

ANÁLISIS MULTITEMPORAL DE PÉRDIDA DE COBERTURA EN 65 MICROCUENCAS DEL CORREDOR SECO HONDUREÑO. AÑO 2010-2017.

José Cáceres Coello^{1,*}

¹Facultad de Ciencias Espaciales (FACES), Universidad Nacional Autónoma de Honduras (UNAH).

Recibido: 17/junio/2020

Aceptado: 23/noviembre/2020

DOI: <https://doi.org/10.5377/ce.v13i1.11255>

RESUMEN

El mapeo y la evaluación de la cobertura del suelo es una de las áreas centrales de la percepción remota. El cambio en la cobertura del suelo es una variable importante del cambio global que afecta a sistemas ecológicos con un impacto en el medio ambiente, asociado con el cambio climático. A pesar del papel de información sobre la cobertura del suelo en el monitoreo y comprensión del medio ambiente, todavía carecemos de conocimiento sobre cobertura del suelo y su dinámica, especialmente en las zonas rurales de Honduras. El objetivo del estudio fue analizar la dinámica de cambio de cobertura del suelo en 65 microcuencas del corredor seco hondureño. Imágenes derivadas de los sensores ETM+ y OLI de los satélites Landsat, para los años 2010, 2015 y 2017 fueron clasificadas en 13 categorías. La cobertura de pastos y cultivos fue la predominante durante los tres años analizados (23%, 28% y 33%), mostrando un avance en el tiempo en detrimento de la cobertura boscosa. La pérdida de bosque para el período 2010-2015 fue de 15% y de 12% para el período 2015-2017. Se utilizó el modelo GEOMOD2 para hacer una proyección de la deforestación al 2020, y se obtuvo que la cobertura boscosa para el área de estudio representará un 47% (siendo de un 58% para el 2010). Finalmente se realizó un análisis de la incidencia de incendios forestales, obteniéndose que las microcuencas más vulnerables son las ubicadas en las mancomunidades MAMSURPAZ y MANCOSOL, siendo el pino denso el más afectado.

Palabras clave: Percepción Remota; Análisis Multitemporal; GEOMOD; Incendio Forestales; Deforestación.

*jcaceres@unah.edu.hn

ABSTRACT

Mapping and evaluating land cover is one of the central areas of remote sensing. The change in land cover is an important variable of global change that affects ecological systems with an impact on the environment, associated with climate change. Despite the role of information on land cover in monitoring and understanding the environment, we still lack knowledge about land cover and its dynamics, especially in rural Honduras. The objective of the study was to analyze the dynamics of change in land cover in 65 micro-basins in the Honduran dry corridor. Images derived from ETM + and OLI sensors from Landsat satellites, for the years 2010, 2015 and 2017 were classified into 13 categories. The coverage of pastures and crops was the predominant one during the three years analyzed (23%, 28% and 33%), showing an advance in time to the detriment of forest cover. Forest loss for the 2010-2015 period was 15% and 12% for the 2015-2017 period. The GEOMOD2 model was used to make a projection of deforestation to 2020, and it was obtained that the forest cover for the study area will represent 47% (being 58% for 2010). Finally, an analysis of the incidence of forest fires was carried out, obtaining that the most vulnerable micro-basins are those located in the MAMSURPAZ and MANCOSOL communities, with dense pine being the most affected.

Keywords: Remote sensing; Multitemporal Analysis; GEOMOD; Forest Fire; Deforestation.

1 Introducción

El mapeo y la evaluación de la cobertura del suelo es una de las áreas centrales de la aplicación de la percepción remota. La cobertura del suelo es una variable fundamental que impacta y se vincula con muchas partes del entorno humano y físico. El cambio en la cobertura del suelo se considera como una de las variables más importantes del cambio global que afecta a los sistemas ecológicos con un impacto en el medio ambiente que, al menos, está asociado con el cambio climático. A pesar del papel importante que desempeña la información sobre la cobertura del suelo en el monitoreo y la comprensión del medio ambiente, todavía carecemos de conocimiento de la cobertura del suelo y su dinámica, especialmente en las zonas rurales de Honduras.

Sin embargo, la creciente disponibilidad de datos económicos y gratuitos, como los proporcionados por el Servicio Geológico de los Estados Unidos (USGS), la constante caída de los precios del hardware y el software, así como la mejora en el conocimiento de las aplicaciones potenciales de la percepción remota, proporcionan el impulso necesario para la evaluación del cambio de la cubierta terrestre, sobre todo en países en desarrollo. El uso combinado de sensores remotos y sistemas de información geográfica (GIS) brinda las herramientas esenciales para el mapeo, almacenamiento, análisis y modelado de escenarios futuros de la cubierta terrestre.

Para obtener información confiable a partir de datos satelitales, las técnicas de clasificación apropiadas son esenciales. En los últimos decenios se han desarrollado varios enfoques de clasificación y se puede encontrar una revisión de estos algoritmos en [Lu y Weng \(2007\)](#). Los clasificadores se pueden clasificar como comunes o avanzados. Algunos de los algoritmos de clasificación comunes incluyen K-media, ISO-DATA, máxima verosimilitud y distancia mínima ([Lillesand et al., 1998](#))

El objetivo del presente estudio es analizar la dinámica de cambio de cobertura del suelo en el área de localización de las 65 microcuencas, que sirva de línea base de los indicadores de alto nivel del Componente de Cuencas del Proyecto ACS-USAID. Para ello se explorará la capacidad de las imágenes derivadas del

satélite Landsat, para la generación de clasificaciones de cobertura del suelo utilizando un algoritmo de clasificación de máxima verosimilitud para los años 2010, 2015 y 2017. Posteriormente, se hará un análisis de detección de cambio para los años 2010-2015 y 2015-2017 utilizando el enfoque de matriz de confusión las cuales permiten evaluar la precisión individual de cada categoría describiendo los errores de inclusión (errores de comisión) y exclusión (errores de omisión) presentes en la clasificación. Finalmente, Para proyectar el modelo de deforestación se utilizará el modelo GEOMOD2 (Pontius Jr. *et al.*, 2001), el cual es un modelo basado en SIG que cuantifica los factores asociados con el uso del suelo, y simula el patrón espacial del uso del suelo hacia adelante y hacia atrás en el tiempo.

2 Metodología

Inicialmente, se definieron 15 clases potenciales, sin embargo, al analizar la separabilidad de coberturas se redujeron a 13 clases (Tabla 1) que se pudieron identificar/clasificar mediante la utilización de imágenes Landsat ETM+ (2010) y OLI (2015 y 2017).

