró un índice NDVI multitemporal (Matellanes, 30 de octubre del 2019). Con este índice, se puede observar mediante una trama de colores, el momento en que las parcelas han presentado actividad fotosintética, permitiendo, delimitar con más detalle el área de estudio y excluir las áreas no agrícolas, evitando introducir sesgo en el análisis.

Con el NDVI multitemporal se observa a la vegetación presente en el primer momento teñida de rojo, la del segundo momento en verde y la del tercero en azul, la mezcla de estos colores también revela si ha habido vegetación en más de un momento o en ninguno, por ejemplo; la combinación del rojo y el verde produce al amarillo, por lo tanto, estas parcelas se cultivaron en el primer y segundo momento; el rojo y azul produce al magenta, estas parcelas se cultivaron en el primer y tercer momento; el verde y el azul producen cian, estas parcelas se cultivaron el segundo y tercer momento; la combinación conjunta de los tres colores produce al blanco, corresponde a parcelas con actividad agrícola permanente y la ausencia de colores da como resultado al negro, esto indica ausencia de vegetación en todos los momentos (Figura 12).

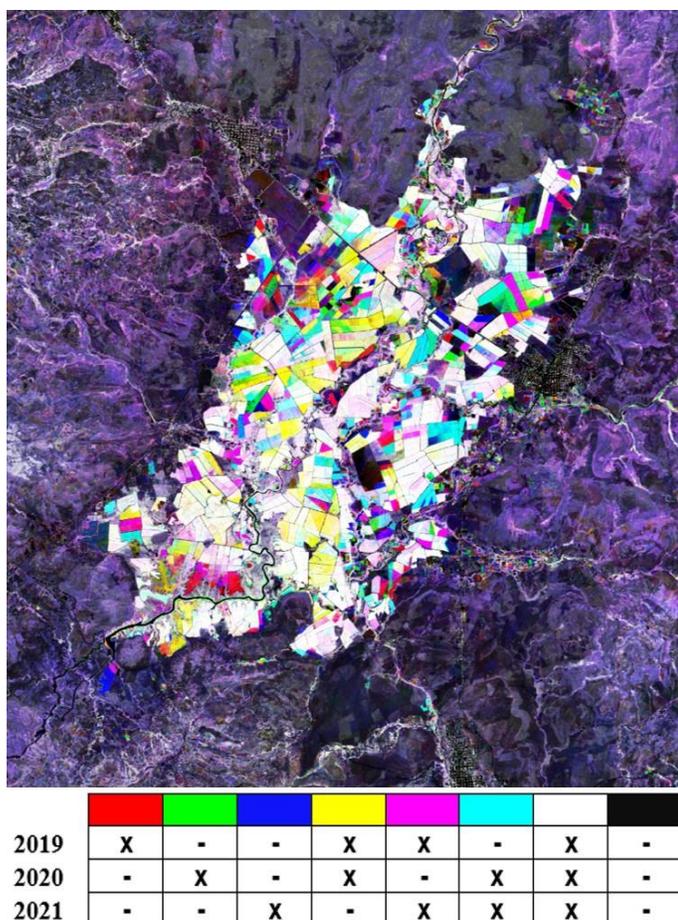


Figura 12. NDVI multitemporal elaborado con datos del 2019, 2020 y 2021.

El área que ha presentado actividad agrícola en los últimos tres años corresponde a una superficie de 18,114 hectáreas (Anexo 10). Una vez delimitada el área agrícola, se descargaron los índices a la computadora para realizar los procesos finales con el software QGIS.

## *Procesos finales en QGIS*

### *Reclasificación de los valores de píxel y transformación de ráster a vector*

Cada NDVI corresponde a una base de datos con valores continuos, estos fueron transformados a valores discretos reclasificándolos en cuatro categorías, asignándole dos de estas a la vegetación, de modo que la vegetación se clasificó como moderadamente sana y muy sana (Cuadro 3). Los valores negativos del NDVI fueron reemplazados por los valores positivos del NDWI, el cual se determina a través de la siguiente expresión  $= \frac{\text{Green}-\text{NIR}}{\text{Green}+\text{NIR}}$  (McFeeters, 1996), de esta manera se obtuvieron datos puros de las superficies de agua. Los valores de la reclasificación se agruparon de la siguiente manera:

Cuadro 3. Definición de las categorías para la reclasificación del NDVI en Sentinel 2 para el Valle de Sébaco

<b>Categoría</b>	<b>Valor NDVI</b>	<b>Tipo de cobertura</b>
1	-1 a 0 <sup>5</sup>	Agua
2	0 a 0.33	Suelo desnudo y rastrojo
3	0.33 a 0.66	Vegetación moderadamente sana
4	0.66 a 1	Vegetación muy sana

Fuente: Balza, (2019).

Posteriormente se realizó la transformación de la imagen clasificada a un archivo vectorial tipo polígono en formato shapefile (Anexo 11). Estos archivos poseen una tabla de atributos con los valores del NDVI agrupados en polígonos, con esta tabla es posible realizar procesos matemáticos que faciliten el manejo y la interpretación de los datos, como el cálculo de las superficies para cada categoría.

---

<sup>5</sup> Reemplazado por los valores positivos del NDWI

### ***Cálculo de áreas y exportación de base de datos a Excel***

Mediante la calculadora de campos integrada a QGIS y utilizando los valores obtenidos de la reclasificación, disponibles en la tabla de atributos de los datos vectorizados, se calculó la superficie ocupada por cada una de las categorías para cada momento analizado. Posteriormente, las tablas de atributos con la información de las superficies por categorías fueron exportadas a un archivo en formato Excel para la interpretación de los resultados.

#### **4.5.2 Segundo estudio**

##### ***Elaboración del Índice de Vegetación de Diferencia Normalizada (NDVI)***

A partir de las 20 imágenes seleccionadas y haciendo uso de la plataforma Google Earth Engine, se elaboró un NDVI con el valor mediano para cada año. En el caso de MODIS, el espectro rojo (RED) se almacena en la banda 1 y el infrarrojo cercano (NIR) en la banda 2, ambas con una resolución espacial de 500 metros.

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \text{ (Rouse et al., 1973).}$$

Una vez obtenidos los NDVIs se descargaron a la PC para los procesos finales con QGIS.

##### ***Determinación de los valores de píxel para cada categoría***

Para separar íntegramente los valores correspondientes a cada categoría, se realizó un muestreo de los valores de píxeles con la herramienta “*identificación de objetos espaciales*” integrada en QGIS. En la figura 13 se presenta un NDVI con una rampa de colores en la que se muestra a la vegetación de porte bajo en tono verde pálido, mientras que las áreas boscosas en verde oscuro. La herramienta permitió identificar las áreas de vegetación herbácea y arbustiva con valores entre 0.7 y 0.8, mientras que las áreas de bosque compacto con valores por encima de 0.8.

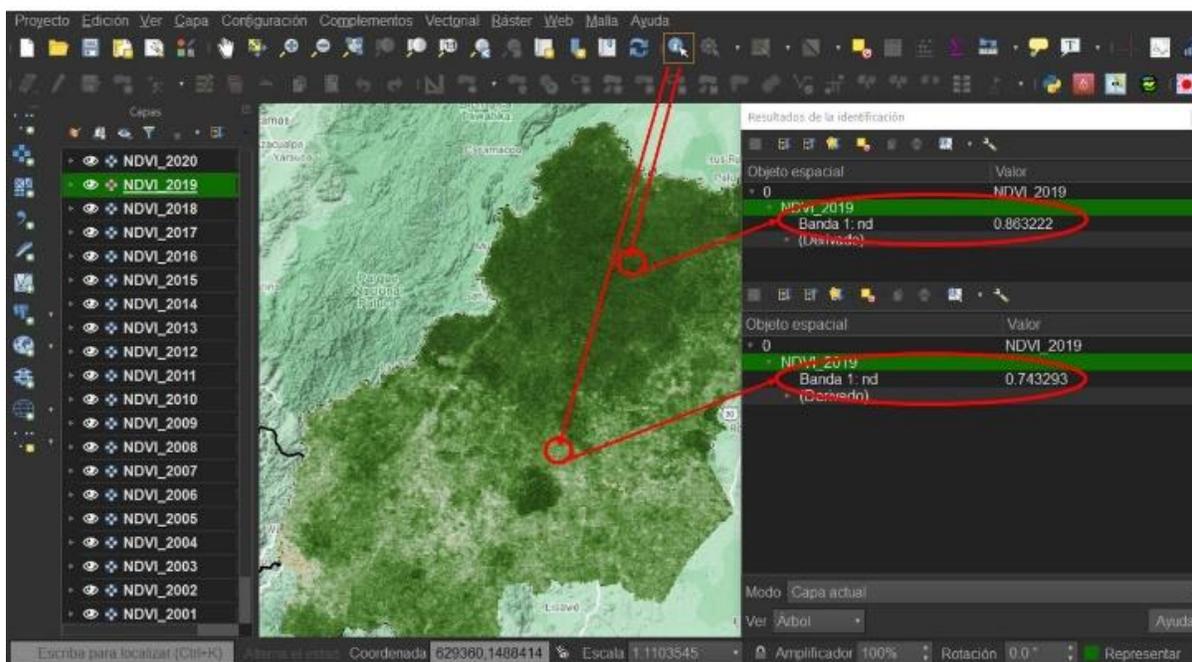


Figura 13. Muestreo de valores de píxel en QGIS.

### ***Reclasificación, transformación de ráster a vector y extracción de las bases de datos***

Estimado el rango de los valores de píxel, se discretizó a cada NDVI, agrupando los valores de sus píxeles en cuatro categorías. En el cuadro 4 se presentan los valores asignados a cada una.

Cuadro 4. Definición de las categorías para la reclasificación del NDVI de MODIS

<b>Categoría</b>	<b>Valor del NDVI</b>	<b>Tipo de cobertura</b>
<b>1</b>	-1 a 0.4	Agua y áreas no agrícolas
<b>2</b>	0.4 a 0.7	Suelo desnudo, vegetación senescente y rastrojo
<b>3</b>	0.7 a 0.8	Agricultura, pastizales y arbustos
<b>4</b>	0.8 a 1	Áreas boscosas

Fuente: Elaboración propia a partir del muestreo de píxeles del NDVI

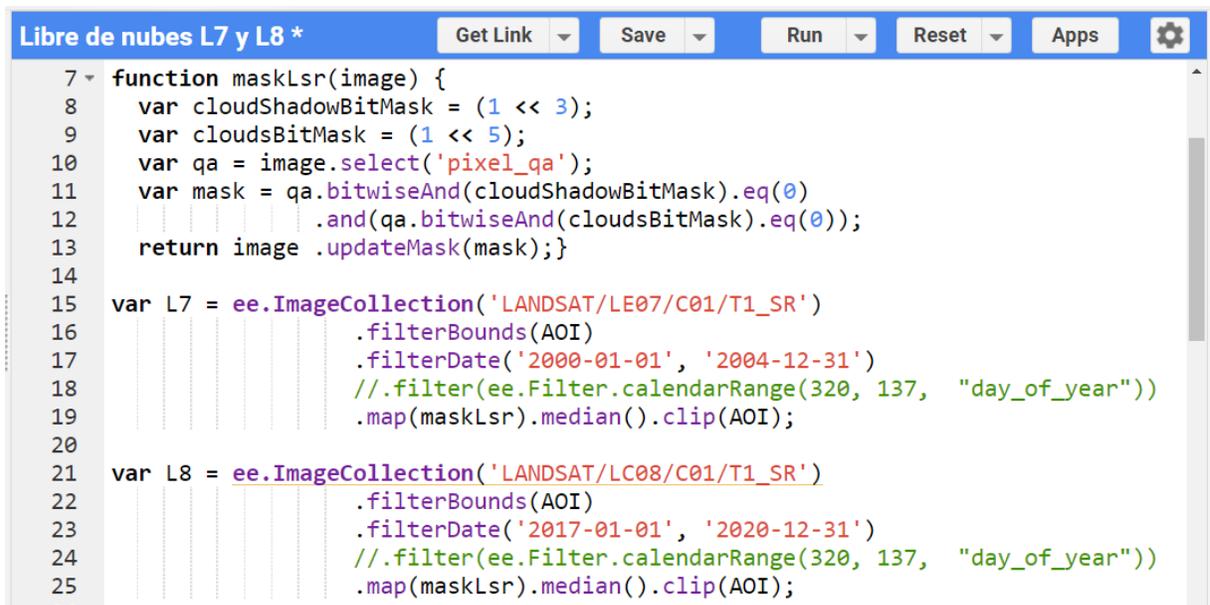
Realizada la reclasificación de cada NDVI, se llevó a cabo la transformación de cada imagen en formato ráster a archivos vectoriales tipo polígono en formato *shp* (Anexo 11). A estos archivos se les realizó el cálculo de las superficies para cada categoría utilizando la calculadora de campos integrada en la tabla de atributos de QGIS. Las bases de datos obtenidas en QGIS fueron descargadas a la computadora en formato Excel.

De manera que el producto obtenido del sensor MODIS-MCD43A4-V6 corresponde a bases de datos con información de la distribución espacial y temporal de las zonas agropecuarias y de los bosques en los siete municipios que comparten la Reserva. Además, los archivos obtenidos del NDVI fueron utilizados para elaborar una secuencia de 20 mapas que revelan la evolución de la frontera agropecuaria en la zona de la Reserva durante el período analizado (Figura 23).

#### ***Uso de imágenes Landsat para visualización de las zonas de cambio de cobertura terrestre***

La importancia de incluir las imágenes Landsat en el análisis, radica en las dimensiones de píxeles de ambos productos. Mientras que los píxeles de MODIS presentan una resolución de 500 m. y son adecuados para análisis de extensas regiones, facilitando el procesado de datos en la computadora, no permiten una visualización en detalle de las zonas afectadas. Mientras que las imágenes Landsat con píxeles de 30 m. poseen un mayor volumen de datos, dificultando el procesado de los mismos en una computadora ordinaria (Anexo 1), pero permiten una mejor visualización de las áreas en donde ha habido un mayor cambio en el tipo de cobertura de suelo.

Mediante Google Earth Engine se accedió a imágenes Landsat 7 de 2000 a 2004 e imágenes Landsat 8 de 2017 a 2020. A cada una de estas colecciones se les aplicaron funciones para eliminar los píxeles con presencia de nubes y sombras, con los datos no removidos se crearon dos imágenes sintéticas con el valor del píxel mediano, con estas se pudo obtener una visualización con una resolución 17 veces mayor que con las imágenes MODIS. En la figura 14 se muestra el código que permitió la obtención de los mosaicos libres de nubes y sombras.



```
Libre de nubes L7 y L8 *
Get Link Save Run Reset Apps
7 function maskLsr(image) {
8   var cloudShadowBitMask = (1 << 3);
9   var cloudsBitMask = (1 << 5);
10  var qa = image.select('pixel_qa');
11  var mask = qa.bitwiseAnd(cloudShadowBitMask).eq(0)
12             .and(qa.bitwiseAnd(cloudsBitMask).eq(0));
13  return image .updateMask(mask);}
14
15 var L7 = ee.ImageCollection('LANDSAT/LE07/C01/T1_SR')
16         .filterBounds(AOI)
17         .filterDate('2000-01-01', '2004-12-31')
18         // .filter(ee.Filter.calendarRange(320, 137, "day_of_year"))
19         .map(maskLsr).median().clip(AOI);
20
21 var L8 = ee.ImageCollection('LANDSAT/LC08/C01/T1_SR')
22         .filterBounds(AOI)
23         .filterDate('2017-01-01', '2020-12-31')
24         // .filter(ee.Filter.calendarRange(320, 137, "day_of_year"))
25         .map(maskLsr).median().clip(AOI);
```

Figura 14. Script para la elaboración del mosaico de Landsat 7 y 8 libre de nubes.

### ***Validación de los resultados con Global Forest Change***

Los resultados obtenidos a partir de MODIS, se validaron con la aplicación *Global Forest Change*,<sup>6</sup> la cual es un proyecto desarrollado por científicos de la Universidad de Maryland, EE. UU. a cargo del Dr. Matt Hansen, (2013). Esta contiene datos de áreas deforestadas a nivel mundial desde el año 2000 y se actualiza cada año. Los productos corresponden a series temporales de imágenes Landsat que caracterizan la extensión y el cambio del bosque. Los datos están procesados y se encuentran a disposición de manera gratuita para ser visualizados, descargados y analizados para cualquier región del mundo.

---

<sup>6</sup> <https://earthenginepartners.appspot.com/science-2013-global-forest>

Entre los productos que ofrece Global Forest Change para descarga, se encuentran datos de cobertura, pérdida anual, ganancia y datos individuales del primer año, y del último año de la cobertura boscosa. Los datos seleccionados para la validación corresponden a la pérdida anual del bosque en formato TIFF (*Target File Format*) con valores reclasificados del NDVI de Landsat. Se seleccionaron los datos correspondientes al cuadrante 20 N, 90 W (Anexo 12) que abarca completamente a Nicaragua, Honduras, El Salvador, Belice y parte de Costa Rica y Guatemala, un área de 120 millones de hectáreas.

Mediante la capa de límites administrativos de la FAO (2015), se delimitó el área de estudio correspondiente a los 7 municipios que rodean la Reserva de Biósfera Bosawás, misma utilizada para delimitar el área en las imágenes MODIS (Anexo 13). Los procesos para la extracción de los datos se realizaron de la misma manera que se realizaron con MODIS, solo que esta vez, a partir de la transformación de ráster a vector.

