



UNIVERSIDAD NACIONAL AUTÓNOMA DE MEXICO

PROGRAMA DE MAESTRÍA Y DOCTORADO EN GEOGRAFÍA

FACULTAD DE FILOSOFÍA Y LETRAS

CENTRO DE INVESTIGACIONES EN GEOGRAFÍA AMBIENTAL

**“MODELACIÓN DE ATRIBUTOS ESTRUCTURALES DE SELVA TROPICAL
CADUCIFOLIA BASADO EN DATOS DE MÚLTIPLES SENSORES PARA EL
MAPEO DE DEGRADACIÓN FORESTAL”**

TESIS

QUE PARA OPTAR POR EL GRADO DE:
MAESTRA EN GEOGRAFÍA

PRESENTA:

DIANA LAURA JIMÉNEZ RODRÍGUEZ

DIRECTORA DE TESIS

DRA. YAN GAO

CENTRO DE INVESTIGACIONES EN GEOGRAFÍA AMBIENTAL

MORELIA, MICHOACÁN NOVIEMBRE DE 2020.



Universidad Nacional
Autónoma de México



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

Índice	
Agradecimientos	5
Resumen	6
Abstract	7
Capítulo I. Introducción	8
1.2 Selva Tropical Caducifolia	9
1.3 Antecedentes	11
1.3.1 Aproximaciones en el estudio de la vegetación con técnicas de percepción remota	11
1.3.2 Estudios de degradación forestal en bosques tropicales con percepción remota.....	16
1.4 Objetivos de la investigación e hipótesis	21
Capítulo II. Área de estudio	22
2.1. Características biofísicas	22
2.2 Características socioeconómicas y territoriales	24
2.3 Población	25
2.4 Manejo forestal	25
Capítulo III. Materiales y métodos	27
3.1 Datos de campo	27
3.1.1 Selección de sitios de muestreo	27
3.1.2 Métricas de vegetación	28
3.1.3 Cálculo de biomasa aérea sobre el suelo	28
3.1.4. Tratamiento de datos	28
3.1.5 Correlación de atributos estructurales de la vegetación	29
3.2 Datos de percepción remota	30
3.2.1 Datos de imágenes ópticas.....	30
3.2.2 Datos de imágenes SAR.....	31
3.3 Preprocesamiento y procesamiento de datos espectrales	32
3.3.1 Imágenes ópticas.....	32
3.3.2 Imágenes de radar.....	33
3.4 Métodos	34
3.4.1 Cálculo de variables espectrales	35
3.4.2 Índices de vegetación	35
3.4.3 Cálculo de texturas	37
3.4.4 Selección de variables espectrales.....	40

3.4.5 Generación de modelos.....	41
3.4.6 Validación de predicciones	42
3.4.7 Mapeo de selva con degradación	42
Capítulo IV. Resultados	43
4.1 Caracterización estructural de la selva.....	43
4.2. Modelación de variables de selva con datos de percepción remota....	46
4.2.1 Insumo de modelos.....	46
4.2.2 Índices de vegetación y de disturbio	46
4.2.3 Métricas texturales.....	52
4.3. Selección de variables espectrales	55
4.4. Modelación de variables de bosque con percepción remota.....	56
4.4.1 Mapeo de atributos de la vegetación	58
4.4.2. Mapeo de atributos del bosque degradado	61
4.4.3. Mapeo de atributos del bosque conservado	68
4.4.5. Identificación de bosques con degradación severa	70
Capítulo V. Discusión y conclusiones.....	74
5.1 Atributos estructurales como indicadores de degradación forestal	74
5.2 Detección de degradación forestal a partir de percepción remota y datos de campo.....	76
5.3 La degradación forestal en la selva caducifolia de Ayuquila.....	83
5.4 Consideraciones finales.....	84
5.5 Conclusiones.....	86
Referencias	89

Índice de figuras

Figura 1.....	24
Figura 2.....	35
Figura 3.....	47
Figura 4.....	48
Figura 5.....	49
Figura 6.....	50
Figura 7.....	51
Figura 8.....	53
Figura 9.....	54
Figura 10.....	58
Figura 11.....	60
Figura 12.....	61
Figura 13.....	64
Figura 14.....	65
Figura 15.....	66
Figura 16.....	67
Figura 17.....	68
Figura 18.....	69
Figura 19.....	71
Figura 20.....	72
Figura 21.....	73

Índice de tablas

Tabla 1.....	29
Tabla 2.....	32
Tabla 3.....	39
Tabla 4.....	43
Tabla 5.....	55
Tabla 6.....	57

Ecuaciones

Ecuación 1. Biomasa viva aérea sobre el suelo.....	29
Ecuación 2. Coeficiente de correlación tau de Kendall.....	30
Ecuación 3. Índice de Vegetación por Diferencia Normalizada.....	37
Ecuación 4. Índice de Vegetación Ajustado al Suelo.....	37
Ecuación 5. Índice de Disturbio.....	38
Ecuación 6. Factor de Inflación de Varianza.....	42
Ecuación 7. Regresión lineal 1.....	42
Ecuación 8. Regresión lineal 2.....	42
Ecuación 9. Regresión lineal 3.....	42
Ecuación 10. Error Cuadrático Medio.....	43

Agradecimientos

Agradezco el apoyo económico brindado por el Consejo Nacional de Ciencia y Tecnología durante mis estudios de maestría. También por el financiamiento del proyecto de ciencia básica “*Análisis del patrón espacial de la degradación en selvas y bosques de México con percepción remota en múltiples escalas en el tiempo y espacio*” (CONACYT SEP-285349) para la realización de trabajos de campo y presentaciones en congresos.

También agradezco al posgrado en Geografía por ofrecerme la oportunidad de continuar mis estudios y permitirme crecer como persona y en el aspecto académico. Al Centro de Investigaciones en Geografía Ambiental por ofrecerme un espacio de trabajo con todo lo necesario para culminar este proyecto. A los servicios administrativos y de docencia por su disposición para orientarme y resolver mis dudas a lo largo de este proceso.

Agradezco a la Dra. Yan Gao por todo su apoyo, por ser mi guía en el desarrollo de ese trabajo. Gracias por ser una excelente tutora y motivarme a seguir trabajando en lo que me gusta.

A mi comité sinodal, Dra. Margaret Skutsch, Dra. Michelle Farfán, Dr. Miguel Salinas y Dr. Diego Pérez por sus valiosos comentarios y apoyo para que el trabajo culmine de la mejor forma. A Jonathan Solórzano por involucrarse tanto en este proyecto, colaborar y aportar comentarios que ayudaron bastante a consolidar el trabajo.

Agradezco a mi familia, mi papá Enrique y mi mamá Guillermina quienes me han seguido apoyando y motivando en todas mis decisiones y pasos, sin ustedes no sería nada de lo que soy ahora.

A mi familia moreliana, conformada por un grupo de mujeres solidarias y fuertes con quienes puedo contar. Gracias por continuar creciendo juntas.

Resumen

La degradación forestal tiene impactos negativos a largo plazo, desde el aumento en las emisiones de gases efecto invernadero (GEI), disminución de hábitats para especies nativas, hasta la pérdida de recursos naturales aprovechables para las comunidades humanas. La degradación hace referencia a pequeños cambios graduales que suceden debajo del dosel del bosque, además que su definición conlleva una alta complejidad, que implica incluir elementos tanto físicos como humanos que la componen. Sin embargo, uno de los principales problemas en este tema ha sido llegar a un consenso de su definición, y por lo tanto la identificación de parámetros para su cuantificación. El uso de herramientas de percepción remota ha sido ampliamente usado para detectar degradación forestal, sin embargo, existen limitaciones en la capacidad de los sensores para detectar aquellos cambios que suceden en pequeñas áreas o debajo del dosel.

El objetivo central del trabajo es evaluar el potencial de diferentes sensores de percepción remota con diferente resolución espacial (TM Landsat-8, MSI Sentinel-2 y radar Sentinel-1) para la detección de atributos estructurales medidos en campo asociados a degradación forestal. El estudio se realizó en la cuenca del río Ayuquila en Jalisco, en vegetación de selva tropical caducifolia (STC). Para lo cual, primero se realizaron mediciones en campo de atributos estructurales de la vegetación en 41 parcelas circulares de 500 m², 17 sitios de bosque degradado y 24 de bosque conservado, donde se midieron: 1) cobertura del dosel, 2) altura de los árboles, 3) número de ramas, 4) densidad de árboles, 5) diámetro a la altura del pecho, y a partir del área basal se calculó 6) biomasa viva sobre el suelo. Por otro lado, se calcularon variables espectrales para las temporadas de lluvias y secas: Índice de Disturbio, Índice de Vegetación por Diferencia Normalizado, Índice de Vegetación Ajustada al Suelo y seis métricas texturales de dos satélites ópticos y uno de radar. Finalmente se generaron modelos lineales múltiples que asociaron los atributos de la vegetación con los índices y métricas espectrales de los diferentes satélites.

Se encontró que, es posible asociar atributos de bosques degradados como cobertura del dosel, cantidad de biomasa y densidad arbórea ($R^2 > 0.6$) con índices de vegetación y textura de diferentes sensores tanto ópticos como de radar. Fue posible modelar la cobertura del dosel para tipos de bosques degradados y conservados ($R^2 = 0.68$). Con la espacialización de los modelos fue posible identificar las zonas de selva caducifolia que potencialmente se encuentran en un estado de degradación, basado en información de cobertura y biomasa. Este primer acercamiento resulta una aproximación importante para la identificación de bosques degradados, ya que en STC representa un reto su detección debido la estacionalidad. Por otra parte, lograr una detección confiable de estas métricas podría dar paso a la cuantificación de bosques degradados, así como la estimación de emisiones GEI para este tipo de bosque a través de herramientas de percepción remota de libre acceso.

Abstract

Forest degradation has long-term negative impacts, from increased greenhouse gas (GHG) emissions, a decrease habitat for native species, to the loss of natural resources that can be leverage by human communities. Degradation refers to small, gradual changes that occur under the forest canopy, and its definition is highly complex, involving both physical and human elements. However, one of the main problems in this topic has been reaching a consensus on its definition, and therefore the identification of parameters for its quantification. The use of remote sensing tools has been widely used to detect forest degradation, however, there are limitations in the ability of sensors to detect those changes that occur in small areas or under the canopy.

The main objective of this work is to evaluate the potential of different remote sensing sensors with different spatial resolution (TM Landsat-8, MSI Sentinel-2 and Sentinel-1 radar) for the detection of field measured structural attributes associated to forest degradation. The study was conducted in the Ayuquila River Basin in Jalisco, in a tropical deciduous forest (TDF) vegetation. First, field measurements of structural attributes of vegetation were made in 41 circular plots of 500 m², 17 sites of degraded forest and 24 sites of conserved forest, where the following attributes were measured: 1) canopy cover, 2) tree height, 3) number of branches, 4) tree density, 5) diameter at breast height, and from the basal area, 6) live biomass on the ground. On the other hand, spectral variables were calculated for the rainy and dry seasons: Disturbance Index, Normalized Difference Vegetation Index, Soil-Adjusted Vegetation Index and six textural metrics from two optical and one radar satellite. Finally, multiple linear models were generated that associated the vegetation attributes with the spectral indexes and metrics of the different satellites.

It was found that it is possible to associate attributes of degraded forests such as canopy cover, biomass amount and tree density ($R^2 > 0.6$) with vegetation indices and texture from different optical and radar sensors. It was possible to model the canopy cover for degraded and conserved forest types ($R^2 = 0.68$). With the spatialization of the models it was possible to identify the areas of tropical deciduous forest that are potentially in a state of degradation, based on coverage and biomass information. This approach is an important approximation for the identification of degraded forests, since in TDF represents a challenge to detect them due to seasonality. On the other hand, achieving a reliable detection of these metrics could give way to the quantification of degraded forests, as well as the estimation of greenhouse gases emissions for this type of forest through open access remote sensing tools.

Capítulo I. Introducción

1.1. Introducción

Los bosques en el mundo han disminuido en promedio 7.84 millones de hectáreas de los años 2010 a 2020 (FAO, 2020), entre las principales causas de esta pérdida está la degradación forestal. En contraste, aproximadamente el 50% de los almacenes de carbono terrestre en el mundo se encuentra en los bosques y suelos en forma de biomasa viva y muerta. Conservar los almacenes de carbono de los bosques es una de las principales medidas para mitigar las emisiones de gases efecto invernadero (GEI) a la atmósfera, una de las principales causas del cambio climático global.

La degradación forestal hace referencia a cambios en la estructura de los bosques a través de la apertura de claros que causan la pérdida gradual de biomasa debajo del dosel y generalmente son reconocibles *in situ*, a diferencia de la deforestación en donde la cubierta de bosque es removida para establecer otro tipo de cubierta y uso (Kissinger et al., 2012; Panta et al., 2008). La degradación puede involucrar procesos de alteración en la estructura horizontal o vertical, por lo tanto, alteran la calidad de las interacciones bióticas que suceden al interior de los ecosistemas y alteran la estructura espacial de los paisajes tal como la fragmentación (Panta et al., 2008). La degradación forestal también afecta la funcionalidad de los bosques, dentro de algunas funciones importantes se encuentran una gran cantidad de servicios ecosistémicos tal como la regulación del clima, producción de biomasa, polinización y en los bosques se encuentran los refugios y hábitats de especies de flora y fauna (Forrester & Bauhus, 2016). Por lo tanto, se puede definir a la degradación forestal como aquella pérdida gradual de almacenes de carbono causada directa o indirectamente por las actividades humanas que persisten durante un periodo largo de tiempo (IPCC, 2003), sin que esta pérdida llegue a ser deforestación.

La degradación forestal también se asocia a la pérdida de almacenes de carbono, una de las principales consecuencias es la alteración del balance del clima en el mundo, ya que, en general los bosques tienen la capacidad de acumular en su biomasa una cantidad significativa de carbono. Es a partir de esto, que se ha hecho un gran esfuerzo por estimar la pérdida de biomasa de los bosques, causada por la deforestación y la degradación. Si bien en México los cambios de cubiertas por deforestación son reportados periódicamente en informes hechos por la Comisión Nacional para el Conocimiento y Uso de la Biodiversidad (CONABIO) e instituciones internacionales p. e. Food and Agriculture Organization (FAO), los cambios por degradación no se cuantifican en reportes nacionales (Chapela, 2012; FAO, 2011; Velázquez et al., 2002). Esto probablemente se deba a la falta de consenso tanto en la definición del problema como en el método de estimación de degradación, así como las múltiples limitaciones que tienen los métodos desarrollados. Por lo tanto, la aportación de técnicas para el monitoreo y detección de degradación en el país resulta valioso para la cuantificación de pérdida de carbono y biomasa resultante de la degradación forestal.

1.2. *Selva Tropical Caducifolia*

Las selvas tropicales caducifolias representan el 7% de la superficie boscosa en todo el mundo, se distribuye entre los 20° de latitud norte y 20° de latitud sur, en México se desarrollan por debajo de los 1200 msnm (Bezaury, 2010). En el mundo estos bosques representan cerca del 42% de los bosques tropicales (Holdridge, 1967) y en México cubre aproximadamente el 11.26% de la superficie del país (Challenger & Soberón, 2008). Su principal característica es que tienen una marcada estacionalidad de 5 a 8 meses de temporada seca, durante la cual la mayoría de los árboles pierden entre el 50 y 100% de sus hojas (Bezaury, 2010; Challenger & Soberón, 2008).

Estos ecosistemas tienen una escasa representación en los esquemas de protección a nivel internacional (Barreda-Bautista et al., 2011). En el caso de México, históricamente ha sido destinado para el desarrollo de actividades productivas a partir de la política de ocupación de “tierras ociosas” en 1930 y

posteriormente la repartición agraria en 1970 cuando la deforestación se incrementó (CONABIO, 2020; González Navarro, 1977), a partir de esto vemos que actualmente la mayor parte de selvas en México son de propiedad social (propiedad ejidal y comunal). Algunos esquemas de protección que pueden ser mencionados para la conservación y uso sustentable de sus recursos son el programa de Conservación de la Biodiversidad por Comunidades e Indígenas, el Proyecto de Conservación y Manejo Sustentable de Recursos Forestales en México, el Corredor Biológico Mesoamericano (Ceballos et al., 2010). Actualmente hay 4 Reservas de la Biósfera y 4 Parques Nacionales que protegen parte de este tipo de ecosistema y 36 sitios prioritarios para la conservación de selva tropical caducifolia en todo el país (CONABIO, 2020). No obstante, se encontró que la selva tropical caducifolia ha sido degradada o deforestada un 73% por la expansión de campos agrícolas y pastoriles (Trejo & Dirzo, 2000).

Algunas estimaciones de los almacenes de carbono en los paisajes de estos bosques indica que pueden acumular entre 46.7 a 571 Mg/ha (Jaramillo et al., 2011). Sin embargo, se ha indicado que los principales depósitos de carbono se encuentran en el suelo más que en la biomasa vegetal viva sobre el suelo (Lai, 2004). La pérdida de bosque provoca una considerable reducción en los almacenes de carbono. Esto a su vez tiene consecuencias tales como el aumento en las emisiones derivadas de la combustión, descomposición de biomasa vegetal y pérdida de carbono orgánico del suelo. Ésta pérdida tiene implicaciones en el cambio de temperatura regional y local, debido al aumento de albedo y la evapotranspiración del suelo, que significa aumento de calor y pérdida de humedad (Barreda-Bautista et al., 2011; IPCC, 2019). Las consecuencias son acumulativas y van escalando con el tiempo, el incremento de intensidad y frecuencia de fenómenos naturales han sido asociados al cambio climático, p. e. temperaturas extremas, sequías, inundaciones, enfermedades, incendios forestales, ciclones tropicales o plagas (Colin Prentice et al., 1993; Sturrock et al., 2011). Estos fenómenos naturales, también pueden ser causantes de degradación forestal cuando aumentan de intensidad y frecuencia en el tiempo.

Los estudios que analizan la pérdida de cubierta forestal a través de métodos de percepción remota aplicados a este tipo de bosque han sido ampliamente usados (Burgos & Maass, 2004; Southworth, 2004; Galicia et al., 2008), sin embargo, ha sido un gran reto estimar cambios precisos, ya que la propia naturaleza del bosque hace difícil una detección correcta. Una parte debido a su senescencia, que, durante la temporada de sequía cuando la mayoría de los árboles pierde sus hojas, las clasificaciones de tipos de cubierta está sujeta a constantes errores de confusión debido a su semejanza espectral p. e. selva-pastizal o selva- matorral. Por otra parte, durante la temporada húmeda, la cubierta de nubes limita la disponibilidad de imágenes.

La degradación forestal ha sido monitoreada a través de diversos métodos y variables, tales como cambios la densidad del dosel, cambio en la densidad de árboles, riqueza de especies de flora y fauna, fragmentación del paisaje, cambio en el volumen de biomasa (I. D. Thompson et al., 2013). Los cambios en la biomasa provocados por la degradación pueden ser detectados a distintas escalas espaciales y temporales a través de inventarios forestales y sensores remotos (Clark, 2017; Halperin et al., 2016; Quintano et al., 2018; Romero-sanchez, 2017; Sharma et al., 2017). Resulta importante entender los diversos enfoques que se han aplicado a los estudios de degradación forestal para reconocer los alcances y limitaciones de los trabajos previos y delimitar este estudio.

1.3 Antecedentes

1.3.1 Aproximaciones en el estudio de la vegetación con técnicas de percepción remota

El abordaje de la degradación forestal tiene diversas visiones, dependiendo el área y enfoque de los estudios. Las áreas del conocimiento que han estudiado las alteraciones de origen antrópico o natural en los bosques han sido desde el enfoque biológico y geográfico. Cada abordaje ha profundizado, teorizado y entendido la

degradación forestal a partir de diferentes elementos que conforman los bosques, han caracterizado las alteraciones y han evaluado sus implicaciones a diferentes escalas. En este trabajo, nos atañen los métodos que se han desarrollado a través de la percepción remota enfocado a la detección de vegetación y degradación forestal, lo que se explicarán algunas de las aproximaciones más comunes, el tipo de datos usados y atributos de vegetación analizados.

El uso de imágenes satelitales para el monitoreo de la tierra tienen grandes ventajas, desde la capacidad de detectar cambios en grandes áreas de superficie, comparado con métodos tradicionales de campo, hasta el monitoreo de la superficie terrestre de forma periódica. Desde la disponibilidad de imágenes satelitales Landsat desde los años 70 es posible hacer una detección continua en el tiempo. Existen diferentes tipos de sensores disponibles. Estos sensores se pueden clasificar en dos grandes grupos, los sensores activos y pasivos, principalmente por sus diferencias en resoluciones espaciales, radiométricas y espectrales. Los sensores activos emiten su propia energía y luego es recibida la cantidad de energía reflejada por la superficie, la cual puede variar dependiendo las características físicas de los objetos (p. e. radar, LiDAR). Los sensores pasivos capturan la cantidad de energía de una fuente externa (energía solar) reflejada o emitida por la superficie de la tierra, también son llamados sensores ópticos (p. e. Landsat-, Sentinel-2, MODIS, ASTER, etc.). Estos sensores se encuentran a cargo de diferentes agencias espaciales en el mundo, como la NASA de Estados Unidos, ESA de la Unión Europea, JAXA de Japón, entre otros. Dependiendo de los objetivos de cada misión, las imágenes capturadas por los satélites de cada agencia pueden obtenerse de forma gratuita, puede solicitarse a la agencia o puede haber un costo para su obtención.

Se han desarrollado diversas aproximaciones al estudio de la vegetación a través de sensores remotos. En estas metodologías prueban la capacidad de diferentes sensores para medir propiedades de la vegetación, por ejemplo, los atributos estructurales han sido frecuentemente estudiados, ya que la estructura puede indicar diversas propiedades de los ecosistemas. Por lo tanto, a través de modelación estadística se han asociado mediciones de referencia con variables

espectrales. Imhoff (1995) estudia el efecto que tiene la señal de retrodispersión del satélite AIRSAR en bandas C- L- y P- en la variación estructural de la vegetación considerando la cantidad de biomasa como una constante. Los autores midieron el efecto de la estructura del dosel sobre la señal capturada por el sensor de radar de AIRSAR, caracterizado como el tamaño y densidad de ramas, troncos y hojas, para lo cual se identificaron sitios con cantidades similares de biomasa, pero con diferentes características estructurales. Estos autores encontraron una respuesta en la variación de estructura del dosel para la polarización VV, ya que ésta tiene un efecto exagerado de la estructura, en especial en atributos asociados a estructura del dosel.

A través de sensores ópticos se han estudiado propiedades de la vegetación asociada a contenido de clorofila, cobertura, biomasa o fenología entre otras, así como detección de impactos en la vegetación por incendios, huracanes, o diferentes tipos de actividades antrópicas. Por ejemplo, Korhonen et al. (2011) usó imágenes de Landsat 8 y Sentinel-2^a para identificar cobertura del dosel (CC), cobertura del dosel efectiva (ECC) e índice de área foliar (LAI) con diferentes índices espectrales a través de modelos aditivos generalizados. Los autores demostraron que las imágenes de Sentinel-2 tuvieron una ligera mejor precisión, debido a la resolución espectral en la parte del infrarrojo cercano. El uso de modelación estadística es muy común en la comparación de datos de referencia con información espectral, son métodos eficientes y el uso de coeficientes hace las investigaciones comparables entre sí. Por otro lado, métodos de análisis de series temporales también son ampliamente usados, como el uso de imágenes Landsat para describir la sucesión natural de la vegetación. Caughlin et al. (2020) mostraron un marco metodológico para analizar 15 años de imágenes, usando la información del índice por diferencia normalizado (NDVI) como indicador de cambios en la estructura de la vegetación. Encontrando que, las imágenes Landsat-8 y Sentinel-2 lograron capturar los cambios a grandes rasgos en la revegetación, sin embargo, el uso de imágenes de mediana resolución como Landsat, hace que la detección de cambios más detallada sea más difícil lograr (Caughlin et al., 2020).

En particular, en el abordaje de la degradación forestal, existe una rama de estudios enfocados en la medición de la pérdida de biomasa viva sobre el suelo y de almacenes de carbono. Alguno de los principales factores asociados a la degradación de los bosques, es la alteración de la masa forestal, ya sea por actividades de tala, apertura de claros para la introducción de pastos, o a causa del forrajeo por ganado (Thompson et al., 2013). Este enfoque ha ido en aumento a raíz del programa creado por la Convención Marco de las Naciones Unidas sobre el Cambio Climático, posteriormente lo retoma la Unión Internacional para la Conservación de la Naturaleza (UICN), “Reducción de Emisiones causadas por la Deforestación y la Degradación de los Bosques” (REDD+) que, en su esfuerzo por revertir las emisiones de carbono causadas por la deforestación y degradación, han implementado programas de pago por almacenes de carbono en países en vías de desarrollo. Sin embargo, parte de la metodología propuesta por la UICN se enfoca en identificar la cantidad de carbono almacenado y perdido por la deforestación y degradación. Por lo tanto, se han propuesto una amplia gama de metodologías para cuantificar los almacenes de carbono en los bosques (<https://www.iucn.org/es>). Las metodologías propuestas se enfocan en el uso de herramientas de percepción remota, ya que estas brindan información a escalas espaciales regionales, nacionales y hasta mundiales (Asner, 2009; Birdsey et al., 2013; Edwards et al., 2010). Lo cual tiene ventajas en la operatividad para evaluar la eficacia de los programas y proyectos desarrollados en diversos países, para distintos tipos de bosque y condiciones ambientales.

El Panel Intergubernamental del Cambio Climático (IPCC) también se enfoca en el estudio de la degradación de la tierra (*land degradation*), el concepto contempla diversos elementos de la superficie terrestre, desde los bosques (degradación forestal), suelo productivo, ciudades, costas, etc. Para el IPCC, se considera que, la degradación se define como un cambio negativo en las condiciones de la tierra, causadas por procesos humanos directos o indirectos incluyendo el cambio climático antropogénico, resultando en la reducción a largo plazo o la pérdida de al menos uno de los siguientes aspectos: productividad biológica, integridad ecológica o valor para los humanos (IPCC, 2019).

Entre las variables predictoras de degradación forestal que se han utilizado se encuentran principalmente algunos atributos estructurales de la vegetación, la biomasa viva sobre el suelo ha sido usada para la estimación en los almacenes de carbono, altura de los árboles o área basal, apertura del dosel (Chaplin-Kramer et al., 2015; Rappaport et al., 2018; Wekesa et al., 2019). La estructura de la vegetación es entendida como la organización espacial de los diferentes tamaños de árboles, altura, cantidad de ramas primarias y secundarias, niveles de estratos de vegetación (p. e. herbáceas, arbustos, árboles) o la cubierta del dosel entre otras características. Estos atributos de la vegetación pueden estar determinados por diferentes condiciones, ya sea por la elevación sobre el nivel del mar, características del terreno como la topografía, las características del suelo (profundidad, tipo, humedad) o la disponibilidad de nutrientes para las plantas (Lieberman et al., 1996). Sin embargo, en sitios que han sido perturbados por las actividades humanas, también pueden indicar niveles de disturbio (McElhinny et al., 2005). El asociar datos de campo sobre estructura y comparar con diferentes datos derivados de la percepción remota, representa una posibilidad de mapear zonas degradadas a grandes escalas (Poorter et al., 2015).

Diversos estudios han mostrado que la investigación de la vegetación a través de sensores remotos juega un rol importante en el monitoreo de recursos a gran escala, a partir de esto se considera que deben seguirse explorando las herramientas y los datos que se ofrecen, para conocer tanto los alcances y limitaciones para cada caso. Por lo tanto, entendemos la importancia de evaluar a los bosques en términos de degradación a partir de ciertos atributos que serán los parteaguas para el entendimiento de los procesos que suceden al interior del paisaje. Para ello, en este trabajo se quiere abordar la degradación forestal a través de diferentes atributos estructurales de la vegetación, los cuales pueden indicar distintos niveles de degradación en sitios de selva tropical caducifolia.

1.3.2 Estudios de degradación forestal en bosques tropicales con percepción remota

Los estudios enfocados en el monitoreo de selvas tropicales caducifolias a través de métodos de percepción remota se han enfocado en ciertas áreas de investigación: detección de cambios o deforestación (Wasseige & Defourny, 2004; Fischer & Lindenmayer, 2007; Trejo & Dirzo, 2000), identificación de etapas sucesionales (Castro et al., 2003; Caughlin et al., 2020; Gallardo-Cruz et al., 2012; Kuplich et al., 2005), estimación de métricas de la vegetación tales como estructura y estimación de almacenes de carbono a través de imágenes satelitales ópticas y de radar (Mayes et al., 2017; Meyer et al., 2019; Rappaport et al., 2018), sin embargo, también se han realizado trabajos para el monitoreo de degradación forestal, presentados a continuación.

En el trabajo de Joshi y colaboradores (2015), uno de los primeros trabajos en materia de identificación de degradación con el sensor radar en selva tropical, evaluó no solo la degradación forestal, incluye la deforestación y gradientes sucesionales. A diferencia de las imágenes ópticas, los sensores remotos de microondas logran capturar información de la estructura y biomasa ya que su señal penetra el follaje del dosel (Kellndorfer, 2019), además logra capturar información durante el día y la noche y en presencia de nubes, lo que tiene una ventaja para la obtención de imágenes continuas en el tiempo. Este tipo de sensor se aplica para identificar disturbios en un bosque tropical húmedo del Amazonas peruano. El trabajo presenta un nuevo algoritmo, llamado Índice de Degradación Forestal con Radar (*Radar Forest Degradation Index*), que detecta disturbios forestales a través de la identificación de cambios en la señal de retrodispersión en series de tiempo. Empleando datos de ALOS PALSAR. Se encontró que, el total de áreas degradadas detectadas con radar fue cerca del doble comparado con estudios enfocados en degradación a través de imágenes ópticas.