Tabla 1: Definición de clases a identificar

Código	Cobertura
1	Bosque de conífera denso
2	Bosque de conífera ralo
3	Bosque de conífera plagado
4	Bosque latifoliado deciduo
5	Bosque latifoliado húmedo
6	Bosque mixto
7	Café
8	Otras superficies de agua
9	Pastos/cultivos
10	Suelo desnudo continental
11	Vegetación secundaria decidua
12	Vegetación secundaria húmeda
13	Asentamientos humanos

2.1 Imágenes Satelitales

Para este estudio se han seleccionado las imágenes derivadas del sensor Enhanced Thematic Mapper Plus (ETM+) y del Operational Land Imager (OLI), a bordo de los satélites Landsat 7 y Landsat 8 respectivamente, los cuales cuentan con una resolución espacial de 30m x 30m en el multispectral y de 15m x 15m en el canal pancromático. Los datos de Landsat constituyen el registro más largo de datos de observación terrestre de resolución espacial media a escala global.

Se seleccionaron tres (3) pares de imágenes de Landsat libres de nubes, en la medida de lo posible, para clasificar el área de estudio: 27 de enero y 5 de febrero de 2010; 06 y 29 de agosto de 2015; y 18 y 27 de agosto de 2017. El área de estudio se encuentra comprendida dentro de dos escenas Landsat con identificados path 18 row 50 y path 19 row 50. Las imágenes fueron Landsat 7 ETM+ para el año 2010 (Figura 1a), Landsat-8 OLI para los años 2015 (Figura 1b) y 2017 (Figura 1c).

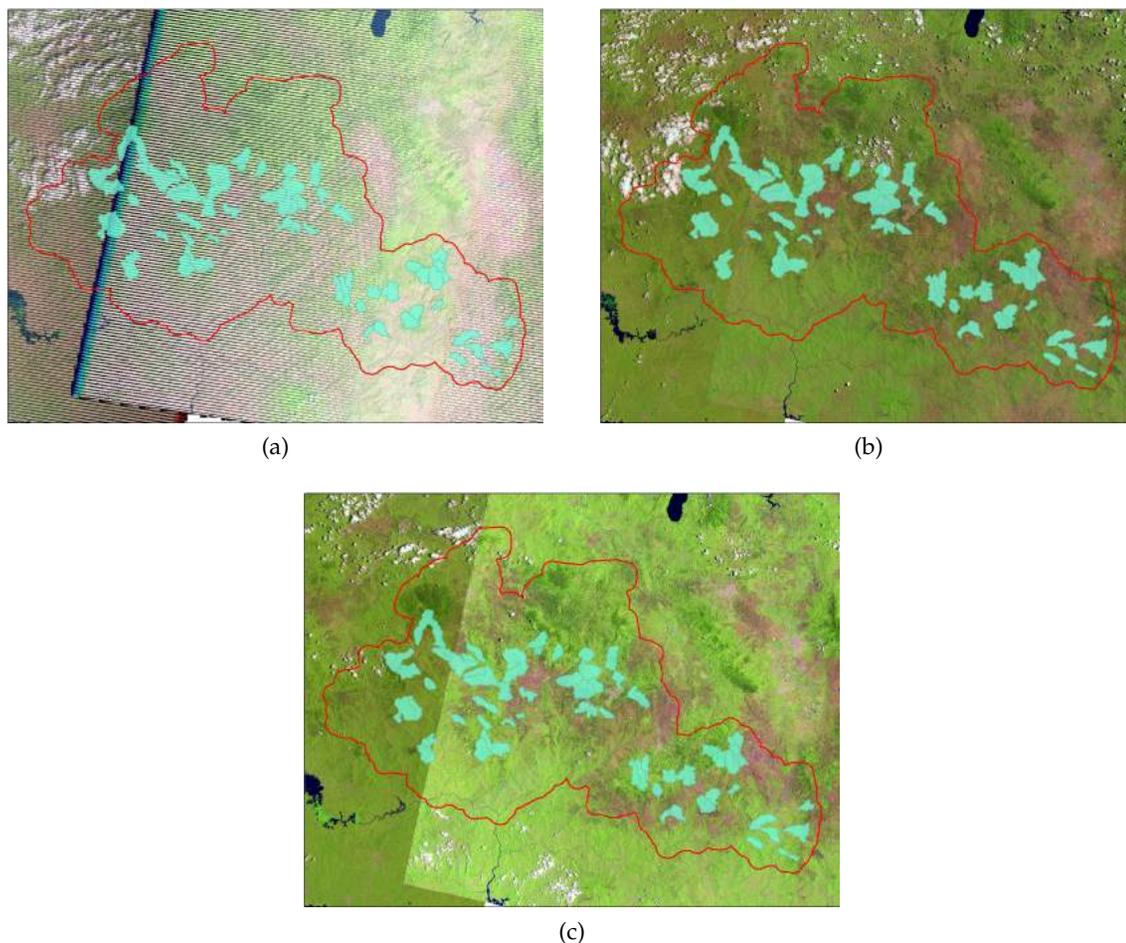


Figura 1: Imágenes Landsat seleccionadas. (a) L7 2010. (b) L8 2015. (c) L8 2017.

Numerosos investigadores, entre ellos [Lillesand *et al.* \(1998\)](#), [Lunetta y Balogh \(1999\)](#), [Oettera *et al.* \(2001\)](#), [Wolter *et al.* \(1995\)](#), y [Yuan *et al.* \(2005\)](#) han demostrado la importancia de las imágenes multitemporales para la clasificación de la cubierta terrestre.

Se seleccionaron 75 puntos de muestreo aleatorios distribuidos a lo largo de toda el área de estudio (Ver [Tabla 2](#)). Estos puntos permitieron la identificación de las coberturas actuales del área de estudio y fueron utilizados en el proceso de clasificación como áreas de entrenamiento. Parte de estos puntos fueron utilizados para la validación de las clasificaciones resultantes para los años 2010, 2015 y 2017. Cabe mencionar que el tamaño de la muestra (puntos de muestreo) podrá aumentar en caso de que los puntos recolectados prueben no ser suficientes para identificar apropiadamente las clases objetivo.

2.2 Algoritmo de Clasificación

Las imágenes multitemporales se clasificaron por separado utilizando el algoritmo de clasificación de máxima verosimilitud. La máxima verosimilitud es uno de los clasificadores paramétricos más utilizados en la práctica, debido a su robustez y su disponibilidad inmediata en casi cualquier software de procesamiento de imágenes ([Lu y Weng, 2007](#)).