La validación de los resultados se realizó a través de un método empírico, comparando los resultados obtenidos de los productos MODIS con los datos de Landsat obtenidos a través de Global Forest Change. De modo que la diferencia de entre ambos productos constituye el % de error estimado. El método se realizó a través de la siguiente expresión:

$$\% \text{ Error} = \left( \frac{\text{Resultados MODIS} - \text{Resultados Global Forest Change}}{\text{Resultados MODIS}} \right) \times 100$$

### 4.5.3 Tercer estudio

Para el mapeo de la cobertura y usos del suelo del departamento de Chinandega, se consultó a los siguientes autores: Barenblitt y Fatoyinbo (2020), Navarro (2020), Rodríguez (2021) y la guía de usuario<sup>7</sup> de Google Earth Engine, donde se describe la metodología para la clasificación automatizada, el proceso está relacionado a ciencias computacionales, específicamente a técnicas de aprendizaje automático o *Machine Learning* (Russell & Norving, 2009).

Los datos de entrada corresponden a la imagen satelital y su conjunto nativo de bandas espectrales más la adición de índices espectrales derivados de las mismas y añadidos a la imagen. Sobre esta imagen robusta se superpone una serie de geometrías de entrenamiento (puntos, líneas y polígonos) que se utilizan para extraer el valor espectral en todas las bandas de cada píxel interceptado, este valor es lo que se conoce como la firma espectral (Anexo 16 y 17).

Con estas firmas espectrales se entrena al algoritmo de clasificación integrado a la plataforma Google Earth Engine, de esta manera el algoritmo adquiere la capacidad de reconocer el valor del resto de píxeles en toda la imagen para asignarles su respectiva categoría o etiqueta. Los datos de salida o resultados corresponden a la imagen clasificada en las categorías que se hayan definido, para este estudio se definieron 9 categorías en función del conocimiento previo de la zona y el análisis visual de la imagen Sentinel 2. Barenblitt y Fatoyinbo (2020) describen el proceso de la clasificación automatizada de manera sencilla en la figura 15.

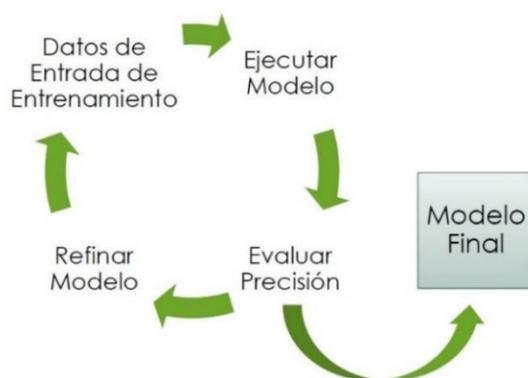


Figura 15. Esquema simple del proceso de clasificación automatizada. Fuente: Barenblitt y Fatoyinbo 2020.

---

<sup>7</sup> <https://developers.google.com/earth-engine/guides>

### *Características de las bandas de la imagen*

Se utilizaron las diez bandas de Sentinel 2, en las que almacena la energía del espectro visible hasta las infrarrojas de onda corta. En el cuadro 5 se presentan algunas de las principales características de estas.

Cuadro 5. Características de las bandas espectrales de Sentinel 2

<b>Banda</b>	<b>Espectro</b>	<b>Longitud de onda, <math>\lambda</math> (<math>\mu\text{m}</math>)</b>	<b>Resolución(m)</b>
2	Blue	0.45 - 0.52	10
3	Green	0.54 - 0.57	10
4	Red	0.65 - 0.68	10
5	Red edge 1	0.69 - 0.71	20
6	Red edge 2	0.73 - 0.74	20
7	Red edge 3	0.77 - 0.79	20
8	NIR 1	0.78 - 0.90	10
8A	NIR 2	0.85 - 0.87	20
11	SWIR 1	1.56 - 1.65	20
12	SWIR 2	2.10 - 2.28	20

Fuente: Matellanes (2019).

### *Elaboración de índices espectrales*

Para aumentar la precisión de la clasificación, se realizó el cálculo de siete índices espectrales de diferencia normalizada (Peña-Barragán, 2011; Barenblitt & Fatoyinbo, 2020), estos fueron añadidos a las demás bandas de la imagen, generándose una imagen más robusta con información en diecisiete bandas. Gracias a la adición de estos índices, el algoritmo de clasificación contó con firmas espectrales más amplias (Anexo 17) que le permitieron la identificación más precisa de los valores de píxel de cada una de las categorías en las que se fragmentó el territorio. En el cuadro 6 se muestran los índices añadidos, así como su aplicación y su respectiva ecuación.

Cuadro 6. Índices añadidos a la imagen Sentinel 2 de Chinandega

Índice	Aplicación	Ecuación
NDVI	Vegetación	$(\text{NIR} - \text{Red}) / (\text{NIR} + \text{Red})$
GNDVI	Vegetación verde	$(\text{NIR} - \text{Green}) / (\text{NIR} + \text{Green})$
NDMI	Humedad del suelo	$(\text{NIR} - \text{SWIR } 1) / (\text{NIR} + \text{SWIR } 1)$
NDWI	Superficies de agua	$(\text{Green} - \text{NIR}) / (\text{Green} + \text{NIR})$
MNDWI	Agua en la vegetación	$(\text{Red} - \text{SWIR } 1) / (\text{Red} + \text{SWIR } 1)$
NBR	Área quemada	$(\text{NIR} - \text{SWIR } 2) / (\text{NIR} + \text{SWIR } 2)$
NDBI	Edificaciones urbanas	$(\text{SWIR } 1 - \text{NIR}) / (\text{SWIR } 1 + \text{NIR})$

Fuente: Rouse *et al.* (1973); Gitelson *et al.* (1996); McFeeters (1996); Gao (1996); Key & Benson (1999), USGS (2019) y Rosell y Vicente (2016).

### *Definición de las categorías*

Se definieron nueve categorías en función de los elementos que predominan en el departamento, en el caso de la vegetación, a esta se le asignaron cinco clases (Cuadro 7).

Cuadro 7. Categorías y tipos de cobertura para cada clase de cobertura

Categoría	Tipo de cobertura	Descripción
1	Urbano	Edificaciones de piedra, metal, cerámica de arcilla, asfalto
2	Suelo desnudo	Suelo sin cobertura vegetal, ni artificial
3	Agua	Intrusión marina, lagunas, reservorios, ríos
4	Humedal	Manglares y vegetación costera
5	Salinera	Bancos de extracción de sal
6	Forestal	Vegetación arbórea compacta
7	Tacotal	Arbustos y terrenos en barbecho
8	Cultivo	Todo tipo de vegetación herbácea
9	Rastrojo	Restos de cultivos y malezas, hojarasca

Fuente: Elaboración propia a partir del conocimiento del área de estudio.

### ***Creación de las regiones de entrenamiento***

Las regiones de entrenamiento se elaboraron mediante elementos geométricos en forma de puntos, líneas o polígonos dibujados estratégicamente sobre la imagen de acuerdo con las categorías establecidas. Con estas se capturó la firma espectral de los píxeles interceptados en función de las bandas de la imagen. Con estas firmas se entrenó al clasificador mediante aprendizaje automatizado, para identificar y clasificar el valor del resto de píxeles. Se muestrearon 174,440 píxeles, equivalente a una superficie de 17.44 km<sup>2</sup> (0.3 % del total de píxeles que componen a la imagen).

La ubicación estratégica de las regiones de entrenamiento fue fundamental para desarrollar el modelo, ya que de la calidad de las muestras depende la precisión alcanzada por el clasificador (Rodríguez, 2021). Para identificar correctamente las superficies de interés, se recurrió a estrategias analíticas de bandas que permitieron obtener visualizaciones RGB que resaltaran elementos difíciles de identificar a color natural. Además, se extrajo una muestra aleatoria del 50 % de los píxeles entrenados, para generar una réplica de la clasificación y así mediante una comparación, estimar el error del modelo. La precisión alcanzada por el modelo en Google Earth Engine fue de 0.9997 (Figura 16).

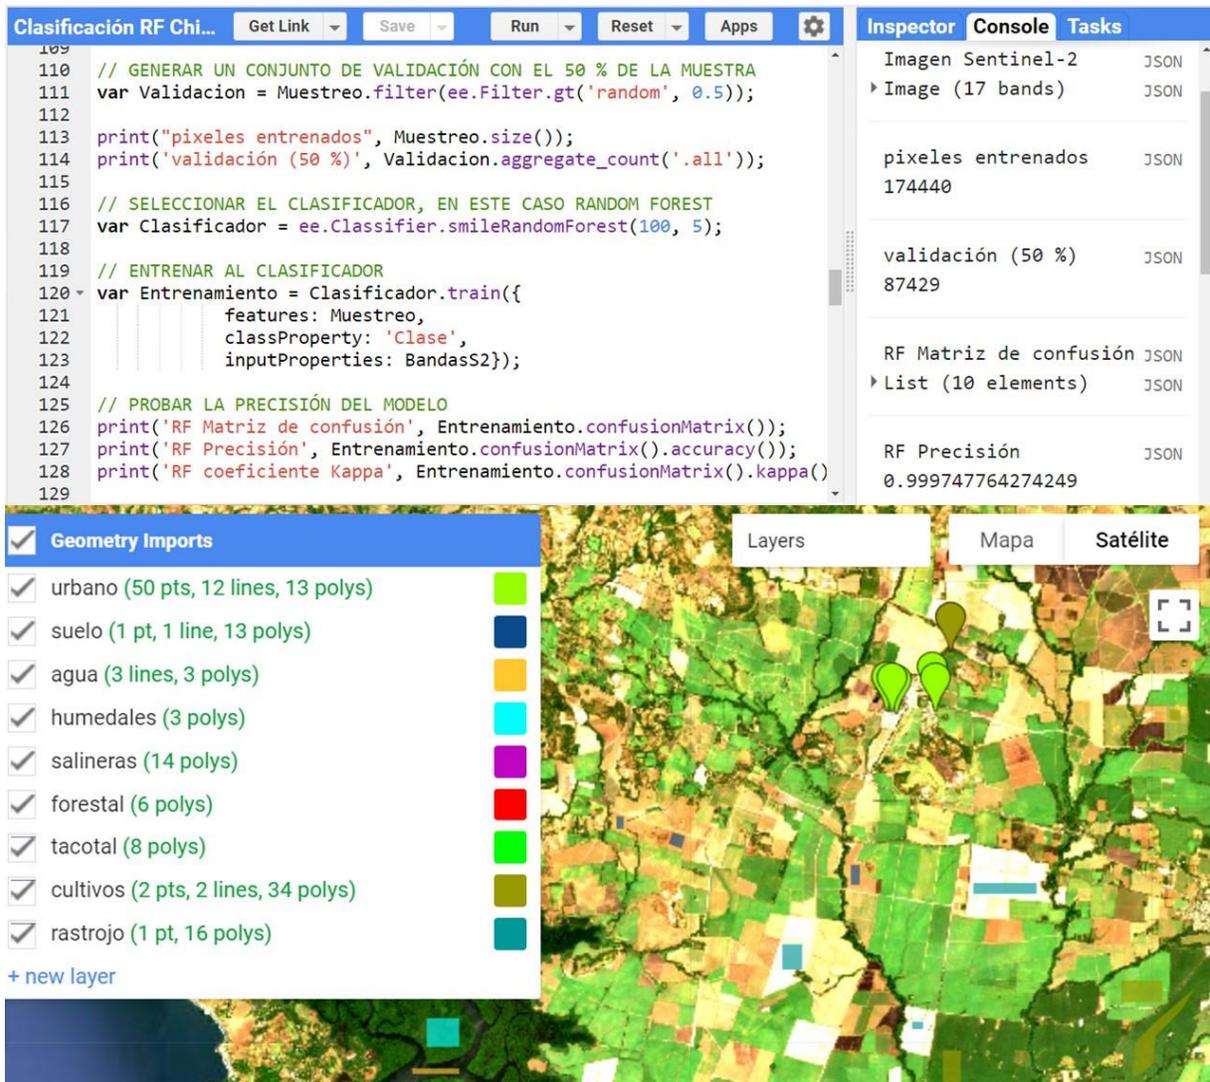


Figura 16. Cantidad y distribución de las geometrías de entrenamiento.

### *Selección y entrenamiento del clasificador*

Google Earth Engine posee un amplio repertorio de algoritmos de aprendizaje automático (Figura 17), entre los que se pueden mencionar: *Random forest* (Bosque aleatorio), *Support vector machine* (Máquina de vectores de soporte), *CART* (Árboles de clasificación y regresión), entre otros con diferentes niveles de precisión (Shesletov *et al.*, 2017). Para esta investigación se utilizó el clasificador *Random forest*, ya que es uno de los que han sido probado con satisfactorios niveles de precisión (Breiman & Cutler 2001; Castillo, 2015; Barenblitt & Fatoyinbo 2020; Rodríguez, 2021).

*Random forest* fue entrenado mediante las firmas espectrales contenida en los 174,440 píxeles interceptados por las geometrías de entrenamiento. Con esta información, el clasificador asumió la tarea de identificar el valor del resto de píxeles para agruparlos en su respectiva categoría. Una vez realizada la clasificación, se calculó la superficie de cada una de las categorías, esta información se descargó de forma directa a la computadora en formato de texto CSV.

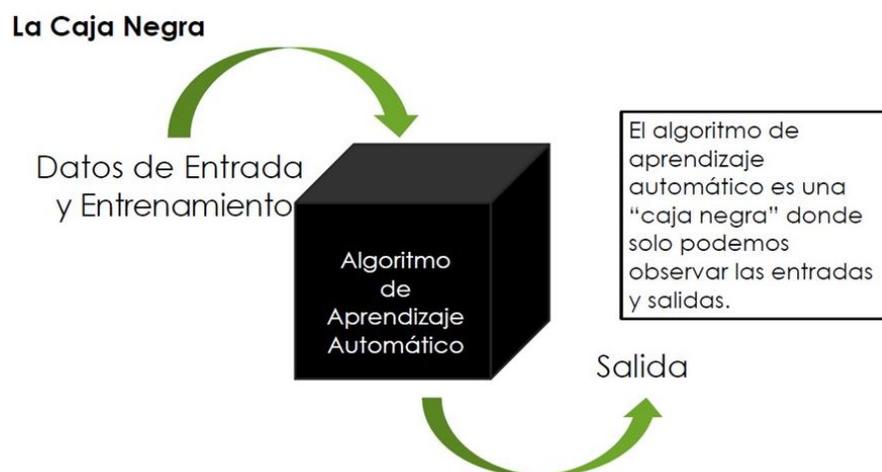


Figura 17. El aprendizaje automático representado como una caja negra (Fuente: Barenblitt & Fatoyinbo, 2020).

### ***Validación del modelo***

La validación del modelo permite estimar la semejanza entre lo que se presenta en la imagen clasificada con la realidad del terreno. Generalmente en una clasificación supervisada, donde lo que se pretende clasificar son las diferentes especies de cultivos, tanto las geometrías de entrenamiento como las de validación deben ser recolectados a través de visitas al campo, siendo estos datos excluyentes entre sí (Barenblitt y Fatoyinbo, 2020; Navarro, 2020 y Rodríguez, 2021).

En este caso, y teniendo en cuenta que el propósito de este análisis es más de carácter didáctico, se seleccionó un subconjunto aleatorio del 50 % de la muestra de píxeles entrenados para ser utilizados como datos de validación. Con este subconjunto de píxeles, se generó una réplica de la clasificación original y mediante comparación de los valores, se estimó el error del modelo.

Si bien Google Earth Engine posee algoritmos que permiten estimar el error del modelo a través de una matriz de confusión y diversos indicadores de precisión como el índice Kappa de Cohen (Carletta, 1996), lo más recomendable es realizar la evaluación de manera externa a la plataforma. En este caso la validación se realizó mediante el software QGIS y el complemento de muestreo estadístico Point sampling tool.

Con las herramientas de geometría vectorial integrada en QGIS se generó una nube de puntos espaciados a 1 km, 4,994 puntos en total (Figura 18). Con el complemento Point sampling tool se recolectaron los valores de las categorías de cada una de las clasificaciones, tanto de la original (generada con el 100 % de los píxeles entrenados) como de la réplica (obtenida con el 50 % de la muestra).

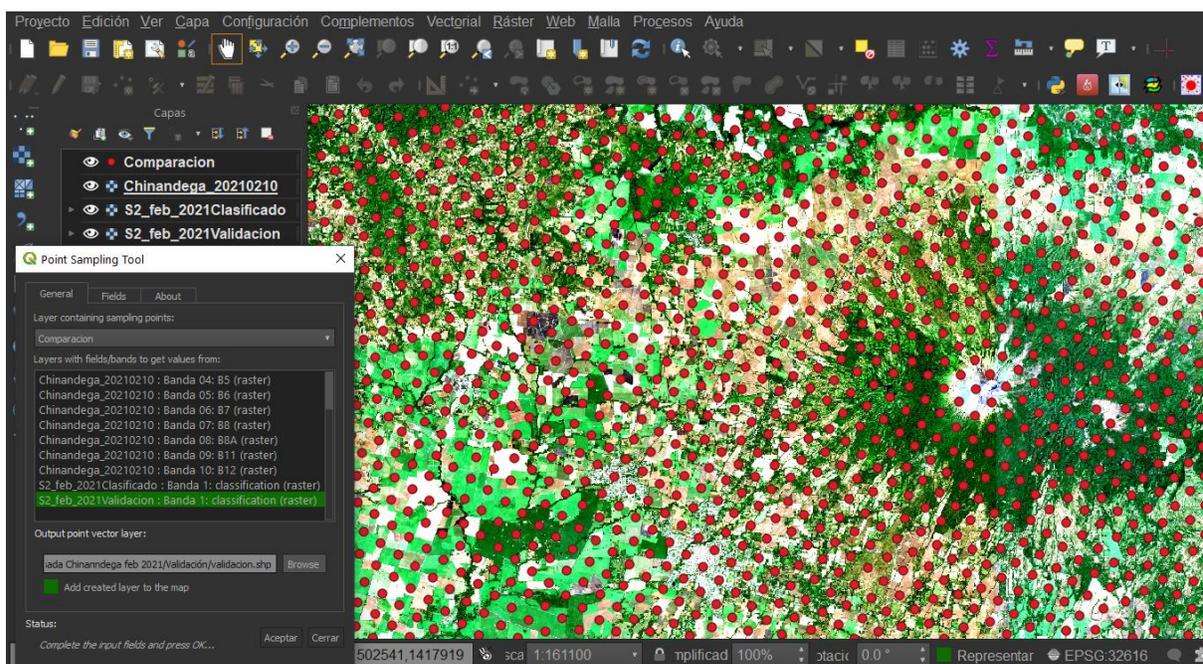


Figura 18. Nube de puntos para la extracción de los valores de la clasificación automatizada en QGIS para el departamento de Chinandega.