En este trabajo algunas limitaciones del algoritmo de detección de disturbios fueron los múltiples procesos asociados a la señal de retrodispersión, los autores de este estudio se enfocaron en áreas perturbadas ya conocidas previamente, y los cambios

de señal predominaron en la banda de señal cruzada HV (Joshi et al., 2015). Sin embargo, la señal de retrodispersión tiene baja sensibilidad a las pérdidas de biomasa de baja magnitud debido a una aparente saturación de la señal (Joshi et al., 2015). Por otro lado, la alteración significativa en la estructura de la vegetación logró ser detectada, asociada a procesos como tala selectiva, esto probablemente porque las áreas fueron mayores a 30 metros de resolución. Por lo tanto, el algoritmo demostró ser más sensible a la extensión espacial de los disturbios. Aún es un reto lograr capturar los cambios producidos a pequeña escala y que son casi imperceptibles a través de sensores remotos ópticos, como la extracción de árboles por tala selectiva, la disminución de estratos debajo del dosel o el pisoteo del suelo por pastoreo dentro del bosque. Se espera que esto pueda ser posible con los futuros lanzamientos de los satélites SAOCOM (banda-L) de la Agencia espacial Argentina y BIOMASS (banda P) de la Agencia Espacial Europea.

En Romero-Sánchez & Ponce-Hernández (2017) se propuso un marco metodológico para el monitoreo de degradación forestal para países en desarrollo. Este estudio se realizó en selva tropical caducifolia, en la región de la Península de Yucatán en México. A través de herramientas de percepción remota confiable y de libre acceso como Landsat ETM y TM, imágenes de alta resolución espacial obtenidas de Google Earth, inventarios forestales (CONAFOR) y datos auxiliares (datos meteorológicos obtenidos de CONAGUA e INIFAP). Los índices de vegetación analizados (NDVI) fueron altamente correlacionados con la fracción de radiación fotosintéticamente activa absorbida por el dosel (fPAR). Por lo tanto, la estimación de productividad primaria neta pudo correlacionarse a los bosques degradados. Este trabajo mostró buenos resultados en cuanto al monitoreo de grandes áreas de bosque con bajos costos, ya que los insumos fueron de libre acceso. Y se señala que los resultados pueden ser mejorados empleando imágenes de mayor resolución tanto espacial como espectral, sin embargo, esto implicaría la inversión de costos más altos de tiempo para su procesamiento.

Considerando que en este trabajo se realizará en selva tropical caducifolia (STC), emplear imágenes de percepción remota de tipo óptico de diferentes resoluciones

puede resultar valioso y puede dar buenos resultados, como lo señala Romero-Sánchez & Ponce-Hernández (2017). Además, comparar diferentes fuentes de datos resulta enriquecedor para la estimación de degradación forestal, ya que estos pueden ser complementarios como lo demostró Meyer et al. (2019) al comparar información óptica y de radar, sin embargo, la información de campo resulta valiosa para poder validar los resultados obtenidos de percepción remota. Por lo tanto, hacer una evaluación de la información que se obtiene de diferentes sensores con diferentes resoluciones espaciales y radiométricas es una partida en la identificación de métodos más eficientes en la detección de degradación forestal. La necesidad de distinguir el estatus de los bosques en términos de degradación es importante, ya que a través de esto puede monitorearse los cambios durante el proceso de degradación y por lo tanto, la identificación de áreas prioritarias para emplear acciones correctivas y de prevención (Simula, 2009).

1.3.3 El uso de los sensores Landsat-8, Sentinel-2 y Sentinel-1 en el monitoreo de vegetación

- Landsat-8

Al ser el primer satélite de acceso libre que ha existido, esta fuente de información ha sido ampliamente usado para todo tipo de aplicaciones en estudios enfocados a la superficie terrestre. Para el caso de la degradación forestal, se han utilizado para realizar análisis de series de tiempo, a partir de la identificación de cambios en los patrones de variables espectrales que pueden indicar tipos de disturbios a diferente magnitud (Banskota et al., 2014; DeVries et al., 2015; Souza et al., 2013). También se han desarrollado algoritmos para la detección automatizada de deforestación y degradación a partir de imágenes Landsat, tal como el *Carnegie Landsat Analysis System* (CLASlite) (Asner, 2009) el cual fue inicialmente pensado para trabajar en bosques tropicales, este método combina una serie de variables derivadas de las imágenes satelitales para la obtención de cambios en cobertura.

Una de las principales ventajas del uso de imágenes Landsat es la cantidad de información disponible desde los años 70, cuando fue su primer lanzamiento. Este

sensor ofrece información de mediana resolución desde hace mucho tiempo y con esto hace posible la detección de cambios en escalas de tiempo mayores, comparado con otros satélites de acceso libre. Aunado a esto, el último satélite disponible de Landsat-8, lanzado en el año 2013 ha mejorado la calidad en la resolución espectral y radiométrica, lo que da posibilidad de detectar cambios en la superficie a mejor detalle. Por otro lado, la resolución de las bandas usadas principalmente para el monitoreo de vegetación (banda 4 y 5) tienen una resolución moderada de 30 m, lo que limita la detección de fenómenos que suceden en áreas muy pequeñas (menores a 900 m²). De ahí la necesidad de evaluar el potencial de este sensor, para identificar sus alcances y limitaciones en la detección de degradación forestal.

- Sentinel-2

Sentinel-2 es uno de los satélites más recientes de alta resolución espacial y de acceso libre. Por lo tanto, ha sido aplicado ampliamente para la detección de cambios de cubiertas, al brindar información de mayor detalle (comparado a Landsat). La aplicación de estas imágenes es similar a las de Landsat, siendo un sensor de tipo óptico las capacidades son similares, sin embargo, también se han utilizado ambos satélites para combinar su información y así aumentar el potencial para detectar cambios, siendo que Sentinel-2 tiene mayor resolución temporal (5 días de Sentinel VS.16 días de Landsat), y al tener la capacidad de mejorar la resolución espacial de Landsat (de 30 m a 10 m) a través de la fusión con la banda pancromática. Ambos satélites resultan complementarios para monitorear cambios de cubierta en menor tiempo y mayor precisión (Wang et al., 2017).

Por otro lado, la estimación de almacenes de carbono a través de Sentinel-2 también ha sido de utilidad para comparar con mediciones de campo (Mura et al., 2018). En este estudio se emplearon imágenes de Sentinel-2, de Landsat 8 y RapidEye para comparar la respuesta espectral en la identificación del crecimiento de almacenes de carbono. Este estudio demostró que las bandas de Sentinel-2 infrarroja y borde rojo tuvieron una relación significativa con las mediciones en campo, sin embargo,

la respuesta fue muy cercana a las bandas de Landsat 8, lo cual indica que ambos satélites son altamente confiables para comparar métricas de vegetación.

Sin embargo, estos últimos satélites, a pesar de tener una gran ventaja sobre aquellos que tienen algún costo monetario, las imágenes de tipo óptico aún representan una gran limitante, sobre todo para aquellos sitios que tienen una continua presencia de nubes, o para detallar información que va más allá del dosel. Por lo tanto, es importante evaluar la capacidad de las imágenes de tipo óptico frente a los sensores pasivos, incluso es importante considerar la posibilidad de combinar diferentes tipos de información con el objetivo de maximizar la capacidad que tiene cada sensor para obtener información de diferentes aspectos de la cubierta terrestre, en este caso de la vegetación. Sobre todo, para detallar aquellos fenómenos que resultan complejos de detectar, tal es el caso de la degradación forestal.

- Sentinel-1

Trabajos enfocados en este tema no son tan numerosos en comparación con los que utilizan información óptica. Sin embargo, aquellos que han abordado este problema ha sido a través del análisis de la señal de retrodispersión. Se ha encontrado que, debido a la pérdida de biomasa, existe una caída en la señal, lo cual puede ser un indicador de este fenómeno (Kellndorfer, 2019). En estudios que hacen estimación de biomasa se han encontrado modelos que demuestran buenos resultados para estimarla (Ghosh & Behera, 2018; Sinha et al., 2015; Sinha et al., 2019). Incluso la información obtenida de radar es vista como una complementaria a la de imágenes ópticas. Ya que por una parte, la señal óptica de la vegetación proviene del dosel y el follaje, y por otra, la señal de microondas refleja información de ramas, tallos incluso el suelo, dependiendo la banda que se trabaje (p. e. banda-L) (De Grandi et al., 2015; Reiche et al., 2018; Suman Sinha et al., 2019).

1.4 Objetivos de la investigación e hipótesis

Objetivo general

Estimar la degradación forestal en la selva tropical caducifolia a través de la modelación de atributos estructurales con datos de múltiples sensores y mediciones en campo en la Cuenca de Ayuquila, Jalisco.

Objetivos particulares

1. Caracterizar los atributos estructurales de la vegetación de sitios bajo diferentes condiciones de degradación forestal.
2. Modelar los atributos estructurales de la vegetación a través de sensores satelitales ópticos y de radar.
3. Mapear la degradación de selva tropical caducifolia en la cuenca de Ayuquila.

Hipótesis

La hipótesis del trabajo parte del supuesto que los atributos estructurales de la vegetación medidos en campo pueden ser usados como indicadores de degradación forestal. Sin embargo, se quiere probar que hay atributos estructurales clave que permiten diferenciar entre niveles de degradación del bosque. A partir de ello se espera que haya una fuerte asociación de los atributos estructurales con variables espectrales de sensores remotos, en este caso se probarán tres tipos Sentinel-2, Landsat-8 y Sentinel-1. Identificar las asociaciones de atributos estructurales con variables espectrales, permitiría mapear la degradación en la selva tropical caducifolia.

Capítulo II. Área de estudio

La cuenca del río Ayuquila ha sido seleccionada para llevar a cabo este estudio ya que presenta condiciones tanto físicas como de manejo de los bosques idóneas para los objetivos del estudio. En la cuenca predomina la cubierta de selva tropical caducifolia bajo diferentes condiciones. Áreas de bosques degradados debido a las prácticas agrícolas predominantes de roza-tumba-quema y ganadería extensiva (Borrego & Skutsch, 2014; Salinas-Melgoza et al., 2018). También existen áreas de protección del bosque a través de las figuras “pago por servicios ambientales” y de “Reserva de la Biósfera Manantlán-Cuicatlán”, lo cual nos permite obtener información de sitios de referencia para bosques conservados y compararlos con los bosques degradados. Además, la región participa en el programa internacional Reduciendo Emisiones de la Deforestación y Degradación forestal (REDD+, por sus siglas en inglés) en la categoría de “Áreas de acción temprana” en conjunto con otras cuencas de Jalisco denominadas “cuenas costeras”. Con el objetivo de atender la disminución de la superficie forestal de la región y de la degradación forestal, revertir las tendencias del cambio de uso de suelo forestal, además de contribuir a mejorar las condiciones de vida de sus habitantes (CONAFOR, 2010).

2.1. Características biofísicas

La cuenca del río Ayuquila se localiza en la región administrativa Sierra de Amula del estado de Jalisco (figura 1) y se forma a partir de la unión de las subcuencas Ayuquila, Tuxcacuesco y Armeria, se clasifica como cuenca exorreica, tiene 179.32 km de longitud y tiene una forma oval-oblonga (índice de compacidad 1.78) (Meza Rodríguez, 2006). Dentro de la cuenca se encuentran diez municipios y tiene una extensión aproximada de 4,114 km². Esta área posee una compleja estructura topográfica, en donde los rangos altitudinales varían de los 260 m a los 2500 metros sobre el nivel del mar, el parteaguas más alto es el volcán de Colima al sureste de la cuenca y en frontera con el estado de Colima. El tipo de vegetación varía dependiendo del rango altitudinal, se caracteriza por predominar la selva tropical

caducifolia en las regiones bajas, mientras que en las zonas más altas hay presencia de bosques de pino y pino-encino, así como bosque mesófilo de montaña (Morales-Barquero et al., 2014).

La pendiente promedio en la cuenca alcanza los 16°, por lo tanto se considera que es un terreno escarpado. Por otro lado, la pendiente que predomina en la cuenca va de los 0° a los 7.5°, lo cual representa un 32.6% del área total de la cuenca. En estas planicies se desarrolla principalmente la agricultura de temporal con 467 km² plantados, seguido por la agricultura de riego con 378 km² plantados. La pendiente que va de 7.5° a 16.2° también predomina en la cuenca (20% del área total), en estas secciones se establecen cubiertas de pastizal inducido (195 km²) y áreas de selva tropical caducifolia (295.3 km²), ésta última cubierta, también es predominante hasta las pendientes más escarpadas de 36°.

El tipo de suelo que predomina en la cuenca es Regosol eútrico (1676 km²) y el Feozem háplico (874.7 km²) de acuerdo con la cartografía de INEGI (2014). El primero es un tipo de suelo joven resultado de los depósitos de rocas y arenas que son arrastrados por el agua, estos suelos se encuentran principalmente en las zonas medias y bajas de la cuenca. Los suelos de tipo Regosol están asociados a vegetación de selvas en México, al igual que los de tipo Feozem pero en menor medida. Los suelos Feozem son suelos profundos y ricos en materia orgánica, por lo tanto, aptos para la actividad agrícola, pero son susceptibles a la erosión.

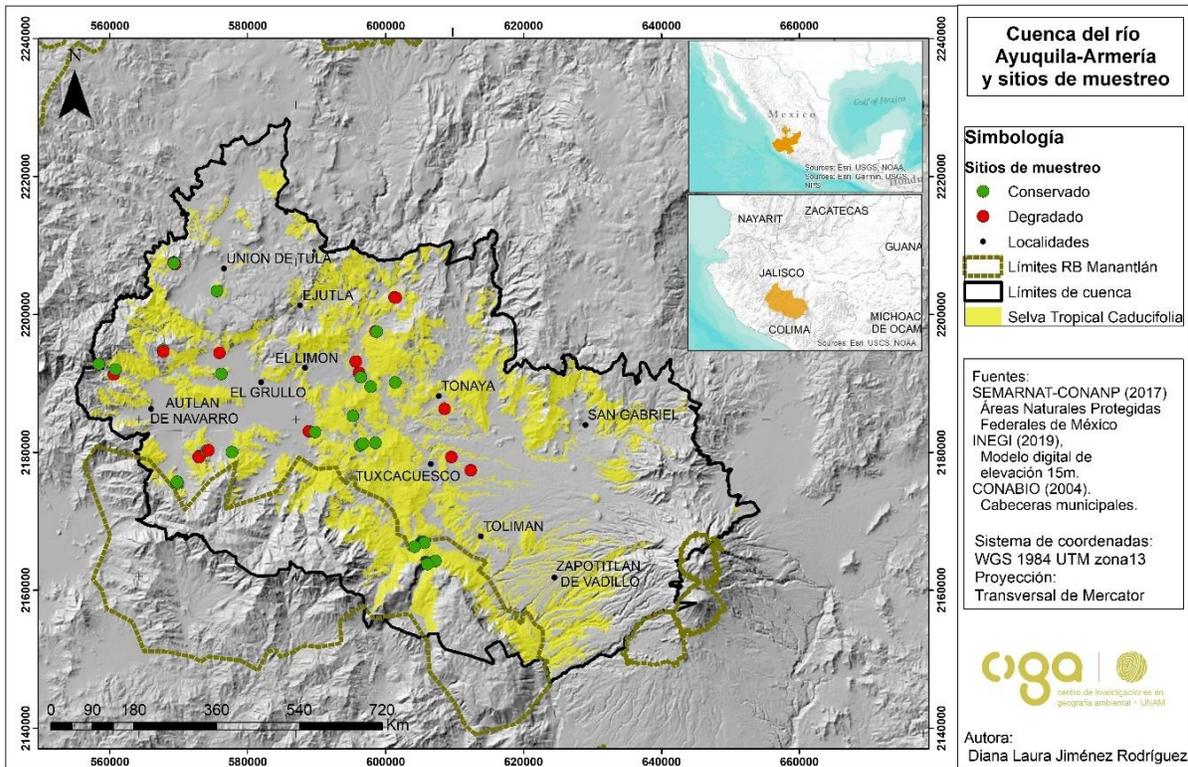


Figura 1. Localización de la cuenca del río Ayuquila Jalisco, extensión de selva tropical caducifolia y sitios de muestreo en campo

2.2 Características socioeconómicas y territoriales

En la cuenca existen 104 ejidos de acuerdo con el Registro Agrario Nacional, por lo tanto, predomina la propiedad de la tierra de tipo ejidal o comunal (1,913 km²) lo cual equivale al 46.5% del total de la cuenca. Del área total de selva (1 259 km²), el 43.9% se encuentra en algún tipo de propiedad social. Los ejidos implementan un sistema de toma de decisiones sobre los bosques y selvas de uso común. Esta forma de manejo se lleva a cabo a través de asambleas con los miembros del ejido, las cuales son lideradas por el comisariado ejidal.

Los principales cultivos de la región son maíz, el cual se produce bajo el sistema de roza-tumba-quema o también llamado localmente *coamil*. Esta forma de cultivo consiste en la limpieza o clareo de áreas de selva para su cultivo. Este dura entre dos o tres años, posteriormente se abandonan los terrenos entre tres y ocho años (Borrego & Skutsch, 2014). Durante el periodo de abandono comienza la sucesión

de la vegetación, comenzando por las especies vegetales llamadas “pioneras” las cuales se adaptan mejor a las condiciones de sequía. Mientras en las áreas de agricultura perenne se cultiva caña de azúcar, aguacate y agave. Entre otras actividades económicas se encuentra la explotación forestal, la industria y el comercio.

2.3 Población

La densidad poblacional de los principales municipios de acuerdo con el censo de población de 2010, El Grullo es el municipio más denso con 134.8 habitantes por área (en total 23, 739 habitantes). Seguido de la Autlán de Navarro con una densidad de 81.46 hab/área (57,098 habitantes totales) (INEGI, 2015). Respecto al grado de marginación clasificado a nivel municipal, el cual está basado en la metodología del Consejo Nacional de Población (CONAPO, 2010) que integra elementos de las dimensiones de educación, vivienda, distribución de la población e ingresos monetarios. Los municipios de Autlán y el Grullo se encuentran en nivel muy bajo (CONABIO, 2010), los municipios San Gabriel, Tuxcacuesco y Tolimán están en nivel medio, y solo el municipio de Cuautitlán de García Barragán esta en nivel alto. Los demás municipios se encuentran en niveles bajos.

2.4 Manejo forestal

En áreas de selva bajo manejo comunal se aprovechan recursos como madera para leña, postes de cercado, plantas medicinales y frutos silvestres, también se usan áreas de selva para el pastoreo de ganado (Borrego y Skutsch, 2014). Y para los ejidatarios que rentan áreas de selva y además se dedican a la agricultura, los ingresos son mayores por las áreas rentadas que por la venta de su producción, por otro lado, los ganaderos que aprovechan la selva como área de forrajeo también se ven considerablemente beneficiados (Borrego y Skutsch, 2014), sin embargo, no todos los propietarios que usan los terrenos comunales tienen ganado, por lo que los beneficios podrían ser desproporcionados dependiendo el recurso que se aproveche.

Por otro lado, el incremento de contaminación en los cuerpos de agua más importantes de la cuenca, el río Ayuquila, enfocó la preocupación por la conservación de los recursos naturales y la disminución de contaminantes. Bajo este margen surgió la Junta Intermunicipal del Río Ayuquila, un organismo público descentralizado capaz de tomar decisiones y actuar en la cuenca, más allá de los límites políticos municipales y bajo un mismo enfoque “promover la conservación, restauración y aprovechamiento sustentable del agua, los suelo, los bosques y la biodiversidad” (Arellano & Pahua, 2011). Este organismo se consolidó en el año 1997, como un producto del Plan de Desarrollo de la región Costa Sur y tenía el objetivo inicial de sanear la cuenca de Ayuquila- Armería. Posteriormente el organismo creció y se vincularon diversas instituciones gubernamentales y académicas, y los objetivos se fueron ampliando hacia el manejo integral de los recursos naturales de la cuenca.

Capítulo III. Materiales y métodos

3.1 Datos de campo

3.1.1 Selección de sitios de muestreo

La toma de información en campo se llevó a cabo en la temporada de secas y principios de lluvias (finales de mayo y principios de junio del 2019). Para la selección de sitios de muestreo en campo se usó un análisis de serie de tiempo con imágenes de Landsat del 2016 al 2018 para identificar diferentes condiciones de la vegetación. 1) Vegetación que habían sufrido cambios en la densidad de árboles, identificados con cambios de textura visibles, los cuales representaban áreas con degradación. 2) Áreas que no habían sufrido cambios notables para esos años (para seleccionar las áreas menos degradadas). Para esto se generaron 30 puntos aleatorios para áreas alteradas y 30 para áreas sin cambios (60 en total). Además, se consideró que estuvieran homogéneamente distribuidos en la cuenca. Posteriormente la selección de puntos fue ajustada en campo de acuerdo con los siguientes criterios: accesibilidad a los sitios, se consideró la opinión de expertos de la zona sobre el nivel de actividad antrópica con ayuda de miembros de la Junta Intermunicipal del Río Ayuquila (JIRA), y se consideró la accesibilidad en cuestión de seguridad para cada punto.

Finalmente se evaluaron 41 puntos de muestreo. 23 sitios para caracterizar bosques conservados y 18 sitios de bosque degradado. Para evaluar estos sitios en campo se consideraron criterios como la presencia/ausencia de ganado, heces de ganado, árboles jóvenes, rebrotes, actividades de tala e incendios. Para todos los sitios, se consideró que la distancia a poblaciones, caminos y zonas agrícolas fuera mayor a 60 metros. Para el caso de los sitios conservados, se situaron principalmente en pendientes escarpadas (de 12° a 35°), zonas de pago por servicios ambientales, cerca de los límites o dentro de la Reserva de la Biósfera Sierra de Manantlán (Figura 1).

3.1.2 Métricas de vegetación

Cada sitio se registró su localización con GPS (Garmin etrex 20), se estableció un centroide en donde se midió la cobertura a través de un densiómetro esférico cóncavo. Desde el centroide se extendieron líneas de 12.6 m de radio para establecer parcelas circulares de 500 m² y dentro de esta parcela se estableció un área concéntrica de 30 m². En cada parcela se midieron atributos estructurales de la vegetación: número de árboles, altura de árboles y diámetro a la altura del pecho (DAP) de cada rama por árbol, dentro del área de 30 m² se midieron los árboles >2.5 cm de DAP y fuera de esta área todos los árboles >5 cm de DAP.

3.1.3 Cálculo de biomasa aérea sobre el suelo

A partir de la información diamétrica de los árboles, se calculó la biomasa aérea sobre el suelo (BAS) a través de una ecuación alométrica (ec.1). Esta ecuación fue desarrollada para selva tropical caducifolia de zona costera (Reserva de la Biósfera Chamela-Cuixmala, Jalisco) (Martínez-Yrizar, 1992). A pesar de que la STC de la cuenca de Ayuquila no es costera, esta ecuación satisface mejor los objetivos de este trabajo.

$$\text{Ecuación 1..... } \log_{10} Y = A + \log_{10} BA$$

Donde Y es biomasa (kg), A es la constante de regresión (-0.5352), y BA el área basal (cm²).

A partir de calcular la biomasa para cada rama por árbol, se sumaron los árboles por sitio y se transformó a mega gramos por hectárea (Mg/ha).

3.1.4. Tratamiento de datos

Se revisaron las bases de datos, se identificaron y eliminaron anomalías (*outliers*). Posteriormente se normalizaron las variables aplicando logaritmo decimal, y se realizaron pruebas de normalidad de Shapiro-Wilk para cada variable medida en el terreno (tabla 1). Una vez que se identificaron las variables con distribución gaussiana y aquellas que no la tenían, los análisis paramétricos y no-paramétricos se aplicaron de acuerdo con la naturaleza de los datos.

Tabla 1. Resultados de análisis de normalidad, (*) indican las variables con distribución gaussiana

	Shapiro-Wilk normality test $\alpha > 0.05$	
Cobertura	W = 0.6848, p-value = 4.245e-08	
Log total de árboles	W = 0.96137, p-value = 0.1756	*
Log área basal	W = 0.97857, p-value = 0.6217	*
Log altura de árboles	W = 0.95368, p-value = 0.09428	*
Log número de ramas	W = 0.95398, p-value = 0.09662	*
Densidad árboles	W = 0.95842, p-value = 0.1384	*
Log pendiente	W = 0.89968, p-value = 0.001622	
Log biomasa	W = 0.95065, p-value = 0.07377	*

3.1.5 Correlación de atributos estructurales de la vegetación

Se aplicaron pruebas de correlación del rango Kendall entre las variables de campo para identificar las posibles asociaciones entre aquellas variables que pueden ser detectadas a través de sensores de percepción remota con aquellas que no. Con el fin de poder detectarlas indirectamente. Se empleó una medida no paramétrica, debido a que no todas las variables presentaron distribución normal (tabla 1). El coeficiente tau de Kendall (τ) se define por la siguiente fórmula, en donde C es el número de pares concordantes, D el número de pares discordantes, n el número total de pares.

$$\text{Ecuación 2} \dots \tau = \frac{C-D}{\frac{1}{2}n(n-1)}$$

Los resultados se pueden interpretar como una prueba de hipótesis, en donde la hipótesis nula (h_0) es que las variables no están correlacionadas ($\tau=0$) y la hipótesis alterna (h_1) es que las variables si están correlacionadas ($\tau=1$), para aceptar la hipótesis alterna se hace bajo un supuesto de significancia $p < 0.05$.

3.2 Datos de percepción remota

Para calcular las variables espectrales para los sitios, se eligieron 3 diferentes tipos de imágenes satelitales de diferente resolución, de sensores pasivos y uno activo y de libre acceso. Dos sensores de tipo óptico pasivo donde los datos son capturados a partir de la cantidad de energía reflejada o emitida por el sol, un sensor activo de tipo radar, el cual emite su propia señal y captura la cantidad de señal reflejada por los objetos, independientemente de la presencia de luz solar y nubes. Ambos tipos de sensores ofrecen distinta información de la superficie terrestre. Para los bosques, en las imágenes ópticas se observa la información del dosel y se detecta el contenido de clorofila reflejado o emitido principalmente en el espectro de luz visible y infrarrojo. Con imágenes de radar, el pulso de energía en microondas penetra el dosel y toma información de la estructura (ramas y troncos). Cabe mencionar que los datos de los sensores ópticos se tomaron de dos temporadas, en secas, en el tiempo más cercano a las fechas de muestreo, y principios de lluvias, que en ese año inició a finales de junio. Los sensores y las variables obtenidas a partir de estos se describen en la tabla 3.

3.2.1 Datos de imágenes ópticas

Landsat 8

Las imágenes adquiridas por los sensores a bordo del satélite Landsat 8 son tomadas en todo el mundo a cargo de la organización gubernamental estadounidense United States Geological Survey (<https://www.usgs.gov/>). El satélite tiene una resolución temporal de 16 días, y resolución espacial de 30 m. Tiene dos sensores, uno es *Operational Land Imager* (OLI) el cual se encarga de capturar nueve bandas espectrales, 3 en la región del espectro electromagnético visible (bandas 1, 2, 3, 4) e infrarrojo (bandas 5,6,7). El sensor *Thermal Infrared Sensor* (TIRS) captura dos bandas termales 10 y 11 (USGS, 2013).

Sentinel-2

La misión de los satélites Sentinel está a cargo de la Agencia Espacial Europea (ESA), puesto en órbita en el año 2015, el satélite Sentinel-2 es de tipo óptico, con resolución temporal de 5 y 10 días, dependiendo el lugar, resolución espectral de 13 bandas y resolución espacial de 10, 20 y 60 metros dependiendo las bandas (<https://sentinel.esa.int/web/sentinel/user-guides/sentinel-2-msi/resolutions>). En este trabajo se utilizaron las bandas roja e infrarroja cercana con resolución espacial de 10 metros (bandas 4 y 8).

3.2.2 Datos de imágenes SAR

Sentinel-1

Este satélite es de tipo Radar de Apertura Sintética (SAR por sus siglas en inglés) y toma información por el día y la noche en banda C con resolución espacial de 10 m, su señal puede penetrar ~6 cm de la superficie, dependiendo de las características de los materiales, y para el caso de los bosques, la densidad del dosel.

Este satélite es el más reciente de tipo radar SAR, se puso en órbita en el año 2014, ha tenido muchas aplicaciones, ya que la señal logra capturar información durante el día y la noche y penetra las nubes, por lo tanto, es posible obtener información continua a pesar de las condiciones atmosféricas. Este tipo de imágenes tiene aplicación desde detección de glaciares, inundaciones, terremotos, hasta detección de cambios de cubierta, y más recientemente detección de degradación forestal y biomasa.

Tabla 2. Tabla resumen de los sensores utilizados y las variables calculadas a partir de cada imagen. PAN, pancromática. VV polarimetría vertical-vertical y VH polarimetría vertical-horizontal.

(Sensor) Misión	Año de inicio	Resolución espacial (m)	Resolución espectral	Resolución radiométrica	Resolución espectral (μm)	Resolución temporal (días)
(OLI) Landsat 8	2013	30 y 15 (PAN)	9 bandas	8-bit	0.45-2.3	16
(MSI) Sentinel-2	2016	10, 20, 60	13 bandas	Banda 4-31 m Banda 8-1.06 m		5 -10
(SAR) Sentinel-1 B	2014	10	VV/ VH	—	Banda C	12

3.3 Preprocesamiento y procesamiento de datos espectrales

3.3.1 Imágenes ópticas

Landsat 8

El producto usado del satélite Landsat fue del nivel-1 (Landsat collection level-1), estos productos tienen un preprocesamiento incluido. Esta calibrada la precisión radiométricamente (L1TP) y orto-rectificado a través de un modelo digital de elevación para la corrección del relieve. Tiene corrección sistemática del terreno (L1GT) esta corrección es el nivel más alto de calibración radiométrica. Y también tiene corrección geométrica (L1GS) aplicado con los datos de la nave ephemeris (USGS <https://www.usgs.gov/land-resources/nli/landsat/landsat-level-1-processing-details>). Adicionalmente se realizó su corrección atmosférica con el algoritmo DOS, este es un método empírico que se basa en la substracción de objetos oscuros (Banskota et al., 2014).