El algoritmo de clasificación de máxima verosimilitud (MLC) es una de las clasificaciones paramétricas

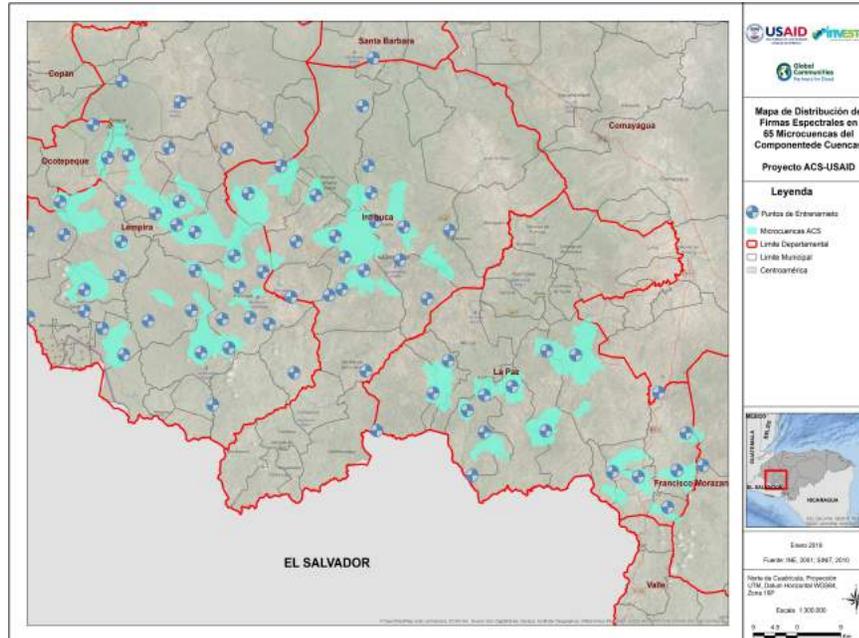


Figura 2: Localización y Distribución de los puntos de muestreo.

bien conocidas utilizadas para la clasificación supervisada. El algoritmo para calcular la distancia ponderada o la probabilidad D del vector de medición desconocido X pertenece a una de las clases conocidas M_c se basa en la ecuación bayesiana.

El vector de medición desconocido se asigna a la clase en la que tiene la mayor probabilidad de pertenencia. La ventaja del MLC como clasificador paramétrico es que toma en cuenta la varianza-covarianza dentro de las distribuciones de clase y para los datos distribuidos normalmente, el MLC se desempeña mejor que las otras clasificaciones paramétricas conocidas. Sin embargo, para los datos con una distribución no normal, los resultados pueden ser insatisfactorios.

2.3 Detección de Cambios

Después de la clasificación, con su debida validación, se utilizó el algoritmo de detección de cambios para determinar los cambios en el tipo de cobertura del suelo entre 2010/2015 y 2015/2017. Podría decirse que es la opción más obvia para el método de detección de cambio cuantitativo, ya que proporciona información de cambio "desde - hasta" (Bouziani *et al.*, 2010; Jensen, 2005). Los resultados de la clasificación de las imágenes multitemporales se compararon para generar una matriz de cambios y medir los cambios en las categorías de cobertura del suelo. La precisión de la clasificación individual debe ser lo más precisa posible, ya que los errores en cada clasificación se propagarán y afectará la precisión general del análisis de cambios. Por lo tanto, la calidad, la precisión y la integridad de los datos de entrenamiento son cruciales para producir una clasificación de alta calidad y, por lo tanto, mejorar la detección de cambios (Erbe *et al.*, 2004; Nackaerts *et al.*, 2006)

Se utilizaron matrices de confusión para evaluar la exactitud de la clasificación. Una matriz de confusión es una forma muy efectiva de representar la precisión del mapa, porque la precisión individual de cada categoría se describe claramente con los errores de inclusión (errores de comisión) y exclusión (errores de omisión) presentes en la clasificación (Congalton, 1991).

2.4 Modelo de Deforestación Futura

Para proyectar el modelo de deforestación se utilizó el modelo GEOMOD2 (Pontius Jr. *et al.*, 2001), el cual es un modelo basado en SIG que cuantifica los factores asociados con el uso del suelo, y simula el patrón espacial del uso del suelo hacia adelante y hacia atrás en el tiempo.

GEOMOD2 selecciona las ubicaciones de las áreas a convertir de acuerdo con tres reglas de decisión. A discreción del usuario, cualquiera de las tres reglas de decisión puede ser incluida o excluida.

La primera regla de decisión se basa en el principio del vecino más cercano, según el cual, en cualquier paso del tiempo, GEOMOD2 restringe la conversión del uso de la tierra a aquellas áreas que se encuentran en el límite entre el bosque de dosel cerrado y la tierra alterada. Esta regla simula el surgimiento de tierra recién perturbada en tierra que ya estaba perturbada.

La segunda regla de decisión se refiere a la estratificación subregional. GEOMOD2 puede especificar la cantidad anual de cambio en el uso de la tierra dentro de una serie de subregiones, como es el caso de los municipios localizados dentro del área de estudio o las propias microcuencas. Es posible tener cualquier estratificación regional para la cual existen datos, como es el caso de los mapas forestales a nivel nacional.

La tercera regla de decisión concierne a los atributos biogeofísicos. Bajo esta tercera regla, GEOMOD2 predice perturbaciones futuras en ubicaciones que tienen atributos que son similares a los atributos de áreas previamente perturbadas. Para incorporar esta regla en el modelo, GEOMOD2 crea un mapa de "idoneidad" empíricamente, utilizando varios mapas de atributos y un mapa de uso de la tierra. El mapa de idoneidad tiene valores altos en ubicaciones que tienen atributos biogeofísicos similares a los de las tierras perturbadas, y valores bajos en ubicaciones que tienen atributos biogeofísicos similares a los de bosques de cobertura cerrada no perturbados. GEOMOD2 simula perturbaciones futuras al buscar en el paisaje la ubicación que tiene el valor de adecuación más alto disponible.

El mapa de idoneidad se crea en dos pasos. Primero, GEOMOD2 reclasifica cada mapa de atributos de tal manera que a las celdas de la cuadrícula de cada categoría del mapa de atributos se les asigna un valor de porcentaje perturbado, obtenido al comparar el mapa de atributos con el mapa de uso de la tierra inicial. El porcentaje de valor perturbado de cada categoría en el mapa de atributos se calcula como la relación entre la cantidad de celdas de cuadrícula perturbadas de esa categoría y la cantidad de todas las celdas de cuadrícula de esa categoría.

Luego de que cada mapa de atributos se reclasifica, GEOMOD2 crea el mapa de idoneidad al calcular para cada celda de la cuadrícula una suma ponderada de todos los mapas de atributos reclasificados.

2.5 Incidencia de Incendios

En muchas ocasiones, los incendios provocan eventos catastróficos principalmente en el bosque y estos suceden todos los años en nuestro país, por lo que con esta metodología se pretende desarrollar un procedimiento que nos dé información no solo de la coordenada como punto de calor sino determinar las áreas quemadas mediante un sensor satelital.

Los puntos calientes resultantes del sensor Moderate Resolution Imaging Spectroradiometer (MODIS), a bordo de los satélites TERRA y AQUA, a través del producto Fire Information for Resource Management System (FIRMS) (Kaufman *et al.*, 1998) se utilizarán para la identificación temporal del incendio para luego

tener una identificación visual mediante Landsat y MODIS utilizando diversas coberturas para determinar el patrón espectral y discriminar las zonas de alta temperatura detectadas mediante la combinación de bandas infrarrojas térmicas referidas a incendios forestales (Figura 3). El análisis multitemporal se utilizará para determinar las zonas recurrentes a incendios con la combinación de bandas espectrales localizadas en el infrarrojo cercano (NIR) e infrarrojo de onda corta (SWIR) obtenidas con la correlación de los puntos calientes.