De modo que los valores de las clasificaciones quedaron integrados en la tabla de atributos de los 4,994 puntos, un campo para cada conjunto de valores. Al aplicar una operación de resta entre ambos conjuntos de valores, se generó un campo en el que los puntos que presentaron valores distintos a cero corresponden a los píxeles clasificados erróneamente, el porcentaje de estos valores con respecto a los puntos muestreados constituyeron el error del modelo.

## V. RESULTADOS Y DISCUSIÓN

### 5.1 Primer estudio de caso

Se presentan los resultados del análisis espacial y temporal de la vegetación. Esto se hizo durante la época seca del año en los meses de febrero y marzo, cuando la producción agropecuaria es bajo riego en el valle de Sébaco. Generalmente los cultivos tradicionales bajo riego en esta zona son arroz y hortalizas. El período de análisis corresponde de los años 2017 al 2021.

#### 5.1.1 Dinámica ocupacional de la vegetación bajo riego en el Valle de Sébaco

Estos resultados cualitativos muestran el conjunto de los cinco mapas producidos a partir de la reclasificación del NDVI Sentinel 2. Indican la dinámica espacial de la vegetación desde el año 2017 hasta el 2021. En cuanto a los tres primeros años (2017 a 2019) no se observan variaciones relevantes, en los cambios de la cobertura. En 2020 se observan las mayores áreas de suelo expuesto y reducción de la vegetación. En 2021 las áreas de suelo se redujeron considerablemente, presentando este año la mayor superficie con cobertura vegetal (Figura 19).

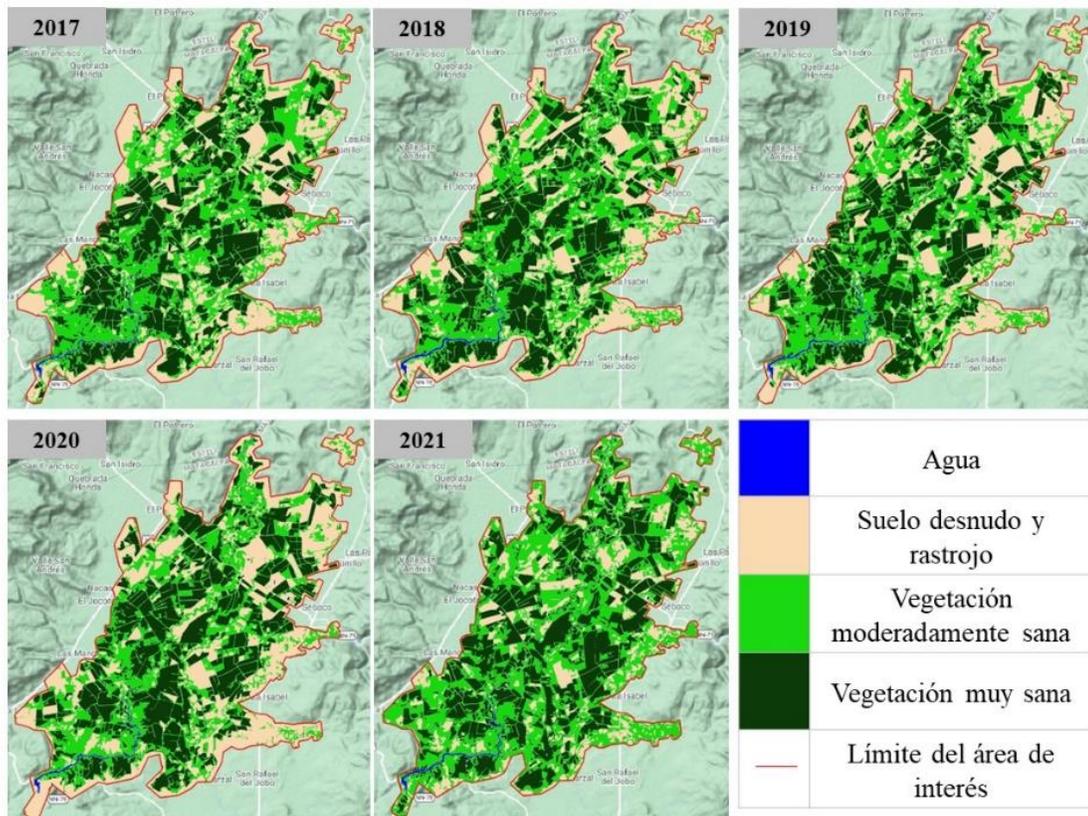


Figura 19. Serie temporal de la distribución espacial de los valores del NDVI.

### 5.1.2 Distribución de los cuatro tipos de cobertura terrestres

En la figura 20 se presenta la distribución superficial para cada tipo de cobertura obtenida a través de la reclasificación del NDVI, esta nos permite observar y cuantificar la evolución anual de los diferentes tipos de cobertura. Para analizar las superficies de agua de una manera más rigurosa, los valores negativos del NDVI se reemplazaron por valores positivos del NDWI<sup>8</sup>.

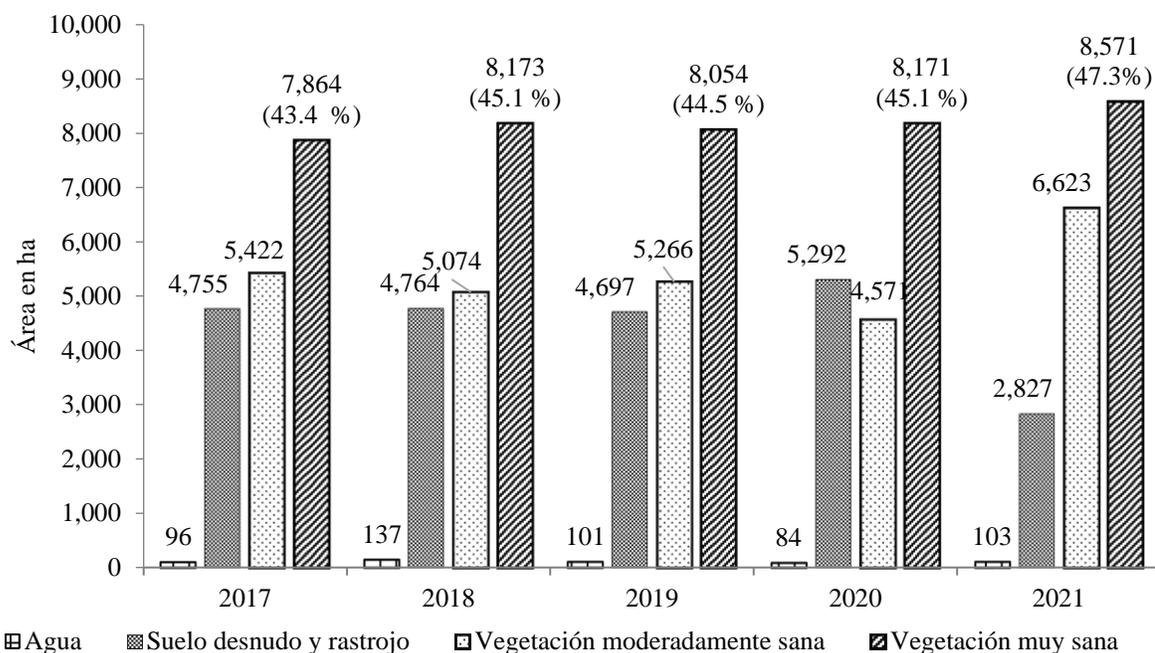


Figura 20. Distribución espacio-temporal de los tipos de cobertura en el Valle de Sébaco.

A través de la dinámica del agua (categoría 1), se puede observar la contribución de las precipitaciones aportadas por la tormenta Nate en octubre 2017 en el incremento de las superficies de agua para 2018. Durante los años 2019 a 2020, al no haber suficiente recarga hídrica de los inviernos anteriores, se observa una notable reducción de las superficies de agua. Los huracanes Eta e Iota a finales de 2020 contribuyeron a que la superficie de agua incrementara notoriamente, pasando de 84 ha en 2020 a 103 ha en 2021, sin embargo, estas precipitaciones no pudieron devolver el nivel de superficies de agua alcanzado en 2018.

<sup>8</sup> Para observar los valores completos del NDVI, consulte el anexo 10

De esta manera, la vegetación muy sana mostró un incremento importante del año 2017 al año 2018, a partir del cual se produjo una notable reducción de las áreas. En el año 2021 se presentó otro incremento importante, que puede asociarse a que las precipitaciones producto de los huracanes, crearon condiciones óptimas de humedad en el suelo que favorecieron el buen desarrollo de los cultivos, presentándose un aumento en las áreas de producción de arroz bajo riego, dado que las imágenes de satélite permiten hacer esta diferenciación.

La utilidad de la herramienta es relevante, dado que llegar a conocer la evolución de las áreas cultivadas junto con el rendimiento esperado permite inferir volúmenes estimados de producción de arroz bajo riego. Este estudio demuestra la utilidad del procesamiento de las imágenes del satélite Sentinel 2 que permite visualizar y cuantificar la evolución o involución de las áreas con cobertura vegetal. Esto es una contribución relevante de bajo costo, accesible y con una alta eficiencia técnica para aportar elementos a los posibles volúmenes de producción agrícola estimados.

## **5.2 Segundo estudio de caso**

Este estudio consiste en el análisis espacial y temporal de la relación entre la cobertura boscosa y la cobertura agropecuaria en los siete municipios que parte de su territorio conforman la Reserva de Biosfera Bosawás. El período de análisis corresponde al período del 2001 al 2020. Se trata de establecer una comparación entre ambos tipos de cobertura en la búsqueda del resultado evolutivo en 20 años consecutivos.

### **5.2.1 Dinámica evolutiva de cobertura boscosa y agropecuaria**

A través del NDVI obtenido del sensor MODIS, se generó una secuencia de 20 mapas que muestran los cambios que han tenido los municipios que comparten la Reserva en los últimos 20 años. Se observa que en 2001 la frontera agropecuaria había comenzado su avance en el suroeste de la Reserva, en el municipio de Wiwilí, posteriormente se fue expandiendo hacia el este, donde avanzaba en forma de medialuna con dirección noreste devastando bosques en Siuna, Bonanza y Waspán. Actualmente, la única región que ha logrado mantenerse intacta corresponde al sector centro-norte de la reserva, en la frontera con Honduras (Figura 21).

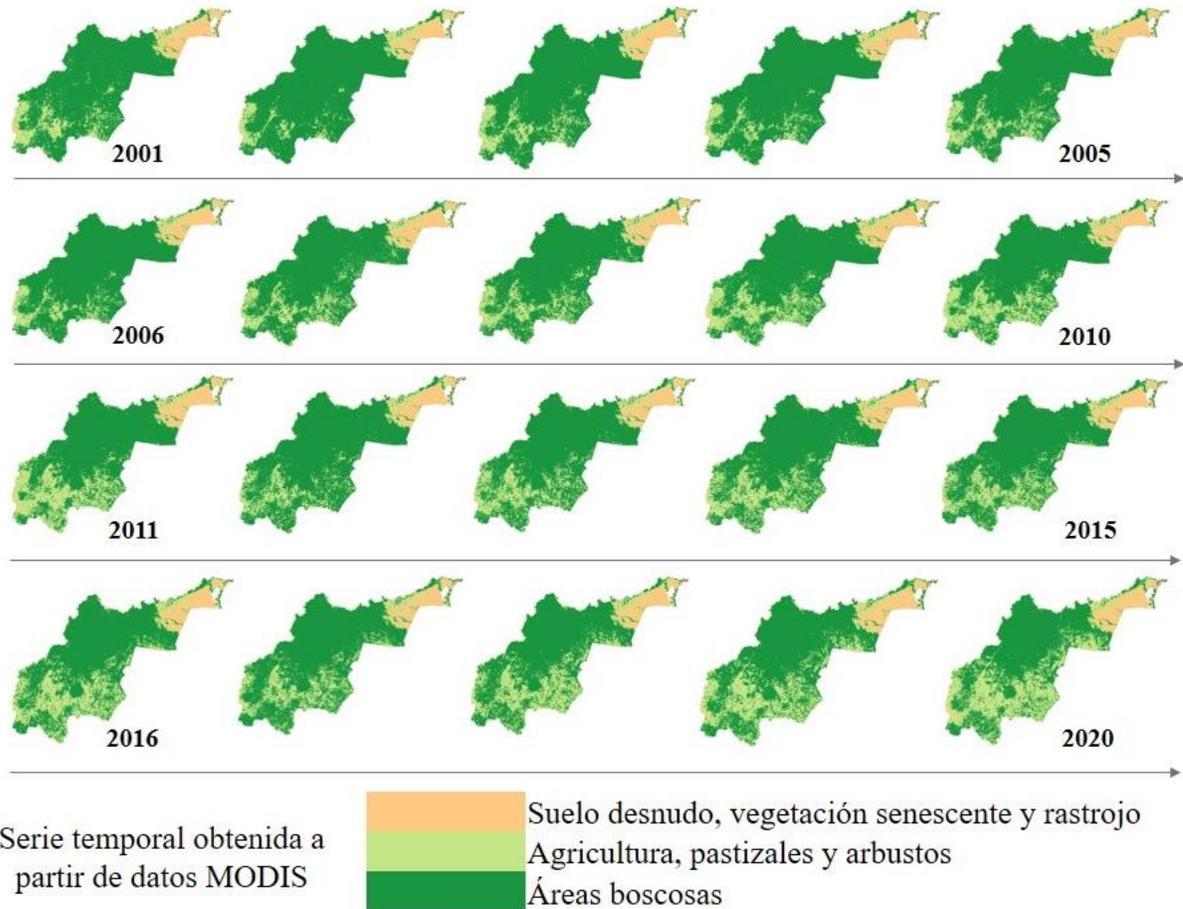


Figura 21. Serie temporal del avance de la frontera agropecuaria de acuerdo con reclasificación del NDVI MODIS, 2001 a 2020.

Al transcurrir 20 años se observan los cambios espaciales y temporales. En relación al parque nacional del cerro Saslaya se puede observar en las imágenes que ya hay una diferenciación evidente en cuanto al cambio de cobertura vegetal; mostrándose límites tangibles del parque nacional. Se pueden observar tres frentes de penetración de deforestación: El primero, procede de la zona entre el macizo de peñas blancas y el cerro Kilambé, hasta bordear el cerro Saslaya; el segundo penetra por el municipio de Rosita en dirección al costado oeste del cerro Saslaya; el tercer frente que se observa es el que procede de Waspán hacia el norte buscando el río Coco. De los tres frentes mencionados, los dos primeros muestran mayores áreas deforestadas y por ende utilizadas con fines agrícolas y/o ganaderos.

### ***Identificación de algunas zonas afectadas con imágenes de alta resolución Landsat 7 y 8***

A pesar de que las imágenes MODIS son ideales para procesar extensas superficies de terreno, su baja resolución no permite identificar factores relacionados a la deforestación, por ejemplo, la minería, expansión urbana o la frontera agropecuaria. Sin embargo, las imágenes Landsat de media resolución sí permiten identificar estos factores. En la figura 22, se muestran dos mosaicos libres de nubes generados con datos de Landsat 7 de 2000 a 2004 y de Landsat 8 de 2017 a 2020, se pueden identificar áreas deforestadas en las cercanías de las zonas pobladas, donde igualmente se muestra un incremento de las áreas agropecuarias.