Sentinel-2

El producto de Sentinel usado fue el de nivel 2A el cual incluye un preprocesamiento de corrección atmosférica desde el fondo de la atmósfera (*bottom of atmosphere*), además esta orto-rectificada a la proyección WGS84. Adicionalmente se le realizó una corrección atmosférica tipo DOS y se obtuvieron los valores de reflectancia de

los píxeles a través del plugin *Semi-automatic Classification Plugin* (<https://plugins.qgis.org/plugins/SemiAutomaticClassificationPlugin/>).

3.3.2 Imágenes de radar *Sentinel-1*

El producto usado de radar fue de Sentinel-1 nivel-1 (S1 level-1) en banda C con una longitud de onda de ~5.54 cm, la cual puede penetrar aproximadamente 6 cm del dosel en una vegetación poco densa y en el suelo seco o húmedo (Meyer et al., 2019; <https://sentinel.esa.int/web/sentinel/technical-guides/sentinel-1-sar/sar-instrument>). Esta imagen tiene una polarización dual, es decir, en VV señal transmitida verticalmente y recibida verticalmente y VH señal transmitida verticalmente y recibida horizontalmente, los diferentes modos de polarización de la señal permite estudiar desde diferentes aspectos la superficie de la tierra. Los ángulos de incidencia con que la imagen fue capturada fue de 30.8° a 46°, este dato es importante cuando se compara con otros estudios de vegetación, ya que el ángulo de captura es un factor que puede intervenir en la toma de datos y la penetración de la señal en la vegetación. La imagen se encuentra en modo de obtención Interferometric Wide Swath (IW), tiene un ancho de franja de 251.8 km en alta resolución (10 m). Este producto tiene un preprocesamiento, el cual consiste en la calibración radiométrica para obtener los valores digitales de los píxeles, posteriormente una calibración de vector para obtener valores de intensidad, finalmente los productos pueden ser obtenidos en modo *Single Look Complex* (SLC) y/o *Ground Range Detected* (GRD), el primero conserva la información de “fase” de la longitud de onda, mientras que el segundo contiene la “amplitud” de longitud de onda. El producto usado en este trabajo fue GRD y está proyectado a coordenadas geográficas usando modelos elipsoidales de la Tierra (<https://sentinel.esa.int/web/sentinel/user-guides/sentinel-1-sar/product-types-processing-levels/level-1>). También incluye el proceso *multi-looking* para reducir el impacto del ruido (*speckle*).

El procesamiento aplicado posteriormente se realizó en el programa Sentinel Application Platform SNAP (<https://step.esa.int/main/toolboxes/snap/>). Consistió en

los siguientes pasos: 1) Aplicación de archivos de órbita para garantizar la posición precisa de los satélites al momento de la obtención de la señal. 2) Calibración radiométrica y geométrica para ajustar los valores de los píxeles con la cantidad de señal de retrodispersión. 3) Filtro de ruido el cual fue Lee 3*3, tuvo un costo en la reducción de la resolución de la imagen, pasando de 10 m a 30 m, 4) Corrección de terreno para orientar correctamente la imagen sobre el terreno.

3.4 Métodos

El desarrollo metodológico del trabajo mostrado en la figura 2, consistió en el desarrollo de modelos lineales que relacionaran información de atributos estructurales medidos en campo con variables espectrales. Para llevar a cabo esto se usaron variables espectrales derivados de diferentes sensores como las variables independientes de los modelos. Mientras que los atributos estructurales medidos en campo se usaron como variables dependientes. A partir de la generación de los modelos, se identificaron los más plausibles a partir de parámetros estadísticos (R^2 , AIC). Finalmente, con la identificación de modelos predictivos, fue posible espacializar la variación de cada atributo para las áreas de selva tropical caducifolia de toda la cuenca.

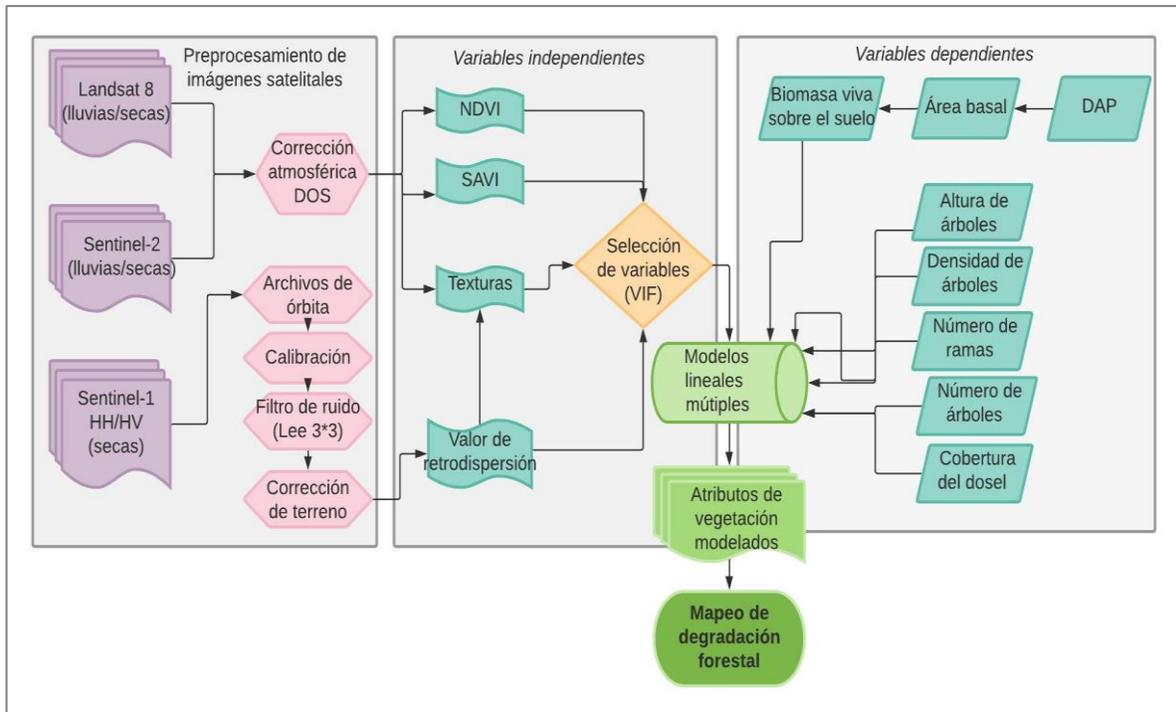


Figura 2. Procesamiento de datos seguido para la obtención de variables espectrales y de campo, para las variables independiente se tiene las variables espectrales obtenidas de los sensores Landsat 8, Sentinel-2 y Sentinel-1, los cuales tuvieron un preprocesamiento y finalmente la obtención de los productos. Mientras que las variables dependientes se tomaron las mediciones de atributos estructurales de la vegetación en campo. NDVI Índice de Vegetación por Diferencia Normalizada, SAVI Índice de Vegetación Ajustada al Suelo, VIF Factor de Inflación de Varianza, DAP diámetro a la altura del pecho.

3.4.1 Cálculo de variables espectrales

Para cada sitio en campo fue marcado el centro con un GPS, estos puntos se llevaron a un sistema de información geográfica y se calcularon buffers de 2.6 metros de radio para cada punto, a partir de estos se extrajeron los valores de cada píxel asociados a esta área y se realizó un promedio para el caso de los sitios con más de un píxel. A partir de este cálculo se obtuvieron los valores de índices espectrales de los sitios degradados y conservados medidos en campo.

3.4.2 Índices de vegetación

El uso de índices espectrales para la detección de degradación en bosques ha sido de las principales variables. Para detectar cambios en la respuesta espectral de la

vegetación que puede ser un indicador de degradación, ya que los índices de vegetación responden a la cubierta vegetal, vegetación caducifolia, pigmentos fotosintéticos o propiedades del suelo (Chabrilat, 2006). Los índices han sido asociados a variables ecológicas que expresan el estado de la vegetación y los ecosistemas (Cihlar et al., 1991). Sin embargo, los índices al ser sensibles al contenido de clorofila en plantas, la vegetación caducifolia podría dar respuesta de otros componentes de la vegetación, como troncos y reflectancia del suelo, para lo cual se emplearon los algunos de los índices más populares en la detección de la vegetación, Índice de Vegetación por diferencia Normalizada (NDVI por sus siglas en inglés) y el índice de Vegetación Ajustada al Suelo (SAVI).

- *Índice de Vegetación por Diferencia Normalizada (NDVI)*

Se emplearon imágenes de Landsat- 8 y Sentinel-2 de dos fechas, la primera corresponde a fecha más cercana a los días de muestreo, y la segunda corresponde a los inicios de temporada de lluvias (finales de julio). Se calcularon índices de vegetación asociados a condiciones de la vegetación, tales como el Índice de Índice de Vegetación por Diferencia Normalizada (NDVI por sus siglas en inglés, ec. 3).

$$\text{Ecuación 3} \dots \dots \dots NDVI = \frac{NIR-RED}{NIR+RED}$$

En donde *NIR* (*Near Infrared*) es la banda de infrarrojo cercano y *RED* la banda que refleja la zona del rojo.

- *Índice de Vegetación Ajustada al Suelo (SAVI)*

El índice de vegetación ajustada al suelo (*Soil Adjusted Vegetation Index, ec. 4*) calcula la reflectancia de la vegetación fotosintéticamente activa, tal como lo hace el índice NDVI. Sin embargo, se considera que el suelo es un factor que afecta esta medición, por lo tanto, lo minimiza a través de la constante *L* que se incluye en la ecuación. Esta constante debe indicar el nivel de brillo del suelo, para lo cual se pueden usar diversos valores.

$$\text{Ecuación 4} \dots \dots \dots SAVI = \frac{NIR-RED}{NIR+RED+L} (1 + L)$$

Donde *NIR* es la banda que refleja el infrarrojo cercano del espectro electromagnético, *RED* la banda que refleja la zona roja, y *L* la constante de brillo del suelo, en nuestro caso se empleó el valor estándar de 0.5 (Huete, 1988).

- *Índice de Disturbio*

Este índice está basado en las transformaciones Tasseled cap de brillo, vegetación, y humedad (Brightness, Greenness y Wetness), con el objetivo de resaltar las propiedades de la superficie con estas características. El índice de disturbio combina linealmente las tres transformaciones Tasseled Cap (ecuación 5). Bajo el supuesto que las áreas con disturbio de bosque tienen un alto nivel de brillo, bajo nivel de verdor y humedad, en relación con las áreas de bosque conservado (Healey et al., 2015).

$$\text{Ecuación 5} \dots\dots\dots ID = B_r - (G_r + W_r)$$

En donde B_r , G_r y W_r son las transformaciones Tasseled Cap reescaladas. La transformación Brightness, Greenness y Wetness utilizan las bandas espectrales de Landsat-8 y Sentinel-2 de la región del espectro electromagnético de azul, verde, rojo, infrarrojo cercano e infrarrojo de onda corta (SWIR 1 y SWIR 2), cada banda es multiplicada por un coeficiente que cambia dependiendo de la transformación y el tipo de sensor. Los resultados se interpretarán considerando que las áreas con disturbio tendrán valores altos y positivos de brillo (B) y valores muy bajos y negativos de verde (G) y humedad (W), por lo tanto, los valores del índice serán altos positivos para áreas con disturbio, mientras que las áreas conservadas se encontrarán en valores bajos, negativos o cercanos a 0.

3.4.3 Cálculo de texturas

Las métricas texturales se calcularon a través de un análisis de matrices de coocurrencia de niveles de gris (*Grey Level Co-occurrence Matrices GLCM*). Se calcularon 6 métricas estadísticas de textura para cada imagen, los cuales se describen en la tabla 2. Se seleccionaron estas medidas pues han demostrado asociación con diversos atributos de la vegetación en selva tropical caducifolia.

(Gallardo-Cruz et al., 2012; Kuplich et al., 2005; Lu & Batistella, 2005; Solórzano et al., 2017).

Tabla 2. Descripción de las métricas de GLCM empleadas.

Métrica	Descripción	Ecuación
Homogeneidad	Mide la uniformidad de los valores diferentes a cero en la matriz de coocurrencia.	$homo = \sum_{i,j} \frac{1}{1-(i-j)^2} P(i,j)$
Disimilaridad	Define la variación del nivel de pares de gris en una imagen.	$diss = \sum_{i,j} i-j p(i,j)$
Entropía	La entropía representa cualquier sistema en desorden, en donde la textura es la medida de su desorden espacial.	$ent = - \sum_{i,j} p(i,j) \log(P(i,j))$
Promedio	Promedio de los valores de la matriz de coocurrencia. Está asociado a la heterogeneidad de los valores de gris de la imagen	$\underline{x} = \sum_{i,j=0}^{N-1} iP_{ij}$
Varianza	Medida de la variación global de la imagen. Valores altos significan una alta variación en los valores de gris	$var = \sum_{i,j=0}^{N-1} P_{i,j} (i - \underline{x})^2$
Correlación	Medida de la dependencia lineal entre los pixeles vecinos	$corr = \sum_{i,j=0}^{N-1} P_{i,j} \left[\frac{(i - \underline{x})(j - \underline{x})}{var} \right]$

Tabla 3 Descripción de todas las variables espectrales calculadas, por temporada, sensor y abreviación.

Sensores/ Resolución	Tipo de variable	Temporada	Variable	Abreviatura
Landsat-8 30 m	Índices espectrales	Lluvias (1) Julio 2019	Normalize Difference Vegetation Index	L8-1NDVI
			Soil Adjusted Vegetation Index	L8-1SAVI
			Disturbance Index	L8-1DI
		Secas (2) Junio 2019	Normalize Difference Vegetation Index	L8-2NDVI-2
			Soil Adjusted Vegetation Index	L8-2SAVI-2
			Disturbance Index	L8-2ID-2
	Texturas (bandas roja e infrarroja)	Lluvias (1) Julio 2019	Homogeneidad	L8-1homo-b4 (b5)
			Disimilaridad	L8-1Diss- b4 (b5)
			Entropía	L8-1Ent-b4 (b5)
			Correlación	L8-1Cor- b4 (b5)
			Promedio	L8-1Prom- b4 (b5)
			Varianza	L8-1Var- b4 (b5)
		Secas (2) Junio 2019	Homogeneidad	L8-2Diss- b4 (b5)
			Disimilaridad	L8-2Ent-b4 (b5)
Lluvias (1) Julio 2019	Entropía	L8-2Cor- b4 (b5)		
	Correlación	L8-2Prom- b4 (b5)		
	Promedio	L8-2Var- b4 (b5)		
Secas (2) Junio 2019	Varianza	L8-2Con- b4 (b5)		
	Contraste	L8-2Diss- b4 (b5)		
	Contraste	L8-2Diss- b4 (b5)		
Sentinel-2 10 m	Índices espectrales	Lluvias (1) Julio 2019	Normalize Difference Vegetation Index	S2-1NDVI
			Soil Adjusted Vegetation Index	S2-1SAVI
			Disturbance Index	S2-1DI

		Secas (1) Mayo 2019	Normalize Diference Vegetation Index	S2-2NDVI
			Soil Adjusted Vegetation Index	S2-2SAVI
			Disturbance Index	S2-ID
	Texturas (bandas roja e infrarroja)	Lluvias (1) Julio 2019	Homogeneidad	S2-1Homo-b4(b8)
			Disimilaridad	S2-1Diss- b4(b8)
			Entropía	S2-1Ent-b4(b8)
			Correlación	S2-1Cor- b4(b8)
			Promedio	S2-1Prom- b4(b8)
			Varianza	S2-1Var- b4(b8)
		Secas (2) Mayo 2019	Contraste	S2-1Con- b4(b8)t
			Homogeneidad	S2-2Diss- b4(b8)
			Disimilaridad	S2-2Ent-b4(b8)
			Entropía	S2-2Cor- b4(b8)
			Correlación	S2-2Prom- b4(b8)
			Promedio	S2-2Var- b4(b8)
Sentinel-1 10 m	Banda-C Texturas (Polarización VV y VH)	Secas Mayo 2019	Varianza	S2-2Con- b4(b8)t
			Contraste	S2-2Diss- b4(b8)
			Homogeneidad	S1-Homo-VV(VH)
			Disimilaridad	S1-Diss- VV(VH)
			Entropía	S1-Ent- VV(VH)
			Correlación	S1-Cor- VV(VH)
			Promedio	S1-Prom- VV(VH)
Varianza	S1-Var- VV(VH)			
Contraste	S1-Con- VV(VH)			

3.4.4 Selección de variables espectrales

Para reducir la dimensión de las variables espectrales calculadas y evitar que los modelos tengan redundancia en la capacidad explicativa se realizó un análisis de Factor de Inflación de Varianza (VIF) el cual detecta la multicolinealidad entre variables. De acuerdo con la ecuación 6, en donde R^2 es el coeficiente que indica la proporción de varianza asociado a las variables predictoras. Por lo tanto, el valor

de VIF muestra el grado en el cual aumenta debido a la multicolinealidad (Thompson et al., 2017). Esto evita que exista alta correlación entre las variables independientes del modelo. Su valor puede ir de 1 a infinito, indicando que en 1 no existe correlación, entre 1 a 5 hay correlación moderada, dependiendo la naturaleza de las variables, >5 o >10 puede haber alta correlación. En este caso se consideraron valores <5 para descartar las variables. Se agruparon en las dos temporadas secas y de lluvias, obteniendo los valores de VIF finales como se indican en las tablas 3 y 4. Estas variables se incluyeron en los modelos lineales múltiples finales.

$$\text{Ecuación 6..... } VIF_j = \frac{1}{1-R_j^2}$$

3.4.5 Generación de modelos

Para identificar la mejor combinación de variables que se asocian a los diferentes parámetros de campo que indican niveles de degradación se ajustaron múltiples regresiones lineales, los cuales pueden tomar una, dos y tres variables predictoras. Los modelos con mejor desempeño o los modelos más plausibles son los que tienen un valor de coeficiente de determinación R^2 más cercano a 1, y los valores de Akaike menores. Las regresiones tuvieron la forma de la ecuación 7, 8, 9. Cabe mencionar que se hicieron regresiones bajo diferentes agrupaciones de datos, primero considerando ambos tipos de bosque medidos en campo (bosque degradado y conservado), y separados por tipo de bosque degradado y conservado. Así como entre variables de temporadas (lluvias y secas).

$$\text{Ecuación 7..... } y = b_1X_1 + b_2X_2 + b_0$$

$$\text{Ecuación 8 } y = b_1X_1 + b_2X_2 + b_3X_1X_2 + b_0$$

$$\text{Ecuación 9 } y = b_1X_1 + b_2X_2 + b_3X_3 + b_0$$

En donde y es la variable dependiente, las cuales fueron las variables medidas en terreno, los términos X_1 , X_2 , X_3 tomaron el lugar de las variables espectrales seleccionadas para cada agrupación (tablas 1 a, b y 2 a, b) y b es el valor de la ordenada al origen. En el caso de la ecuación 9, $b_3 X_1 X_2$ corresponde a una interacción dada entre las variables X_1 y X_2 y su coeficiente.

3.4.6 Validación de predicciones

Como métrica para evaluar la calidad de las predicciones se usó el error cuadrático medio (ECM), el cual mide el tamaño global de las diferencias entre los valores de las variables observadas y las predicciones (Bosch, 1993). Este error se calcula a partir de la ecuación 10, en donde \hat{Y}_i es el vector de las predicciones y Y_i el vector de los valores observados. Este valor indica que en cuanto más pequeño es el error, el modelo hizo mejores predicciones.

$$\text{Ecuación 10..... } ECM = \frac{1}{N} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2$$

También se puede interpretar a partir de los gráficos de dispersión de puntos entre los valores observados y los predichos por los modelos. El error cuadrático medio mide la distancia que se encuentra cada punto por encima o por debajo de la recta de regresión.

3.4.7 Mapeo de selva con degradación

Una vez que se identifiquen los atributos que pueden ser modelados a través de las variables espectrales, se categorizarán los mapas obtenidos de la modelación en niveles de degradación, conservando el rango de valores que pueda ser distinguible de los sitios de selva conservados para descartar en la medida de lo posible aquellos valores que se encuentren en el rango de las selvas conservados y reducir errores en el mapeo. Se combinarán los diferentes mapas obtenidos para cruzar la información de diferentes variables, con el objetivo de identificar las zonas con la mayor degradación de acuerdo con diferentes atributos estructurales. Para finalmente obtener un mapa binario de degradación forestal severa de selva tropical caducifolia de la cuenca.

Este mapa también será validado a partir de puntos aleatorios de verificación, los cuales serán clasificados como “degradado” y “no degradado” y se verificarán en imágenes de alta resolución de Google Earth.

Capítulo IV. Resultados

Los resultados encontrados se presentan en el orden de los objetivos y en orden a las escalas de medición de atributos asociados a degradación forestal. Siendo el primer objetivo referido a la identificación de la variación entre las características estructurales de selvas conservadas *versus* selvas degradadas, se presenta una descripción de los resultados obtenidos de las variables de campo. Posteriormente se hace una caracterización de las variables espectrales asociados a los sitios medidos en campo para identificar la tendencia de cada caso. Finalmente se muestran los modelos más plausibles que se asocian a las variables independientes, para dar paso al mapeo de degradación, así como la verificación de los modelos.

4.1 Caracterización estructural de la selva

La información de los atributos estructurales medidos en campo se comparó entre tipos de bosque para identificar aquellos que tienen diferencias significativas (tabla 4). Se identificó que el porcentaje de cobertura, el área basal, la altura y la biomasa aérea sobre el suelo (BAS) son las principales características que se diferencian entre bosques conservados y degradados. La proporción de estos parámetros es en promedio más alta para bosques conservados que para degradados, lo cual contrasta con la primera parte de la hipótesis del trabajo, referida a la identificación de los atributos estructurales que diferencian tipos de bosque (tabla 4).

Tabla 4 Resumen de parámetros estructurales medidos in situ por sitio. Se resalta en negritas los resultados que tienen valores de $\alpha < 0.05$ en las pruebas Man-Whitney-Wilcoxon

Parámetros estructurales	Selva conservada			Selva degradada			Prueba Wilcoxon
	Máx.	Min	Media	Máx.	Min	Media	P-value
Cobertura (%)	100	83.8	96.1	100	16	69.4	8.641^{e-06}
Área basal (m²/ha)	21.47	4.95	11.49	19.87	2.69	7.38	0.001

Altura (m)	7.7	3.7	5.7	7.2	2.5	4.8	0.001
Biomasa (Mg/ha)	62.46	7.42	32.35	57.8	8.44	20.90	0.003
Densidad de ramas/ha (>2.5cm)	2020	480	1314.4	2560	540	1502.2	0.427
Densidad de árboles/ha	1240	220	736.6	1420	220	726.7	0.228

- Correlación de atributos estructurales de la vegetación

Posteriormente se correlacionaron los atributos de la vegetación por pares que diferencian las selvas degradadas de las no degradadas (tabla 5). Se empleó el coeficiente de correlación de Kendall (τ) ya que las variables no cumplen con el supuesto de normalidad. Se encontró una correlación significativa entre el total de árboles y la densidad de árboles por área considerando todos los sitios (tabla 5 a). Analizando los sitios por tipo de selva (degradada y conservada) se encontró que para los sitios de selva degradada hay una fuerte correlación entre biomasa por sitio y el total de árboles, y con la densidad de árboles por sitio, también del total de árboles por sitio con el total de ramas y la densidad de árboles (tabla 5 b). Mientras que, para los sitios conservados, solo hubo una correlación fuerte entre el total de árboles y la densidad de árboles (tabla 5 c). Esta correlación fue consistente entre los tres grupos de análisis, debido a que la densidad de árboles por sitio fue derivada del total de árboles.

Tabla 5. Resultados de coeficiente de correlación de Kendall para sitios de ambos tipos de bosque a), coeficiente de correlación de Kendall para todos los sitios b) y resultados de correlación para el grupo de sitios de bosque conservado c). En negritas se muestran las correlaciones con valores de significancia $p < 0.001$. * $P < 0.05$, ** $p < 0.01$, *** $p < 0.001$

a)	Cobertura (%)	Densidad de árboles/h a	Área basal (m ² /ha)	Altura (m)	Biomasa viva sobre suelo (Mg/ha)	Densidad de ramas/ha	Pendiente (°)
Cobertura	1						
Densidad de árboles (árboles/área)	0.24*	1					
Área basal (m ² /ha)	0.31**	0.46***	1				
Altura (m)	0.24*	0.25	0.37	1			
Biomasa (Mg/ha)	0.31**	0.46***	1	0.37***	1		
Número de ramas ha	0.11	0.57***	0.27***	0.037	0.27*	1	
Pendiente (°)	0.16	-0.012	0.08	-0.062	0.08	-0.048	1
b)							
Cobertura (%)	1						
Densidad de árboles (árboles/ área)	0.2	1					
Área basal (m ² /ha)	0.027	0.34*	1				
Altura (m)	-0.075	0.034	0.18	1			
Biomasa viva sobre suelo (Mg/ha)	0.027	0.34*	1	0.18	1		
Número de ramas ha	0.22	0.54***	0.3	-0.097	0.3	1	
Pendiente (°)	0.081	-0.12	-0.007	-0.2	-0.0072	-0.11	1
c)							
Cobertura	1						
Densidad de árboles (árboles/ área)	0.47*	1					
Área basal (m ² /ha)	0.4*	0.7***	1				
Altura (m)	0.25	0.39	0.44	1			
Biomasa viva sobre suelo (Mg/ha)	0.4*	0.7***	1***	0.44	1		
Densidad de ramas/ha	0.38*	0.69***	0.54***	0.34*	0.54	1	
Pendiente (°)	0.044	0.075	0.088	-0.16	0.088	0.096	1

4.2. Modelación de variables de selva con datos de percepción remota

Para realizar la modelación de las variables de campo de las selvas degradadas y conservadas, se calcularon diferentes variables espectrales que fueron usadas como variables predictoras de los atributos de vegetación. A continuación, se muestran los resultados de los índices de vegetación (NDVI y SAVI) e índice de disturbio (ID), así como métricas texturales. Las variables espectrales fueron separadas por tipo de bosque, por tipo de sensor y temporada del año (lluvias y secas), para tener un análisis más detallado del comportamiento de cada variable.

4.2.1 Insumo de modelos

4.2.2 Índices de vegetación y de disturbio

Los resultados de índices de vegetación mostrados a continuación derivan particularmente de los tipos de sensores ópticos, estos resultados también se muestran a partir de los valores calculados por sitio en campo.

- *Temporada de lluvias*

En la gráfica 4a se muestran los valores obtenidos de los índices NDVI, ID y SAVI para los sitios de selva conservada y selva degradada de la temporada de lluvias. En general se puede apreciar que, entre los tres índices calculados, los índices NDVI y SAVI muestran tendencias similares entre los sitios. Sin embargo, para el caso del ID, tanto para las imágenes de Landsat 8 como de Sentinel 2, se observa una alta variación entre sus valores y resalta una clara diferencia entre ambos tipos de imágenes, mientras que para la imagen de Landsat 8 los valores van de -2.1 a 1.3, en el sensor de Sentinel-2 van de -0.89 a 0.18.

En el caso de los sitios de selva conservada de la temporada seca (figura 3 b) se visualizan tendencias similares que, en el caso de la temporada de lluvias, pero los valores cambian. En este caso, los valores de los índices NDVI y SAVI están en los mismos rangos para ambos tipos de imágenes, entre 0 y 0.5. A diferencia del índice de disturbio en donde hay mayor variación entre sitios y entre tipos de

imágenes, ya que los valores de Landsat pueden ir entre -1.9 hasta 0.5 y Sentinel 2 puede ir de -2 hasta 0.8, es decir, la segunda imagen tiene un rango de valores mayor.

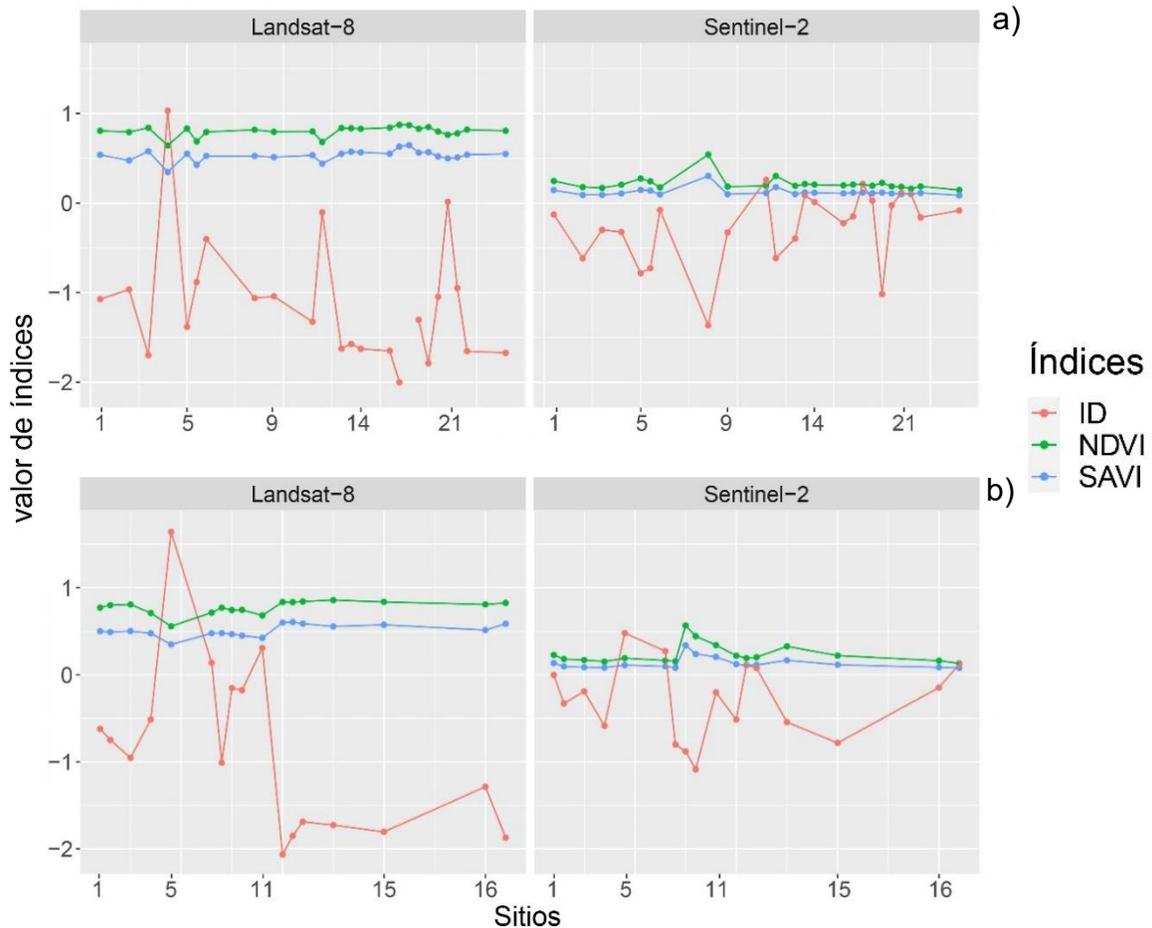


Figura 3. Comparación de índices de vegetación entre imágenes de Landsat-8 y Sentinel 2 de la temporada de lluvias para sitios de a) bosque conservado y b) degradado. Índice de Disturbio (ID), Índice de Vegetación normalizada (NDVI), Índice de Vegetación Ajustada al Suelo (SAVI). El eje X representa el número de sitios mientras que el eje Y son los valores de cada índice.