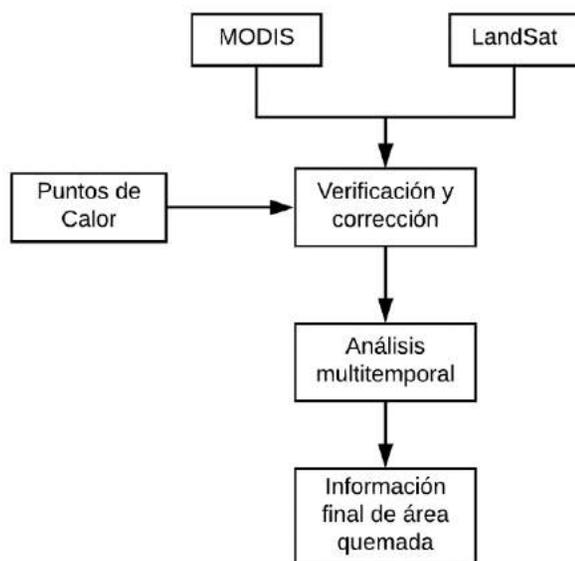


Figura 3: Modelo para la determinación de Incendios.

3 Resultados

A continuación, se presentan los resultados obtenidos.

3.1 Clasificación 2010

Según los resultados obtenidos de la clasificación correspondiente al año 2010 (Figura 4), la cobertura del suelo predominante dentro de las microcuencas corresponde a la categoría, Pastos y/o Cultivos, cubriendo un 23 % del área total de todas las microcuencas, en segundo lugar, se encuentra el bosque Latifoliado (17%) y en tercer lugar el bosque de conífera denso (14%) el resto de las coberturas pueden encontrarse en la Tabla 2.

3.2 Clasificación 2015

Para el año 2015, se encontró que la cobertura del suelo predominante fue Pastos y/o Cultivos, cubriendo un 28 % del área total de todas las microcuencas (Figura 5), le sigue el bosque mixto (14%) y en tercer lugar el café (13%) el resto de las coberturas pueden encontrarse en la Tabla 3.

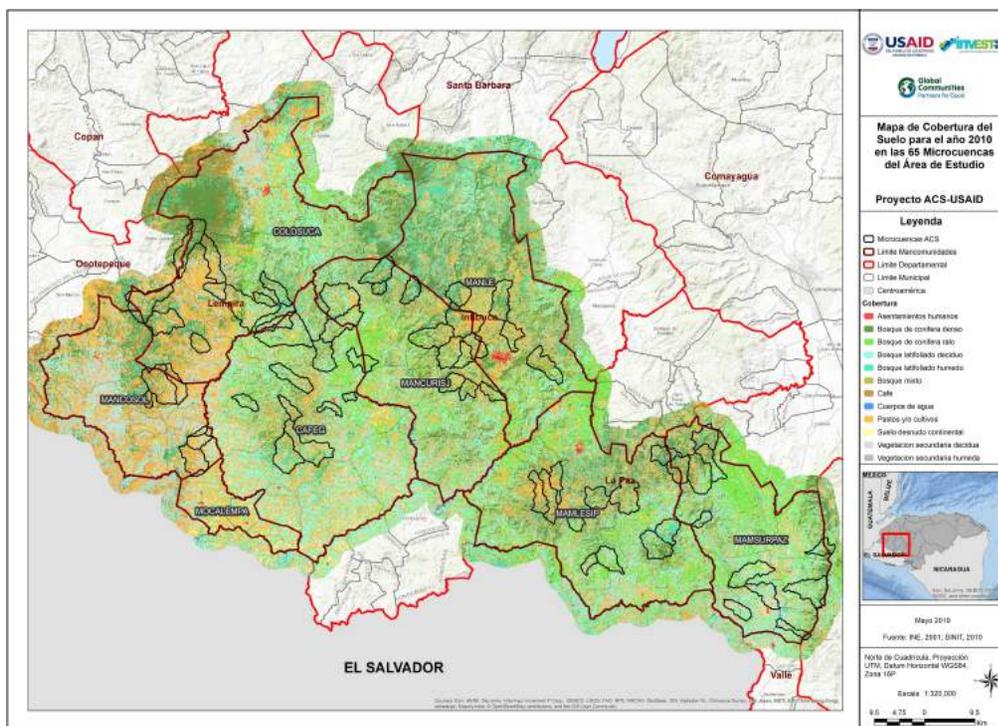


Figura 4: Clasificación de Coberturas. Año 2010.

Tabla 2: Coberturas por Área y Porcentaje para el Año 2010

Código	Cobertura	Área (Ha)	Porcentaje (%)
1	Bosque de conífera denso	15,338.39	14.41
2	Bosque de conífera ralo	8,320.53	7.82
3	Bosque de conífera plagado	0.00	0.00
4	Bosque latifoliado deciduo	18,134.12	17.04
5	Bosque latifoliado húmedo	6,699.33	6.29
6	Bosque mixto	13,878.26	13.04
7	Café	8,287.18	7.79
8	Cuerpos de agua	14.21	0.01
9	Pastos y/o cultivos	24,386.15	22.91
10	Suelo desnudo continental	980.74	0.92
11	Vegetación secundaria decidua	7,681.12	7.22
12	Vegetación secundaria húmeda	2,596.03	2.44
13	Asentamientos humanos	111.63	0.10

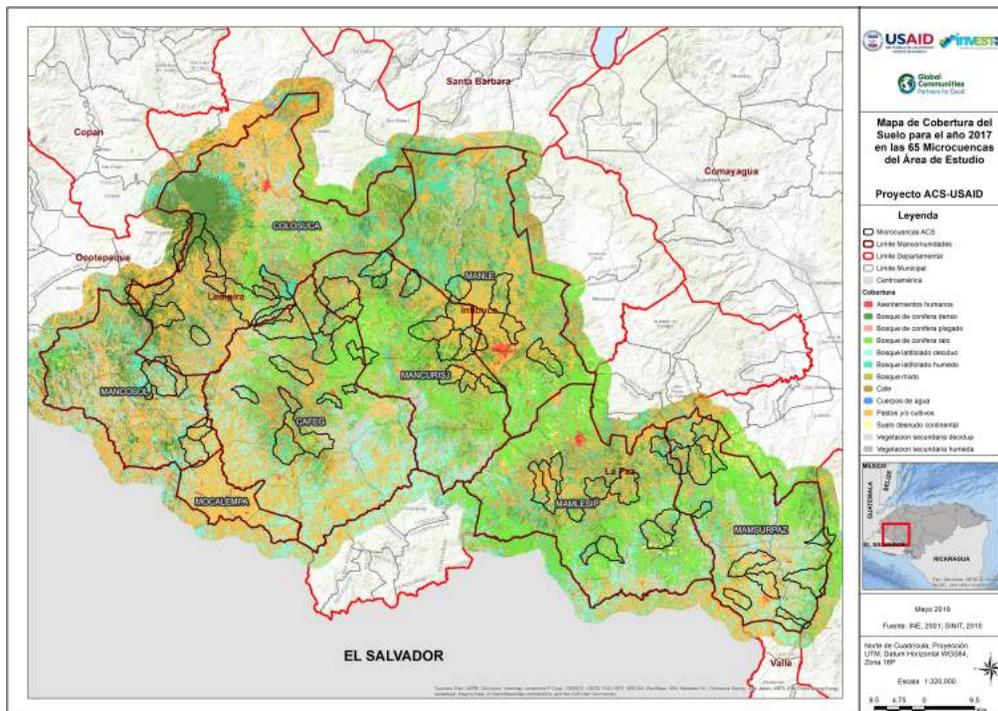


Figura 6: Clasificación de Coberturas. Año 2017.