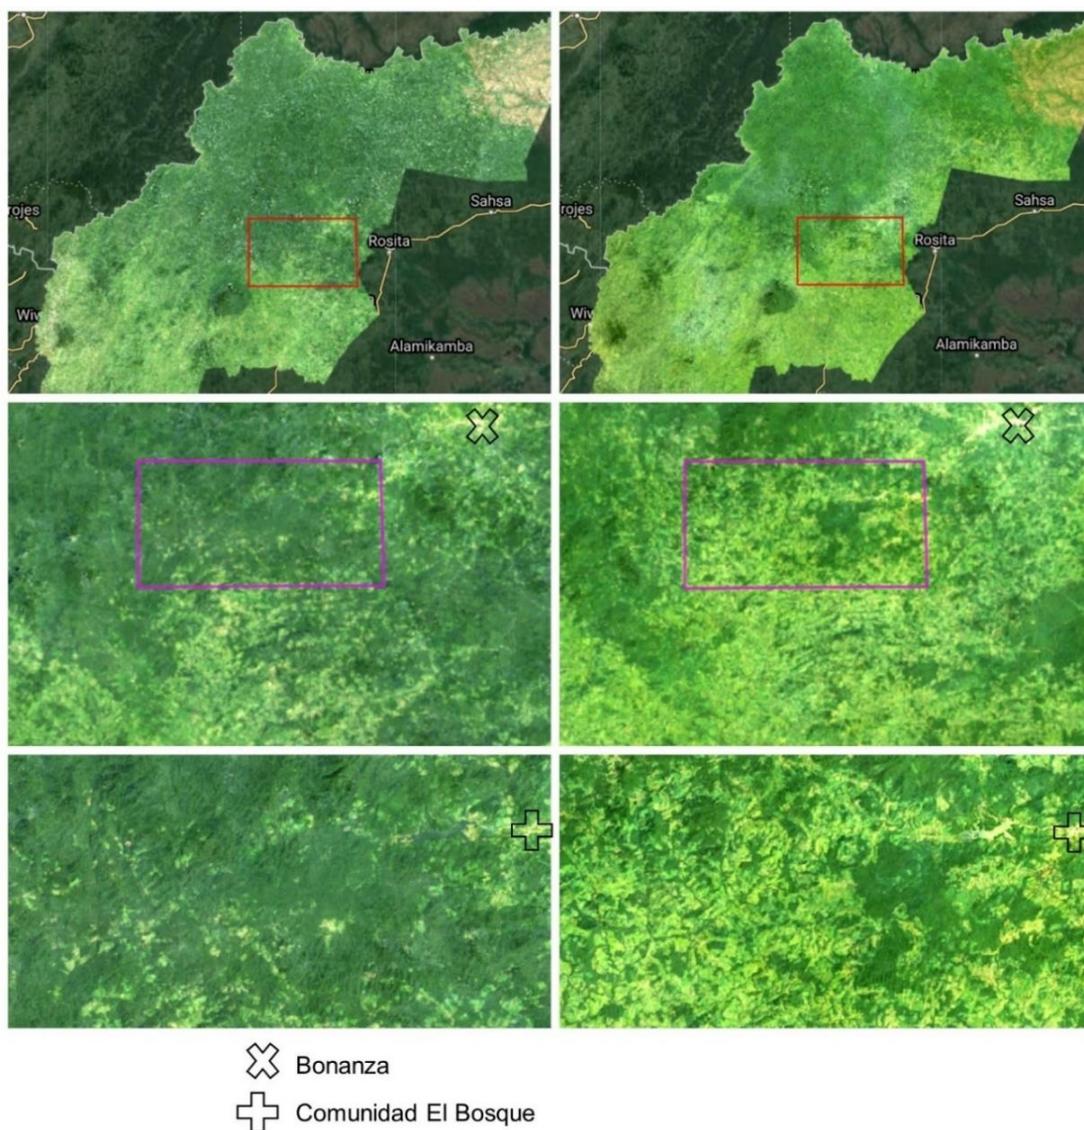


Figura 22. Mosaico libre de nubes con datos de Landsat 7 (izquierda) y de Landsat 8 (derecha).

### 5.2.2 Análisis cuantitativo de la evolución de las áreas con bosque y/o agropecuarias

Los registros de cobertura obtenidos a partir del sensor MODIS se muestran de manera lineal en la figura 23. De 2001 a 2020 se observa un incremento de 386,216 ha en las superficies agropecuarias (cultivos, pastizales y arbustos); en cambio, para el mismo periodo, las superficies boscosas han decrecido con una pérdida total de 382,353 ha de bosque compacto. Estos resultados permiten estimar una tasa de deforestación de alrededor de 19,118 ha año<sup>-1</sup> entre 2001 y 2020. De la misma manera, la herramienta aplicada permite estimar que hay una tasa de incremento de áreas agropecuarias hasta de 19,311 ha año<sup>-1</sup>.

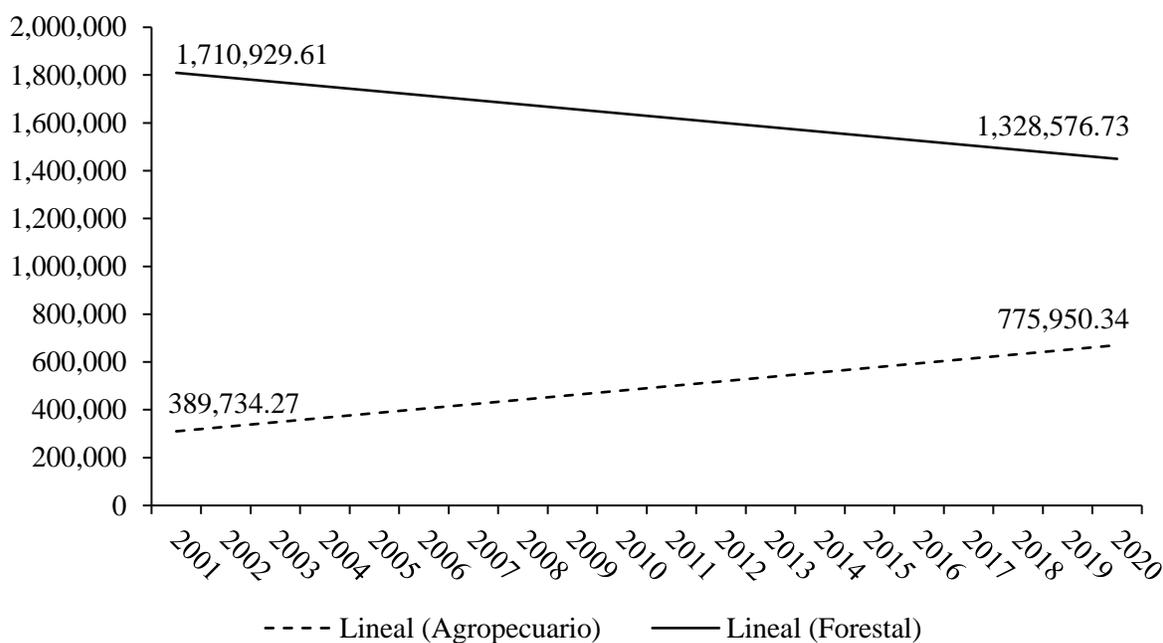


Figura 23. Dinámica de la frontera agropecuaria y áreas de bosques, período 2001 - 2020.

De acuerdo a los resultados obtenidos con el análisis de las imágenes durante 20 años y la construcción de gráficos indicadores del comportamiento de la cobertura boscosa y agropecuaria se ha determinado dos elementos importantes:

La tasa de deforestación e incremento de áreas agropecuarias: el instrumento aplicado (sensor MODIS) permitió calcular las cantidades anuales de cambios de usos de suelo, siendo la tendencia normal la sustitución de áreas de bosques por las áreas agropecuarias, adicionalmente el instrumento permite identificar algunas áreas que siendo boscosas no necesariamente son sustituidas por áreas para uso agropecuario.

La relación temporal y espacial entre la cobertura boscosa y la agropecuaria: La construcción de una gráfica que muestra la evolución de las áreas con cobertura boscosa y cobertura agropecuaria, año con año en los últimos 20 años, permite inferir que existe una relación lineal negativa entre la cobertura boscosa y la cobertura agropecuaria en los municipios que integran la Reserva de Biósfera Bosawás.

### 5.2.3 Estimación de la relación entre la pérdida de bosques y la expansión agropecuaria

Se evaluó el avance de la frontera agropecuaria en relación con las superficies de pérdida de bosque bajo un modelo de regresión lineal simple (Figura 24). El modelo refleja que existe una relación negativa altamente significativa entre la dinámica de ambas áreas con un coeficiente de determinación  $R^2 = 0.99$ , demostrándose de esta manera que la principal causa de la deforestación de los bosques en la Reserva se debe a la intromisión de la agricultura y ganadería.

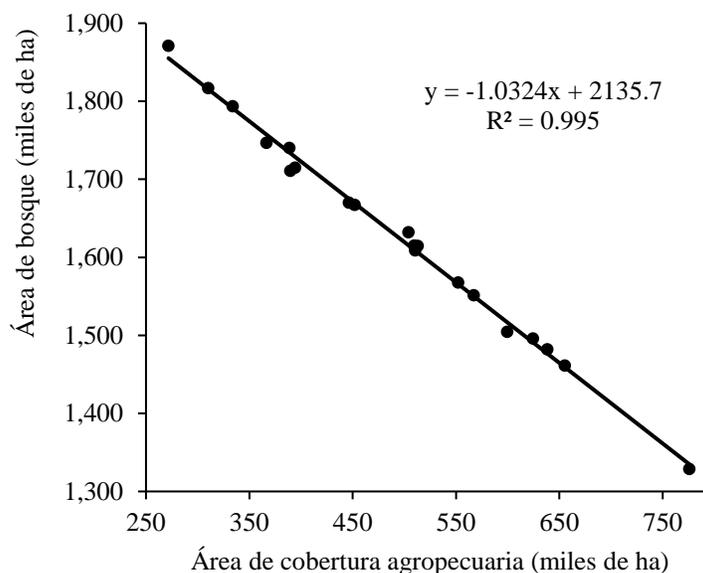


Figura 24. Correlación entre el área agropecuaria y el área de bosques.

#### 5.2.4 Estimación del momento en que las áreas agropecuarias y forestales coincidirán en superficie

El modelo de regresión muestra que las áreas agropecuarias están sustituyendo a las áreas boscosas. Uno de los momentos críticos para la Reserva sería cuando la vegetación de porte bajo iguale o supere en superficie a las áreas boscosas. Para determinar este momento, se realizó una estimación empírica, a través de un modelo de regresión lineal en el que se relaciona la dinámica de cada tipo de vegetación a través de los 20 años:

Se obtuvo el área que correspondería a cada categoría en un 50 %

$$(1,328.58 + 775.95) / 2 = 1,052.26 \text{ (en miles de ha)}$$

El resultado es la variable x, en donde se intersecan ambas superficies.

Se correlacionaron los datos de cada superficie vegetal (Cuadro 8) en función de los años evaluados para obtener un modelo de regresión de la dinámica de cada superficie (Figura 25).

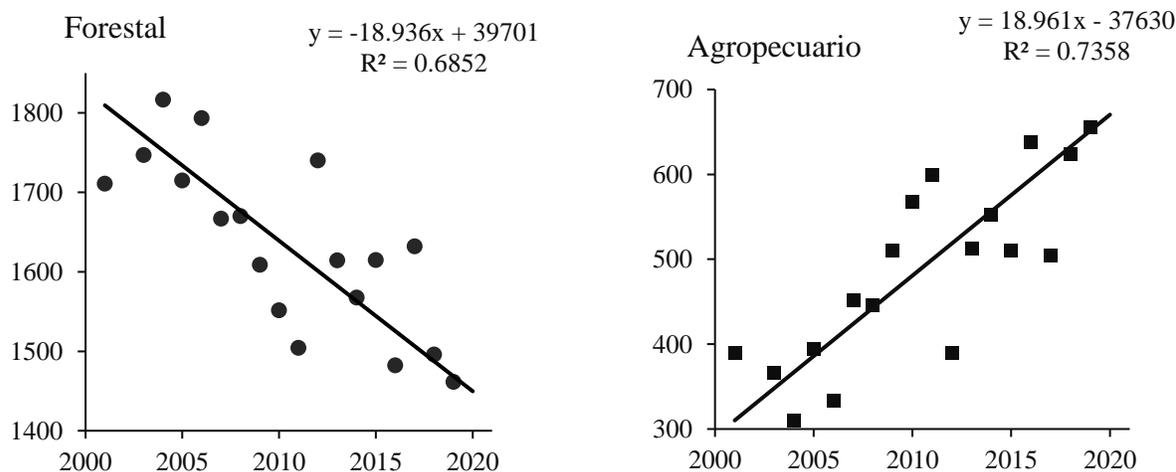


Figura 25. Relación de las áreas forestales (izquierda) y agropecuarias (derecha) en función del tiempo (Área en miles de ha).

Las ecuaciones obtenidas permiten hacer estimaciones del efecto que una variable ejerce sobre la otra. Sin embargo, estas ecuaciones están representando a la variable Forestal y Agropecuaria como variables dependientes (“y”) y el tiempo como la variable independiente (“x”), para solucionar este problema se despejaron a ambas ecuaciones, quedando de la siguiente manera:

Forestal:  $x = (y - 39701) / -18.936$

Agropecuaria:  $x = (y + 37630) / 18.961$

Reemplazando 1,052.58 en “y” en ambas expresiones

Forestal:  $x = (1,052.58 - 39701) / -18.936 = 2041$

Agropecuaria:  $x = (1,052.58 + 37630) / 18.961 = 2040$

De modo que, al ritmo actual, entre el año 2040 y el 2041, el 50 % de la superficie de los municipios que comparten la Reserva estará ocupada por tierras de uso agrícola y ganadero (Anexo 14). Lo que significará una drástica reducción en la diversidad biológica presente en la región, sumado a los demás factores negativos que ocasiona la deforestación, como la reducción de las fuentes hídricas, erosión del suelo, entre otros.

### ***Validación de los resultados***

En el cuadro 8 se presenta una comparación de los resultados obtenidos con los datos MODIS que muestran la dinámica de ocupación de la cobertura agropecuaria y cobertura boscosa para cada uno de los años de 2001 a 2020 en los municipios que rodean la Reserva de Biósfera Bosawás, mientras que la última columna se presentan los datos extraídos de la aplicación Global Forest Change (GFC) que cuantifican la pérdida anual de la superficie boscosa en región.

Para obtener la pérdida de las superficies boscosas con MODIS, se obtuvo la diferencia entre la superficie boscosa presente en el año 2001 menos la superficie boscosa del 2020. Mientras que con los datos de GFC, se hizo una sumatoria de las superficies de pérdida anual del bosque. La diferencia entre ambos resultados, sirve como un indicador que permite medir la precisión que se ha alcanzado con ambos productos.

Cuadro 8. Distribución de las áreas agropecuarias y forestales con datos MODIS (columna 3 y 4 respectivamente) vs pérdida anual de bosque mediante Global Forest Change

Año	Áreas en hectáreas		
	Datos MODIS		GFC*
	Agropecuario	Bosques	Pérdida de bosque
2001	389,734.27	1,710,929.61	4,833.33
2002	271,787.00	1,870,866.03	9,510.54
2003	366,616.88	1,746,774.17	8,604.62
2004	310,252.69	1,816,575.01	3,584.10
2005	394,431.34	1,714,634.84	20,573.12
2006	333,951.69	1,793,401.53	8,873.49
2007	452,183.18	1,666,928.98	29,686.86
2008	446,428.89	1,669,831.40	6,041.79
2009	510,569.92	1,608,830.16	22,849.28
2010	567,238.62	1,551,335.07	36,522.74
2011	599,734.51	1,504,312.83	18,296.85
2012	389,030.45	1,740,209.10	5,872.47
2013	513,050.66	1,614,449.87	13,225.97
2014	552,120.67	1,567,538.97	21,539.09
2015	509,784.88	1,614,811.40	8,946.60
2016	638,521.85	1,482,016.78	39,970.04
2017	504,193.98	1,631,938.91	33,586.42
2018	624,543.65	1,495,780.31	28,210.02
2019	655,387.62	1,461,218.34	29,275.70
2020	775,950.34	1,328,576.73	31,202.00
Diferencia =	386,216.07	-382,352.88	Σ = 381,205.06

\*Global Forest Change

El error se determinó empíricamente mediante una comparación a través de la siguiente relación:

$$\% \text{ Error} = \frac{382,352.88 - 381,205.06}{382,552.88} \times 100 = 0.3 \%$$

### 5.3 Tercer estudio de caso

Este estudio consiste en la aplicación del instrumento Google Earth Engine y la reclasificación con el algoritmo Random forest en imágenes del satélite Sentinel 2 para la elaboración de un mapa de cobertura y usos del suelo para el año 2021 en el departamento de Chinandega.

#### 5.3.1 Mapeo de los tipos de cobertura y uso del suelo del departamento de Chinandega

Para realizar el mapeo de la cobertura y usos actual del suelo se generaron dos premisas:

- a-) Se establecieron nueve categorías de uso de suelo con base en el conocimiento del territorio
- b-) Se identificaron sitios clave o de referencia, donde era fácilmente identificable el tipo de uso a los cuales se les asignó una categoría específica, la cual el clasificador Random forest procedió a extrapolar en toda la imagen, de manera que se realizara el mapeo, mediante una clasificación automatizada, de todo el departamento.

En la figura 26, se muestra una imagen del resultado obtenido:

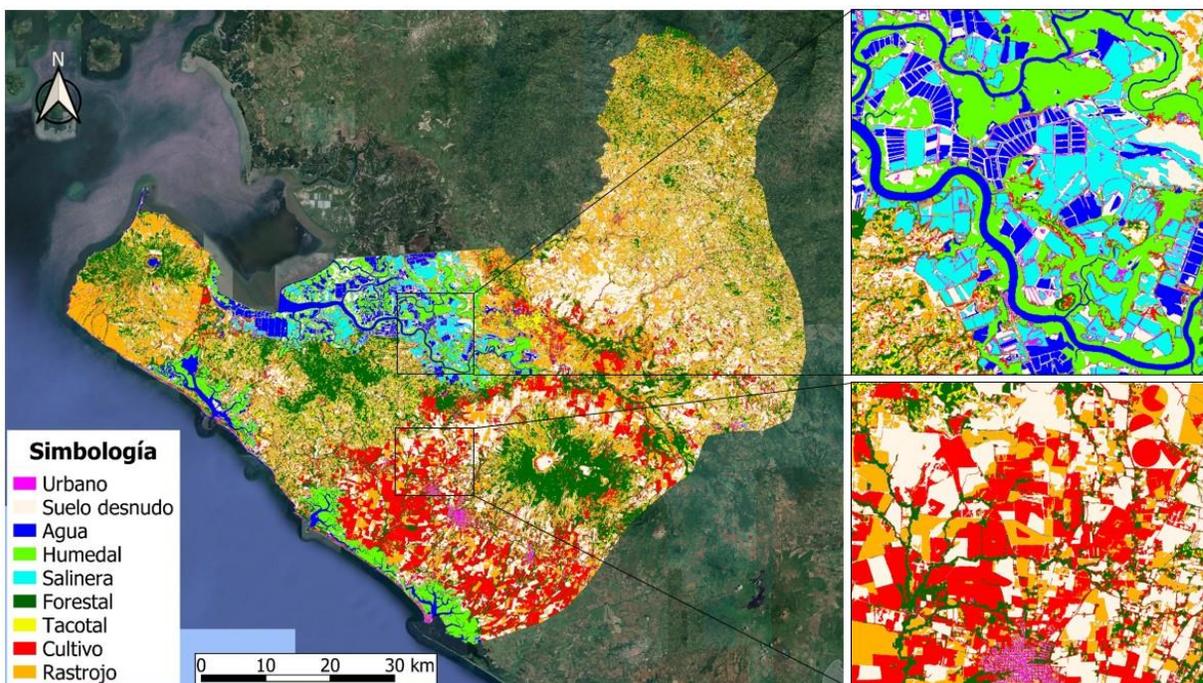


Figura 26. Mapa temático obtenido mediante el algoritmo Random forest a partir de imagen Sentinel 2 del 10 de febrero del 2021.