- *Temporada de secas*

En las figuras 4 a) y b) se muestran los valores obtenidos para los sitios de selva conservada a) y degradada b) de la temporada secas. Al igual que los resultados para selva degradada, hay una similitud entre valores de NDVI y SAVI, sin embargo, entre las imágenes Landsat-8 y Sentinel-2 hay diferencias, ya que para Landsat los valores pueden ir de 0.5 a 0.9. mientras que en Sentinel van de 0.1 a 0.5. Al igual que los resultados anteriores, hay una coincidencia en la tendencia de los valores del ID, al haber alta variación entre los sitios para ambas imágenes.

En el caso de los sitios de selva conservado de la temporada seca (figura 4 b) se visualizan tendencias similares que, en el caso de la temporada de lluvias, pero los valores cambian. En este caso, los valores de los índices NDVI y SAVI son muy cercanos entre si, pero tienden a concentrarse hacia el 0.

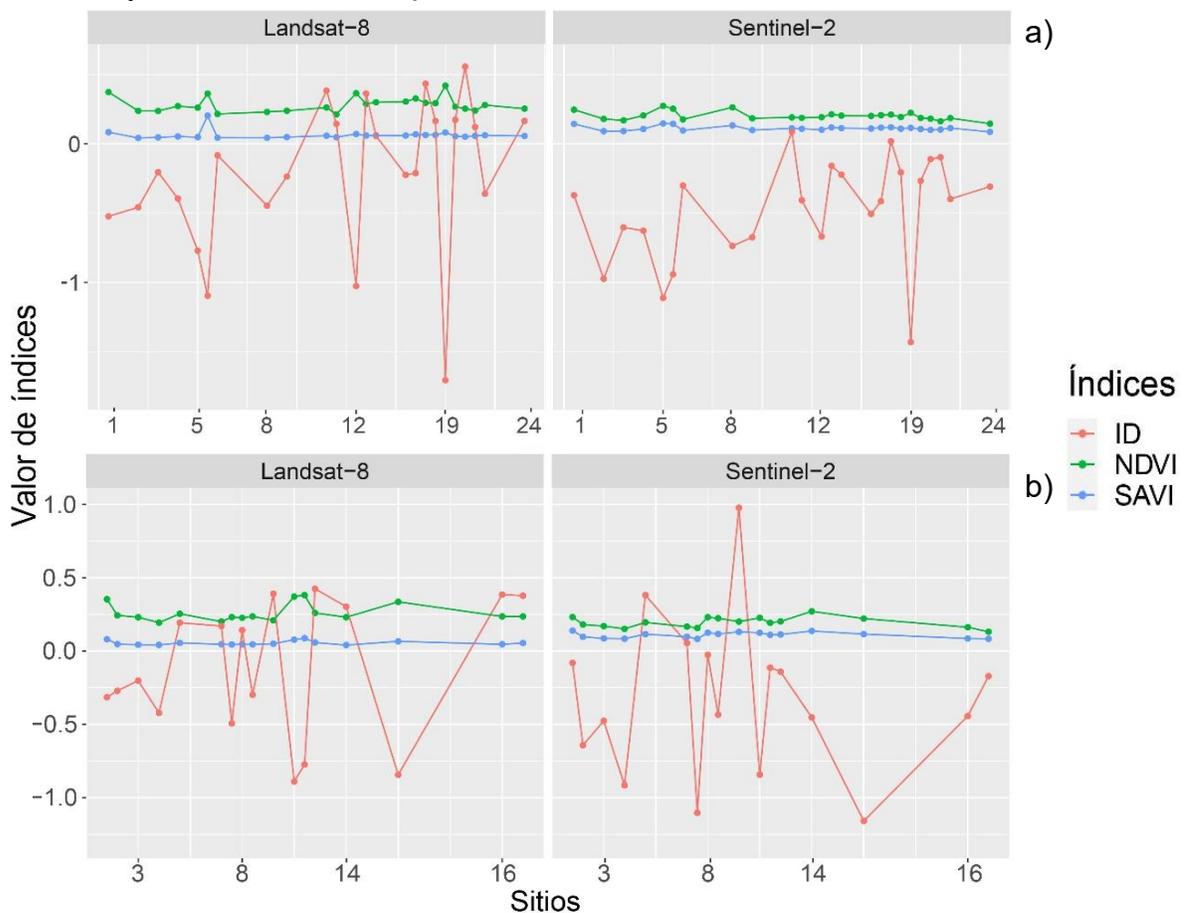


Figura 4. Comparación de índices de vegetación entre imágenes de Landsat-8 y Sentinel 2 para los sitios de a) bosque conservado y b) bosque degradado de la temporada de secas. El eje X representa el número de sitios mientras que el eje Y son los valores de cada índice, y los colores de las líneas representan los índices ID, NDVI, SAVI.

4.2.1 Mapas de índices de vegetación para la cuenca de Ayuquila

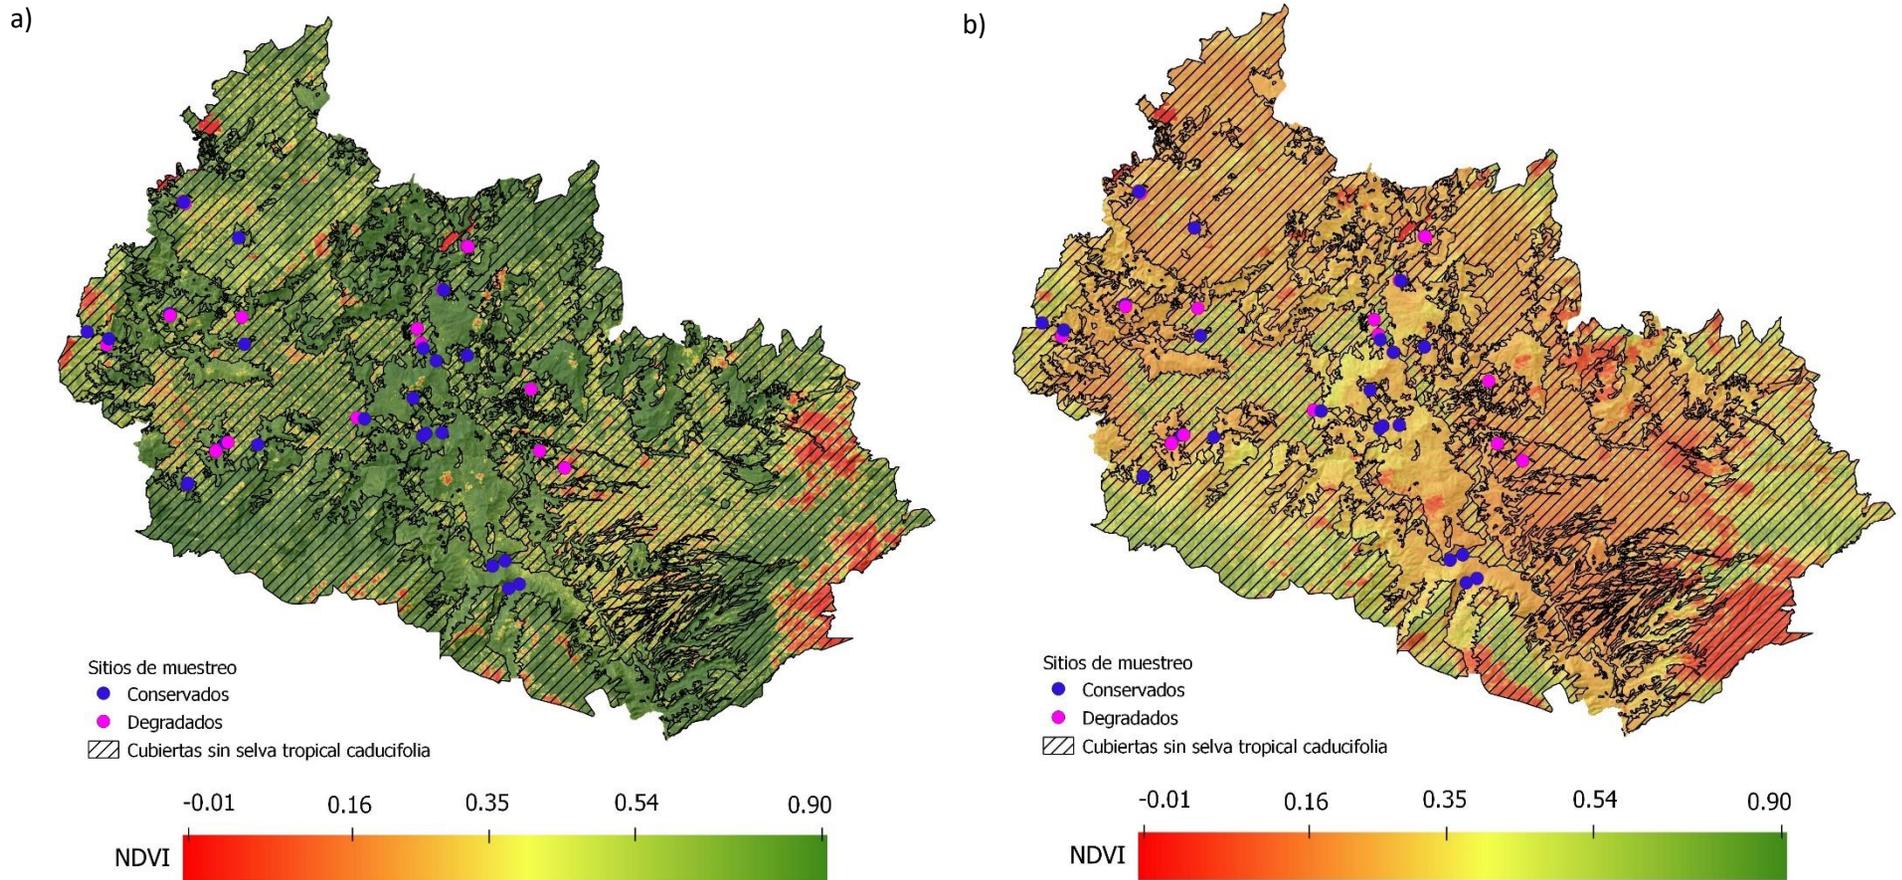
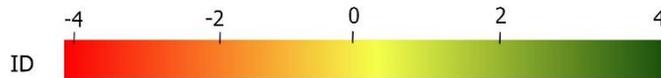
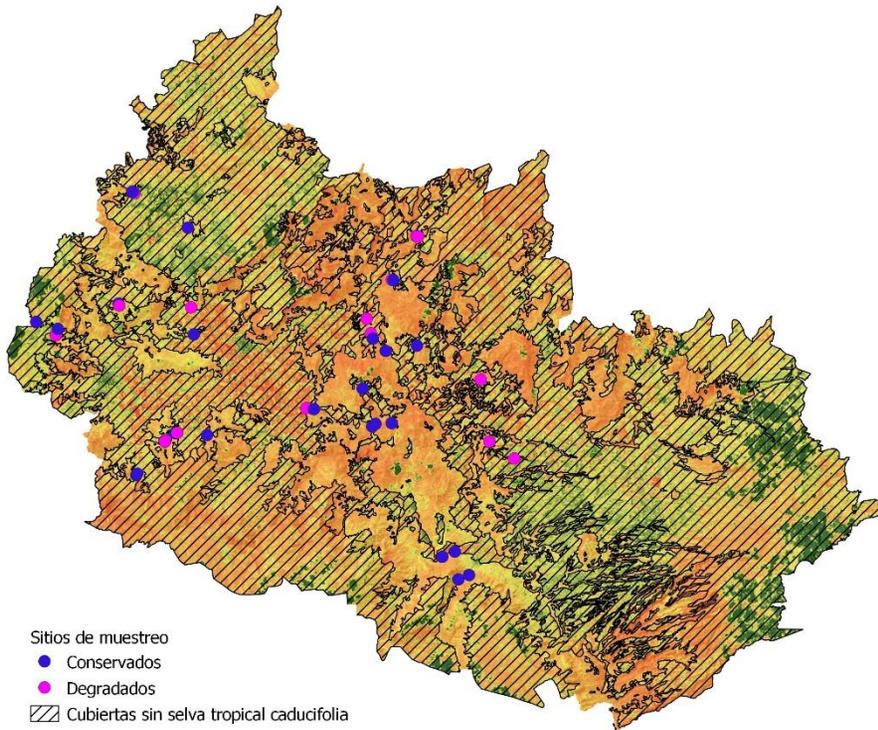


Figura 5. Índice de Vegetación por diferencia normalizado (NDVI) obtenido de Landsat 8 para la temporada de a) lluvias y b) secas. Los colores indican el nivel de verdor de la vegetación fotosintéticamente activa, teniendo en colores hacia el rojo los valores más bajos que indican zonas con poca vegetación verde y hacia tonos amarillos y verdes los vales más altos que indican zonas con vegetación verde. En la imagen a) de lluvias, las zonas muy rojas que están al este de la cuenca la cual corresponde a la zona más alta, corresponden a zonas con nubes. Al igual que la imagen b) en esa misma zona se localizan áreas de bosque de neblina lo cual impide tener imágenes libres de nubes. En la imagen b) se observan valores intermedios y bajos de tonos naranja y amarillo correspondiente a vegetación con pocas hojas y actividad fotosintética baja.

a)



b)

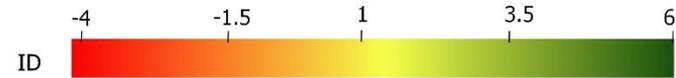
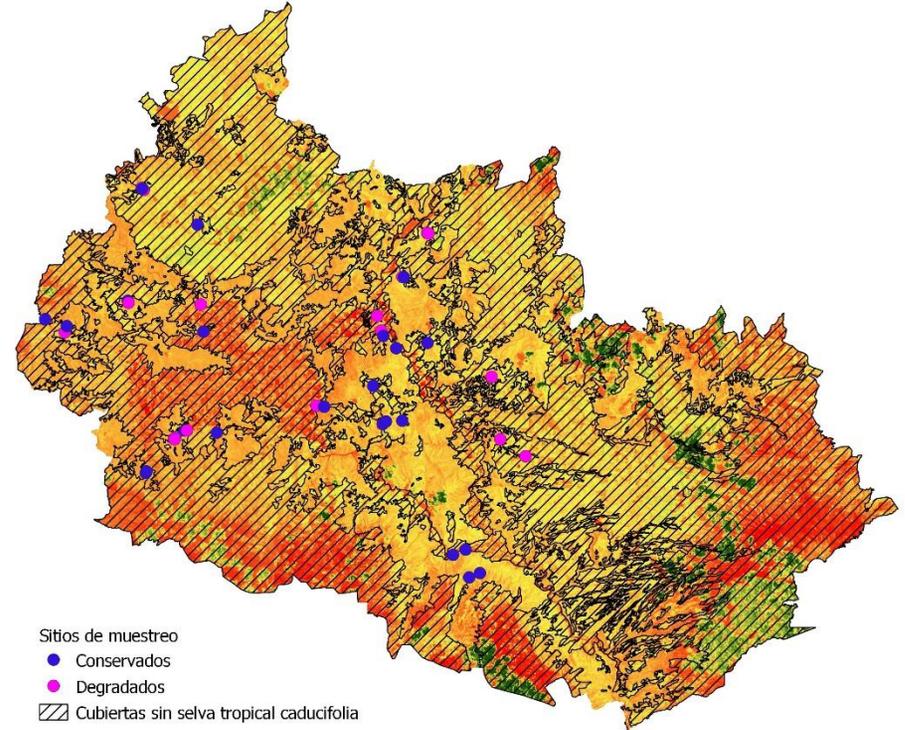
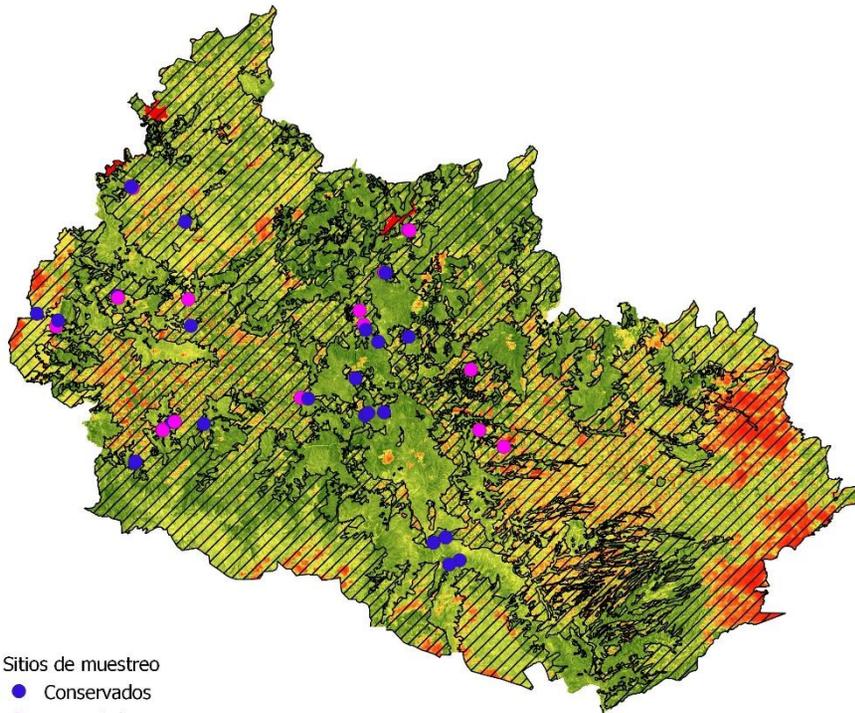
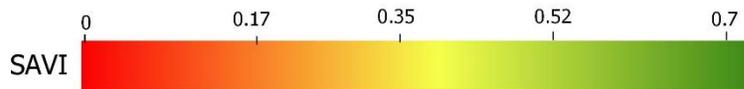


Figura 6. Índice de Disturbio (ID) obtenido de Landsat 8 para la temporada de a) lluvias y b) secas. Este índice indica que la escala de los valores refleja la desviación estándar de las capas transformadas (tasseled cap) para brillo, humedad y verdor. Los valores extremos negativos indican una menor cantidad de humedad y los valores extremos positivos indican mayor cantidad de brillo. Por lo tanto, los valores intermedios (cerca de 0) indican los píxeles de menor disturbio.

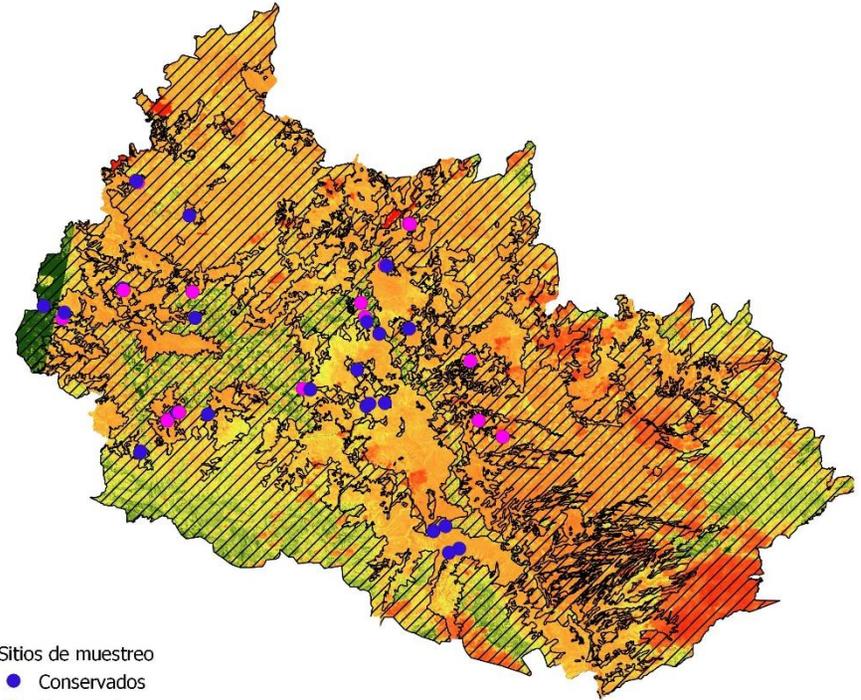
a)



Sitios de muestreo
● Conservados
● Degradados
▨ Coberturas sin selva tropical caducifolia



b)



Sitios de muestreo
● Conservados
● Degradados
▨ Coberturas sin selva tropical caducifolia

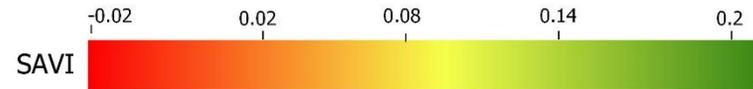


Figura 7. Índice de Vegetación Ajustada al Suelo (SAVI) obtenido de Landsat 8 para la temporada de a) lluvias y b) seca. Este índice también indica el nivel de verdor o vegetación fotosintética activa, quitando el efecto de la reflectancia del suelo. En la imagen a) de lluvias en valores más bajos se refieren a zonas con menor vegetación o nubes, mientras que las áreas amarillas a verde oscuro pertenecen a zonas con vegetación vigorosa. En la imagen b) de la temporada seca se aprecian niveles más bajos ya que la vegetación ha perdido casi todas sus hojas

4.2.3 Métricas texturales

A continuación, se muestran los resultados obtenidos de las métricas texturales para cada sitio, dividido entre tipo de selva, temporada (lluvias/secas) y comparando entre tipos de imágenes. Estos valores se extrajeron solo a partir del centroide de cada sitio, ya que el método para calcular las matrices de nivel de coocurrencia (GLCM) se hace a partir de una ventana móvil, lo cual hace que los valores por píxel sean el resultado de cálculos entre píxeles vecinos.

En los resultados obtenidos de los sitios conservados (figura 8 a) los valores de la imagen de Landsat-8 tiene un rango mayor para algunas métricas p. e. varianza de banda roja (R), promedio R, entropía de banda infrarroja cercana (IR) y contraste IR, en casi todos los resultados de estas métricas para los sensores ópticos hay presencia de valores extremos (*outliers*), aunque para cada sitio se revisó que no fuera afectado por distorsiones topográficas como sombreados. Por otro lado, entre las métricas existe una gran semejanza de valores promedios y su distribución, sobre todo los que corresponden a los sensores ópticos. Efecto que puede verse reflejado en la autocorrelación entre variables. Para la temporada de secas (figura 8 b) los valores que provienen de Sentinel-1 también son muy similares entre las bandas VH y VV, sin embargo, para algunas métricas se diferencian de los valores derivados de imágenes ópticas p. e. varianza, promedio, entropía, contraste.

Los resultados obtenidos de los sitios de selva degradada (figura 9 a y b) se observa un comportamiento similar de los sitios conservados. Por una parte, en la temporada de lluvias (figura 9 a) el rango de valores de Landsat-8 es más amplio para algunas métricas (p. e. varianza R, promedio R, contraste IR), sin embargo, la distribución y medias son muy cercanos a los valores de Sentinel-2. Para la temporada de secas (figura 9 b) algunas métricas de Sentinel-1 tienen un comportamiento distinto de los sensores ópticos, y cabe mencionar que, tanto para sitios degradados como conservados, los valores de retrodispersión de VV y VH son diferenciados entre bandas, es decir, es probable que aporten diferente tipo de información. Por otro lado, es muy probable que entre métricas la información aportada para los sitios sea redundante.

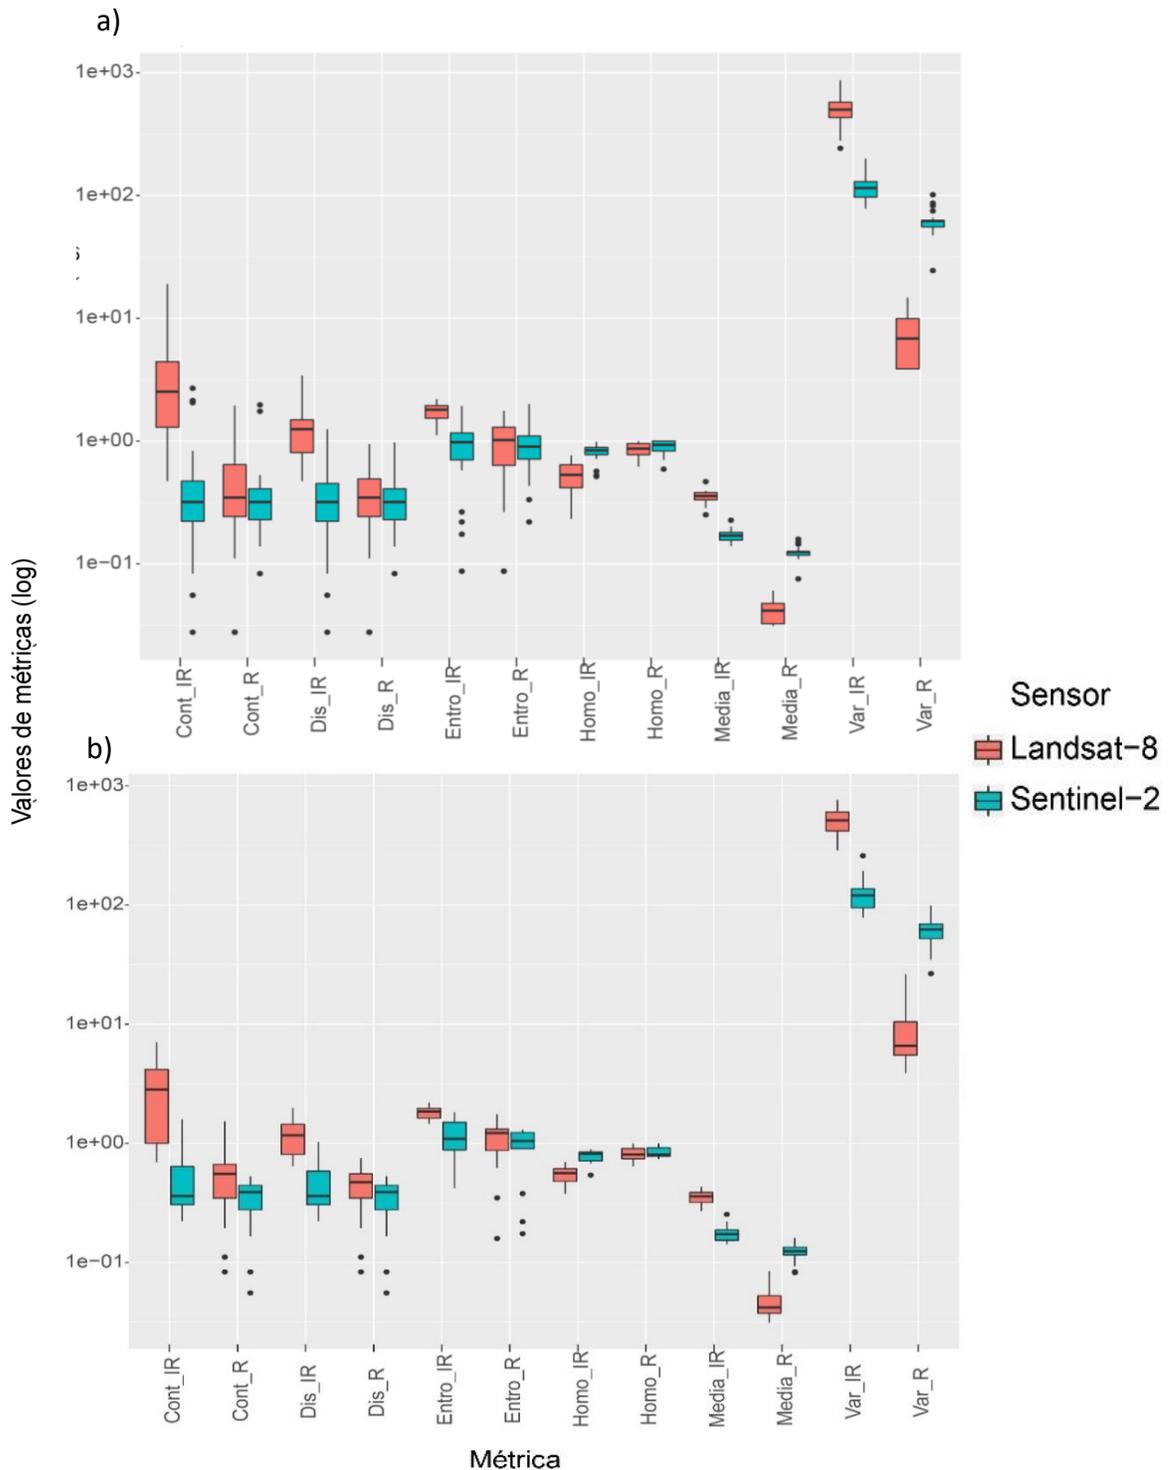


Figura 8. Métricas texturales obtenidos para los sitios muestreados en campo de bosque conservado. a) métrica textural de la temporada de lluvias y b) métrica textural de la temporada seca. Las métricas medidas fueron: Contraste (Cont), disimilaridad (Dis), entropía (Entro), homogeneidad (Homo), media, varianza (Var) de las bandas roja (R) e infrarroja cercana (IR), de las imágenes de Landsat 8 en color rojo y Sentinel-2 en azul. Los valores fueron obtenidos del centroide de cada parcela.