Tabla 4: Coberturas por Área y Porcentaje para el Año 2017.

Código	Cobertura	Área (Ha)	Porcentaje (%)
1	Bosque de conífera denso	12,216.10	11.48
2	Bosque de conífera ralo	12,337.55	11.59
3	Bosque de conífera plagado	684.63	0.64
4	Bosque latifoliado deciduo	5,578.53	5.24
5	Bosque latifoliado húmedo	12,085.26	11.36
6	Bosque mixto	10,077.04	9.47
7	Café	10,836.64	10.18
8	Cuerpos de agua	81.60	0.08
9	Pastos y/o cultivos	35,538.25	33.39
10	Suelo desnudo continental	1,799.29	1.69
11	Vegetación secundaria decidua	3,501.10	3.29
12	Vegetación secundaria húmeda	1,509.27	1.42
13	Asentamientos humanos	183.28	0.17

3.4 Validación de Clasificaciones

Para tener una idea de la fiabilidad de la clasificación se procedió a calcular una matriz de confusión con errores de omisión y comisión, derivar el índice kappa y un valor de la precisión general entre el mapa clasificado y los datos de referencia tomados en campo.

La matriz muestra la precisión del usuario y la precisión del productor para cada clase, así como también un índice de acuerdo kappa general. Estas tasas de precisión van de 0 a 1, donde 1 representa el 100 por ciento de precisión.

La precisión del usuario muestra falsos positivos, donde los píxeles se clasifican incorrectamente como una clase conocida cuando deberían haberse clasificado como otra cosa. La precisión del usuario también se conoce como errores de comisión o error de tipo 1. Los datos para calcular esta tasa de error se leen de las filas de la tabla. La fila Total muestra la cantidad de puntos que deberían haberse identificado como una clase determinada, de acuerdo con los datos de referencia.

La precisión del productor es un falso negativo, donde los píxeles de una clase conocida se clasifican como algo distinto de esa clase. La precisión del productor también se conoce como errores de omisión o error de tipo 2. Los datos para calcular esta tasa de error se leen en las columnas de la tabla. La columna Total muestra el número de puntos que se identificaron como una clase dada, según el mapa clasificado.

El índice de acuerdo Kappa ofrece una evaluación general de la precisión de la clasificación. Los valores obtenidos, para cada clasificación, se presentan en la Tabla 5.

Tabla 5: Valores de índice Kappa para cada clasificación

Año	Índice Kappa
2010	0.7293
2015	0.7557
2017	0.7851

3.5 Incidencia y Probabilidad de Incendios

El siguiente mapa muestra la incidencia – probabilidad de recurrencia en los 5 años (Figura 7), las coloraciones rojas muestran los lugares en donde se concentra la mayor cantidad de puntos de calor (Figura 8) lo que implica que el fenómeno es recurrente en esos sectores y por ende presentan una mayor probabilidad de ocurrencia de incendios, por el contrario, las zonas en azul representan las áreas con menos probabilidad de ocurrencia.

La Tabla 6 muestra la cantidad de puntos de calor en las 8 mancomunidades, se observa que el año 2014 fue el año con mayor cantidad de puntos de calor en la zona de estudio y que la mancomunidad MAMSURPAZ es la que contiene la mayor cantidad de puntos para ese año.

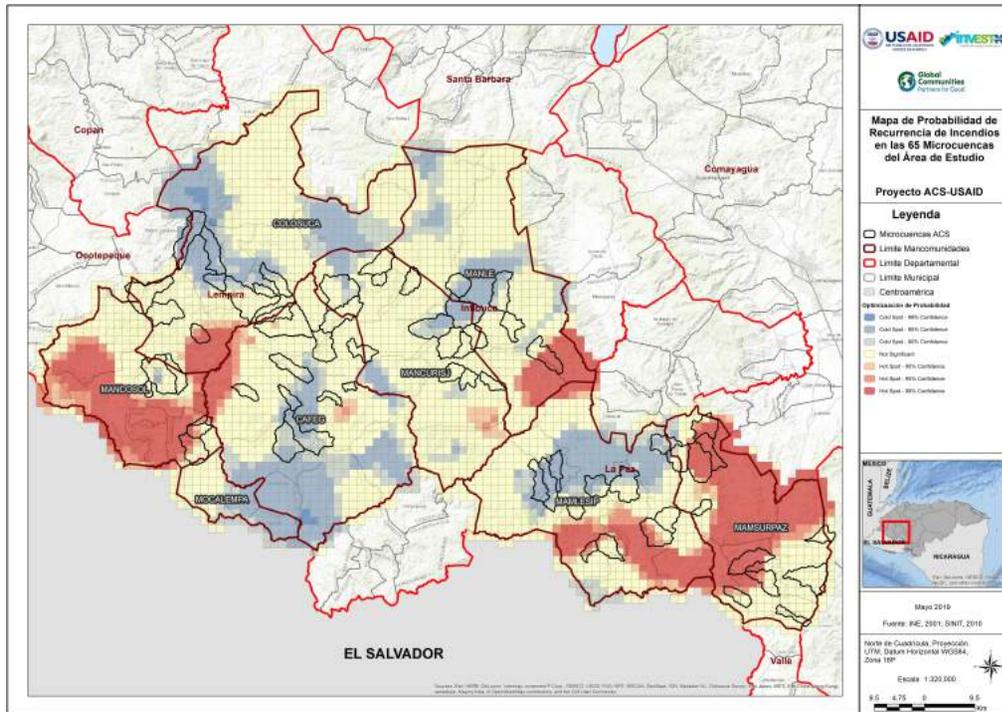


Figura 7: Mapa de probabilidad de recurrencia con microcuencas.