La figura 26 muestra la distribución de los 9 tipos de cobertura y usos del suelo en el departamento a partir de la clasificación realizada por el algoritmo Random forest.

**Urbano:** Se pueden identificar claramente las zonas urbanas de las cabeceras municipales (Figura 27 f). Se debe tener en cuenta que en esta categoría se agruparon distintos materiales como asfalto, metal, piedra y cerámica. Por lo que cualquier superficie natural con este tipo de material (como las piedras de ríos secos o despeñaderos) quedaría incluida en esta categoría.

**Suelo desnudo:** Es la categoría que mostró mayor superficie, esto se debe a que la imagen que se está analizando corresponde a la época seca. Además, en este departamento se presentan las temperaturas más altas del país, lo que también influye en la senescencia de la vegetación.

**Agua y humedales:** Se observan 4 afluentes que alimentan a 4 importantes reservas de humedales; 3 ubicados en la costa pacífica este y uno al norte, en la zona del golfo de Fonseca.

**Salineras:** Se identificaron abundantes bancos de sal en la zona del golfo de Fonseca, la cual es extraída principalmente para consumo nacional y exportación hacia El Salvador. Además, en estas áreas se pudo observar como el clasificador pudo discriminar entre la sal y los ladrillos de barro que conforman el borde de las piletas de captación.

**Forestal y tacotal:** Se observan 3 principales regiones de cobertura boscosa; dos de estas ubicadas en los alrededores de las zonas altas del Volcán San Cristóbal y del Cosigüina y una entre los municipios de Puerto Morazán y El Viejo. Además, estas presentaron superficies de transición con vegetación del tipo arbustiva, correspondiente a tacotales.

**Cultivo:** Debido a que no se utilizaron muestras de campo, esta categoría engloba cualquier tipo de vegetación herbácea, temporal o semipermanente sin distinción de especies. Se observa que las superficies de cultivos en su mayoría se concentran en los alrededores de las zonas bajas de volcán San Cristóbal.

**Rastrojo:** Corresponde a vegetación herbácea o arbustiva sin actividad fotosintética, entre las que se encuentran restos de cultivos y vegetación natural muerta. Esta se observó principalmente en los alrededores del volcán Cosigüina y la zona del corredor seco, donde también había una elevada exposición de suelo desnudo.

Con el producto final obtenido de la clasificación, es posible aplicar filtros que muestren un tipo de categoría en particular para análisis más rigurosos de los mismos (Figura 27).

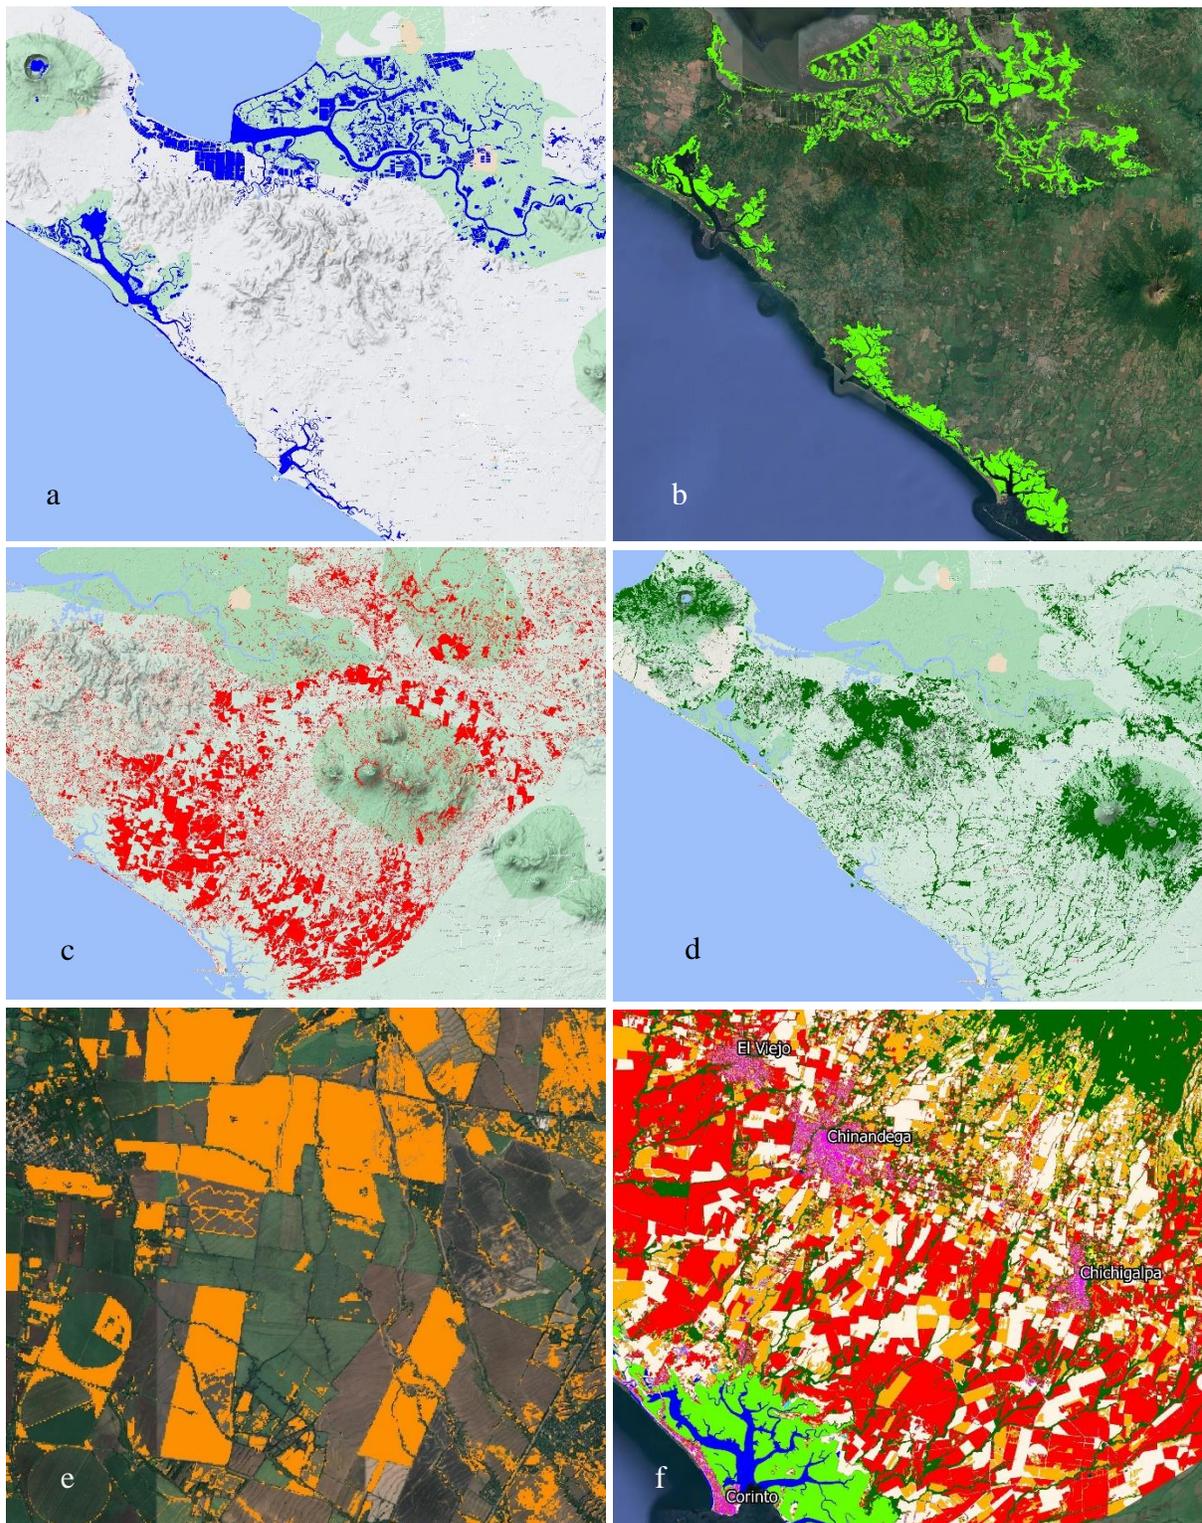


Figura 27. (a) Superficies de agua; (b) humedal; (c) zonas de cultivos, (d) áreas de bosques, (e) terrenos con rastrojo, (f) zonas urbanas de El Viejo, Chinandega, Corinto y Chichigalpa.

### 5.3.2 Distribución de los tipos de cobertura en el departamento de Chinandega

Además de realizar el mapeo, Google Earth Engine permite realizar el cálculo del área de cada superficie, la cual se puede descargar en formato de texto CSV. En la figura 28 se presenta el gráfico que muestra el inventario de la superficie en ha de los tipos de cobertura del departamento.

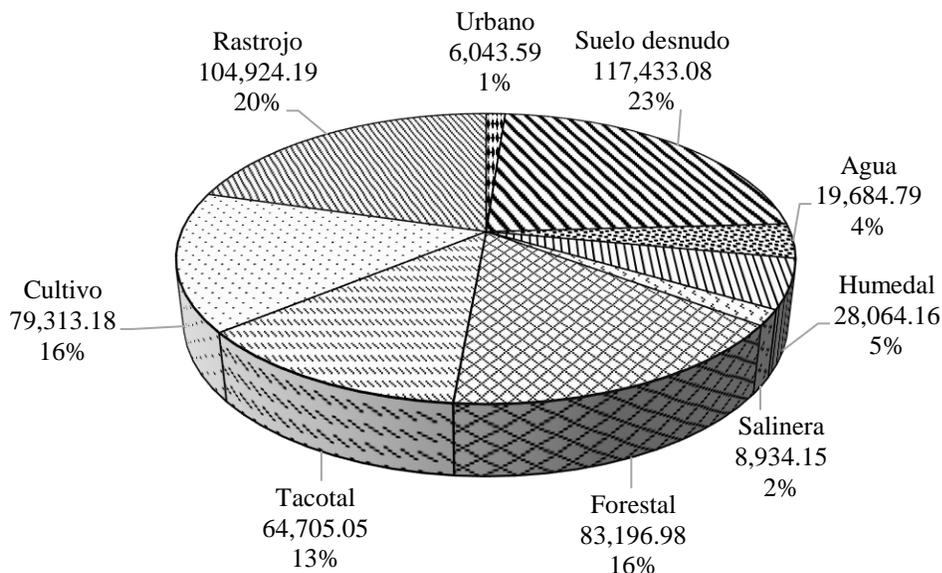


Figura 28. Distribución de las superficies de los tipos de cobertura y usos del suelo en el departamento de Chinandega, 10/02/2021 (área en ha).

Los resultados muestran el tipo de vocación agrícola del departamento de Chinandega, ya que, si se juntan las áreas potenciales agrícolas que corresponden a zonas de cultivo, rastrojo, suelo desnudo y tacotal, estas conforman un total de 366,375.5 ha, correspondientes al 72 % del territorio del departamento, el 21 % del restante de la vegetación corresponde a humedales y bosques y no deberían cambiar de vocación. El 4 % corresponde a agua y el 3 % a salineras y zonas urbanas.

Además, se puede deducir que el 16 % del territorio departamental dispone de sistema de producción bajo riego dado que la imagen se corresponde a la época seca y la única alternativa de producción es la utilización de agua irrigada. En el anexo 15 se presenta la base de datos con la distribución de las categorías.

### ***Validación del modelo***

Con los 4,994 generados con QGIS, se obtuvo el valor de píxel de cada una de las clasificaciones, es decir, de la clasificación original elaborada a partir de los 174,440 píxeles entrenados y de la réplica elaborada a partir del 50 % de entrenamiento (87,429 píxeles). Al comparar las diferencias entre ambas clasificaciones, se obtuvo que 393 puntos no coincidían, ya que, al aplicarles una operación de resta en la tabla de atributos de QGIS, estos dieron valores distintos a cero. Al relacionar los 393 puntos que mostraron diferencias en la clasificación, con el total de puntos de muestreo (4,994), se obtuvo la siguiente relación:

$$\% \text{ Error} = \frac{393}{4,994} \times 100 = 7.87 \%$$

Por lo tanto, los datos de clasificación se presentan con un nivel de confianza del 92.13 %.

## VI. CONCLUSIONES

Se ha demostrado que los satélites ópticos Sentinel 2, MODIS, Landsat 7 y Landsat 8, permiten realizar análisis sobre la dinámica de la agricultura a diferentes escalas espaciales y con satisfactorios niveles de precisión. Los datos que recopilan a diario estos satélites junto a las herramientas para su procesamiento están accesibles de manera gratuita para cualquier persona, institución, empresa o gobierno que deseen utilizarlos.

Con el primer estudio de caso se pudo observar que las parcelas cultivadas en época de riego en el Valle de Sébaco han aumentado sus superficies de cultivos sanos hasta un 9 % global, de 2017 a 2021. Se pudo observar además que después de las tormentas tropicales o huracanes propios de la época lluviosa, queda almacenado un buen nivel de humedad en el suelo, que favorece el desarrollo de los cultivos en la época seca.

La frontera agropecuaria incrementó 386,216 ha en los siete municipios que comparten la Reserva Bosawás, esto provocó la deforestación de 382,353 ha de bosque. La dinámica que ha adquirido la frontera agropecuaria ha sido en dirección suroeste-noreste, en los últimos años la frontera agropecuaria ha ido avanzando con gran notoriedad devastando los bosques de Siuna y Waspán.

Se generó un mapa con el inventario del departamento de Chinandega segmentado en nueve categorías bien definidas y actualizado a fecha del 10 de febrero del 2021, el nivel de precisión alcanzado fue de 92.13 %. Se pudo observar la vacación agrícola en este departamento, ya que el 72 % de su territorio corresponde a zonas potencialmente agrícola (áreas con cultivos, suelo desnudo, rastrojo y tacotal).

## VII. RECOMENDACIONES

Integración del uso de imágenes satelitales en los procesos de investigación agronómica.

Monitoreo permanente a través de teledetección por parte de las autoridades estatales, para vigilar los cambios que se producen en la reserva de Biosfera Bosawás y así tomar a tiempo medidas que contribuyan a frenar el deterioro que se está produciendo en este valioso ecosistema.

Para los estudios que se abordaron en este documento, se analizó a la vegetación de una manera superficial. Pero es posible realizar análisis a niveles más detallados, por ejemplo, tomando muestras de campo con GPS, se podría diferenciar entre diferentes tipos de cultivos; esto permitiría realizar estimaciones precisas *a priori* de los volúmenes de producción esperados en los diferentes rubros que se deseen investigar.

En este documento solamente se destacó la teledetección pasiva a través de imágenes ópticas. Sin embargo, la teledetección activa por medio de radar tiene un sinnúmero de aplicaciones dentro del campo de la agronomía y es ideal para las épocas lluviosas, período en que las masas nubosas afectan la captura de imágenes ópticas. Con satélites de radar como Sentinel 1, se pueden realizar clasificaciones de cultivos, mapeo de inundaciones bajo las espesas nubes propias de tormentas o huracanes, medir la humedad del suelo e incluso mapear la erosión de un territorio.

Los resultados obtenidos en estos estudios, pueden ser útiles como indicadores del estado actual agropecuario en las regiones que se consideraron, con los que es posible confeccionar políticas encaminadas al cumplimiento de dos de los Objetivos de Desarrollo Sostenible: Hambre Cero (2) y Protección de Vida de Ecosistemas Terrestres (15).