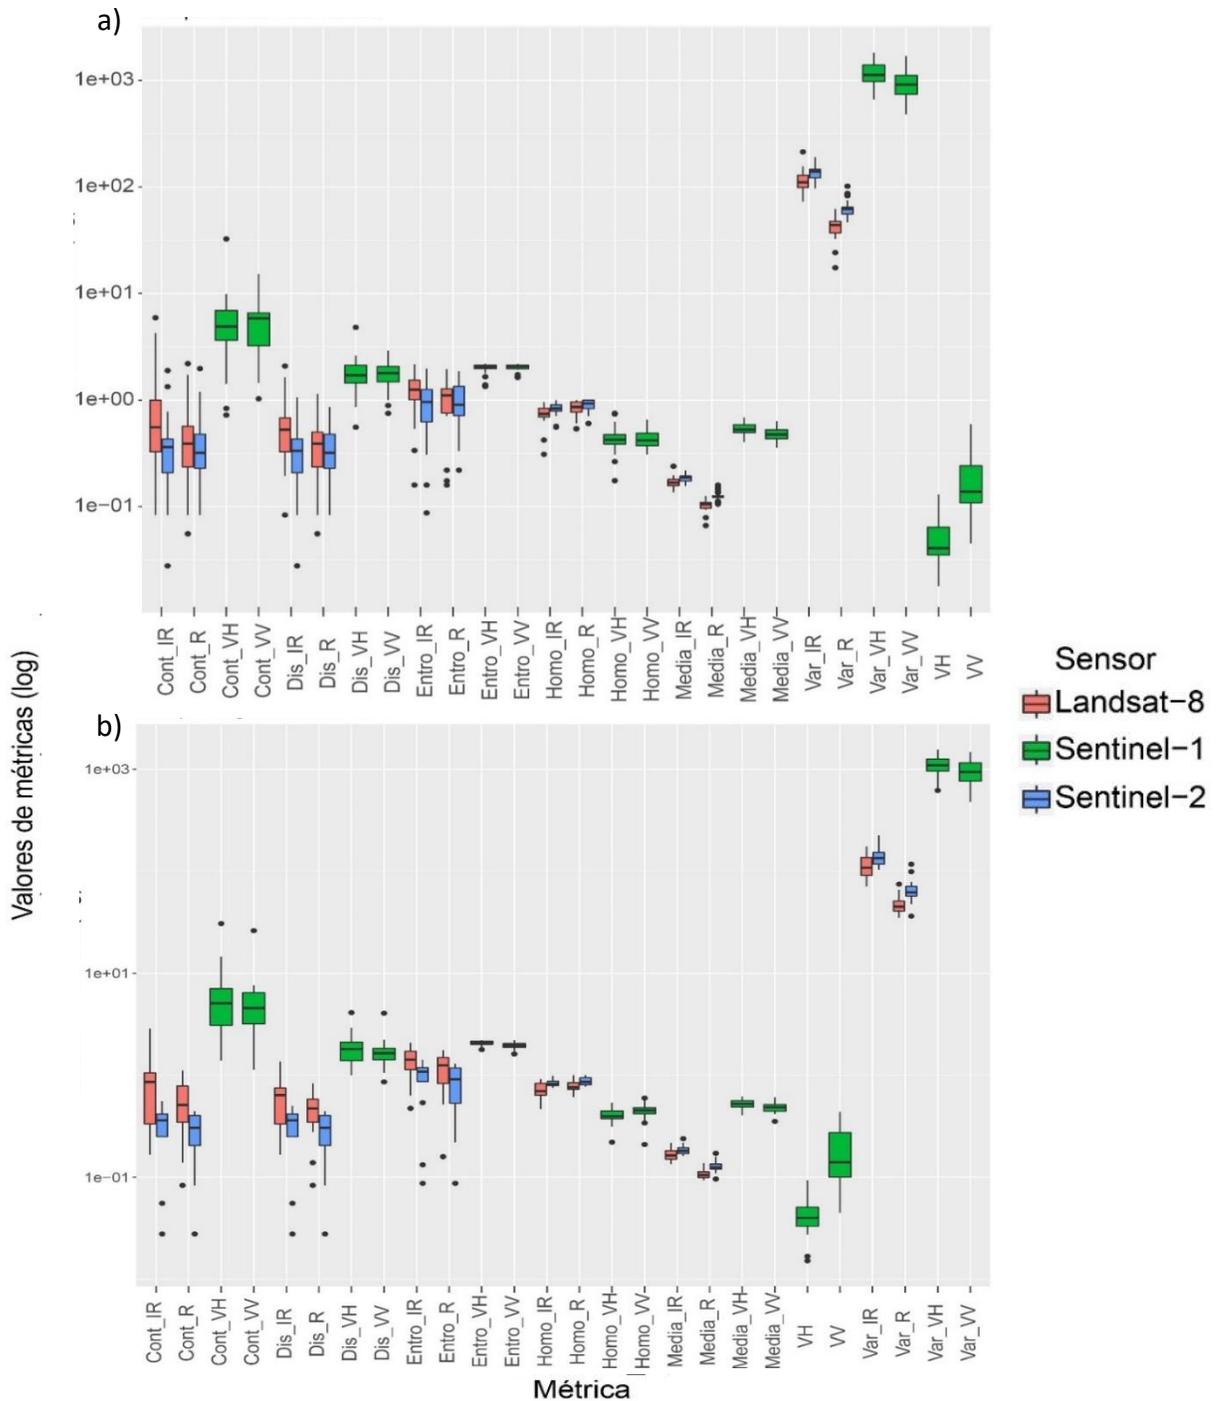


Figura 9. Métricas texturales obtenidos para los sitios muestreados en campo de bosque degradado, a) lluvias b) secas. Las métricas medidas fueron: contraste (Cont), disimilaridad (Dis), entropía (Entro), homogeneidad (Homo), media, varianza (Var) de las bandas roja (R) e infrarroja cercana (IR), de las imágenes de Landsat 8 en color rojo, Sentinel-2 en azul En las imágenes ópticas R la banda roja, IR se refiere a la banda infrarroja. En figura 10 b) la imagen de Sentinel-1 VV y VH son los valores de retrodispersión para dichos modos de captura.

4.3. Selección de variables espectrales

De acuerdo con el análisis de factor de inflación de varianza VIF (por sus siglas en inglés *variance inflation factor*), se descartaron las variables con valor de VIF >6 (tabla 3 a y b). Para evitar autocolinealidad entre variables, se mantuvo una máxima autocorrelación de $r = 0.63$ y mínima autocorrelación $r = -0.004$ para el grupo de variables correspondiente a los bosques conservados. Mientras que el grupo de variables de bosque degradado, máxima autocorrelación de $r = -0.7$ y mínima de $r = 0.008$. En total se descartaron 52 variables por cada agrupación es decir el 70% del total de variables.

Tabla 5. Resultados de las pruebas VIF para todas las variables espectrales. a) Bosques conservados y b) Bosques degradados. Para ambos tipos de bosque se consideraron variables de la temporada de lluvia y seca. En total se calcularon 74 variables espectrales para ambos tipos de bosque, posterior a este análisis quedaron 22 para cada grupo.

a) Bosques conservados			b) Bosques degradados		
Sensor	Variable/ Temporada	VIF	Sensor	Variable/ Temporada	VIF
Landsat-8	NDVI / Secas	2.33	Landsat-8	NDVI / Lluvia	1.56
Landsat-8	SAVI / Secas	1.96	Landsat-8	NDVI / secas	1.58
Landsat-8	ID / Lluvia	1.23	Sentinel-2	NDVI / secas	2.37
Sentinel-2	NDVI / Lluvia	2.13	Sentinel-2	SAVI / secas	2.24
Sentinel-2	SAVI / Secas	2.66	Sentinel-2	ID / secas	1.51
Sentinel-2	ID / Secas	1.31	Landsat-8	Disimilaridad B4 / Lluvia	4.08
Landsat-8	Entropía B4 / Lluvia	5.95	Landsat-8	Promedio B4 / Lluvia	5.09
Landsat-8	Varianza B4 / Lluvia	3.22	Landsat-8	Entropía B5 / Lluvia	5.41
Landsat-8	Varianza B5 / Lluvia	1.73	Landsat-8	Promedio B5 / secas	4.56
Landsat-8	Contraste B5 / Lluvia	1.72	Landsat-8	Promedio B4 / secas	2.63
Sentinel-2	Varianza B4 / Lluvia	2.69	Landsat-8	Homogeneidad B5 / secas	5.00
Sentinel-2	Varianza B8 / Lluvia	2.54	Sentinel-2	Homogeneidad B4 / Lluvia	2.11
Landsat-8	Entropía B4 / Secas	4.31	Sentinel-2	Homogeneidad B8 / secas	1.32
Landsat-8	Promedio B4 / Secas	3.80	Sentinel-2	Homogeneidad B8 / secas	1.61
Landsat-8	Varianza B4 / Secas	2.55	Sentinel-1	Homogeneidad VH / Secas	4.72
Sentinel-2	Homogeneidad B4 / Secas	2.68	Sentinel-1	Entropía VH / Secas	2.14
Sentinel-1	Entropía VH / Secas	1.72	Sentinel-1	Contraste VV / Secas	1.71
Sentinel-1	Contraste VH / Secas	1.60	Sentinel-1	Retrodispersión VH / Secas	3.06
Sentinel-1	Entropía VV / Secas	4.29	Sentinel-1	Retrodispersión VV / Secas	2.24
Sentinel-1	Contraste VV / Secas	4.82			
Sentinel-1	Retrodispersión VH / Secas	2.01			
Sentinel-1	Retrodispersión VV / Secas	2.66			

4.4. Modelación de variables de bosque con percepción remota

Se ajustaron diferentes modelos lineales múltiples (*Multiple Linear Model*, MLM) para diferentes grupos de variables: variables por tipo de sensor, por temporada (lluvias y secas) y considerando todos los sitios de muestreo y agrupando por tipo de bosque (degradado y conservado).

Los resultados aquí mostrados fueron los modelos más plausibles, es decir que tuvieron mayor capacidad explicativa de las variables de campo. Se encontró que en el modelo que considera todos los sitios (bosque degradado y conservado), las variables espectrales, índice de disturbio (ID) y la métrica varianza de la imagen Sentinel-2, explicaron mejor la variabilidad de cobertura del dosel ($R^2= 0.68$, AIC= 12.02, tabla 6a). El modelo que le siguió fue el modelo de dos variables explicativas simple, combinando las variables de NDVI de Sentinel-2 y el ID de Landsat 8 ($R^2=0.42$, AIC= 181)

Mientras que los modelos ajustados por tipo de bosque (bosque degradado o bosque conservado) también tuvieron resultados significativos. Para los sitios de bosque degradado las variables espectrales describieron mejor la cobertura de dosel ($R^2= 0.77$, AIC= 142.9) el modelo con tres variables explicativas. Le siguió densidad de árboles ($R^2= 0.78$, AIC= 142.95). Y seguido por el modelo que describe biomasa aérea sobre el suelo ($R^2= 0.72$, AIC= 122.22) presentado en la tabla 6b. Mientras que para los sitios de bosque conservado se describió con más precisión la densidad de árboles ($R^2= 0.61$, AIC= -31.98) presentado en la tabla 6c.

Tabla 6 Resumen de los modelos lineales múltiples con mejor desempeño del grupo de variables a) considerando todos los sitios, b) bosque degradado y c) bosque conservado. Se tomaron en cuenta los modelos con el coeficiente de determinación $R^2 > 0.6$ y el menor valor Akaike (AIC). Las abreviaciones de los sensores Sentinel-2 (S2), Landsat-8 (L8), Sentinel-1 (S1) y las temporadas lluvias, secas. Mientras que el signo positivo (+) y negativo (-) corresponden a la asociación de cada variable explicativa con la variable dependiente dada por la pendiente de la regresión.

Modelo a) Bosque degradado y conservado					
	<i>Variable independiente</i>	Variables explicativas	Temporada	R²	AIC
Ec 6	<i>Densidad de árboles</i>	(+) NDVIs ₂	Lluvias	0.428	181.62
		(-) ID _{L8}			
Ec 7	<i>Cobertura</i>	(+) ID _{S2}	Secas	0.68	12.02
		(-) Vars ₂ B8	Lluvias		
Ec 8	<i>Cobertura</i>	(-) ID _{S2}	Secas	0.34	-129.44
		(+) Ent _{L8} B5	Secas		
		(-) Cont _{s1} VH	Secas		
b) Bosque degradado					
Ec 7	<i>Densidad de árboles</i>	(-) NDVI _{L8}	Secas	0.78	142.95
		(+) VV _{S1}	Secas		
Ec 6	<i>Cobertura</i>	(+) NDVIs ₂	Secas	0.61	-11.79
		(-) ID _{S2}	Secas		
Ec 7	<i>Biomasa aérea</i>	(+) Homos ₁ B4	Secas	0.72	122.22
		(+) Entros ₂ VH	Secas		
Ec 8	<i>Cobertura</i>	(-) ID _{S2}	Secas	0.77	142.9
		(-) NDVI _{S2}	Secas		
		(+) Entros ₁ VV	Secas		
Ec 8	<i>Biomasa aérea</i>	(+) Mean _{L8} B4	Secas	0.61	128.32
		(-) Homo _{L8} B8	Secas		
		(+) VV _{S1}	Secas		
c) Bosque conservado					
Ec 6	<i>Densidad de árboles</i>	(+) NDVIs ₂	Lluvias	0.42	-116.67
		(-) ID _{L8}	Lluvias		
Ec 7	<i>Densidad de árboles</i>	(-) L81ID	Lluvias	0.58	-30.45
		(-) VV _{S1}	Secas		
Ec 8	<i>Densidad de árboles</i>	(-) NDVI _{L8}	Secas	0.61	-31.98
		(-) NDVI _{S2}	Lluvias		
		(+) ID _{L8}	Lluvias		

4.4.1 Mapeo de atributos de la vegetación

A continuación, se mostrarán los resultados de los modelos con mejor desempeño mostrados en la tabla 4. Se proyectaron los modelos con mayor coeficiente de determinación por cada grupo de datos (bosques degradados, conservados y ambos), así como el mejor modelo para cada atributo de la vegetación.

- *Cobertura del dosel de bosques degradados y conservados*

En la figura 10 se muestra de forma gráfica la comparación entre los datos medidos en campo y los que proyecta el modelo. Se puede apreciar que, aunque no tienen un ajuste lineal, si se mantiene la tendencia entre los bosques conservados y degradados, es decir, que los conservados se agrupan hacia valores más altos de cobertura (>75%) mientras que los degradados se encuentran más dispersos debido a su alta variación mostrada en la tabla 4.

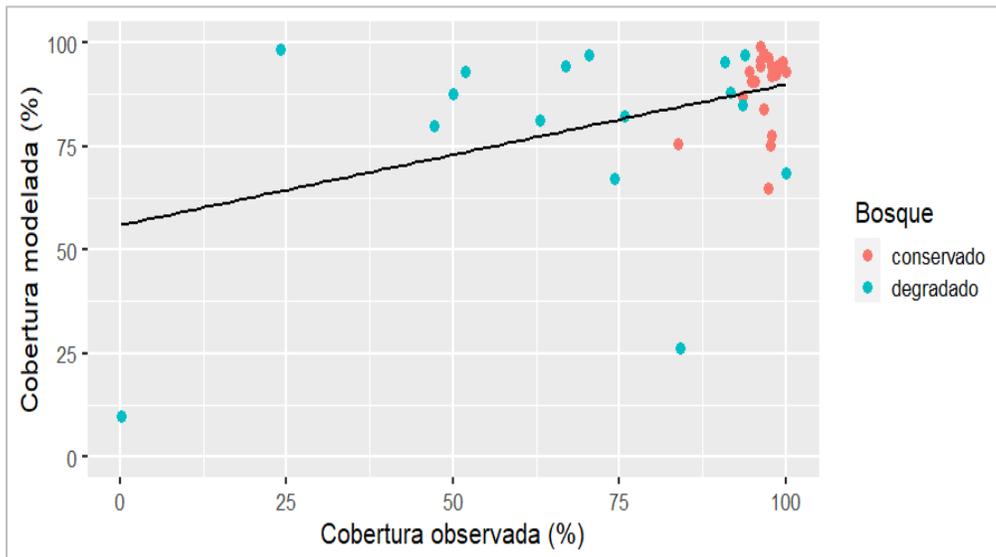


Figura 10 Comparación de datos medidos en campo (eje X) contra datos modelados (eje Y) basado en el modelo con ambos tipos de bosque ($R^2= 0.19$, $ECM= 22.43$).

Posteriormente se encuentra en la figura 12 el modelo espacializado para el total de área de bosque tropical caducifolio (BTC) de la cuenca de Ayuquila. El gradiente de color representa el porcentaje del dosel que va de 0 a 100% así como en la parte

inferior de la barra se muestra una clasificación del nivel de porcentaje (bajo, intermedio bajo, intermedio, intermedio alto y alto).

En general se puede apreciar que predominan las tonalidades que van de la cobertura intermedia alto a la cobertura alta, aunque hay áreas en donde predominan los tonos amarillos de coberturas intermedias a bajas. Esto principalmente en áreas de bosques aislados, así como pies de monte y orillas que pueden ser fronteras con otros tipos de cubiertas. Sin embargo, los gradientes de cobertura bajas también se encuentran hacia las pendientes con orientación oeste-este, es decir la pendiente con mayor tiempo de cara al sol. Por otro lado, las zonas con mayor cobertura de acuerdo con este modelo se encuentran en zonas de áreas continuas de bosque, más homogéneas y hacia las zonas con mayor altitud lo cual puede coincidir con lo observado en campo.

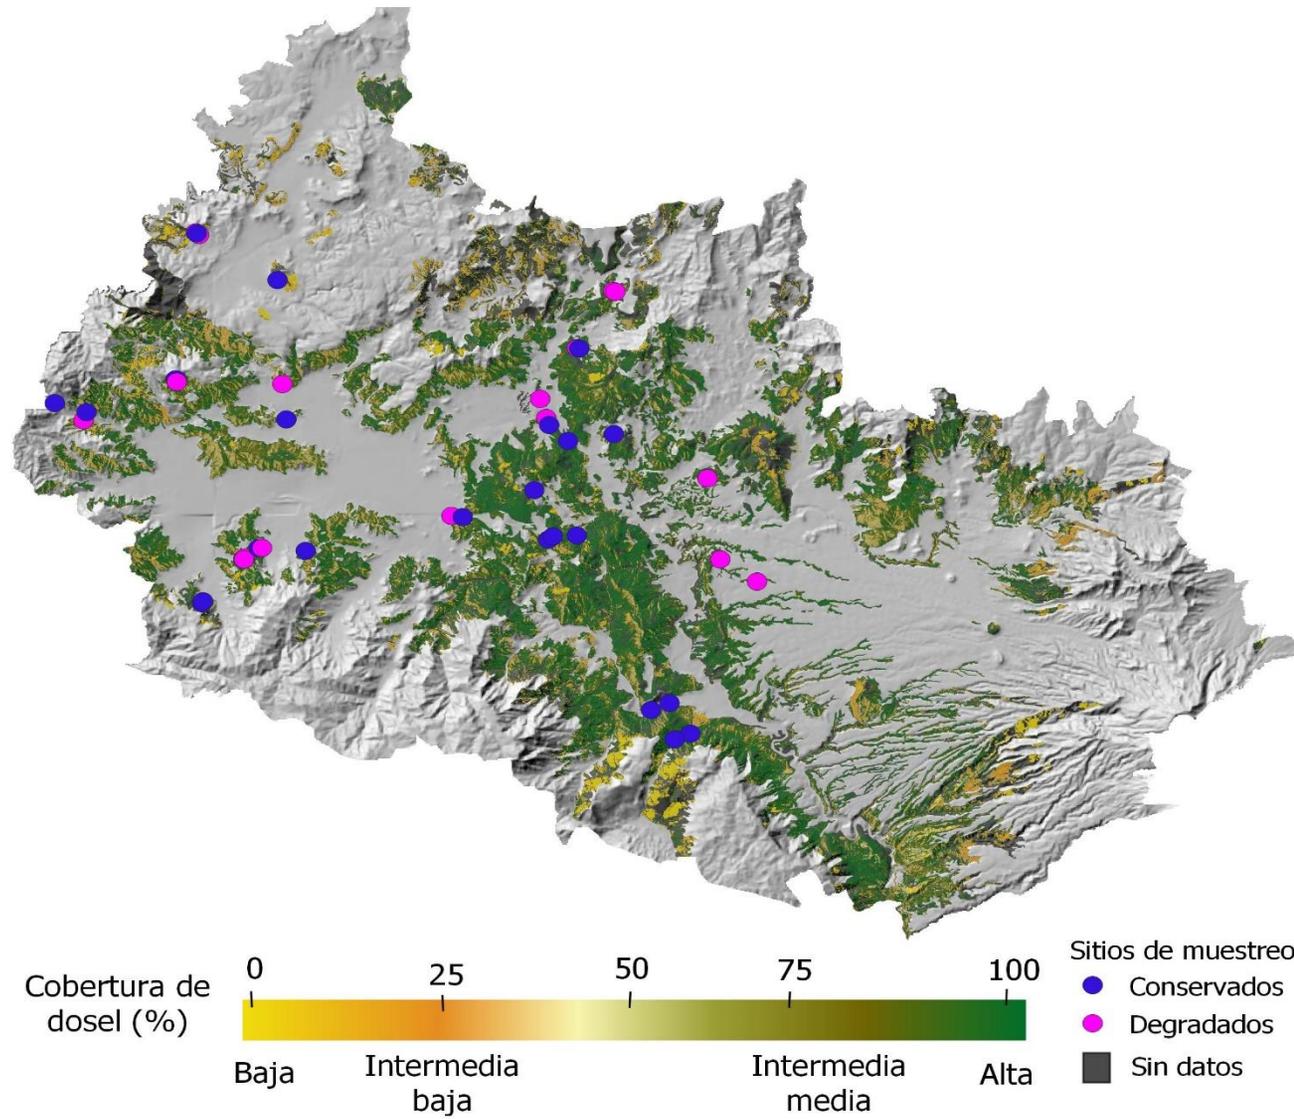


Figura 11 . Mapeo de cobertura del dosel de la selva tropical caducifolia basado en el modelo con ambos tipos de bosque. La barra inferior representa el porcentaje de cobertura clasificado en baja, intermedia baja, intermedia, intermedia alta y alta. Los puntos azules representan los sitios de bosque conservado y los rojos los de bosque degradado. Este modelo se realizó a partir del índice de disturbio (ID, Sentinel-2) y la métrica textural varianza de la banda infrarroja (Sentinel-2).

4.4.2. Mapeo de atributos del bosque degradado

- *Densidad de árboles por área*

En la figura 12 se muestran los valores medidos respecto a los predichos por el modelo. En este modelo se puede apreciar un ligero ajuste de los resultados esperados. Sin embargo, no se encuentran totalmente alineados, sobre todo en los valores más altos de densidad de árboles medida. Es decir, este modelo se ajusta mejor en intervalos de densidad menores.

Por otra parte, en la figura 13 se aprecia de forma espacializada el modelo de densidad para los bosques degradados, considerando que el rango de valores de densidad que tienen estos bosques es de 0.2 a 0.12 (tabla 1) es este rango con el que el modelo tiene mejores predicciones, por lo tanto, el rango de valores proyectados de ajuste a este mismo.

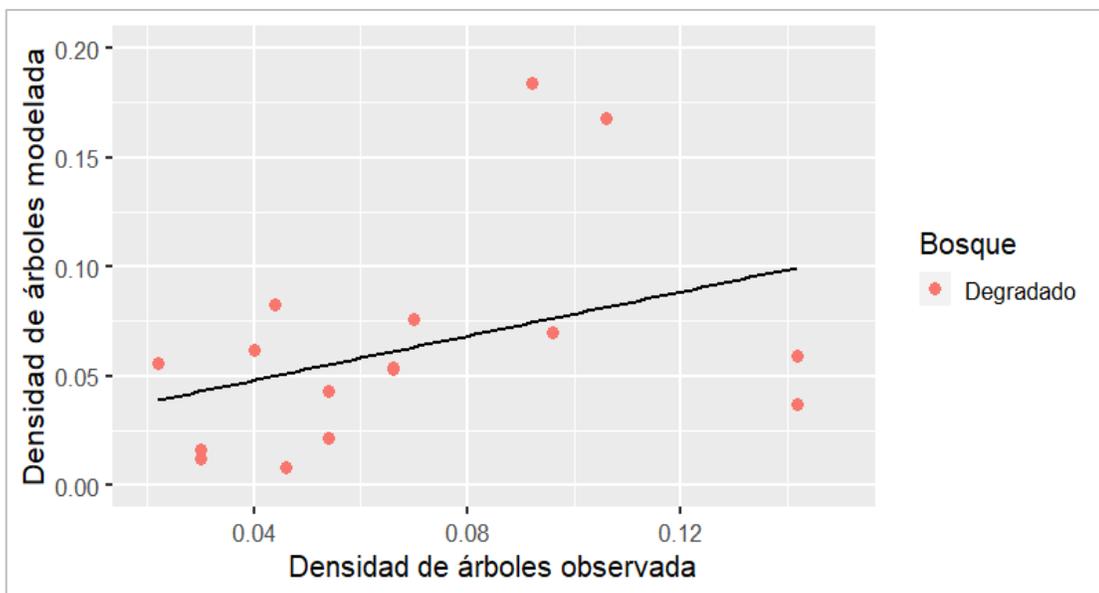


Figura 12 Comparación de datos de densidad medidos (eje X) contra los modelados (eje Y) basado en el modelo de bosques degradados con $R^2=0.14$, $ECM= 0.04$

Teniendo como resultado de manera general que predominan áreas con densidad intermedia a intermedia baja, y solo algunas áreas más pequeñas pero presentes

en toda el área de bosque de densidades altas. Las áreas de alta densidad de árboles se muestran principalmente en zonas de barrancas, en donde hay mayor acumulación de humedad. Mientras que las densidades menores están en pies de monte y parches de vegetación discontinua. Una observación importante de este modelo es su limitación para proyectar áreas con valores extremos altos o pequeños, es decir en zonas de bosque muy denso no fue posible proyectar valores coherentes, así como zonas con escasa o nula vegetación, lo cual se esperaba de acuerdo con la información obtenida en campo.

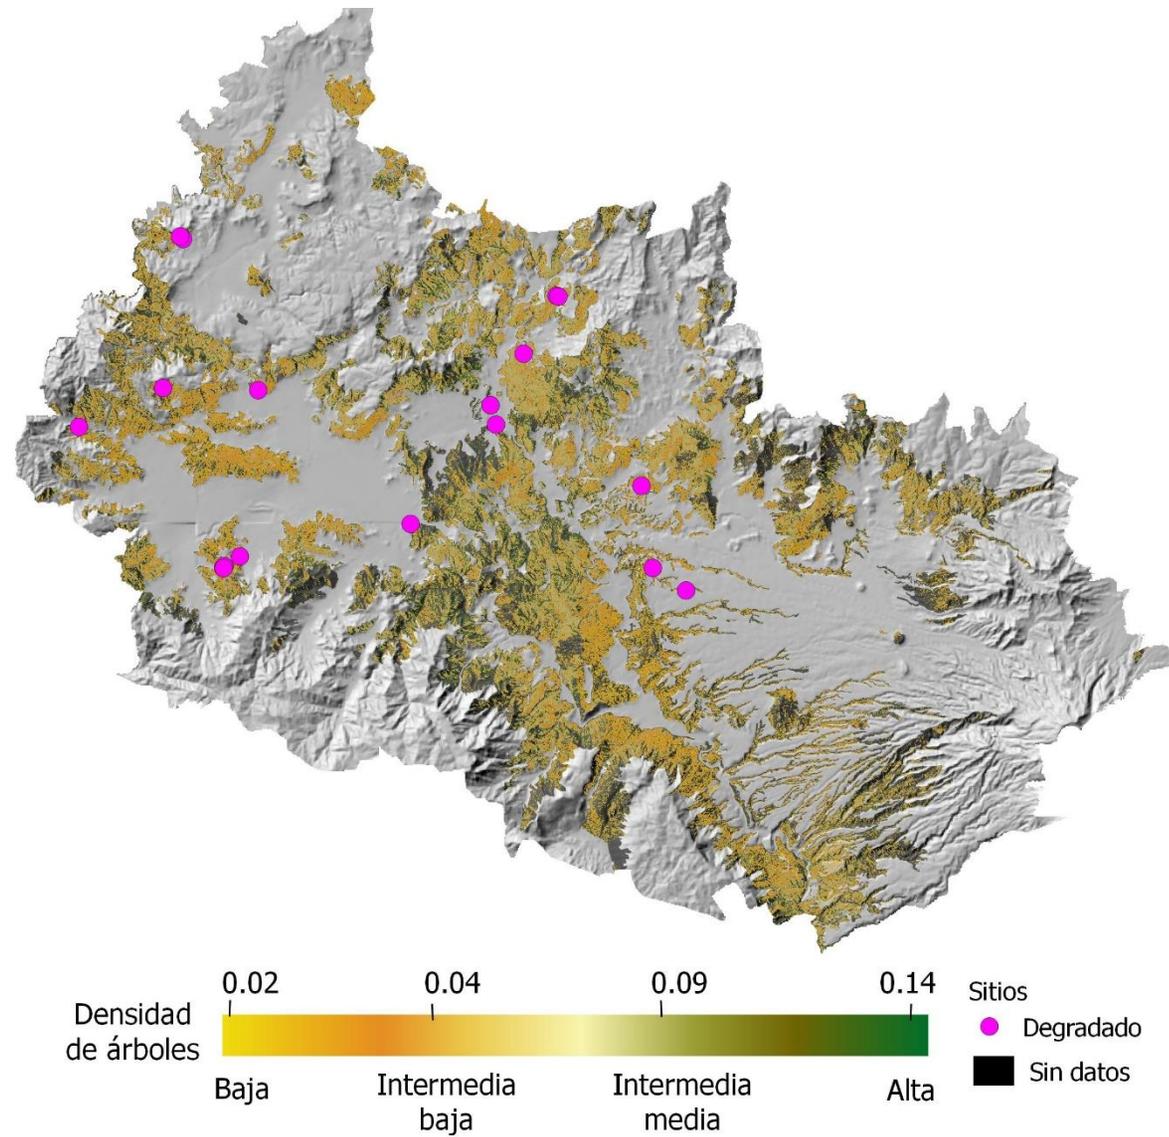


Figura 13. Proyección de modelo para densidad de árboles basado en datos de bosque degradado ($R^2= 0.78$). Hecho a partir de información del índice de vegetación por diferencia normalizada (NDVI, Landsat-8 y Sentinel-2) y los valores de retrodispersión de radar en modo VV (Sentinel-1).