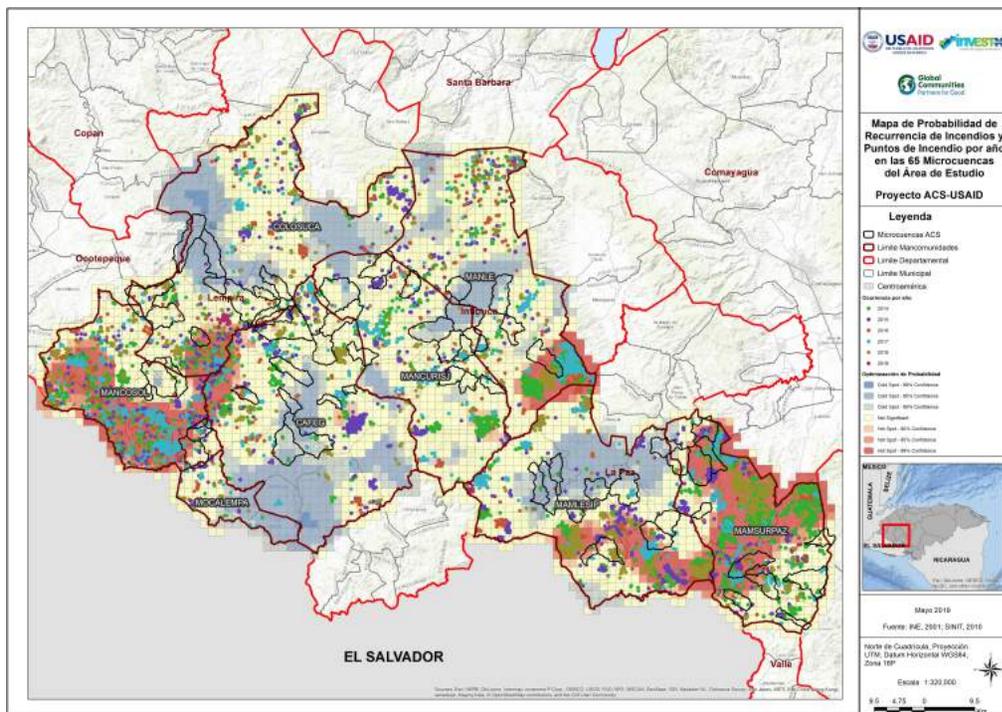


Figura 8: Mapa probabilidad de recurrencia con microcuencas y puntos de calor por año.

Tabla 6: Puntos de calor por mancomunidad.

Mancomunidad	2014	2015	2016	2017	2018	2019	Total
CAFEG	194	254	72	153	162	7	842
COLOSUCA	163	271	101	115	163	32	845
MAMLESIP	215	232	103	200	373	12	1135
MAMSURPAZ	795	234	62	305	425	55	1876
MANCOSOL	306	258	166	344	155	2	1231
MANCURISJ	212	132	49	161	58	6	618
MANLE	311	102	117	319	136	2	987
MOCALEMPA	8	22	12	15	9	3	69
Total	2204	1505	682	1612	1481	119	7603

En la Tabla 7 podemos observar claramente que la cobertura más afectada es pino denso, ya que es la cobertura que presenta la mayor cantidad de puntos de calor a lo largo de los cinco años analizados, con sus peores años en 2014 y 2018.

Tabla 7: Puntos de calor por tipo de cobertura.

Tipo de Cobertura	2014	2015	2016	2017	2018	2019	Total
Árboles Dispersos	40	24	12	29	21		126
Bosque Latifoliado Húmedo	25	29	16	11	28	2	111
Bosque Latifoliado Seco	122	111	49	74	76	4	436
Bosque Mixto	67	82	24	64	51	1	289
Café	13	10	4	25	6	1	59
Pastos y/o Cultivos	572	514	226	412	370	29	2123
Pino Denso	654	294	117	616	384	24	2089
Pino Ralo	359	195	88	158	341	29	1170
Suelos Desnudos Continentales	6	2	2	1	4		15
Vegetación Secundaria Seca	272	154	66	163	156	25	836
Vegetación Secundaria Húmeda	70	89	78	55	44	4	340
Zonas Urbanizadas continuas	1	1					2
Zonas Urbanizadas discontinuas	3			4			7
Total	2204	1505	682	1612	1481	119	7603

4 Discusión

Para estimar los cambios en la cobertura del suelo, se tomaron como referencia dos períodos, 2010-2015 y 2015-2017. Para esto se partió de las 13 clases clasificadas para cada año, y se realizó una reclasificación en dos categorías, bosque (1-6) y no bosque (7-13), para determinar de manera directa la pérdida de cobertura boscosa (deforestación) así como la ganancia de la misma dentro del área de estudio. Para representar dichos cambios se generaron 3 categorías:

- Pérdida (-1): hace referencia a las zonas que fueron clasificadas como bosque en el primer año y pasaron a ser no bosque en el segundo.
- Sin cambios (0): zonas que no presentaron ninguna variación en su categoría.

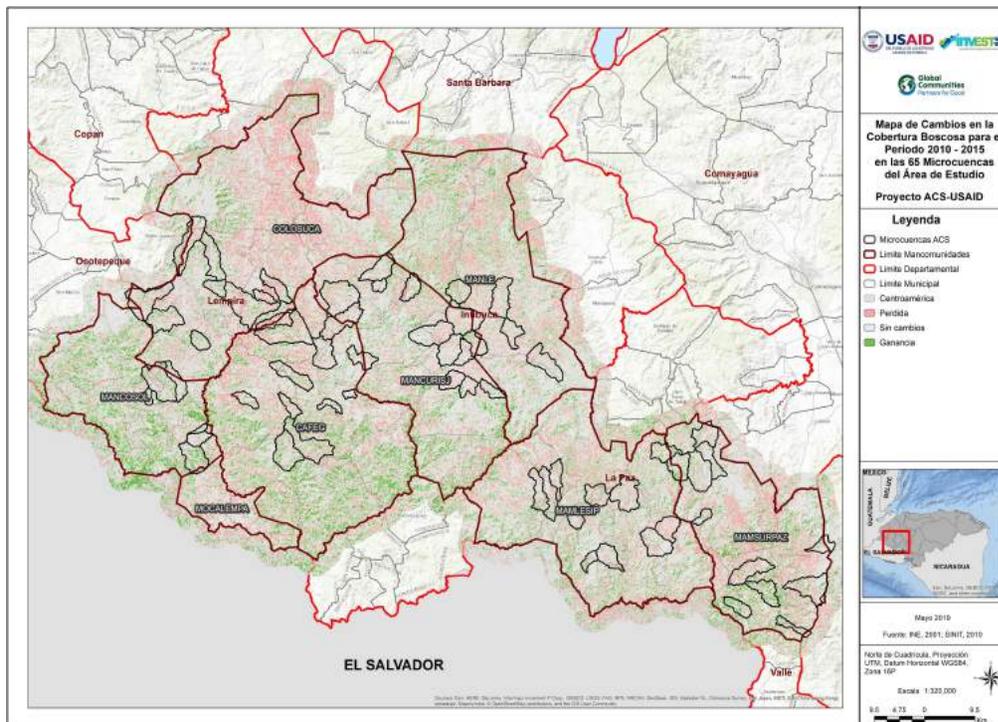


Figura 9: Cambios para el período 2010 – 2015.

- Ganancia (1): zonas que fueron clasificadas como no bosque en el año uno y pasaron a ser bosque en el año dos.