## VIII. LITERATURA CITADA

- Abatzoglou, J. T., Dobrowski S. Z., Parks S. A., Hegewisch K. C. (2018) Terraclimate, a high-resolution global dataset of monthly climate and climatic water balance from 1958-2015, *Scientific Data* 5:170191, doi: 10.1038/sdata.2017.191. Consultado en: <https://www.nature.com/articles/sdata2017191>
- Artola Gutierrez, L.A. (18 de diciembre del 2013). Bandas Espectrales. *Términos de la Geomática*. Blog. Consultado en: <https://sites.google.com/site/terminosdelageomatica/system/app/pages/search?scope=search-site&q=BANDAS>
- Balza, J. (2019). Información precisa que viene del espacio. *Redagricola*. Sistema de monitoreo satelital Bay-Sat de Bayer. Consultado en: <https://www.redagricola.com/pe/informacion-precisa-viene-del-espacio/>
- Barenblitt, A. y Fatoyinbo, L. (2020). Mapeo de la Extensión de Manglares y Series Temporales. NASA's applied Remote Sensing Training Program. Consultado en: [https://appliedsciences.nasa.gov/sites/default/files/2020-11/Part2\\_\\_Span.pdf](https://appliedsciences.nasa.gov/sites/default/files/2020-11/Part2__Span.pdf)
- Breiman, L., & Cutler, A. (2001). "Random Forest" Machine Learning. DOI: <https://doi.org/10.1023/A:1010933404324>
- Bravo Morales, N.F. (2017). Teledetección espacial, Landsat, Sentinel2, Aster L1T y Modis. p. 7. Huánuco: Universidad Nacional Agraria de la Selva, Consultado en: [https://issuu.com/ninoobravomorales/docs/libro\\_teledeteccion\\_espacial\\_2017](https://issuu.com/ninoobravomorales/docs/libro_teledeteccion_espacial_2017)
- Carletta, J. (1996). Assessing agreement on classification tasks: The kappa statistic. *Computational Linguistics*. Consultado en: <https://web.archive.org/web/20120526213354/http://acl.ldc.upenn.edu/J/J96/J96-2004.pdf>
- Casanova J.L. (1992). La teledetección y la enseñanza de la meteorología. Valladolid, España. Consultado en: <https://core.ac.uk/download/pdf/58902279.pdf>
- Castro Sobalvarro, A.K., Avellán Castellón, J.R, Martínez Espinoza, E.M. (2014). Problemática económica, social y ambiental de la Reserva de Biósfera Bosawás (2009-2013). *Revista Electrónica de Investigación en Ciencias Económicas*. UNAN Managua, NI. Consultado en: <http://www.lamjol.info/index.php/REICE/article/view/1730/1526>
- Comisión Económica para América Latina. (2020). Balance Preliminar de las Economías de América Latina y el Caribe 2020. Consultado en: [https://repositorio.cepal.org/bitstream/handle/11362/46501/122/BP2020\\_Nicaragua\\_es.pdf](https://repositorio.cepal.org/bitstream/handle/11362/46501/122/BP2020_Nicaragua_es.pdf)
- Environmental Systems Research Institute. (sf.) ¿Qué es ArcGIS? Consultado en: <https://resources.arcgis.com/es/help/getting-started/articles/026n00000014000000.htm>

- Euronews (11 de mayo del 2016). La importancia de los satélites en la observación de la tierra – science [Archivo de video]. Consultado en: <https://www.youtube.com/watch?v=MXxe06-tqQA&t=43s>
- European Space Agency, ESA. (2020). Escritorio SNAP, recuperado de: [https://www.esa.int/ESA\\_Multimedia/Images/2020/04/SNAP\\_desktop#.YNIygBUQOZY.link](https://www.esa.int/ESA_Multimedia/Images/2020/04/SNAP_desktop#.YNIygBUQOZY.link)
- European Space Agency. (12 de febrero del 2016). Sentinels for Copernicus [Archivo de video], recuperado de: <https://www.youtube.com/watch?v=xcfIQZJ5n88>
- European Space Agency. (2015). Sentinel 2 User Handbook. Consultado en: [https://sentinel.esa.int/documents/247904/685211/Sentinel-2\\_User\\_Handbook](https://sentinel.esa.int/documents/247904/685211/Sentinel-2_User_Handbook)
- European Space Agency. (2014). Los sensores. Consultado en: [http://www.esa.int/SPECIALS/Eduspace\\_ES/SEM36X3FEXF\\_0.html](http://www.esa.int/SPECIALS/Eduspace_ES/SEM36X3FEXF_0.html)
- European Space Agency. (2011). Satélites de observación terrestre. Consultado en: [https://www.esa.int/SPECIALS/Eduspace\\_ES/SEMJC07SXIG\\_2.html](https://www.esa.int/SPECIALS/Eduspace_ES/SEMJC07SXIG_2.html)
- Farr, T.G., Rosen, P.A., Caro, E., Crippen, R., Duren, R., Hensley, S., Kobrick, M., Paller, M., Rodríguez, E., Roth, L., Seal, D., Shaffer, S., Shimada, J., Umland, J., Werner, M., Oskin, M., Burbank, D. & Alsdorf, D.E. (2007). The shuttle radar topography mission: Reviews of Geophysics, v. 45, no. 2, RG2004. Consultado en: [https://www.scirp.org/\(S\(vtj3fa45qm1ean45vvffcz55\)\)/reference/ReferencesPapers.aspx?ReferenceID=1588560](https://www.scirp.org/(S(vtj3fa45qm1ean45vvffcz55))/reference/ReferencesPapers.aspx?ReferenceID=1588560)
- García, E. y Flego, F. (2008) Agricultura de precisión, Ciencia y tecnología, vol. 8, anual 2008. Gale OneFile: Informe Académico. Buenos Aires, Argentina. Consultado en: <https://www.palermo.edu/ingenieria/downloads/pdfwebc&T8/8CyT12.pdf>
- Gao, B. (1996). NDWI: A normalized difference water index for remote sensing of vegetation liquid water from space. Remote Sensing of Environment. Volume 58, Issue 3. [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)
- Gastón Pascual, I. (2018). Clasificación de áreas sembradas y determinación del momento de cosecha en Caña de azúcar y Pastizales mediante imágenes ópticas y SAR. *Tesis de maestría*. Instituto de Altos Estudios Espaciales Mario Gulich. Cordoba, Argentina. Consultado en: <https://rdu.unc.edu.ar/bitstream/handle/11086/10753/Pascual-1.pdf?sequence=1&isAllowed=y>
- Gitelson, A. A., Kaufman, Y. J. & Merzlyak, M.N (1996). Use of a green channel in remote sensing of global vegetation from EOS-MODIS. Remote Sens. Environ.,58, 289-298. [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7)

- Goodchild, M.F., Guo, H., Annoni, A., Bian, L., de Bie, K., Campbell, F., Craglia, M., Ehlers, M., van Genderen, J., Jackson, D., Lewis, A.J., Pasaresi, M., Remete-Fülöpp, G., Simpsons, R., Skidmore, A., Wang, C & Woodgate, P. (2012). Next-generation Digital Earth. Editado por Kenneth Wachter, Universidad de California, Berkeley, CA. PNAS. Consultado en: <https://www.pnas.org/content/109/28/11088>
- Gobierno de Reconciliación y Unidad Nacional. (2021). Plan Nacional de Producción, Consumo y Comercio 2021/2022. Consultado en: [https://www.el19digital.com/app/webroot/tinymce/source/2021/Mayo/19May/PLAN%20NACIONAL%20DE%20PRODUCCION%202021-2022%20\(08May21\)3.pdf](https://www.el19digital.com/app/webroot/tinymce/source/2021/Mayo/19May/PLAN%20NACIONAL%20DE%20PRODUCCION%202021-2022%20(08May21)3.pdf)
- 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*. Consultado en: <https://www.sciencedirect.com/science/article/pii/S0034425717302900?via%3Dihub>
- Hansen, M.C., Potapov, P.V., Moore, R., Hancher, M., Turubanova, S.A., Tyukavina, A., Thau, D., Stehman, S.V., Goetz, S.J., Loveland, T.R., Kommareddy, A., Egorov, A., Chini, L., Justicia, C.O. & Townshend, J.R. (2013). “High-Resolution Global Maps of 21st-Century Forest Cover Change”. *Science* 342 (15 de noviembre): 850–53. Consultado en: <http://earthenginepartners.appspot.com/science-2013-global-forest>
- Instituto Interamericano de Cooperación para la Agricultura, IICA. (2014). Manual de agricultura de precisión. Eds: Evandro Chartuni Mantovani y Empresa Brasileira de Pesquisa Agropecuaria (EMBRAPA). Prociur. Consultado en: <https://repositorio.iica.int/handle/11324/2972>
- Instituto Internacional de Investigación sobre Políticas Alimentarias, IFPRI. (2009). Cambio Climático, el impacto en la agricultura y los costos de adaptación. Washington D.C. Consultado en: [http://www.fao.org/fileadmin/user\\_upload/AGRO\\_Noticias/docs/costo%20adaptacion.pdf](http://www.fao.org/fileadmin/user_upload/AGRO_Noticias/docs/costo%20adaptacion.pdf)
- Key, H. C. & Benson, N. (1999). Measuring and remote sensing of burn severity: the CBI and NBR. Researchgate. Consultado en: [https://www.researchgate.net/publication/241687936\\_Measuring\\_and\\_remote\\_sensing\\_of\\_burn\\_severity\\_the\\_CBI\\_and\\_NBR](https://www.researchgate.net/publication/241687936_Measuring_and_remote_sensing_of_burn_severity_the_CBI_and_NBR)
- Larragaña Urien, A. (2016). Clasificación de cultivos a partir de observaciones de teledetección radar. Aplicación a zonas de secano y regadío de Navarra. *Tesis doctoral*. Universidad pública de Navarra, España. Consultado en: <https://academic.e.unavarra.es/handle/2454/23861>
- Loría Solano, A. (2018). Identificar áreas del cultivo de café, por medio de una clasificación supervisada por imágenes satelitales multiespectrales, para el cantón de Pérez Zeledón. Instituto Tecnológico de Costa Rica, Cartago. Consultado en: <https://repositoriotec.tec.ac.cr/handle/2238/11289>

- Maes, J.M., Aker, C., Meyrat A., Ruíz, G.A., Obregón, F., Cordon, M.R., Pérez, M., Torres, N., Medina, A., Hernández, D., Van den Berg, E., Griffith, D. y Polishar, J. (2006). Plan de conservación de la reserva natural Bosawás. The Nature Conservancy. Consultado en: <http://www.bio-nica.info/biblioteca/TNC2006Bosawas4.pdf>
- Matellanes Ferreira, R. (22 de febrero del 2020). Todo lo que deberías saber sobre imágenes Landsat. *Gis and beers. Blog personal*. Consultado en: <http://www.gisandbeers.com/lo-deberias-saber-imagenes-landsat/>
- Matellanes Ferreras, R. (21 de diciembre del 2019). Todo lo que deberías saber sobre imágenes Sentinel 2. *Gis and beers. Blog personal*. Consultado en: <http://www.gisandbeers.com/lo-deberias-saber-imagenes-sentinel-2/>
- Matellanes Ferreira, R. (30 de octubre del 2019). Cálculo de índices NDVI multitemporales. *Gis and beers. Blog personal*. Consultado en: <http://www.gisandbeers.com/calculo-indices-ndvi-multitemporales/>
- Matellanes Ferreras, R. (15 de agosto del 2019). La jerga de la teledetección de la A la Z. *Gis and Beers. Blog personal*. Consultado en: <http://www.gisandbeers.com/la-jerga-terminologia-teledeteccion/>
- McFeeters, S. K. (1996). The use of normalized difference water index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, 17, 1425-1432. <https://doi.org/10.1080/01431169608948714>
- National Aeronautics and Space Administration, NASA. (s. f.). MODIS espectroradiómetro de resolución moderada. EE. UU. Consultado en: <https://terra.nasa.gov/about/terra-instruments/modis>
- Navarro, C. S. (26 de abril del 2020). Clasificación supervisada paso a paso en Google Earth Engine. [Archivo de video]. Consultado en: <https://www.youtube.com/watch?v=B2G-oqOaLbI>
- Organización de las Naciones Unidas para la Agricultura y la Alimentación, FAO. (2015). Gaul 2015 Data License. Consultado en: <https://developers.google.com/earth-engine/datasets/catalog/DataLicenseGAUL2015.pdf>
- Organización de las Naciones Unidas para la Agricultura y la alimentación, FAO. (2009). Sistemas de información geográfica, sensores remotos y mapeo para el desarrollo y la gestión de la acuicultura marina. Consultado en: <http://www.fao.org/3/a0906s/a0906s.pdf>
- Organización de las Naciones Unidas, ONU. (2018). Informe de los Objetivos de Desarrollo Sostenible. Nueva York, EEUU., Consultado en: <https://unstats.un.org/sdgs/files/report/2018/TheSustainableDevelopmentGoalsReport2018-es.pdf>

- Organización de las Naciones Unidas, ONU. (2015). Transformar nuestro mundo: la Agenda 2030 para el Desarrollo Sostenible. Asamblea General. Septuagésimo período de sesiones. ISBN: 15-15900 (S) 220915 220915. Nueva York, EEUU., Consultado en: [https://www.cepal.org/sites/default/files/events/files/2030\\_agenda\\_es.pdf](https://www.cepal.org/sites/default/files/events/files/2030_agenda_es.pdf)
- Organización de las Naciones Unidas, ONU. (2012). El futuro que queremos para todos. Informe para el secretario general, Nueva York, EEUU. Consultado en: [https://www.un.org/en/development/desa/policy/untaskteam\\_undf/unttreport\\_sp.pdf](https://www.un.org/en/development/desa/policy/untaskteam_undf/unttreport_sp.pdf)
- Organización de las Naciones Unidas, ONU. (2000). 55/2 Declaración del milenio. Quincuagésimo quinto período de sesiones, Nueva York, EEUU., Consultado en: <https://www.un.org/spanish/milenio/ares552.pdf>
- Parente, L. y Ferreira, L. (2018). Assessing the Spatial and Occupation Dynamics of the Brazilian Pasturelands Based on the Automated Classification of MODIS Images from 2000 to 2016. *Remote Sensing*. 10 (4): 606. Consultado en: <https://www.mdpi.com/2072-4292/10/4/606>
- Peña-Barragán, J. M., Ngugi, M., Plant, R. E., & Six, J. (2011). Object-based crop identification using multiple vegetation indices, textural features and crop phenology. *ResearchGate*. 115(6):1301-1316. DOI: 10.1016/j.rse.2011.01.009. Consultado en: [https://www.researchgate.net/publication/229397179\\_Object-based\\_crop\\_identification\\_using\\_multiple\\_vegetation\\_indices\\_textural\\_features\\_and\\_crop\\_phenology](https://www.researchgate.net/publication/229397179_Object-based_crop_identification_using_multiple_vegetation_indices_textural_features_and_crop_phenology)
- Pérez Martín, B., Serna Martínez, A.R., Delgado Hernández, J., Caballero García, M. E., Villa Alcázar, G. (2020). El Programa Copernicus para la monitorización del territorio y los Objetivos del Desarrollo Sostenible. Ed. Instituto Geográfico Nacional (IGN). Madrid, ES: DOI: 10.7419/162.13.2020, Consultado en: <http://www.gisandbeers.com/libro-programa-copernicus-la-monitorizacion-del-territorio/>
- Podest, E. (2018). Conceptos Básicos del Radar de Apertura Sintética. *Applied Remote Sensing Training*. NASA.gov. Consultado en: <https://appliedsciences.nasa.gov/sites/default/files/Session1-SAR-Spanish.pdf>
- Puerta Tuesta, R., Bengifo Trigozo, J. y Bravo Morales, N. (2011). ArcGIS 10 Básico, p. 8. Tingo/Santa María: Universidad Nacional Agraria de la Selva, recuperado de: <https://actswithscience.com/Descargas/ManualArcGis.pdf>
- QGIS.org (s. f.). QGIS, el líder de Código abierto para escritorio. Recuperado de: <https://qgis.org/es/site/about/index.html>
- Reardon, T. y Vosti, S. A. (1995). Vínculos entre la pobreza rural y el medio ambiente en los países en desarrollo: categorías de activos y pobreza de inversión. Consultado en: <https://www.sciencedirect.com/science/article/abs/pii/0305750X9500061G?via%3DiHub>

- Rivas, R., Ocampo, D. y Carmona, F. (2011). Modelo de predicción del rendimiento de trigo a partir de NDVI: aplicación en el contexto de agricultura de precisión. Agencia Nacional de Promoción Científica y tecnológica de Argentina. Consultado en: <http://marte.sid.inpe.br/col/dpi.inpe.br/marte/2011/06.29.14.49/doc/p0542.pdf>
- Rodríguez Montellano, A. M. (24 de enero del 2021). Clasificación supervisada Random Forest – Google Earth Engine. [Archivo de video]. Consultado en: <https://www.youtube.com/watch?v=swlVCowqnKk>
- Rouse, J. W., Hass R. H., Schell, J. A. & Deering D. W. (1973). Monitoring vegetation systems in the Great Plains with ERTS. *Proc. 3rd ERTS Symposium*, NASA SP-3511. US Government Printing Office, Washington DC. pp 309-317. Consultado en: <https://ntrs.nasa.gov/citations/19740022614>
- Rosell, P. A. y Vicente, M. (2016). Análisis del crecimiento demográfico y la relación entre espacios verdes y edificados en Darregueira con QGIS. Consultado en: [https://www.researchgate.net/figure/Figura-6-Indice-Build-Up-2015-Fuente-Elaboracion-propia-El-NDBI-es-un-indice-de-area\\_fig5\\_300018730](https://www.researchgate.net/figure/Figura-6-Indice-Build-Up-2015-Fuente-Elaboracion-propia-El-NDBI-es-un-indice-de-area_fig5_300018730)
- Russell, S. & Norving, P. (2009). Artificial Intelligence: A Modern Approach. 3ra Ed. Consultado en: <https://www.elsolucionario.org/inteligencia-artificial-stuart-russell-peter-norvig-3ed/>
- Shelestov, A., Lavreniuk, M., Kussul, N., Novikov, A. & Skakun, S. (2017). Exploring Google Earth Engine Platform for Big Data Processing: Classification of Multi-Temporal Satellite Imagery for Crop Mapping. *Front. Earth Sci.* 5:17. doi: 10.3389/feart.2017.00017. Consultado en: <https://www.frontiersin.org/articles/10.3389/feart.2017.00017/full>
- Solomon, E. P., Berg, L. R., Martin, D. W. (2013). Biología. Novena Ed. *Cengage Learning*. Trads. A. E. García Hernández., H. Villagómez Velázquez., J. H. Romo Muñoz., V. Campos Olguín. ISBN: 978-607-481-934-2. Consultado en: <https://latam.cengage.com/libros/biologia-2/>
- Stern, David P. (2001). Ondas y fotones. Trad. J. Méndez. nasa.gov. Consultado en: <https://pwg.gsfc.nasa.gov/stargaze/Msun5wav.htm>
- Telemediciones, (2017). Límites máximos de exposición a campos electromagnéticos. Blog. Consultado en: <http://telemediciones.com/blog/radiaciones-no-ionizantes/limites-maximos-de-exposicion-a-campos-electromagneticos/>
- United States Geological Survey, USGS. (s. f. a). MCD43A4 v006 MODIS/Terra+Aqua Nadir BRDF-Adjusted Reflectance (NBAR) Daily L3 Global 500 m SIN Grid. Consultado en: <https://doi.org/10.5067/MODIS/MCD43A4.006>
- United States Geological Survey, USGS. (s. f. b). Misiones Landsat. Consultado en: <https://www.usgs.gov/core-science-systems/nli/landsat>