- *Cobertura del dosel para bosques degradados*

Para modelar la cobertura del dosel se incorporaron datos del índice de disturbio, el índice de vegetación por diferencia normalizada (NDVI) y la métrica textural entropía, estos datos de los satélites Sentinel-2 y Sentinel-1. En la figura 14 se observan los valores medidos contra los proyectados, en donde se aprecia una tendencia lineal positiva, aunque con moderada dispersión ya que en sitios con cobertura aproximada a 75% el modelo proyectó menos del 50%.

Por otro lado, en la figura 15 esta representado el modelo para la cubierta de selva caducifolia de la cuenca. Se observa que predominan los colores que van del 50% al 75% y 100%, hay una mezcla heterogénea entre las áreas amarillas y verdes, esto posiblemente al nivel de detalle que ofrecen las imágenes Sentinel 1 y 2 con resolución espacial de 10 m ambas. En tonalidades rojas se identifican las áreas de menor cobertura, las cuales se identifican principalmente en los límites de las selvas, y se logran apreciar en combinación con los píxeles de valores 25 y 50. Es decir, los resultados son coherentes con los que se pueden ver en la realidad ya que se esperan áreas con mayor perturbación en zonas más accesibles o cercanas a áreas agrícolas o poblados.

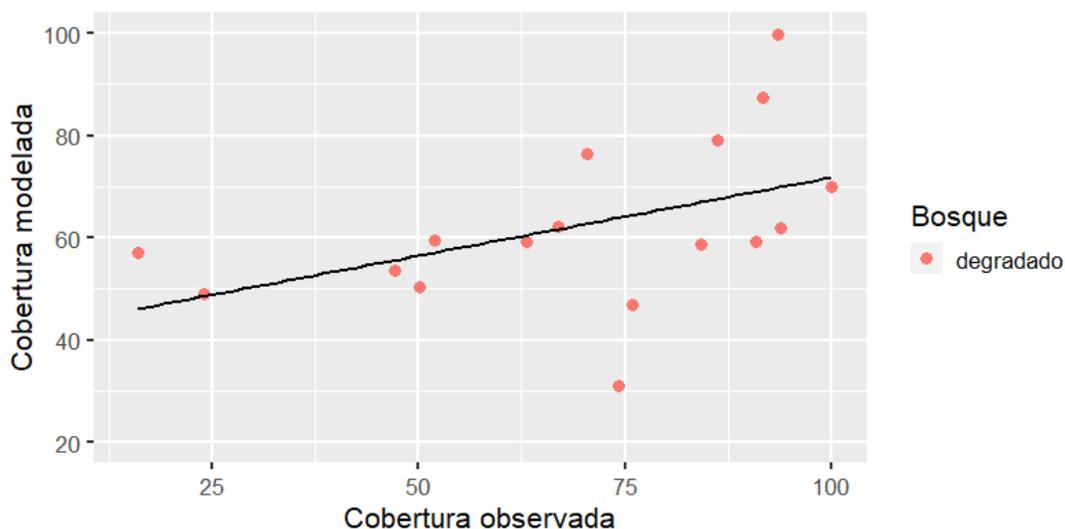


Figura 14 Comparación de datos de cobertura del dosel medidos (eje X) contra los modelados (eje Y) basado en el modelo de bosques degradados con $R^2= 0.21$, EMC= 22.82

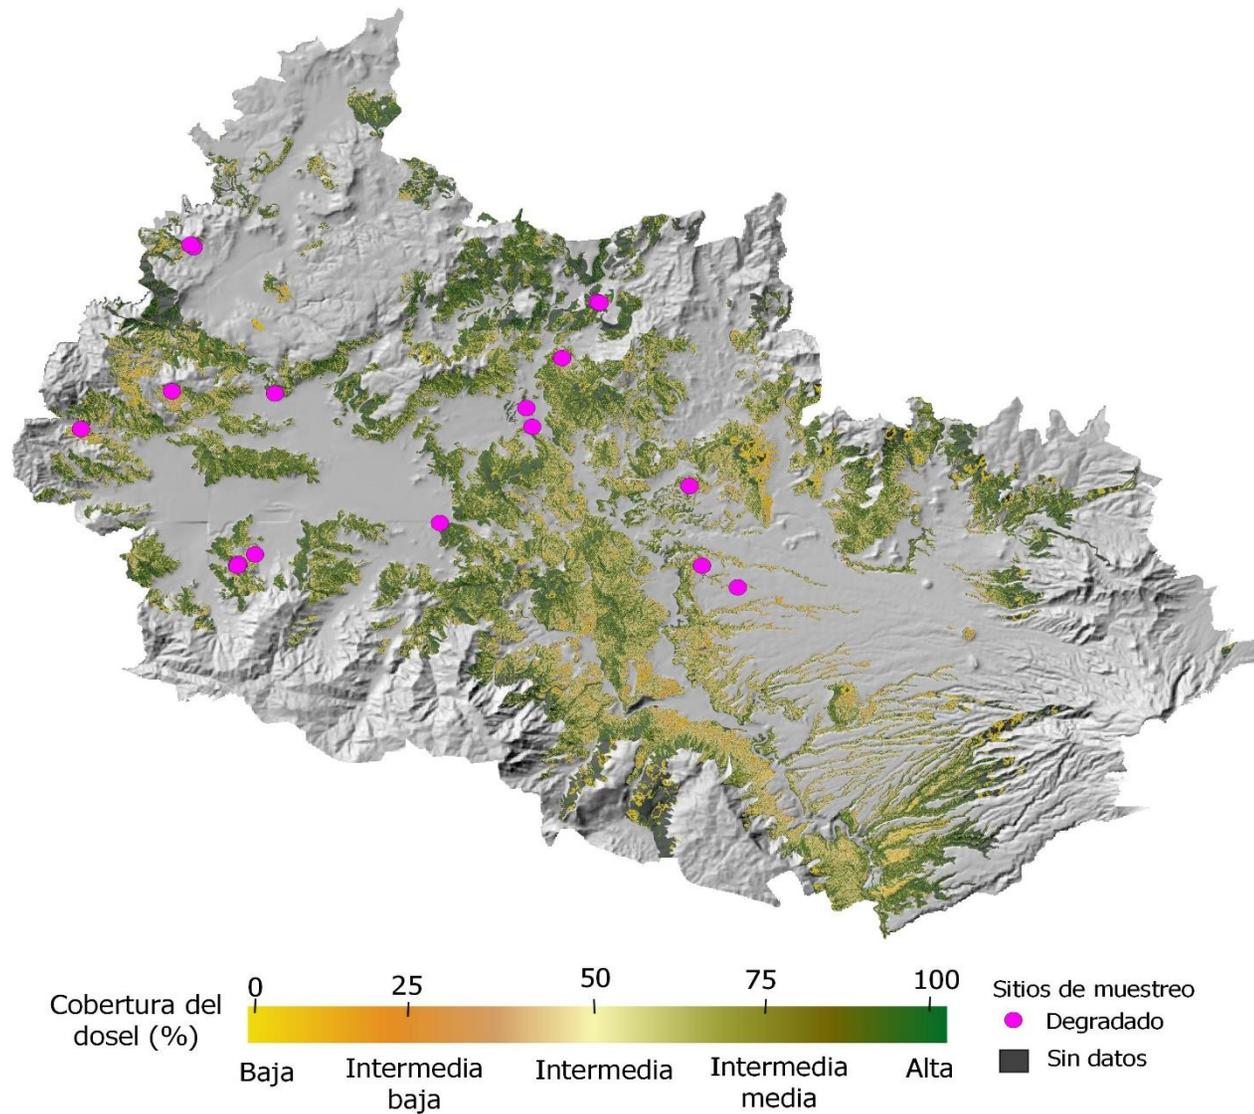


Figura 15. Proyección de modelo para cobertura del dosel basado en datos de bosque degradado ($R^2= 0.77$). Hecho a partir de información del índice de degradación (ID, Sentinel-2), índice de vegetación por diferencia normalizada (NDVI, Sentinel-2) y la métrica de textura entropía (VV, Sentinel-1).

- Biomasa aérea sobre el suelo para bosques degradados

En el modelo de este atributo de vegetación se incorporaron variables espectrales de los valores de homogeneidad y entropía de Sentinel 2 y 1. En la figura 16 se presentan los valores medidos contra los proyectados, esta comparación presenta una alta variación entre los valores 20 y 40 Mg, coincidiendo con el rango de valores de los sitios degradados que van de 8.4 a 57.8 Mg/ha. A pesar de estos errores se aprecia una tendencia lineal positiva.

Respecto al modelo espacializado que se observa en la figura 17 se aprecia una tonalidad similar homogénea en la selva, que va de los valores 7 a 30 Mg. Y en tonalidades blancas a azules se encuentran más dispersos y distribuidos heterogéneamente.

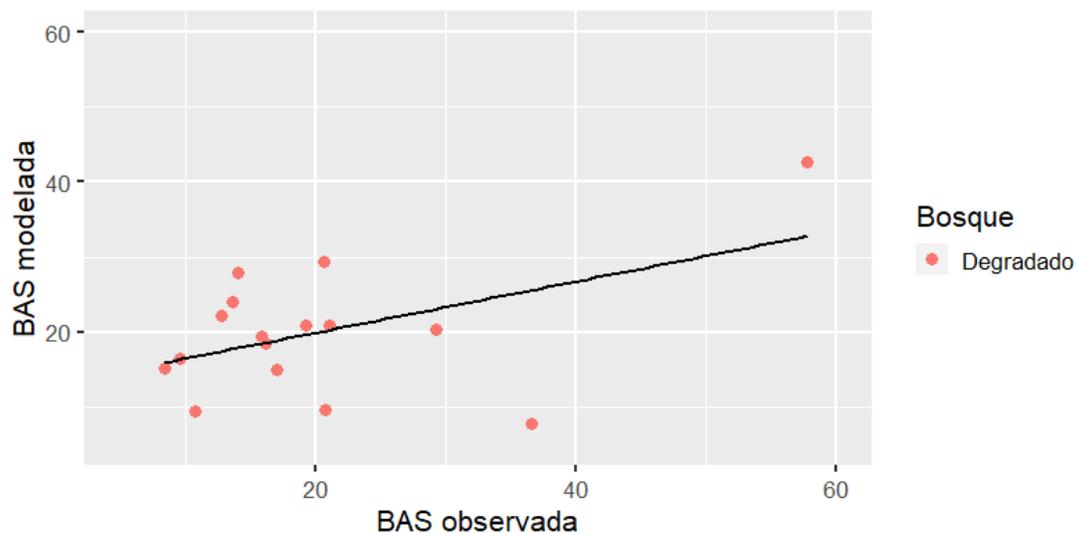


Figura 16. Comparación de datos de biomasa aérea sobre el suelo medida (eje X) contra la modelada (eje Y) basado en el modelo de bosques degradados con $R^2= 0.72$. $R^2= 0.49$, RMSE= 8.33.

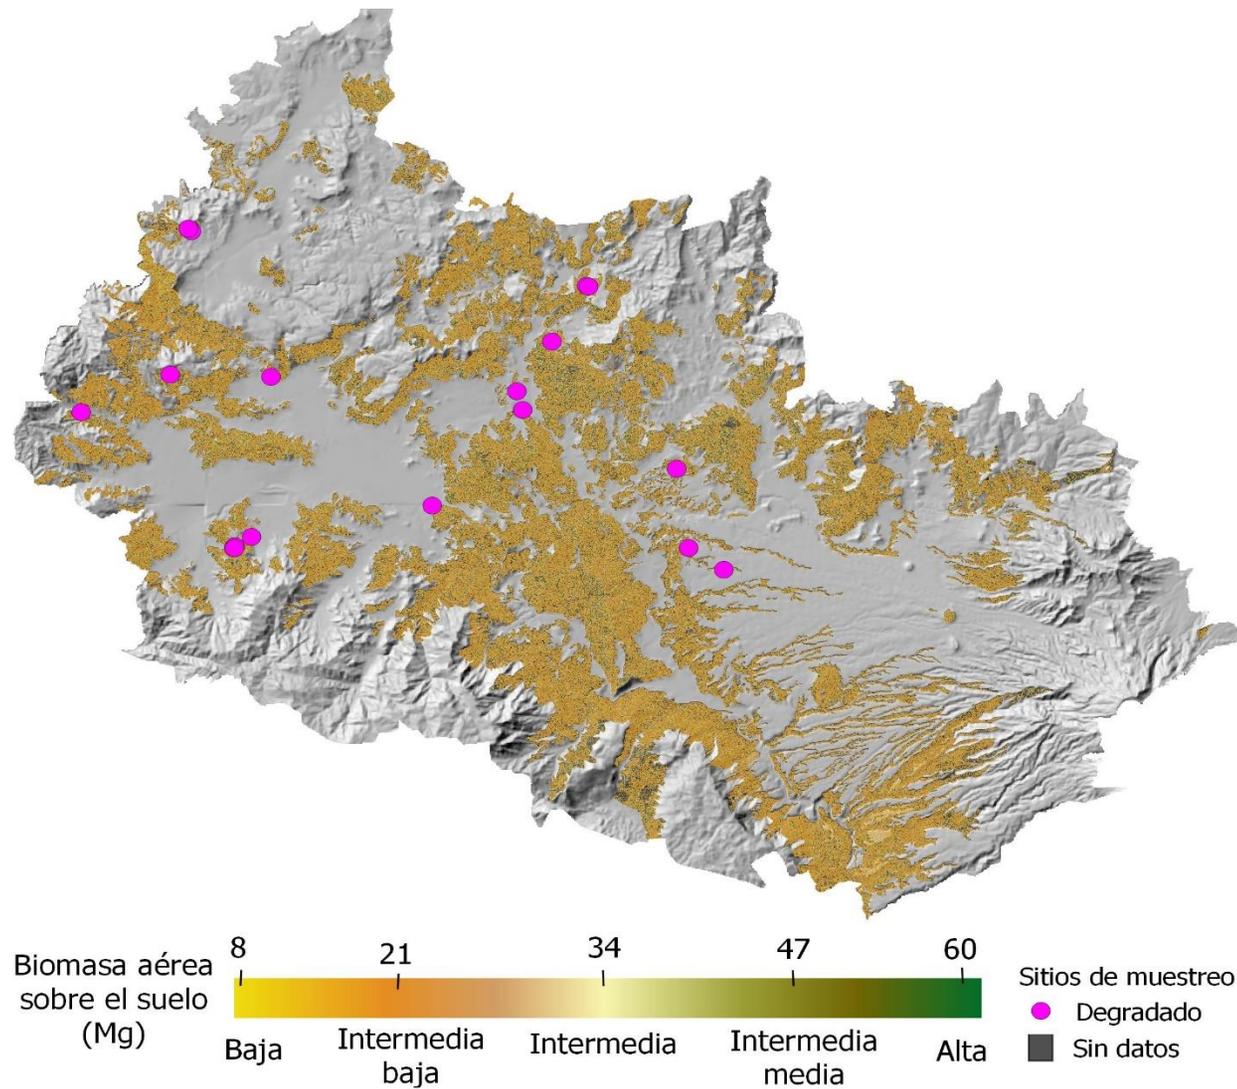


Figura 17 Proyección de modelo para biomasa basado en datos de bosque degradado ($R^2= 0.72$). Hecho a partir de información de la métrica de textura homogeneidad de la banda roja (Sentinel-2) y la métrica entropía de VH (sentinel-1)

4.4.3. Mapeo de atributos del bosque conservado

- *Detección de densidad de árboles para bosque conservado*

El modelo que describió mejor la densidad de árboles combinando las variables de $NDVI_{L8}$, $NDVI_{S2}$ y el ID_{L8} . En la figura 18 se muestra la comparación de las variables medidas contra las modeladas, a pesar de haber dispersión entre valores, es posible ver la asociación entre valores. Además de tener el mismo rango de valores ambas densidades y correspondiendo al rango limitado por el mínimo y máximo de los muestreados (0.02 a 0.12).

Respecto a la figura 19 en donde se muestra el valor proyectado para la selva de toda la cuenca, se observan valores homogéneos que están entre 0.06 a 0.09 que están en tonos amarillo y verde, correspondiendo con densidades intermedias. Mientras que los valores más bajos, se localizan en manchones cercanas a las orillas del límite de la selva, así como en barrancos y parches de vegetación aisladas. Por otro lado, hay zonas con valores más altos hacia el norte de la cuenca. Esto puede ser un efecto de la diferencia entre imágenes de Sentinel-2 y de Landsat-8 ya que se usaron estas imágenes en lluvia y en secas al mismo tiempo.

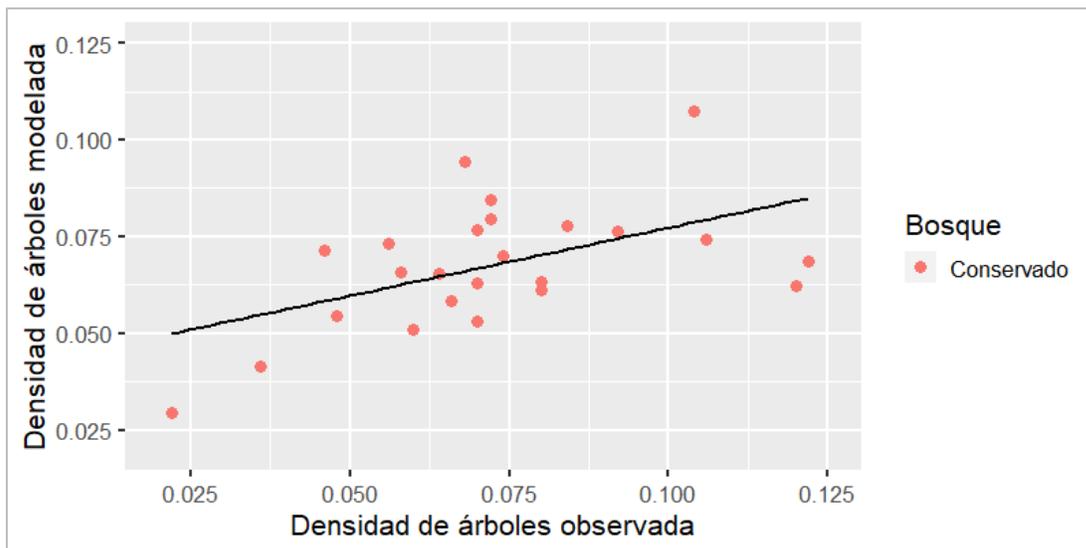


Figura 18 Comparación de datos de densidad de árboles medida (eje X) contra la modelada (eje Y) basado en el modelo de bosques conservados con $R^2= 0.27$. EMC=0.021

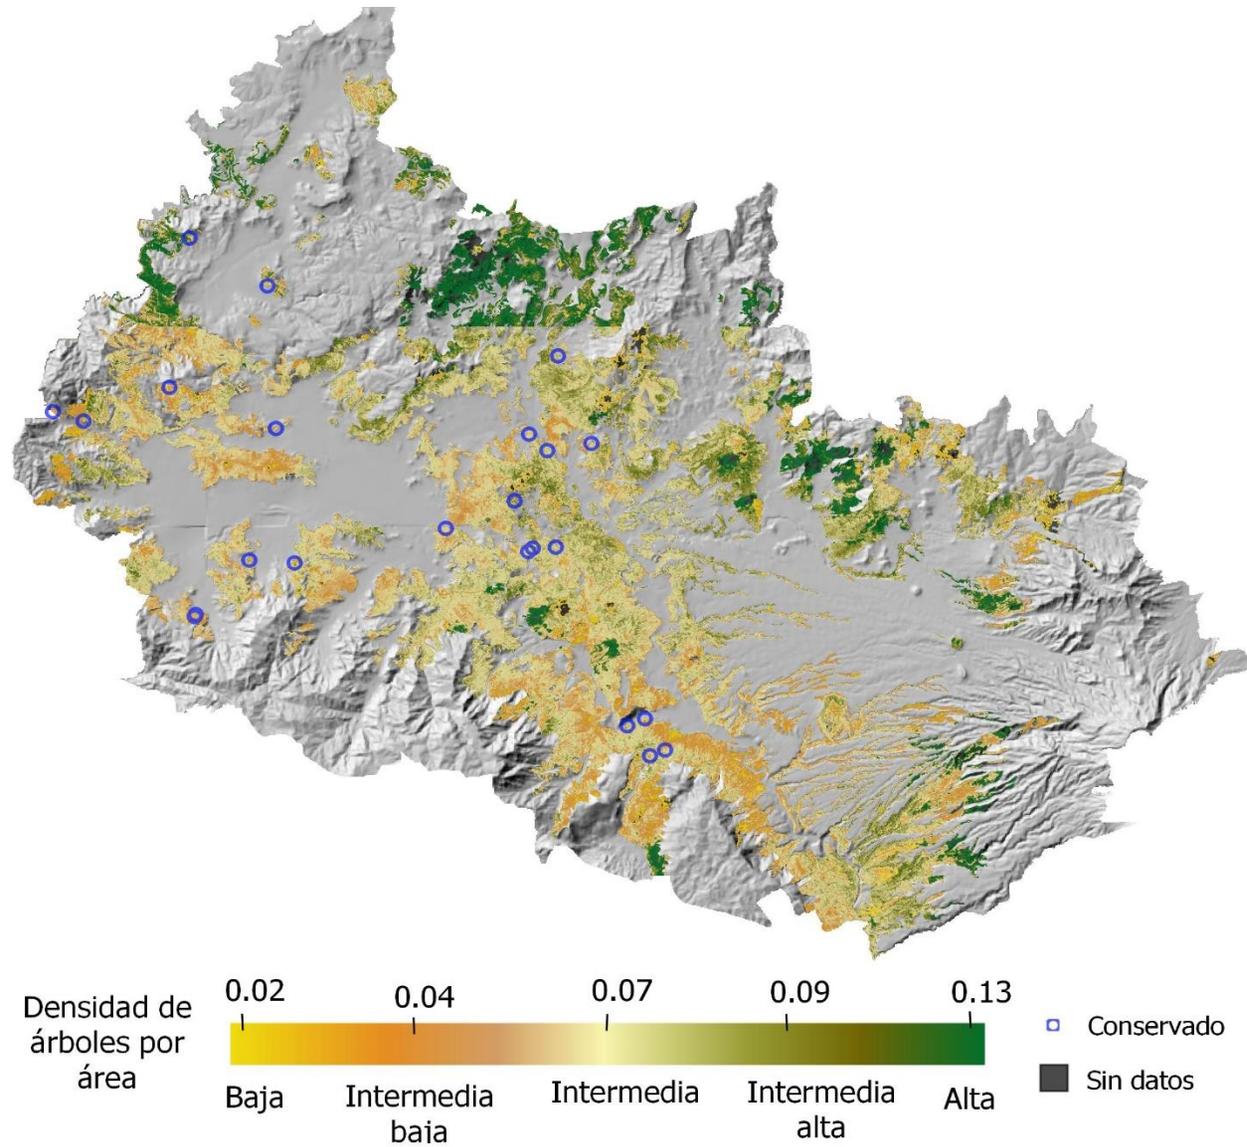


Figura 19. Proyección de modelo para densidad de árboles basado en datos de bosque conservado ($R^2= 0.61$). Hecho a partir de información del índice de degradación (ID, Landsat-8) e índice de vegetación por diferencia normalizada (NDVI Landsat-8 y Sentinel-2)

4.4.5. Identificación de bosques con degradación severa

Para identificar áreas con mayor degradación usando los resultados de los modelos, se emplearon los modelos de cobertura y biomasa para sitios de bosque degradado debido a que estas variables fueron distinguibles en campo de los bosques conservados y al mismo tiempo se obtuvieron buenos resultados para modelación. Para llevar a cabo este procedimiento primero se seleccionó el rango de valores debajo del promedio obtenido en campo para porcentaje de cobertura (<70%) y biomasa viva sobre el suelo (<20 Mg), indicando que estos rangos pertenecen a los sitios con degradación severa. Se usaron estas variables ya que ambas tuvieron diferencias significativas respecto a los bosques conservados y ambas pudieron ser modeladas. Se usa el menor rango de valores pues garantiza que los bosques en condiciones extremas puedan ser mapeados y al mismo tiempo evita que el rango de valores se intercepte con los valores que potencialmente se encuentren en condiciones de “conservado”.

A las condiciones de bosque seleccionadas se convirtieron en dos mapas binarios, indicando que los valores 1 son para áreas con menor cobertura de dosel y menor biomasa y valor 0 para áreas que no cumplen con este criterio. Posteriormente se cruzaron ambos mapas para mantener las áreas que cumplían con ambos criterios al mismo tiempo, obteniendo un mapa con áreas de menor cantidad de dosel y menor cantidad de biomasa, el mapa resultante se puede apreciar en la figura 20.

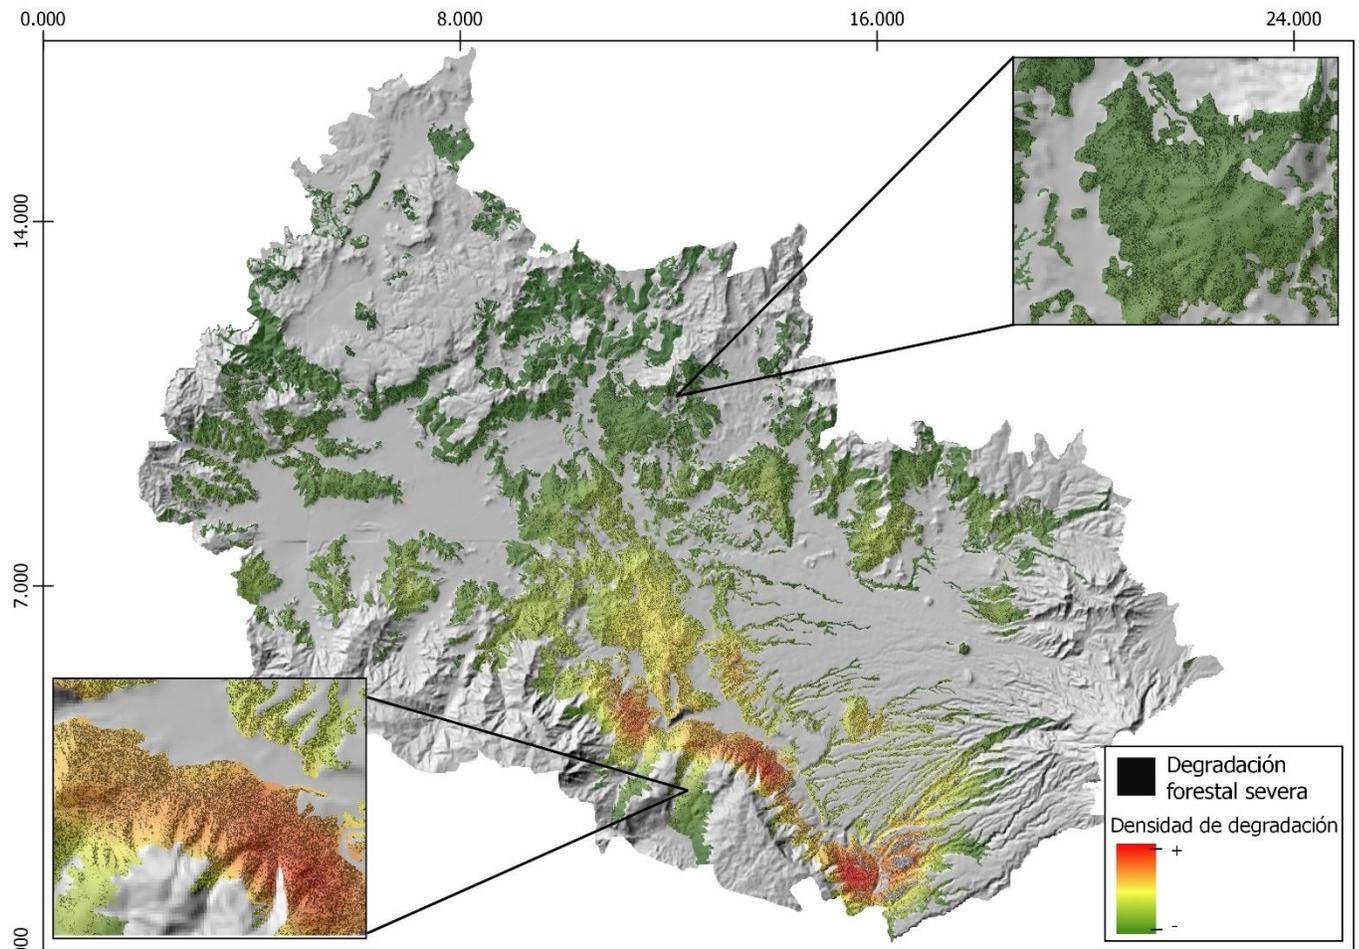


Figura 20. Mapeo de bosques severamente degradados de la cuenca de Ayuquila. Basado en los modelos de cobertura y biomasa para bosques degradados. Las áreas en negro representan los píxeles en donde ocurre la degradación severa, el fondo de color representa la densidad de píxeles en el área, siendo el tono verde zonas con menor densidad de píxeles y las áreas rojas con mayor densidad.