Para el período 2010-2015 (Figura 9), se obtuvo que la pérdida de bosque fue de 16,000 hectáreas (15 % del área de estudio), mientras que la ganancia de bosque fue de 11,789 hectáreas (Tabla 8).

Tabla 8: Pérdida y ganancia de bosque. Periodo 2010 – 2015.

Valor	Descripción	Área (ha)	Porcentaje
-1	Pérdida	16,003.53	15.04
0	Sin cambios	78,632.91	73.89
1	Ganancia	11,789.19	11.08

Para el período 2015-2017 (Figura 10), la pérdida de bosque fue de 13,015 hectáreas (12 %), mientras que se ganaron 7,968 hectáreas (Tabla 9).

Por último, se analizó la dinámica de cobertura del suelo durante el período total de estudio (2010 – 2017), encontrándose que se perdieron 19,970 hectáreas (19 %) de bosque (Figura 11), mientras que se ganaron 10,700 hectáreas (Tabla 10)

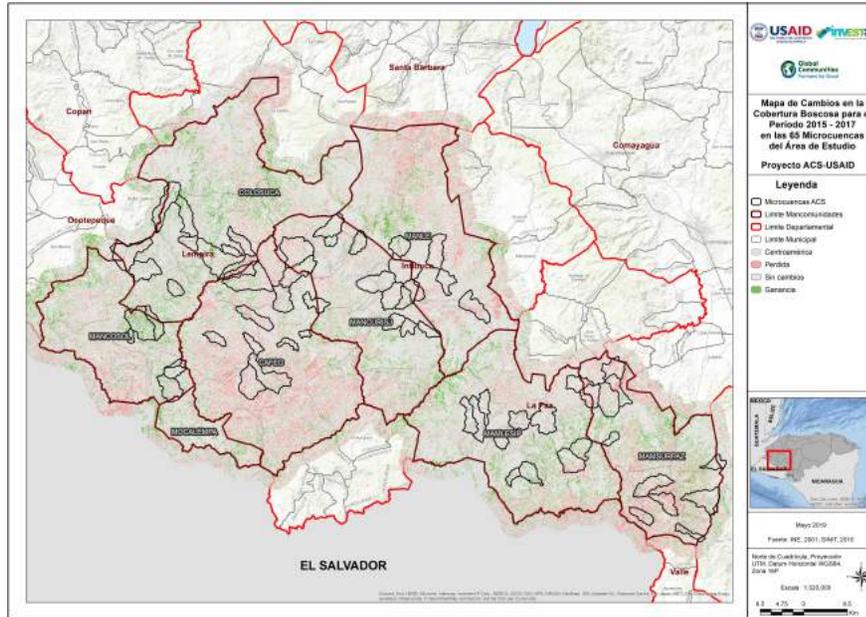


Figura 10: Cambios para el período 2015 – 2017.

Tabla 9: Pérdida y ganancia de bosque. Periodo 2015 – 2017.

Valor	Descripción	Área (ha)	Porcentaje
-1	Pérdida	13,015.98	12.23
0	Sin cambios	85,441.95	80.28
1	Ganancia	7,968.78	7.49

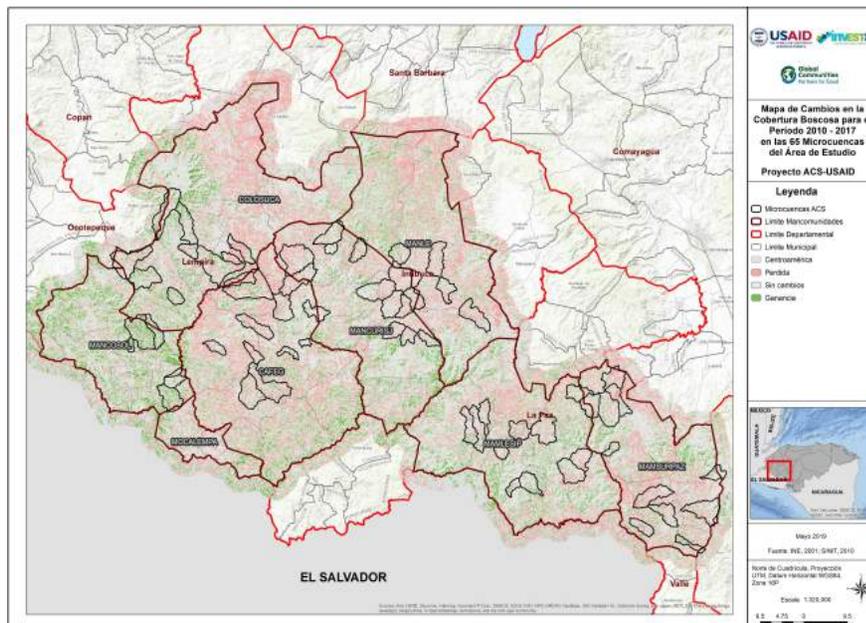


Figura 11: Cambios para el período 2010 – 2017.

Tabla 10: Pérdida y ganancia de bosque. Periodo 2010 – 2017.

Valor	Descripción	Área (ha)	Porcentaje (%)
-1	Pérdida	19,970.10	18.76
0	Sin cambios	75,748.41	71.17
1	Ganancia	10,708.29	10.06

Para predecir el comportamiento de la cobertura boscosa del área de estudio, proyectada a cinco años a partir del 2015, se utilizó como capa de entrada la reclasificación de la cobertura, en las categorías bosque y no bosque, para el año 2015. Adicionalmente, se utilizó el mapa de clasificación 2017, con las 13 categorías y un mapa de pendientes, como posible condicionante para los procesos de deforestación en la zona.

Después de modelar el comportamiento de la deforestación utilizando el modelo Geomod, se obtuvo el comportamiento de la cobertura boscosa proyectada al año 2020 (Figura 12).

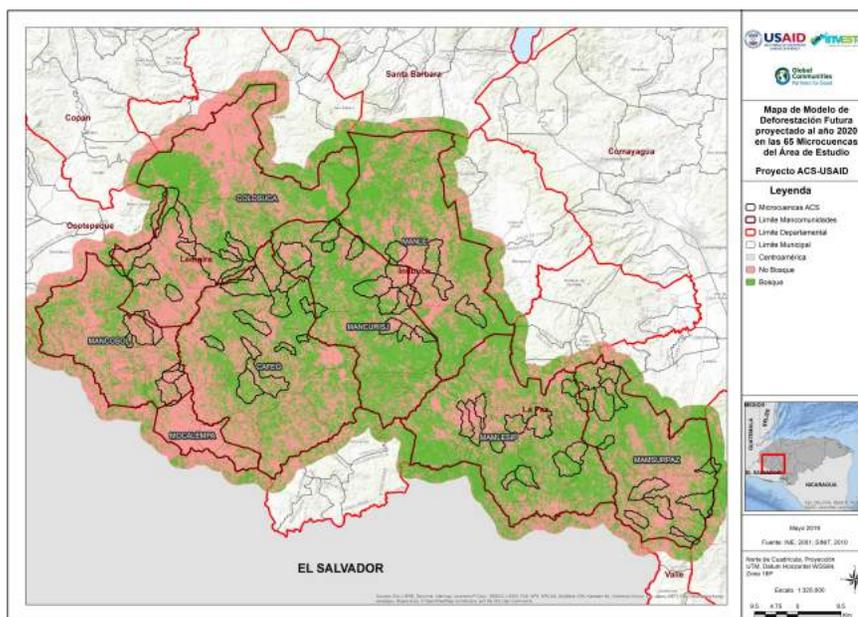


Figura 12: Proyección de Deforestación al 2020.