- United States Geological Survey, USGS. (2019). Landsat Surface Reflectance-Derived Spectral Indices Normalized Difference Moisture Index. Consultado en: <https://www.usgs.gov/core-science-systems/nli/landsat/normalized-difference-moisture-index>
- Villalobos Mateluna, P., Manríquez Ramírez, R., Acevedo Opazo, C., Ortega Farías, S. (2009). Alcance de la agricultura de precisión en Chile: estado del arte, ámbito de aplicación y perspectivas. Oficinas de estudios y políticas agrarias del ministerio de agricultura de Chile. Consultado en: <https://www.odepa.gob.cl/wp-content/uploads/2009/07/AgriculturaDePrecision.pdf>
- Yang, C., Huang, Q., Li, Z., Liu, K., & Hu, F. (2017). Big Data and cloud computing: innovation opportunities and challenges. *International Journal of Digital Earth*. Consultado en: <https://doi.org/10.1080/17538947.2016.1239771>

# **IX. ANEXOS**

## Anexo 1. Especificaciones técnicas de las computadoras utilizadas

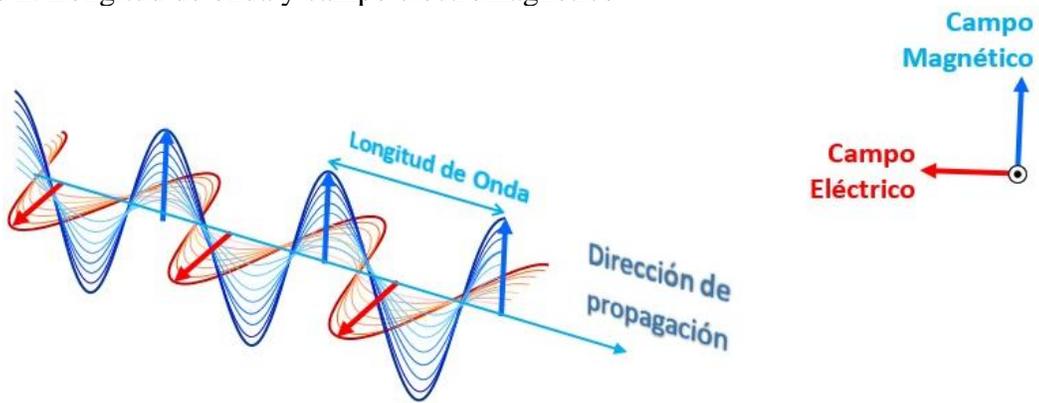


Nombre del dispositivo: Acer Aspire A315-21  
Procesador: AMD A9-9420 RADEON R5, 5 COMPUTE CORES 2C + 3G 3.00 GHz  
RAM instalada: 6.00 GB (5.58 GB utilizable)  
Tipo de sistema: Sistema operativo de 64 bits, procesador x64



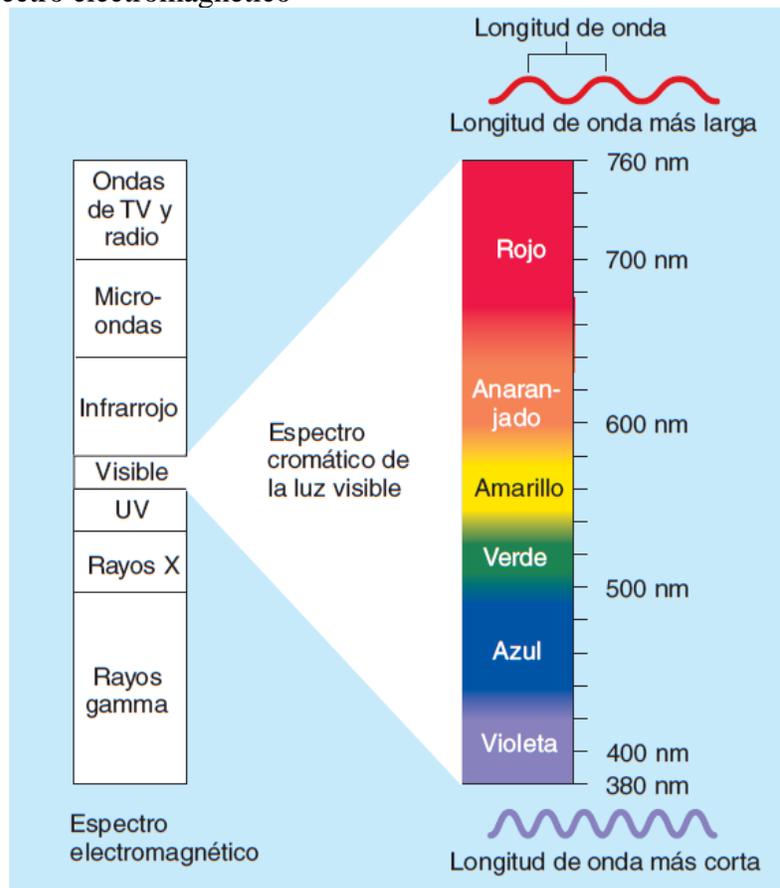
Nombre del dispositivo: Dell Latitude E7240  
Procesador: Intel® Core™ i7-4600U CPU @2.10 GHz + 2.70 GHz  
RAM instalada: 8 GB  
Tipo de sistema: Sistema operativo de 64 bits, procesador x64

## Anexo 2. Longitud de onda y campo electromagnético



Fuente: Telemediciones, 2017.

## Anexo 3. El espectro electromagnético



Fuente: Solomon *et al.*, 2013.

Anexo 4. Ejemplo de diferentes tipos de resolución espacial mediante visualización de la zona urbana del departamento de Managua



Landsat 8 (30 m)

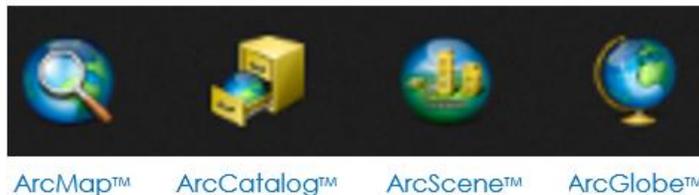


MODIS (500 m)

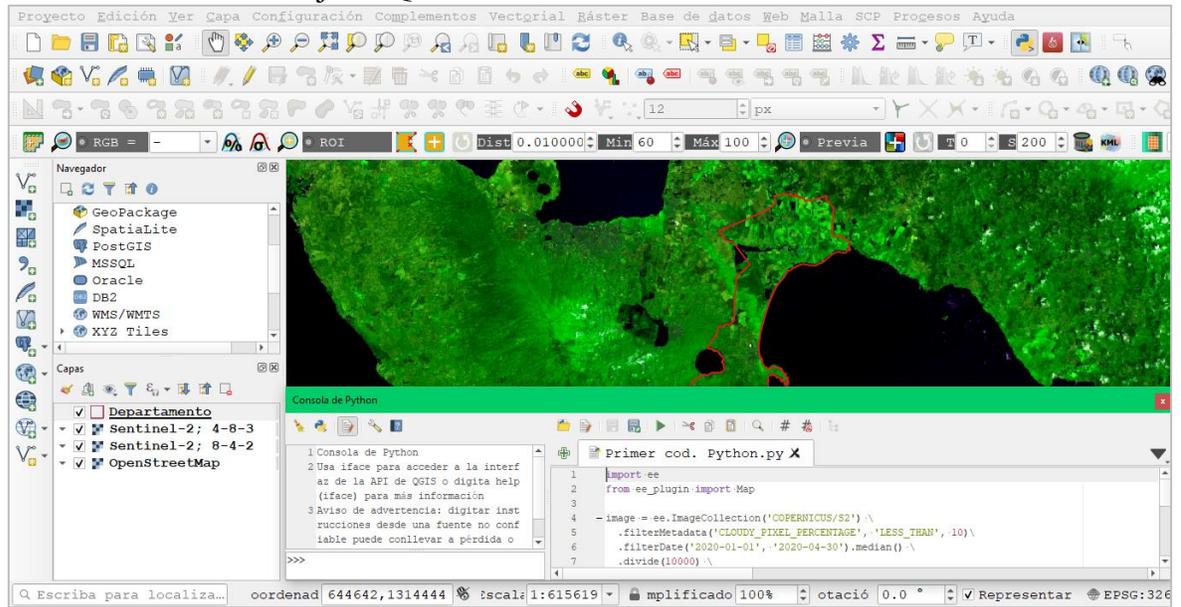
Anexo 5. Ejemplo de cómo se expresan los niveles radiométricos en los píxeles



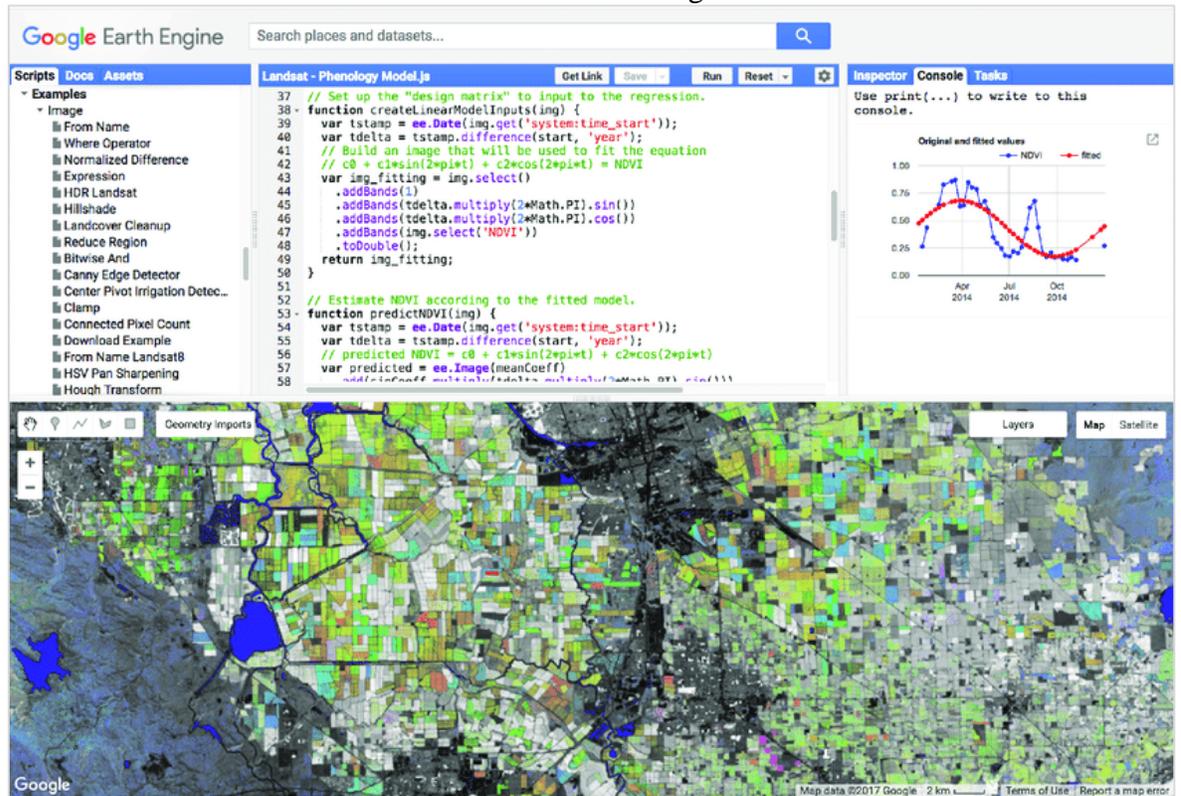
Anexo 6. Logos de los principales componentes de ArcGIS



## Anexo 7. Interfaz de trabajo de QGIS

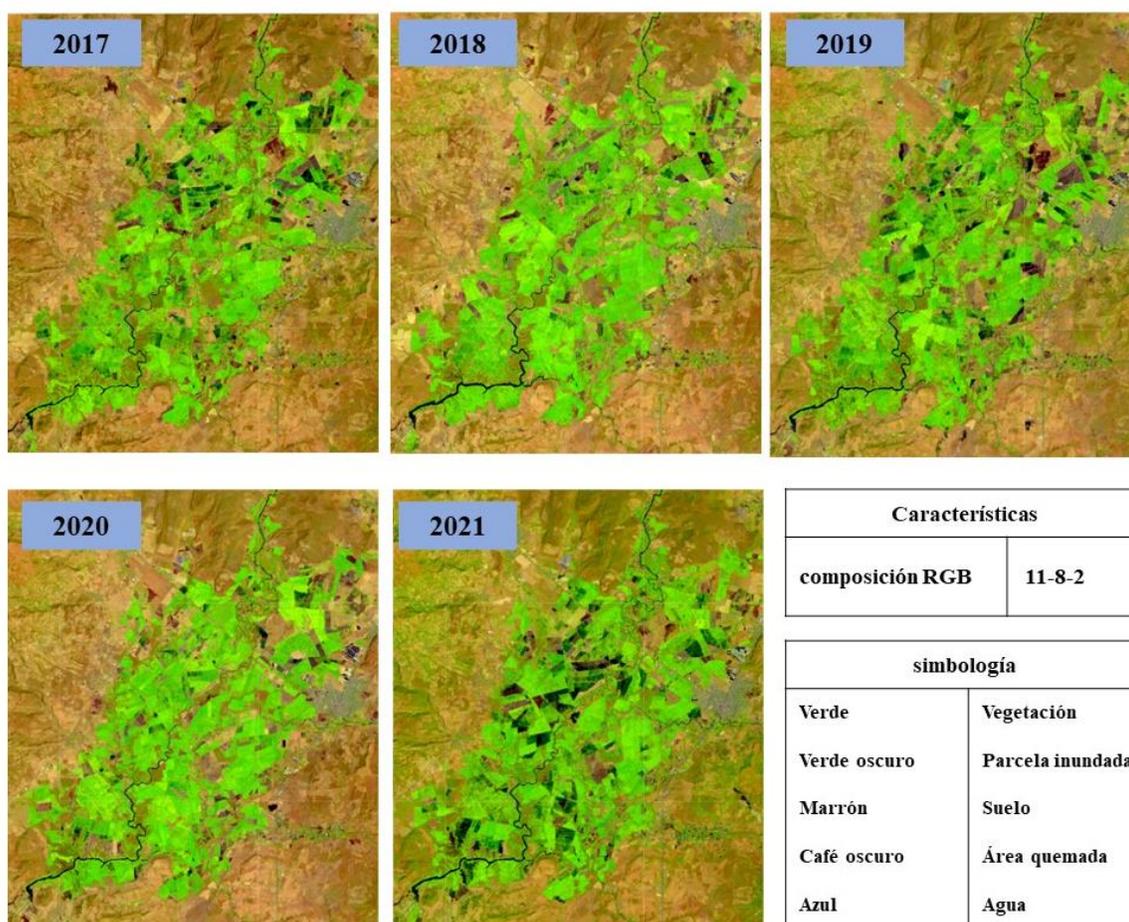


## Anexo 8. Entorno de desarrollo interactivo de Earth Engine



Fuente: Gorelick *et al.*, 2017

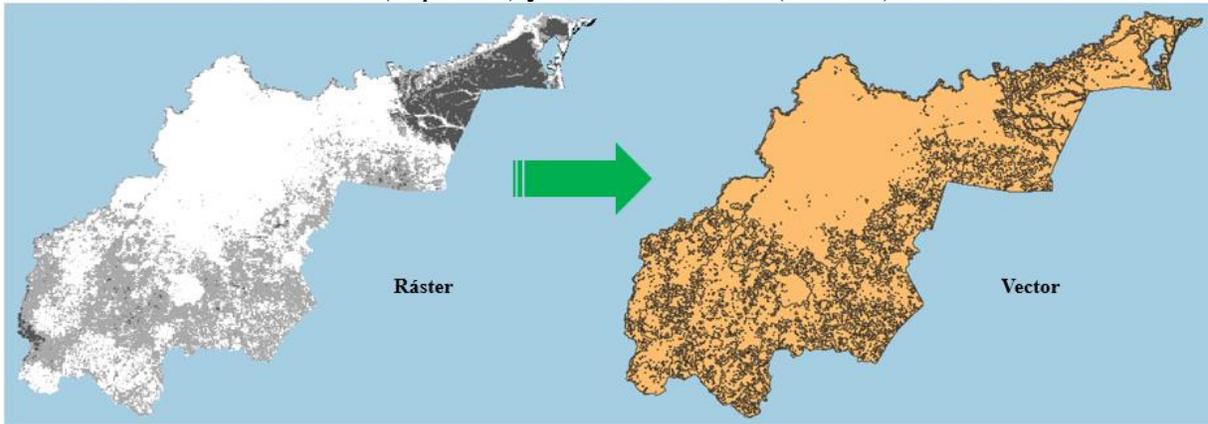
Anexo 9. Imágenes Sentinel 2 del valle de Sébaco a pseudo color natural