4.4.6. Validación de mapeo de degradación severa

Para finalizar, se realizó una evaluación de este mapeo a través de 50 puntos de verificación aleatorios. Se clasificaron como “degradados” y “no degradado” usando imágenes de alta resolución de Google Earth, como criterio de evaluación se tomó la apertura del dosel, dada por la textura y el color de la superficie, algunos ejemplos se encuentran en la figura 21. Se usó un solo criterio ya que no es posible identificar

biomasa a través de estas imágenes. Se clasificaron 37 puntos como áreas degradadas (74%), mientras que 13 fueron “no degradadas” (26%), es decir de acuerdo con este mapeo fue posible identificar con buena precisión bosque degradado, basado exclusivamente en estos criterios.

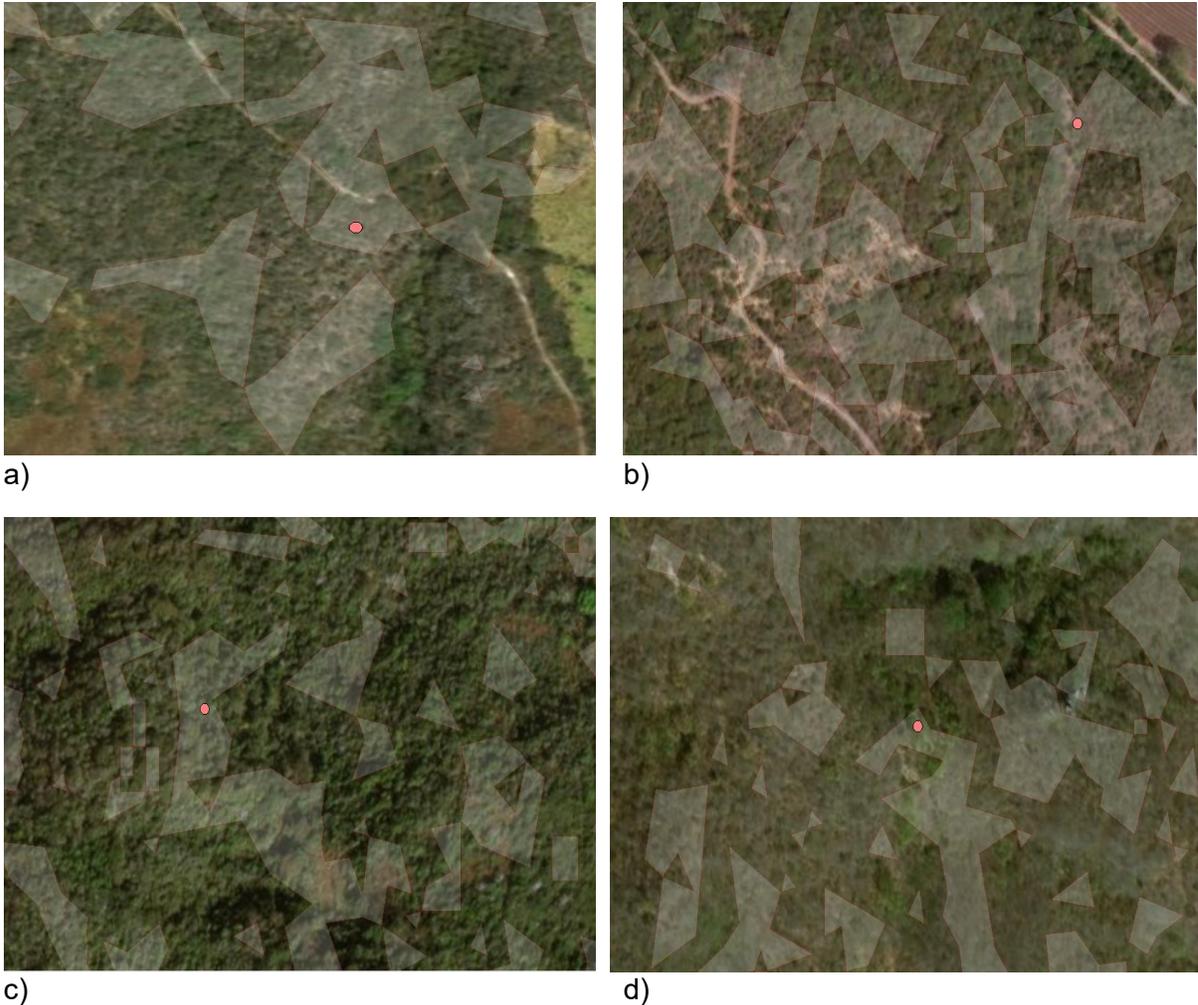


Figura 21. Ejemplos de puntos de verificación vistos en imágenes de alta resolución de Google Earth para el mapeo de bosques degradados basado en los modelos de biomasa y cobertura, el sombreado gris corresponde al mapeo de bosque degradado severamente. Las imágenes a) y b) corresponden a puntos validados como “bosques degradados” y las imágenes c) y d) son ejemplos de puntos identificados como “no degradados”.

De acuerdo con este mapeo de degradación basado en el porcentaje de cobertura y cantidad de biomasa, se identificó un total de 325 km² con degradación severa, esto representa un 16.55% del total de selva caducifolia en esta cuenca (1967.99 km²). Por otra parte, se encontró que, de acuerdo con este mapa, la mayor proporción de degradación severa se encuentra en el rango de pendiente entre los 15.3° y 21.33°, esto cubre el rango en el que se encuentra la mayor parte de cubierta de selva de esta cuenca (7.5° – 36°), es decir que potencialmente la degradación se intensifica en rangos intermedios, muy cercanos a las áreas de actividad agrícola y pastizales que se establecen entre los 7.5° a 16.2° de pendiente (figura 22).

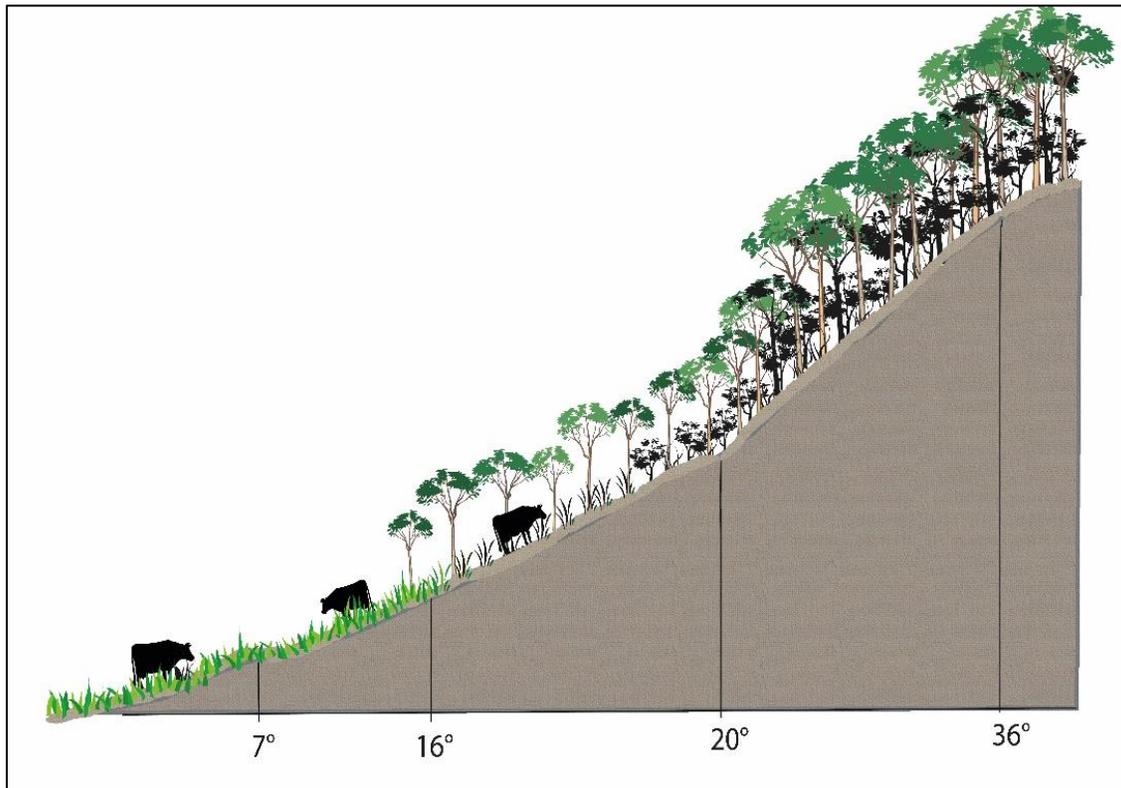


Figura 22 Esquema que ilustra en dónde se concentra la degradación forestal severa de acuerdo con el mapeo realizado para la cuenca de Ayuquila, entre los 15.3° a los 21.3° de pendiente hay mayor proporción de selva tropical caducifolia con menor cobertura del dosel y menor biomasa aérea, estas zonas corresponden a aquellas con vecindad a los pastizales y cultivos. Elaboración propia.

Capítulo V. Discusión y conclusiones

Esta tesis tiene por objetivo entender el potencial de diferentes sensores remotos con múltiple resolución espacial aplicados en la detección de degradación forestal. Esta sección se divide en tres grandes temas. Primero se discute la caracterización de los sitios en campo a través de sus atributos estructurales. Posteriormente la importancia de la percepción remota en el trabajo de detección de degradación forestal y sus principales aportaciones y métodos en esta investigación. Finalmente se aborda la caracterización de los bosques en Ayuquila de acuerdo con los resultados encontrados y sus implicaciones. Se concluye con los principales hallazgos y limitaciones metodológicas, así como consideraciones para futuros trabajos.

5.1 Atributos estructurales como indicadores de degradación forestal

Los atributos estructurales medidos en campo que se diferencian principalmente entre bosques degradados y conservados fueron cobertura, área basal, altura y biomasa. En promedio, los bosques degradados presentan menor cobertura (69%) que el bosque conservado (96%), contienen menor área basal ($7.38 \text{ m}^2 \text{ ha}^{-1}$ vs. $11.49 \text{ m}^2 \text{ ha}^{-1}$) y los árboles presentan menor altura promedio (4.7m vs. 5.7m). Esto coincide con estudios previos realizados en selva caducifolia, por ejemplo, Santos et al., (2017), donde colectaron datos estructurales de la vegetación en parches de vegetación que fueron manejados por tala selectiva para extracción de leña y se encontraban bajo el pisoteo constante de ganado, posteriormente se aislaron y 5 años después se midieron los mismos sitios. Se encontró que en bosques jóvenes había un área basal de $16.49 \text{ m}^2 \text{ ha}^{-1}$, mientras que para sitios de bosque maduro habían $18.34 \text{ m}^2 \text{ ha}^{-1}$, es decir se espera que en bosques jóvenes o con disturbios recientes sean más pequeños en tamaño, reflejado por el área basal y la altura. Ya que el proceso de degradación se debe a la incidencia constante de actividades antrópicas, en nuestra zona de estudio algunas de las actividades más persistentes es la roza-tumba-quema, agricultura de temporal, la ganadería y la extracción de

leña para postes, entre otros productos del bosque (Borrego & Skutsch, 2014). Las mismas propician la pérdida de complejidad estructural, es decir, la disminución de diversos atributos del bosque que resultan en superficies con vegetación menos densas, conformadas por árboles delgados y estratos simplificados. Por ejemplo, la biomasa viva sobre el suelo disminuye por la tala de ramas y troncos, o la inhibición del reclutamiento de árboles jóvenes por la compactación del suelo. La disminución de complejidad también se refiere al patrón espacial diferenciado de los árboles, como la apertura de claros o disminución de la copa arbórea, en relación con los bosques menos afectados por las actividades antrópicas. La disminución de estratos se refiere a las capas verticales de la vegetación que también está asociada a la inhibición del crecimiento de plántulas, y el desarrollo de diferentes formas de crecimiento, p. e. plantas rastreras, herbáceas, lianas, matorrales, etc. (Seidel et al., 2019).

Las categorías de análisis que se emplean en vegetación pueden agruparse en dos grandes campos, atributos funcionales y estructurales (Joseph et al., 2011). Los atributos funcionales se refieren a aquellas características morfológicas, bioquímicas, fenológicas que responden a la variabilidad del ambiente, y explican el comportamiento de las especies a través de su historia evolutiva (Chaturvedi et al., 2012, Diaz et al., 2013), estas características han sido estudiadas tradicionalmente desde mediciones físicas en campo y laboratorio, ya que se requiere una precisión a nivel foliar y de distinción de especies, sin embargo, también se han desarrollado trabajos que desde percepción remota satelital han caracterizado algunos atributos asociados a la fenología y contenido de clorofila a través de la respuesta óptica de la vegetación (Ustin & Gamon, 2010). Por otro lado, la estructura es sin duda una categoría más asequible para medir en campo, ya que requiere menos equipo especializado, y es posible detectar a través de sensores remotos de alta y mediana resolución. Por lo tanto, se emplearon atributos estructurales de la vegetación en este trabajo los cuales sirvieron como aproximación a la degradación. Estos atributos han sido ampliamente usados y cada uno indica diversas propiedades del ecosistema. La biomasa ha sido de interés para identificar la cantidad de carbono que puede ser almacenado por los bosques, y es una función altamente valorada

de los ecosistemas (García-Oliva & Jaramillo, 2011). Sin embargo, la vegetación de selva tropical caducifolia no ha sido reconocida como uno de los principales almacenadores de carbono en el mundo, ya que las características de algunas de sus especies en condiciones de aridez tienden a ser de tipo arbustivo y de maderas poco densas (Lott & Atkinson, 2010). No obstante, el ecosistema en conjunto con otros elementos si es un gran captador de carbono, este se almacena en diferentes niveles, como los suelos y la biomasa subterránea (Joseph et al., 2011). Por lo tanto, entender y proteger la vegetación de este ecosistema es importante para la protección de los almacenes de carbono y otros nutrientes tanto en especies con alta capacidad de captura como en el suelo (García-Oliva y Jaramillo, 2011). Mantener este ecosistema conlleva al mantenimiento de una serie de procesos que cumplen funciones elementales que resultan en bienes para la sociedad y la naturaleza. Tal como la disponibilidad de agua, la cual es capturada por las zonas de selva, modulación del microclima en la cuenca, y provisión de alimento e insectos para la polinización de cultivos (Jaramillo, et al., 2010)

Desde el punto de vista de los riesgos derivados de la pérdida de vegetación, también resulta importante considerar que debido a la degradación y deforestación en zonas de montaña también puede haber un incremento en el riesgo por deslizamientos e inestabilidad de los ríos ante el incremento de lluvias (O'Loughlin, 2020). Un ejemplo reciente es lo que sucedió en esta región en la población de San Gabriel en junio del 2019, en donde el río que cruza el poblado se desbordó tras una fuerte lluvia que traía con la corriente una masa de lodo y troncos arrastrados de los cerros y lomeríos donde habían talado recientemente (Serrano, 2019).

5.2 Detección de degradación forestal a partir de percepción remota y datos de campo.

El uso de técnicas de percepción remota para el monitoreo de cobertura terrestre tiene una larga trayectoria, con el lanzamiento del primer satélite Landsat en 1972 se incrementó el desarrollo de técnicas de análisis multiespectral. Las imágenes de Landsat representaron grandes ventajas, ya que se podía monitorear periódicamente grandes extensiones de superficie. Desde entonces se ha trabajado

en el desarrollo de técnicas para el monitoreo de vegetación, principalmente a través de técnicas de detección de cambios y clasificación de coberturas (Bootkin, 1984; Lambin, 1999). Con la identificación de las diferentes firmas espectrales de cubiertas, se desarrollaron índices espectrales de vegetación como el pionero Índice de vegetación de diferencia normalizada (NDVI) (Tucker, 1979) que hasta la actualidad se continúa usando como indicador de cantidad de biomasa, densidad de vegetación, estado de salud etc. Sin embargo, las imágenes de Landsat están limitadas para capturar información menor a 30 metros debido a su resolución espacial.

Posteriormente, el espectralradiómetro de imágenes de moderada resolución (MODIS), fue puesto en órbita a mediados de los noventa. Este sensor tiene capacidad de cubrir mayores extensiones de terreno (2,330 km), y también ha sido ampliamente usado para detectar cambios en la vegetación a nivel global, sin embargo, estas imágenes al tener 500 m de resolución, su capacidad para detectar fenómenos finos es imposible. Con el lanzamiento de Sentinel-2 en 2015, fue posible el acceso a imágenes con mayor resolución espacial y espectral con 13 bandas de 10 m, 20 m y 60 m. Con esto, una posibilidad para la detección y monitoreo de fenómenos más pequeños en la superficie terrestre, como la degradación forestal.

El tipo de sensores que se han usado para el monitoreo de vegetación han sido principalmente de tipo ópticos pasivos, ya que son los que detectan las frecuencias de onda de luz visible e infrarroja. Sin embargo, también se han usado los sensores activos ya que tienen la ventaja de capturar información por el día y la noche, ya que emiten su propia señal en microondas e infrarrojo, en radar no existe interferencia de nubes y esta señal es capaz de penetrar superficies, dependiendo de la banda de frecuencia del espectro electromagnético en que trabaje, de menor capacidad de penetración a mayor capacidad las bandas más comunes son: K-, X-, C-, S-, L-, P-. Las bandas que se han usado principalmente para el monitoreo de vegetación han sido C- y L-, sin embargo, se ha demostrado que no es posible detectar información muy profunda en doseles muy densos con banda C-. Por otro lado, las imágenes en banda L-, están restringidas, como los satélites JERS o ALOS

2, sin embargo, han demostrado ser capaces de monitorear cantidad de biomasa. Por otro lado, el satélite en banda P- que se pondrá en órbita en 2021 es BIOMASS con 70 cm de longitud de onda, y se espera que a partir sus datos se pueda estimar los almacenes de carbono con mayor precisión.

Hasta el momento, para estudiar atributos estructurales de la vegetación como cobertura del dosel, cantidad de biomasa viva sobre el suelo o densidad arbórea se han utilizado desde los sensores con mayor resolución espacial como fotografías aéreas (Lin et al., 2017) o imágenes RapidEye (5 m), QuickBird (2.4 m, Hirata et al., 2014), IKONOS (1m, Song & Dickinson, 2008), de mediana resolución como Sentinel-2 (10 m, Nichol & Sarker, 2011) o Landsat-8 (30 m), y para la detección de cambios a gran escala se han usado imágenes de baja resolución como MODIS (250 m, Knyazikhin et al., 1998; Pisek et al., 2011). Estas aproximaciones han mostrado tener un buen desempeño para monitorear vegetación, sobre todo características asociadas a la cobertura y que pueden relacionarse con el color, pues es el atributo visible desde el espacio. Las imágenes con mayor resolución suelen tener un mejor desempeño para detectar cambios más finos, pero su limitante es el costo monetario, sin embargo, lo que sucede debajo del dosel no es posible detectarlo con sensores ópticos.

Los estudios realizados con sensores activos como LiDAR (Zolkos et al., 2013) o radar (Townsend, 2002), han mostrado mejor desempeño en la estimación de biomasa, aunque en el caso de radar, se han aplicado principalmente en bandas L- o P-, ya que su señal penetra más profundo en la vegetación (~23 cm) (Kuplich et al., 2005).

La detección de la superficie terrestre a través de un solo sensor es importante ya que evalúan sus capacidades para medir diferentes parámetros, en este caso de la vegetación como densidad de árboles, área foliar o hasta enfermedades. Por otro lado, las limitantes de estos estudios radican en las capacidades de los sensores para estimar ciertos parámetros de acuerdo con sus características técnicas como la resolución espacial, espectral o radiométrica. Limitantes que podrían ser mejoradas a través de un abordaje multi-sensor, pues a través de este se podrían

combinar las aptitudes de dos o más sensores para detectar propiedades físicas y fenómenos de la superficie terrestre.

Los métodos más frecuentemente usados de tipo estadístico para la modelación de atributos de la vegetación son a través de modelos lineales, los cuales tienen diferentes criterios de calidad, como el coeficiente de determinación R^2 , el cual indica que en cuanto más cercano al valor 1, el modelo explica mejor la variación de los datos y su capacidad de predicción. En conjunto con el error cuadrático medio (EMC) que indica las diferencias entre los valores medidos u observados con los valores estimados por el modelo, la calidad del modelo mejora en cuanto el valor es más pequeño, así como el criterio Akaike (AIC), que indica la calidad de un modelo estadístico, en cuanto menor es el valor, mejor es la calidad del modelo.

Aunado a lo anterior, identificar modelos que asocien diferentes atributos de vegetación es el paso previo a la detección de degradación, ya que se usan estos modelos para espacializar la variación de atributos en un área específica. Las áreas con menor cantidad de biomasa, cobertura o densidad de arbolado son clave para la zonificación de bosques degradados. De aquí radica la importancia de la calidad de los modelos para cada atributo, pues es a partir de estos que se puede realizar una mejor detección de degradación.

De acuerdo con algunos estudios que han detectado atributos estructurales a través de múltiples sensores se ha encontrado buenos resultados, como en Hyde et al., (2006) en donde la estimación de biomasa a través de los sensores Lidar, QuickBird, InSAR y ETM de Landsat-7 tuvo un valor $R^2= 0.83$ $RMSE= 7.3$, este fue el mejor resultado de las diferentes pruebas que hicieron, incluyendo modelos usando datos de un sensor. En nuestro trabajo se encontraron dos modelos para biomasa viva sobre el suelo con buenos resultados que combinaron 2 y 3 variables de 2 sensores, SAR de Sentinel-1 y MSI de Sentinel-2, siendo el modelo con dos variables el que mejor respuesta tuvo $R^2= 0.72$. Comparando en Hyde et al. (2006) se usaron sensores de alta resolución, y en este trabajo sensores de mediana resolución, los resultados de este trabajo no están muy alejados por lo que podría indicar que las variables espectrales responden adecuadamente a la variación de biomasa.

De acuerdo con los resultados encontrados en este trabajo, es posible detectar y cuantificar la degradación forestal a través de distintas fuentes de información satelital. La combinación de dos tipos de sensores (óptico y radar) fueron los resultados más consistentes y con mejores coeficientes de determinación ($R^2 > 0.7$). Estos valores coinciden con otros trabajos que se han realizado a través de aproximaciones multi-sensor para parámetros de la vegetación en selva tropical caducifolia (Arellano & Pahuá, 2011). Sin embargo, estos estudios se limitan a la estimación de biomasa viva sobre el suelo, a diferencia de este trabajo en donde se tomaron en cuenta otros parámetros de la vegetación que también son indicadores de degradación forestal. Los resultados mostraron que es posible identificar la densidad de árboles, la cobertura del dosel, así como biomasa con alta confiabilidad.

El detectar otros parámetros auxiliares que determinan degradación hace que las estimaciones pueden ser más confiables, por ejemplo, los resultados mostraron que la densidad arbórea estuvo correlacionada con cantidad de biomasa para el grupo de datos de bosque degradado, esta información puede ser auxiliar en la identificación de zonas con mayor y menor densidad. Identificar y mapear niveles de densidad de arbolado, la distribución de biomasa y cobertura puede servir como herramienta en la toma de decisiones, por ejemplo, en el contexto de la degradación forestal, ayuda a zonificar aquellas áreas prioritarias para la restauración y conservación. También en una zona como la cuenca de Ayuquila, cuya prioridad es mejorar la captación de agua para el río Ayuquila y sus afluentes (Arellano y Pahuá, 2011), identificar y mejorar la calidad de la vegetación en zonas de captación de agua como los parteaguas y la vegetación ribereña es de utilidad para mejorar la calidad y cantidad de agua que afluye al río principal (Zhang et al., 1999).

La modelación de cobertura del dosel también fue posible de acuerdo con nuestros datos y obteniendo resultados confiables ($R^2 = 0.68$ y $R^2 = 0.77$). Monitorear este atributo resulta importante, ya que es una característica de la vegetación que es posible monitorear a través de sensores remotos con mayor efectividad. Además, como propiedades físicas se encuentra que es uno de los reguladores del intercambio de agua y energía en los ecosistemas, como los flujos de carbón y

nutrientes a la atmósfera y la transpiración, igualmente tiene una fuerte influencia en el control del microclima y la evapotranspiración del suelo (Romero-sanchez, 2017; Zhou & Wang, 2018).

La modelación de biomasa también tuvo buenos resultados ($R^2= 0.72$), este es el atributo que se ha usado principalmente para el monitoreo de degradación, ya que en el marco de estrategias del programa REDD+ trata de conservar el carbono almacenado en la biomasa viva sobre el suelo. Este enfoque hace que el monitoreo de degradación forestal sea más eficiente (Herold et al., 2011; Romero-sanchez, 2017), por lo tanto, lograr este modelo resulta un aporte importante para identificar zonas de degradación y ser comparable con otros estudios nacionales e internacionales.

El monitoreo de los cambios en la vegetación a través de imágenes satelitales y de índices espectrales se ha demostrado previamente. Sin embargo, el efecto combinado de variables entre diferentes tipos sensores como los ópticos fusionado con radar se ha demostrado en menor medida. Aunque resulta más complejos de explicar debido al tipo de información que aporta cada fuente de datos y de los diferentes errores que pueden contribuir las imágenes, también es un método que potencialmente podría aportar información a diferentes niveles dentro de la vegetación, que a su vez se traducen en alteraciones al interior del dosel, cuya característica es esencial para describir la degradación forestal y es la más difícil de abordar a través de percepción remota (Sasaki & Putz, 2009).

Los índices que predominaron en los modelos para densidad de árboles y cobertura del dosel fueron el índice de vegetación por diferencia normalizada (NDVI) y el índice de disturbio (ID). Estos índices reflejan principalmente la superficie del dosel, esto a su vez esta correlacionado con densidad de árboles y biomasa (Kendall $\tau= 0.47$ y $\tau = 0.40$). A partir de esto asumimos que los índices de vegetación responden a atributos de la vegetación, y que a su vez son indicadores que diferencian bosques degradados de conservados. Otra característica del ID es que tiene como fundamento usar la porción del espectro de las imágenes asociadas al verdor, humedad y suelo desnudo (Healey et al., 2005), esto puede usarse como indicador

de mayor y menor densidad de árboles, los cuales son señalados por los atributos de cobertura del dosel y densidad de árboles.

El NDVI ha sido ampliamente usado como predictor de la cantidad de biomasa y ha tenido buenas respuestas del sensor MSI de Sentinel-2 (Imran et al., 2020), sin embargo, en modelos lineales simples que asocian valores de NDVI con biomasa medida en campo, esta variable ha explicado alrededor del 50% de la variación de biomasa. En nuestros resultados se encontró asociación del NDVI con densidad de árboles ($R^2=0.78$), y cobertura del dosel ($R^2=0.77$), también se han encontrado buenos resultados modelando cobertura del dosel usando este índice como variable predictora en conjunto con otros índices y variables espectrales de Landsat-8 ($R^2=0.77$) (Karlson et al., 2015).

Por otro lado, también hubo una gran presencia de métricas texturales en los modelos, estas también han mostrado explicar la variación de atributos estructurales en sitios de selva tropical caducifolia (Gallardo-Cruz et al., 2012; Solórzano et al., 2017). Nuestros modelos mostraron que las métricas texturales de varianza, entropía, homogeneidad y media tuvieron respuesta de algún atributo de la vegetación a nivel de terreno. Este tipo de métricas han mostrado estar asociadas a características de homogeneidad o heterogeneidad de la vegetación, es decir, en el caso de áreas continuas uniformes de bosque conservado, el contraste entre los tonos de los píxeles será menor, a diferencia de aquellas áreas que son constantemente modificadas, ya que los píxeles no solo reflejarán las características del dosel, sino fragmentos de troncos, ramas y suelo que están expuestas por la alteración de la vegetación y que también puede ser capturado por los sensores.

En las imágenes de radar, la señal penetra unos centímetros del dosel, por lo tanto, la variación en los tonos de los píxeles estaría asociado a la cantidad de troncos y ramas al interior del dosel. Los resultados mostraron asociación de cantidad de biomasa con homogeneidad, entropía y promedio. Estos resultados comprueban la alta capacidad que tienen las variables de textura para explicar cantidad de biomasa, contrastado con otros estudios que obtuvieron buenos resultados en modelos predictivos de biomasa empleando métricas de textura ($R^2=0.88$)

(Debastiani et al., 2019; $R^2= 0.88$ Hlatshwayo et al., 2019). Sin embargo, la capacidad de radar en banda C-, como es este caso, está limitada para predecir biomasa, ya que se ha reportado una saturación en la señal de retrodispersión en sitios con alta cantidad de biomasa (Debastiani et al., 2019; Saatchi et al., 2011). Sin embargo, para sitios tan secos de selva caducifolia como Ayuquila, el uso de este tipo de información podría representar un alto potencial para predecir tanto biomasa como otros atributos de la vegetación, ya que es probable que la señal del satélite pueda penetrar más profundamente que en otro tipo de bosques más densos. Hasta el momento, los mejores sensores para cuantificar biomasa suelen ser aquellos en banda P- y L- ya que su señal podría penetrar el dosel y llegar al suelo, lo que posibilita tomar información más completa y precisa de la vegetación (Sinha et al., 2015). Un buen ejemplo fue el que realizó Ranson (1997) donde probó diferentes ecuaciones y combinó las bandas C- y P- del satélite AIRSAR para modelar biomasa considerando parámetros medidos en campo como diámetro a la altura del pecho y altura para bosques boreales, lo cual tuvo buenos resultados ya que el mejor modelo tuvo $R^2= 0.85$.

5.3 La degradación forestal en la selva caducifolia de Ayuquila

De acuerdo con el mapeo de bosques degradados el 16.55% del bosque en la cuenca se encuentra severamente degradado, este criterio está basado en el menor rango de cobertura del dosel (<70%) y menor cantidad de biomasa viva sobre el suelo modelada (<20 Mg). Tal como se observó en el mapa de degradación severa (figura 21) una gran proporción de estas áreas se situaban en los límites con otro tipo de cubiertas, como la agricultura, esto coincide con aquellos bosques fragmentados en donde a las orillas de estos fragmentos la altura, el área basal y la biomasa disminuyen por un “efecto de borde” (Almeida et al., 2019). Debido a la mortalidad de árboles grandes causado por la limpieza de terrenos para la actividad agrícola. Este efecto también puede deberse a la alteración en el microclima y por lo tanto aquellos árboles que no toleran el estrés de altas temperaturas y menor humedad pueden morir gradualmente (Laurance et al., 2007).