Según los valores obtenidos, para el 2020, se tendrá una cobertura de bosque, dentro de las 65 microcuencas, de 50,140 hectáreas (Tabla 11), lo que representa un 47 % del total del área de todas las microcuencas, por lo que la tendencia indica que se tendrá una mayor proporción de tierras sin bosque dentro de las mismas, lo cual es coincidente con la tendencia observada en el análisis del período 2010 - 2017.

Tabla 11: Cobertura boscosa al año 2020 según modelo de deforestación

Código	Descripción	Área (ha)	Porcentaje
1	No bosque	56,288.34	52.89
2	Bosque	50,140.80	47.11

5 Conclusiones

- Después de analizada la información se puede observar que el área de estudio se encuentra bajo una severa presión, principalmente por el avance y el desarrollo de actividades agropecuarias dentro de las microcuencas, siendo la categoría pastos y cultivos la predominante en el área de estudio durante los tres años analizados, 23 % para el 2010, 28 % para el 2015 y 33 % para el 2017. Además, se observa claramente que la tendencia de la frontera agrícola es al alza, en deterioro de la cobertura boscosa en la zona. Se obtuvo que para el 2010 la cobertura de bosque en la zona de las 65 microcuencas era de 58 %, para el 2015 se redujo a un 54 % y para el 2017 fue de 50 %, lo que acrecienta la necesidad de realizar una intervención en la zona para revertir esta tendencia de deforestación, debiendo los programas estar orientados a la protección y recuperación de áreas degradadas. Dicha tendencia es validada por el Modelo de deforestación proyectado al 2020, el cual muestra que la cobertura de bosque para ese año será de un 47 %.
- Originalmente se esperaba discriminar entre café bajo sombra y café sin sombra, sin embargo, debido a las limitantes del sensor para distinguir entre estos dos tipos de clases, las coberturas de café bajo sombra fueron clasificados como bosque de pino o latifoliado, según el tipo de sombra que se utilice en el cultivo; por lo que esto debe tomarse en cuenta al momento de analizar la información presentada, ya que si bien este tipo de coberturas no inciden en la estimación de la pérdida de bosque, si inciden en los procesos de degradación del suelo.
- Cabe mencionar que la tasa de deforestación para el periodo proyectado de 5 años (2015-2020) se ve disminuida en más de un 1 % en relación al periodo de comparación 2010-2015, por lo que se recomienda analizar las acciones que se han realizado in situ para disminuir esta tendencia, y sistematizar esas experiencias para la sostenibilidad, preservación y recuperación de la cobertura boscosa dentro del área de estudio.
- En cuanto a las áreas propensas a incendios forestales, se muestra que las microcuencas localizadas dentro de las Mancomunidades de MAMSURPAZ y MANCOSOL son las que presentan mayor probabilidad de ser afectadas por estos fenómenos, siendo la cobertura de pino denso la de mayor vulnerabilidad ante la ocurrencia de incendios forestales en la zona de estudio, acrecentando la presión que existe sobre el recurso bosque dentro del área de estudio.

6 Referencias

- Bouziani, M., Goïta, K., y He, D. C. (2010). Automatic Change Detection of Buildings in Urban Environment from Very High Spatial Resolution Images Using Existing Geodatabase and Prior Knowledge. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1):143–153.
- Congalton, R. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37(1):35–46. [https://doi.org/10.1016/0034-4257\(91\)90048-B](https://doi.org/10.1016/0034-4257(91)90048-B).
- Erbek, F. S., Özkan, C., y Taberner, M. (2004). Comparison of maximum likelihood classification method with supervised artificial neural network algorithms for land use activities. *International Journal of Remote Sensing*, 25(9):1733–1748.
- Jensen, J. R. (2005). *Introductory Digital Image Processing: A Remote Sensing Perspective*. 3era. edición. Toronto: Prentice Hall.

- Kaufman, Y. J., Justice, C. O., Flynn, L. P., Kendall, J. D., Prins, E. M., Giglio, L., y Setzer, A. W. (1998). Potential global fire monitoring from eos-modis. *Journal of Geophysical Research: Atmospheres*, 103(D24):32215–32238. <https://doi.org/10.1029/98JD01644>.
- Lillesand, T. M., Chipman, J. W., Nagel, D. E., Reese, H. M., Bobo, M. R., y Goldmann, R. A. (1998). *Upper Midwest Gap Analysis Program Image Processing Protocol*. Onalaska, Wisconsin: U.S. Geological Survey.
- Lu, D. y Weng, Q. (2007). A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, 28(5):823–870. <https://doi.org/10.1080/01431160600746456>.
- Lunetta, R. S. y Balogh, M. (1999). Application of multi-temporal landsat 5 TM imagery for wetland identification. *Photogrammetric Engineering and Remote Sensing*, 65(11):1303–1310.
- Nackaerts, K., Vaesen, K., Muys, B., y Coppin, P. (2006). Comparative performance of a modified change vector analysis in forest change detection. *International Journal of Remote Sensing*, 26(5):839–852. <https://doi.org/10.1080/0143116032000160462>.
- Oettera, D., Cohenb, W. B., Berterretchea, M., Maierspergera, T. K., y Kennedy, R. (2001). Land cover mapping in an agricultural setting using multiseasonal thematic mapper data. *Remote Sensing of Environment*, 76(2):139–155. [https://doi.org/10.1016/S0034--4257\(00\)00202--9](https://doi.org/10.1016/S0034--4257(00)00202--9).
- Pontius Jr., G., Cornell, J., y Hall, C. (2001). Modeling the spatial pattern of land-use change with GEO-MOD2: application and validation for Costa Rica. *Ecosystems and Environment*, 85:191–203. [https://doi.org/10.1016/S0167--8809\(01\)00183--9](https://doi.org/10.1016/S0167--8809(01)00183--9).
- Wolter, P. T., Mladenoff, D. J., Host, G. E., y Crow, T. R. (1995). Improved Forest Classification in the Northern Lake States Using Multi-Temporal Landsat Image. *Photogrammetric Engineering and Remote Sensing*, 61:1129–1143.
- Yuan, F., Sawaya, K. E., Loeffelholz, B. C., y Bauer, M. E. (2005). Land cover classification and change analysis of the twin cities (minnesota) metropolitan area by multitemporal landsat remote sensing. *Remote Sensing of Environment*, 98(2-3):317–328. <https://doi.org/10.1016/j.rse.2005.08.006>.