Anexo 10. Datos de la distribución espacio-temporal de los tipos de cobertura terrestre Valle de Sébaco de acuerdo con el NDVI (áreas en hectáreas)

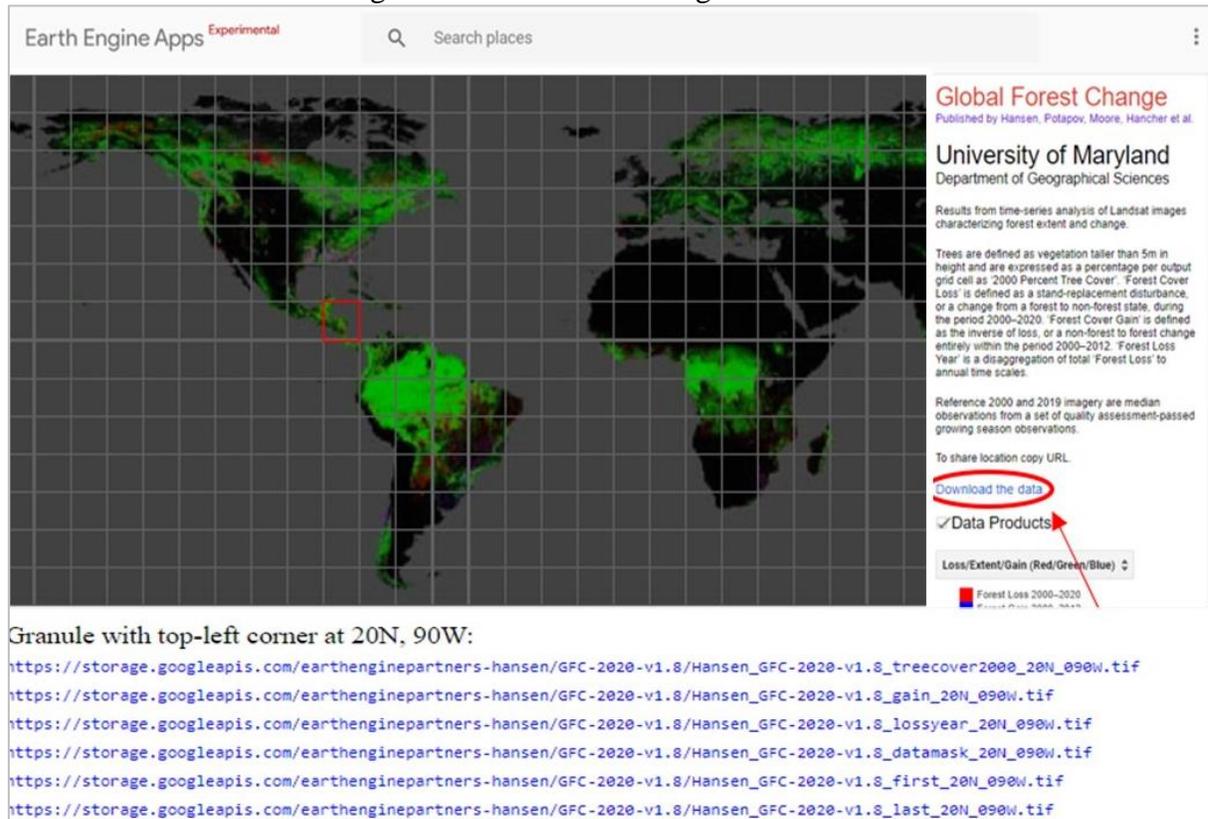
Categoría	2017	2018	2019	2020	2021
Agua	72.88	103.24	97.46	81.06	93.89
Suelo denudo y rastrojo	4,755.23	4,764.27	4,696.80	5,291.86	2,827.21
Vegetación moderadamente sana	5,422.20	5,074.04	5,265.99	4,570.75	6,622.72
Vegetación muy sana	7,864.10	8,172.97	8,054.19	8,170.82	8,570.61
<b>Total</b>	<b>18,114.40</b>	<b>18,114.51</b>	<b>18,114.45</b>	<b>18,114.50</b>	<b>18,114.43</b>

## Anexo 11. Ráster clasificado (izquierda) y archivo vectorial (derecha)



## Anexo 12. Interfaz de descarga de Global Forest Change

Earth Engine Apps Experimental



**Global Forest Change**  
Published by Hansen, Potapov, Moore, Hancher et al.  
University of Maryland  
Department of Geographical Sciences

Results from time-series analysis of Landsat images characterizing forest extent and change.

Trees are defined as vegetation taller than 5m in height and are expressed as a percentage per output grid cell as '2000 Percent Tree Cover'. Forest Cover Loss' is defined as a stand-replacement disturbance, or a change from a forest to non-forest state, during the period 2000-2020. Forest Cover Gain' is defined as the inverse of loss, or a non-forest to forest change entirely within the period 2000-2012. Forest Loss Year' is a disaggregation of total 'Forest Loss' to annual time scales.

Reference 2000 and 2019 imagery are median observations from a set of quality assessment-passed growing season observations.

To share location copy URL

[Download the data](#)

Data Products

Loss/Extent/Gain (Red/Green/Blue) ▾

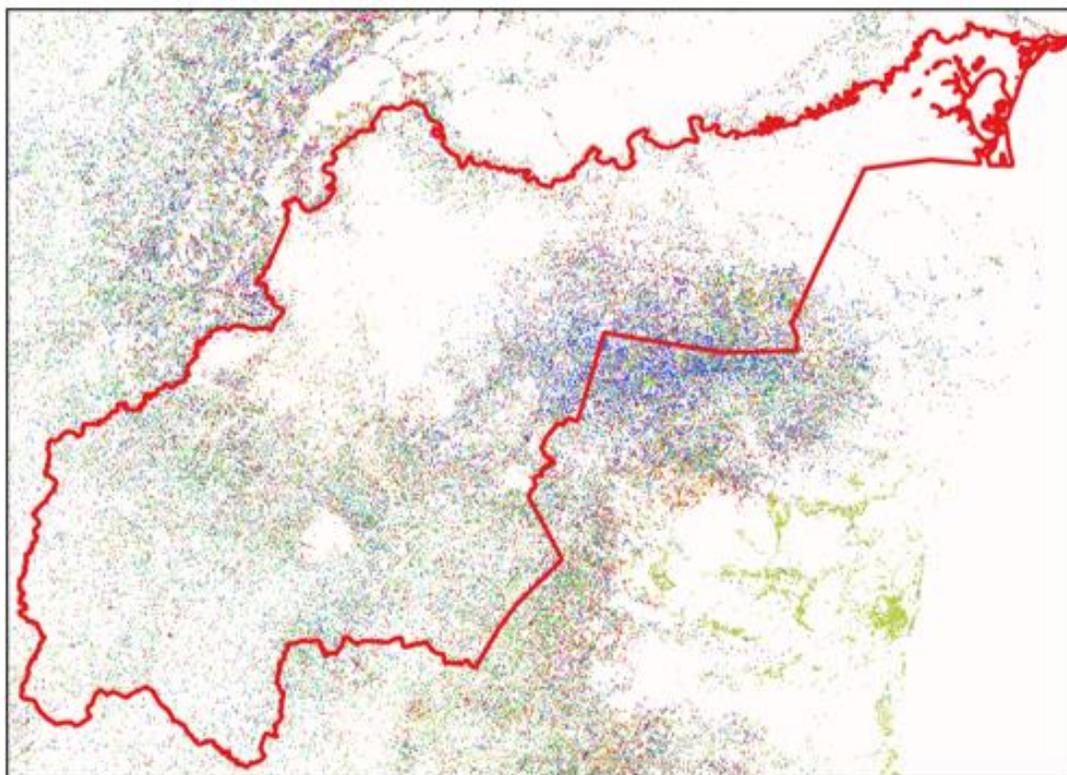
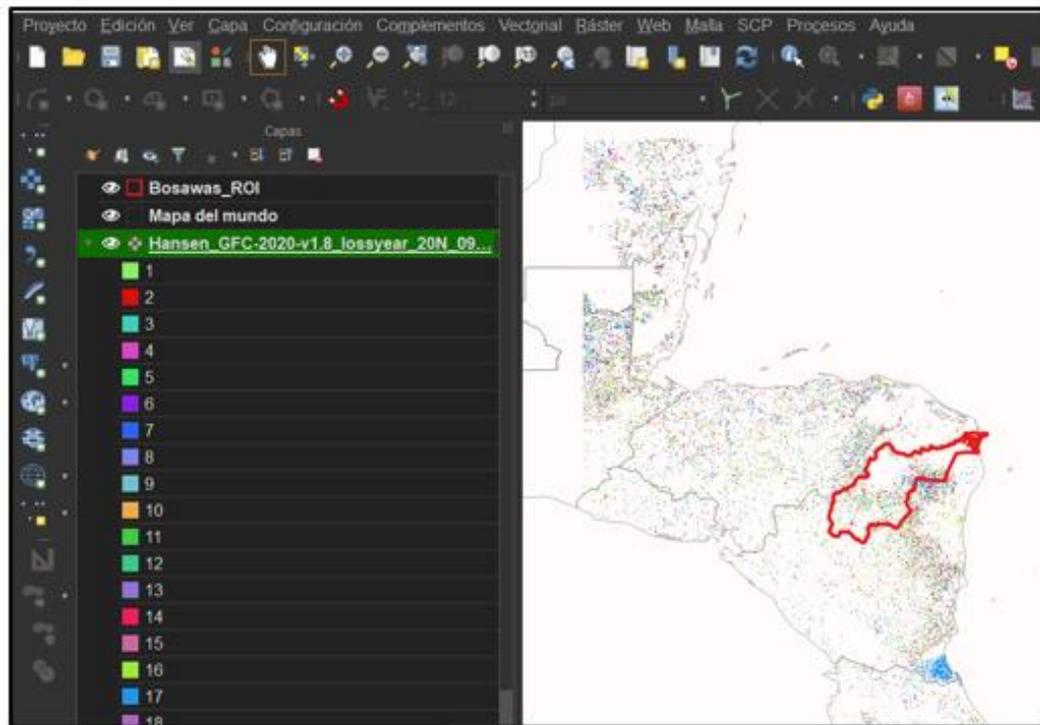
Forest Loss 2000-2020

Granule with top-left corner at 20N, 90W:

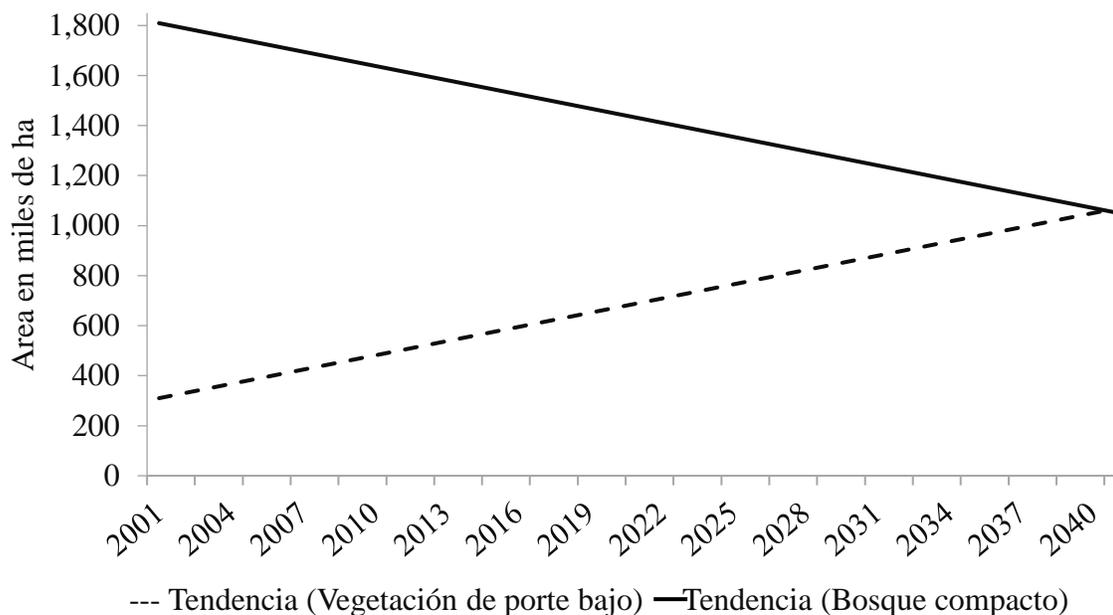
- [https://storage.googleapis.com/earthenginepartners-hansen/GFC-2020-v1.8/Hansen\\_GFC-2020-v1.8\\_treecover2000\\_20N\\_090W.tif](https://storage.googleapis.com/earthenginepartners-hansen/GFC-2020-v1.8/Hansen_GFC-2020-v1.8_treecover2000_20N_090W.tif)
- [https://storage.googleapis.com/earthenginepartners-hansen/GFC-2020-v1.8/Hansen\\_GFC-2020-v1.8\\_gain\\_20N\\_090W.tif](https://storage.googleapis.com/earthenginepartners-hansen/GFC-2020-v1.8/Hansen_GFC-2020-v1.8_gain_20N_090W.tif)
- [https://storage.googleapis.com/earthenginepartners-hansen/GFC-2020-v1.8/Hansen\\_GFC-2020-v1.8\\_lossyear\\_20N\\_090W.tif](https://storage.googleapis.com/earthenginepartners-hansen/GFC-2020-v1.8/Hansen_GFC-2020-v1.8_lossyear_20N_090W.tif)
- [https://storage.googleapis.com/earthenginepartners-hansen/GFC-2020-v1.8/Hansen\\_GFC-2020-v1.8\\_datamask\\_20N\\_090W.tif](https://storage.googleapis.com/earthenginepartners-hansen/GFC-2020-v1.8/Hansen_GFC-2020-v1.8_datamask_20N_090W.tif)
- [https://storage.googleapis.com/earthenginepartners-hansen/GFC-2020-v1.8/Hansen\\_GFC-2020-v1.8\\_first\\_20N\\_090W.tif](https://storage.googleapis.com/earthenginepartners-hansen/GFC-2020-v1.8/Hansen_GFC-2020-v1.8_first_20N_090W.tif)
- [https://storage.googleapis.com/earthenginepartners-hansen/GFC-2020-v1.8/Hansen\\_GFC-2020-v1.8\\_last\\_20N\\_090W.tif](https://storage.googleapis.com/earthenginepartners-hansen/GFC-2020-v1.8/Hansen_GFC-2020-v1.8_last_20N_090W.tif)

Fuente: Hansen *et al.*, (2013).

Anexo 13. Delimitación de los datos de la pérdida anual de bosques con los datos de Global Forest Change en QGIS



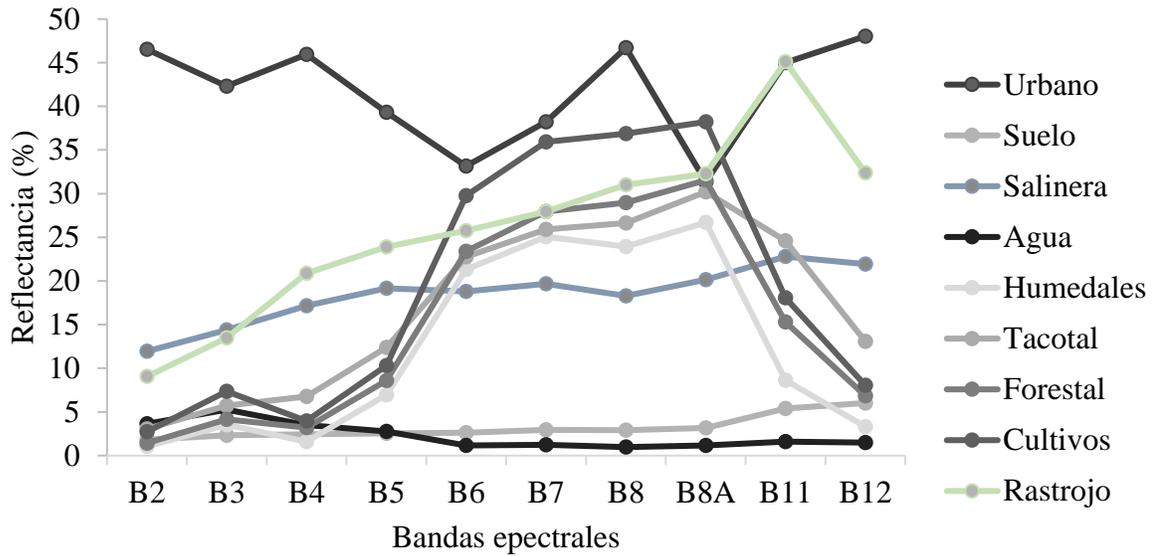
Anexo 14. Tendencia proyectada de la dinámica espacio-temporal de la vegetación en la Reserva de Bosawás



Anexo 15. Distribución de los diferentes tipos de cobertura terrestre en el departamento de Chinandega

Tipo de cobertura	Área en ha	%
Urbano	6,043.59	1.18
Suelo desnudo	117,433.08	22.92
Agua	19,684.79	3.84
Humedal	28,064.16	5.48
Salinera	8,934.15	1.74
Forestal	83,196.98	16.24
Tacotal	64,705.05	12.63
Cultivo	79,313.18	15.48
Rastrojo	104,924.19	20.48
<b>Total</b>	<b>512,299.17</b>	<b>100</b>

Anexo 16. Firmas espectrales obtenidas de los tipos de cobertura terrestre del departamento de Chinandega a partir de las 10 bandas de Sentinel 2



Anexo 17. Firmas espectrales más la adición de 7 índices espectrales multiplicados por 100 obtenidas de los principales tipos de cobertura terrestre del departamento de Chinandega