Sumado a esto, una actividad vista en campo es la alta presencia de ganado que puede pastorear libremente dentro del bosque, lo cual agrava la situación de las zonas limítrofes de la selva. Alguno de los efectos importantes del pastoreo en selvas es la alta mortalidad de árboles juveniles que reducen considerablemente el reclutamiento de árboles, por lo tanto la recuperación de los bosques y los almacenes de carbono, sobre todo de aquellas especies que tienen mayor potencial de acumularlo (Chaturvedi et al., 2012). Por lo tanto, la constante actividad del ganado podría ser una de las causas fundamentales de la degradación forestal en esta región.

5.4 Consideraciones finales

Este trabajo demostró que es posible detectar degradación forestal a través de diferentes atributos de la vegetación modelados con datos de percepción remota. Por otra parte, entre las variables que si se distinguían entre tipos de bosque a nivel de terreno también se encontraron altura y área basal, sin embargo, estos atributos no pudieron ser modelados a través de las imágenes satelitales usadas ya que sus propiedades físicas no son capaces de distinguirlos. Para poder incluir esta información en los modelos, se tendría que tomar información de tipo LiDAR.

Light Detection and Ranging (LiDAR) es un tipo de sensor activo de energía infrarroja (λ 900 y 1064 nm), este ha mostrado tener la capacidad de proveer medidas estructurales verticales y horizontales, como altura del dosel, altura de estratos, densidad de troncos o distribución de ramas. Aunque sus mediciones han mostrado incertidumbre en regiones extensas, sin embargo, es posible modelar biomasa en altas cantidades aproximadamente 1000 Mg ha⁻¹ (Means, 1999; Zolkos et al., 2013). En trabajos que predicen cantidad de biomasa con LiDAR para selva tropical caducifolia se encontraron resultados de coeficientes de determinación $R^2=0.71$ (Hernández-Stefanoni et al., 2014). Sin embargo, también se suele fusionar diferentes sensores para mejorar las estimaciones de atributos estructurales, en el trabajo de Luo (2017) combinó la información de LiDAR con información hiperespectral para modelar biomasa viva sobre el suelo, obteniendo un coeficiente

de $R^2 = 0.89$, la fusión de ambos tipos de información mejoró los resultados un 2.2%. Esto prueba, que el uso combinado de sensores podría mejorar la precisión para modelar diferentes parámetros de la vegetación.

En este trabajo, biomasa y cobertura del dosel fueron modelados eficazmente, y son dos propiedades relevantes para detectar degradación forestal. A través del mapeo de estos atributos es posible identificar las zonas prioritarias para la conservación o aplicación de estrategias para la recuperación de bosques. Por otro lado, es importante considerar el elemento temporal, en este trabajo, se consideraron imágenes en dos temporadas de un mismo año, sin embargo, aplicar este enfoque en un periodo de tiempo mayor, podría ayudar a identificar las fluctuaciones de biomasa o cobertura en sitios de bosque degradado para identificar el nivel de degradación por área, lo cual es información auxiliar en la toma de decisiones.

Es importante resaltar que hacer este monitoreo de degradación forestal fue posible a través de imágenes de acceso libre, entre las limitantes de estas imágenes es su resolución espacial para detectar procesos más finos, como la degradación, sin embargo, mostraron tener una buena respuesta, lo cual posibilita a otro tipo de imágenes con mayor resolución a detallar este problema con más eficacia y eficiencia.

5.5 Conclusiones

El trabajo mostró que los principales atributos estructurales que pueden diferenciar los bosques degradados de los conservados fueron la cobertura del dosel, la biomasa viva aérea sobre el suelo el área basal y la altura, considerando que la biomasa esta calculado a partir del área basal, ambos atributos aportan la misma información, además la biomasa también estuvo correlacionada con densidad arbórea para bosques degradados, la cual podría ser modelada indirectamente a través de percepción remota.

Las características de la vegetación que pudieron ser modeladas fueron cobertura del dosel, biomasa viva sobre el suelo y densidad arbórea a través de los sensores probados Sentinel-1, Sentinel-2 y Landsat-8 y a partir de los índices de vegetación NDVI, ID, y las métricas texturales varianza, entropía, contraste, homogeneidad y promedio. La cobertura del dosel pudo se modelada a través de variables espectrales como el índice de disturbio con imágenes de Sentinel-2, la varianza de la banda-8 de Sentinel-2, el NDVI de Sentienl-2 y la entropía de VH Sentinel-1. Como se puede observar, las variables derivadas de imágenes de Sentinel-2 predominaron para modelar este atributo, lo cual podría significar que sus características aportan la mayor proporción de información en los modelos, comparado con Landsat-8 y Sentienl-1. La biomasa fue modelada a través de las variables homogeneidad de Sentienel-2 y de Landsat-8, entropía Sentinel-1, promedio de Landsat-8, y los valores de retrodispersión de VV de Sentinel-1, en este caso, hubo presencia de los tres sensores probados, los cuales aportan información igual de importante para esta variable, por otro lado, predominaron las variables espectrales de texturales, las cuales se pueden seguir considerando de importancia para la predicción de biomasa viva sobre el suelo. Mientras que la densidad arbórea se modeló a través del NDVI de Sentinel-2 y Landsat-8, el ID de Landsat-8 y los valores de retrodispersión de VV Sentinel-1, en este caso para esta variable tuvieron mayor importancia los índices de vegetación tanto de Landsat 8 como de Sentinel-2, mientras que los valores de retrodispersión en la forma de polarización VV fue una variable que se mostró tanto en el modelo de densidad

arbórea como en biomasa, lo cual nos puede indicar que esta variable esta respondiendo a la variabilidad de estos atributos y puede seguirse considerando para futuros trabajos. Una característica importante de los modelos en particular para aquellos que describían atributos de bosque degradado fue que todas las variables que los conformaron fueron de la temporada de secas, lo cual podría considerarse a futuro pues quizás las imágenes durante esta temporada describen mejor los atributos a nivel de terreno.

A partir de los atributos modelados se delimitó el rango de degradación forestal severa a partir de la información obtenida en campo, y con esto fue posible construir un mapa de degradación forestal de la cuenca de Ayuquila para evaluar el estado de degradación de la selva tropical caducifolia, este mapeo se pudo realizar a partir de los atributos de biomasa y cobertura ya que además de lograr buenos modelos, las variables son distinguibles entre tipos de bosque de acuerdo con los datos de campo, obteniendo un mapa con alta confiabilidad. Este método empírico podría ser tomado y mejorado en futuros trabajos de detección de degradación.

Algunas de las limitaciones del método desarrollado fueron, por un lado, en la caracterización en campo la toma de datos para toda la cuenca, es posible que no se hayan considerado sitios importantes para la caracterización, debido a la logística y accesibilidad a ciertas zonas. Por otro lado, el uso de imágenes satelitales de mediana resolución, ya que, a pesar de tener hasta 10 m de resolución espacial, la degradación podría suceder en áreas más pequeñas a esta extensión. Si se quiere tener información más precisa del nivel de degradación es importante considerar imágenes con mayor resolución espacial. Por otro lado, la imagen de radar en banda C- también está limitada ya que no logra capturar toda la información estructural, esta información se puede mejorar a través de sensores con mayor capacidad como la banda L o P o con sensores tipo LiDAR aéreo. Con estas últimas consideraciones sería posible incluir información de la altura del dosel o la densidad de ramas a los modelos.

El desarrollo del trabajo tuvo buenos resultados, sin embargo, hay consideraciones que sería interesante abordar en futuros trabajos, como la incorporación de otras

variables auxiliares para caracterizar los bosques degradados como erosión del suelo, humedad del suelo, historia de manejo etc. Esto, en conjunto con información de satélite de mayor resolución serían elementos ideales para tener una caracterización más profunda y detallada de la situación de los bosques. Es importante seguir trabajando en esta línea para desarrollar métodos de estimación de degradación forestal, debido a las implicaciones que tiene la pérdida de bosques, también es importante seguir aportando datos lo más confiables posible del estado de los bosques incluyendo los niveles de degradación.

Referencias

- Almeida, D. R. A., Stark, S. C., Schietti, J., Camargo, J. L. C., Amazonas, N. T., Gorgens, E. B., Rosa, D. M., Smith, M. N., Valbuena, R., Saleska, S., Andrade, A., Mesquita, R., Laurance, S. G., Laurance, W. F., Lovejoy, T. E., Broadbent, E. N., Shimabukuro, Y. E., Parker, G. G., Lefsky, M., ... Brancalion, P. H. S. (2019). Persistent effects of fragmentation on tropical rainforest canopy structure after 20 yr of isolation. *Ecological Applications*, 29(6). <https://doi.org/10.1002/eap.1952>
- Arellano, A., & Pahua, Y. (2011). Asociacionismo municipal y medio ambiente. La junta intermunicipal del río Ayuquila , Jalisco. *Espacios Públicos*.
- Asner, G. P. (2009). Automated mapping of tropical deforestation and forest degradation: CLASlite. *Journal of Applied Remote Sensing*, 3(1), 033543. <https://doi.org/10.1117/1.3223675>
- Banskota, A., Kayastha, N., Falkowski, M. J., Wulder, M. A., Froese, R. E., & White, J. C. (2014). Forest Monitoring Using Landsat Time Series Data: A Review. *Canadian Journal of Remote Sensing*, 40(5), 362–384. <https://doi.org/10.1080/07038992.2014.987376>
- Barreda-Bautista, B., López-Caloca, A., Couturier, S., & Silván-Cárdenas, J. L. (2011). Tropical Dry Forest in the Global Picture: The Challenge of Remote Sensing-Based Change Detection in Tropical Dry Environments. En E. G. Carayannis (Ed.), *Planet Earth 2011 Global Warming Challenger and Opportunities for Policy and Practice*. InTech.
- Bezaury, C. J. (2010). Diversidad, amenazas y áreas prioritarias para la conservación de las selvas secas del Pacífico de México. En G. Ceballos, L. Martínez, A. García, E. Espinoza, & R. Dirzo (Eds.), *Las selvas secas del Pacífico Mexicano en el contexto mundial* (Vol. 1, pp. 21-40). Fondo de Cultura Económica.
- Birdsey, R., Angeles-Perez, G., Kurz, W. A., Lister, A., Olguin, M., Pan, Y., Wayson, C., Wilson, B., & Johnson, K. (2013). Approaches to monitoring changes in carbon stocks for REDD+. *Carbon Management*, 4(5), 519–537. <https://doi.org/10.4155/cmt.13.49>
- Borrego, A., & Skutsch, M. (2014). Estimating the opportunity costs of activities that cause degradation in tropical dry forest: Implications for REDD+. *Ecological Economics*, 101, 1–9. <https://doi.org/10.1016/j.ecolecon.2014.02.005>
- Burgos, A., & Maass, J. M. (2004). Vegetation change associated with land-use in tropical dry forest areas of Western Mexico. *Agriculture, Ecosystems & Environment*, 104(3), 475-481. <https://doi.org/10.1016/j.agee.2004.01.038>
- Castro, K. L., Sanchez-Azofeifa, G. A., & Rivard, B. (2003). Monitoring secondary tropical forests using space-borne data: Implications for Central America. *International Journal of Remote Sensing*, 24(9), 1853–1894. <https://doi.org/10.1080/01431160210154056>
- Caughlin, T. T., Barber, C., Asner, G. P., Glenn, N. F., Bohlman, S. A., & Wilson, C. H. (2020). Monitoring tropical forest succession at landscape scales despite uncertainty in Landsat time series. *Ecological Applications*. <https://doi.org/10.1002/eap.2208>

- Ceballos, G., Martínez, L., García, A., & Espinoza, E. (2010). *Selvas Secas del Pacífico de México*. 597.
- Chabrilat, S. (2006). Land degradation indicators: Spectral indices. *Annals of Arid Zone*, 45(3-4), 331–354.
- Challenger, A., & Soberón, J. (2008). Los ecosistemas terrestres. En *Capital Natural de México: Conocimiento Actual de la Biodiversidad* (Vol. 1, p. 621). Comisión Nacional para el Conocimiento y Uso de la Biodiversidad.
- Chapela, F. (2012). El manejo forestal en México: Estado actual y perspectivas. *Estado de los bosques de México*, 52, 51.
- Chaplin-Kramer, R., Ramler, I., Sharp, R., Haddad, N. M., Gerber, J. S., West, P. C., Mandle, L., Engstrom, P., Baccini, A., Sim, S., Mueller, C., & King, H. (2015). Degradation in carbon stocks near tropical forest edges. *Nature Communications*, 6, 1–6. <https://doi.org/10.1038/ncomms10158>
- Chaturvedi, R. K., Raghubanshi, A. S., & Singh, J. S. (2012). Effect of grazing and harvesting on diversity, recruitment and carbon accumulation of juvenile trees in tropical dry forests. *Forest Ecology and Management*, 284, 152-162. <https://doi.org/10.1016/j.foreco.2012.07.053>
- Cihlar, J., St.-Laurent, L., & Dyer, J. A. (1991). Relation between the normalized difference vegetation index and ecological variables. *Remote Sensing of Environment*, 35(2-3), 279–298. [https://doi.org/10.1016/0034-4257\(91\)90018-2](https://doi.org/10.1016/0034-4257(91)90018-2)
- Clark, M. L. (2017). Comparison of simulated hyperspectral HypsIRI and multispectral Landsat 8 and Sentinel-2 imagery for multi-seasonal, regional land-cover mapping. *Remote Sensing of Environment*, 200(June 2016), 311–325. <https://doi.org/10.1016/j.rse.2017.08.028>
- Colin Prentice, I., Sykes, M. T., & Cramer, W. (1993). A simulation model for the transient effects of climate change on forest landscapes. *Ecological Modelling*, 65(1-2), 51–70. [https://doi.org/10.1016/0304-3800\(93\)90126-D](https://doi.org/10.1016/0304-3800(93)90126-D)
- CONABIO. (2010). *Grado de marginación municipal* [Map].
- CONABIO. (2020). *Selvas secas*. Biodiversidad Mexicana. <https://www.biodiversidad.gob.mx/ecosistemas/selvaSeca>
- CONAFOR. (2010). *Vision de México sobre REDD+*. 56.
- De Grandi, E. C., Mitchard, E., Woodhouse, I. H., & De Grandi, G. D. (2015). Spatial wavelet statistics of SAR backscatter for characterizing degraded forest: A case study from Cameroon. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(7), 3572–3584. <https://doi.org/10.1109/JSTARS.2015.2420596>
- de Wasseige, C., & Defourny, P. (2004). Remote sensing of selective logging impact for tropical forest management. *Forest Ecology and Management*, 188(1-3), 161-173. <https://doi.org/10.1016/j.foreco.2003.07.035>
- Debastiani, A. B., Sanquetta, C. R., Corte, A. P. D., Pinto, N. S., & Rex, F. E. (2019). Evaluating SAR-optical sensor fusion for aboveground biomass estimation in a Brazilian tropical forest. *Annals of Forest Research*, 0(0). <https://doi.org/10.15287/afr.2018.1267>
- DeVries, B., Decuyper, M., Verbesselt, J., Zeileis, A., Herold, M., & Joseph, S. (2015). Tracking disturbance-regrowth dynamics in tropical forests using structural change

- detection and Landsat time series. *Remote Sensing of Environment*, 169, 320–334. <https://doi.org/10.1016/j.rse.2015.08.020>
- Edwards, D. P., Fisher, B., & Boyd, E. (2010). Protecting degraded rainforests: Enhancement of forest carbon stocks under REDD+. *Conservation Letters*, 3(5), 313–316. <https://doi.org/10.1111/j.1755-263X.2010.00143.x>
- FAO. (2011). Assessing forest degradation: Towards the development of globally applicable guidelines. *Forest Resources Assessment*, 99. <https://doi.org/10.1023/B:VEGE.0000029381.63336.20>
- FAO. (2020). *Evaluación de los recursos forestales mundiales 2020*. FAO. <https://doi.org/10.4060/ca8753es>
- Fischer, J., & Lindenmayer, D. B. (2007). Landscape modification and habitat fragmentation: A synthesis. *Global Ecology and Biogeography*, 16(3), 265–280. <https://doi.org/10.1111/j.1466-8238.2007.00287.x>
- Forrester, D. I., & Bauhus, J. (2016). A Review of Processes Behind Diversity—Productivity Relationships in Forests. *Current Forestry Reports*, 2(1), 45–61. <https://doi.org/10.1007/s40725-016-0031-2>
- Galicia, L., Zarco-Arista, A. E., Mendoza-Robles, K. I., Palacio-Prieto, J. L., & García-Romero, A. (2008). Land use/cover, landforms and fragmentation patterns in a tropical dry forest in the southern Pacific region of Mexico. *Singapore Journal of Tropical Geography*, 29(2), 137–154. <https://doi.org/10.1111/j.1467-9493.2008.00326.x>
- Gallardo-Cruz, J. A., Meave, J. A., González, E. J., Lebrija-Trejos, E. E., Romero-Romero, M. A., Pérez-García, E. A., Gallardo-Cruz, R., Hernández-Stefanoni, J. L., & Martorell, C. (2012). Predicting tropical dry forest successional attributes from space: Is the key hidden in image texture? *PLoS ONE*, 7(2), 38–45. <https://doi.org/10.1371/journal.pone.0030506>
- García-Oliva, F., & Jaramillo, V. J. (2011). Seasonally Dry Tropical Forests. *Seasonally Dry Tropical Forests*, 159–172. <https://doi.org/10.5822/978-1-61091-021-7>
- Ghosh, S. M., & Behera, M. D. (2018). Aboveground biomass estimation using multi-sensor data synergy and machine learning algorithms in a dense tropical forest. *Applied Geography*, 96, 29–40. <https://doi.org/10.1016/j.apgeog.2018.05.011>
- González Navarro, M. (1977). Las tierras ociosas. *Historia Mexicana*, 26(4), 503–539.
- Halperin, J., LeMay, V., Coops, N., Verchot, L., Marshall, P., & Lochhead, K. (2016). Canopy cover estimation in miombo woodlands of Zambia: Comparison of Landsat 8 OLI versus RapidEye imagery using parametric, nonparametric, and semiparametric methods. *Remote Sensing of Environment*, 179, 170–182. <https://doi.org/10.1016/j.rse.2016.03.028>
- Healey, S. P., Cohen, W. B., Zhiqiang, Y., & Krankina, O. N. (2005). Comparison of Tasseled Cap-based Landsat data structures for use in forest disturbance detection. *Remote Sensing of Environment*, 97(3), 301–310. <https://doi.org/10.1016/j.rse.2005.05.009>
- Hernández-Stefanoni, J., Dupuy, J., Johnson, K., Birdsey, R., Tun-Dzul, F., Peduzzi, A., Caamal-Sosa, J., Sánchez-Santos, G., & López-Merlín, D. (2014). Improving Species Diversity and Biomass Estimates of Tropical Dry Forests Using Airborne LiDAR. *Remote Sensing*, 6(6), 4741–4763. <https://doi.org/10.3390/rs6064741>

- Herold, M., Román-Cuesta, R. M., Mollicone, D., Hirata, Y., Van Laake, P., Asner, G. P., Souza, C., Skutsch, M., Avitabile, V., & MacDicken, K. (2011). Options for monitoring and estimating historical carbon emissions from forest degradation in the context of REDD+. *Carbon Balance and Management*, 6(1), 13. <https://doi.org/10.1186/1750-0680-6-13>
- Hirata, Y., Tabuchi, R., Patanaponpaiboon, P., Pongparn, S., Yoneda, R., & Fujioka, Y. (2014). Estimation of aboveground biomass in mangrove forests using high-resolution satellite data. *Journal of Forest Research*, 19(1), 34-41. <https://doi.org/10.1007/s10310-013-0402-5>
- Hlatshwayo, S. T., Mutanga, O., Lottering, R. T., Kiala, Z., & Ismail, R. (2019). Mapping forest aboveground biomass in the reforested Buffelsdraai landfill site using texture combinations computed from SPOT-6 pan-sharpened imagery. *International Journal of Applied Earth Observation and Geoinformation*, 74, 65-77. <https://doi.org/10.1016/j.jag.2018.09.005>
- Holdridge, L. R. (1967). *Life zone ecology*. Tropical Science Center.
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295-309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- Hyde, P., Dubayah, R., Walker, W., Blair, J. B., Hofton, M., & Hunsaker, C. (2006). Mapping forest structure for wildlife habitat analysis using multi-sensor (LiDAR, SAR/InSAR, ETM+, Quickbird) synergy. *Remote Sensing of Environment*, 102(1-2), 63-73. <https://doi.org/10.1016/j.rse.2006.01.021>
- Imhoff, M. L. (1995). A theoretical analysis of the effect of forest structure on synthetic aperture radar backscatter and the remote sensing of biomass. *IEEE Transactions on Geoscience and Remote Sensing*, 33(2), 341-351. <https://doi.org/10.1109/TGRS.1995.8746015>
- Imran, A. B., Khan, K., Ali, N., Ahmad, N., Ali, A., & Shah, K. (2020). Narrow band based and broadband derived vegetation indices using Sentinel-2 Imagery to estimate vegetation biomass. *Global Journal of Environmental Science and Management*, 6(1), 97–108. <https://doi.org/10.22034/gjesm.2020.01.08>
- INEGI. (2015). *Conjunto de datos vectoriales de información topográfica E13B12 escala 1:50000 serie III* [Map].
- IPCC. (2019). *IPCC Special Report on Climate Change and Land: Chapter 4: Land Degradation*. 1–112.
- Jaramillo, V. J., Martínez-Yrizar, A., & Sandford, R. (2011). Primary Productivity and Biochemistry of Seasonally Dry Tropical Forests. En R. Dirzo, H. S. Young, & G. Ceballos (Eds.), *Seasonally Dry Tropical Forests*. Island Press/Center for Resource Economics.
- Jaramillo, Victor J., García-Oliva, Felipe, & Martínez-Yrizar, Angelina. (2010). La selva seca y las perturbaciones antrópicas en un contexto funcional. En Ceballos, Gerardo, Martínez, Lourdes, García, Andrés, Espinoza, Eduardo, Bezauri Creel, Juan, & Dirzo, Rodolfo (Eds.), *Diversidad, amenazas y áreas prioritarias para la conservación de las Selvas Secas del Pacífico de México*. Fondo de Cultura Económica.

- Joseph, S., Murthy, M. S. R., & Thomas, A. P. (2011). The progress on remote sensing technology in identifying tropical forest degradation: A synthesis of the present knowledge and future perspectives. *Environmental Earth Sciences*, 64(3), 731–741. <https://doi.org/10.1007/s12665-010-0893-8>
- Joshi, N., Mitchard, E. T., Woo, N., Torres, J., Moll-Rocek, J., Ehammer, A., Collins, M., Jepsen, M. R., & Fensholt, R. (2015). Mapping dynamics of deforestation and forest degradation in tropical forests using radar satellite data. *Environmental Research Letters*, 10(3), 034014. <https://doi.org/10.1088/1748-9326/10/3/034014>
- Karlson, M., Ostwald, M., Reese, H., Sanou, J., Tankoano, B., & Mattsson, E. (2015). Mapping Tree Canopy Cover and Aboveground Biomass in Sudano-Sahelian Woodlands Using Landsat 8 and Random Forest. *Remote Sensing*, 7(8), 10017-10041. <https://doi.org/10.3390/rs70810017>
- Kellendorfer, J. (2019). Using SAR Data for Mapping Deforestation and Forest Degradation. En A. Flores, K. Herndon, R. Thapa, & E. Cherrington (Eds.), *SAR Handbook: Comprehensive Methodologies for Forest Monitoring and Biomass Estimation*. NASA.
- Kissinger, G., Herold, M., De, V., Angelsen, A., Bietta, F., Bodganski, A., Boucher, D., Boyle, T., Brickell, E., Defries, R., Dragisic, C., Elias, P., Enters, T., Kishwan, J., Loisel, C., Lotsch, A., Masripatin, N., Neufeldt, H., Ngarize, S., ... Wolf, R. (2012). *Drivers of Deforestation and Forest Degradation*. 0–48. <https://doi.org/10.1016/j.rse.2010.01.001>
- Knyazikhin, Y., Martonchik, J. V., Myneni, R. B., Diner, D. J., & Running, S. W. (1998). *Synergistic algorithm for estimating vegetation canopy leaf area index and fraction of absorbed photosynthetically active radiation from MODIS and MISR data*. 19.
- Korhonen, L., Korpela, I., Heiskanen, J., & Maltamo, M. (2011). Airborne discrete-return LIDAR data in the estimation of vertical canopy cover, angular canopy closure and leaf area index. *Remote Sensing of Environment*, 115(4), 1065-1080. <https://doi.org/10.1016/j.rse.2010.12.011>
- Kuplich, T. M., Curran, P. J., & Atkinson, P. M. (2005). Relating SAR image texture to the biomass of regenerating tropical forests. *International Journal of Remote Sensing*, 26(21), 4829–4854. <https://doi.org/10.1080/01431160500239107>
- Lai, R. (2004). Soil Carbon Sequestration in Natural and Managed Tropical Forest Ecosystems. *Journal of Sustainable Forestry*, 21(1), 1-30. https://doi.org/10.1300/J091v21n01_01
- Laurance, W. F., Nascimento, H. E. M., Laurance, S. G., Andrade, A., Ewers, R. M., Harms, K. E., Luizão, R. C. C., & Ribeiro, J. E. (2007). Habitat Fragmentation, Variable Edge Effects, and the Landscape-Divergence Hypothesis. *PLoS ONE*, 2(10), e1017. <https://doi.org/10.1371/journal.pone.0001017>
- Lieberman, D., Lieberman, M., Peralta, R., & Hartshorn, G. S. (1996). Tropical Forest Structure and Composition on a Large-Scale Altitudinal Gradient in Costa Rica. *The Journal of Ecology*, 84(2), 137. <https://doi.org/10.2307/2261350>
- Lin, H., Chen, Y., Song, Q., Fu, P., Cleverly, J., Magliulo, V., Law, B. E., Gough, C. M., Hörtnagl, L., Di, F., Matteucci, G., Montagnani, L., Duce, P., Shao, C., Kato, T., Bonal, D., Paul-Imoges, E., Beringer, J., Grace, J., & Fan, Z. (2017). Science of the Total Environment Quantifying deforestation and forest degradation with thermal

- response. *Science of the Total Environment*, 607-608(July), 1286–1292. <https://doi.org/10.1016/j.scitotenv.2017.07.062>
- Lott, E. J., & Atkinson, T. H. (2010). Diversidad florística. En Ceballos, Gerardo, Martínez, Lourdes, García, Andrés, Espinoza, Eduardo, & Bezauri Creel, Juan (Eds.), *Diversidad, amenazas y áreas prioritarias para la conservación de las Selvas Secas del Pacífico de México* (Primera). Fondo de Cultura Económica.
- Lu, D., & Batistella, M. (2005). Exploring TM image texture and its relationships with biomass estimation in Rondônia, Brazilian Amazon. *Acta Amazonica*, 35(2), 249-257. <https://doi.org/10.1590/S0044-59672005000200015>
- Luo, S. (2017). Fusion of airborne LiDAR data and hyperspectral imagery for aboveground and belowground forest biomass estimation. *Ecological Indicators*, 10.
- Mayes, M., Mustard, J., Melillo, J., Neill, C., & Nyadzi, G. (2017). Going beyond the green: Senesced vegetation material predicts basal area and biomass in remote sensing of tree cover conditions in an African tropical dry forest (miombo woodland) landscape. *Environmental Research Letters*, 12(8). <https://doi.org/10.1088/1748-9326/aa7242>
- McElhinny, C., Gibbons, P., Brack, C., & Bauhus, J. (2005). Forest and woodland stand structural complexity: Its definition and measurement. *Forest Ecology and Management*, 218(1-3), 1–24. <https://doi.org/10.1016/j.foreco.2005.08.034>
- Means, J. (1999). Use of Large-Footprint Scanning Airborne Lidar To Estimate Forest Stand Characteristics in the Western Cascades of Oregon. *Remote Sensing of Environment*, 67(3), 298-308. [https://doi.org/10.1016/S0034-4257\(98\)00091-1](https://doi.org/10.1016/S0034-4257(98)00091-1)
- Meyer, V., Saatchi, S., Ferraz, A., Xu, L., Duque, A., García, M., & Chave, J. (2019). Forest degradation and biomass loss along the Chocó region of Colombia. *Carbon Balance and Management*, 14(1), 1–15. <https://doi.org/10.1186/s13021-019-0117-9>
- Meza Rodríguez, D. (2006). *CARACTERIZACIÓN HIDROGRÁFICA DE LA CUENCA AYUQUILA-ARMERÍA MEDIANTE LA APLICACIÓN DE UN SISTEMA DE INFORMACIÓN GEOGRÁFICA*. <https://doi.org/10.13140/RG.2.1.4581.1440>
- Morales-Barquero, L., Skutsch, M., Jardel-Peláez, E. J., Ghilardi, A., Kleinn, C., & Healey, J. R. (2014). Operationalizing the definition of forest degradation for REDD+, with application to Mexico. *Forests*, 5(7), 1653–1681. <https://doi.org/10.3390/f5071653>
- Mura, M., Bottalico, F., Giannetti, F., Bertani, R., Giannini, R., Mancini, M., Orlandini, S., Travaglini, D., & Chirici, G. (2018). Exploiting the capabilities of the Sentinel-2 multi spectral instrument for predicting growing stock volume in forest ecosystems. *International Journal of Applied Earth Observation and Geoinformation*, 66(July 2017), 126–134. <https://doi.org/10.1016/j.jag.2017.11.013>
- Nichol, J. E., & Sarker, L. R. (2011). Improved Biomass Estimation Using the Texture Parameters of Two High-Resolution Optical Sensors. *IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING*, 49(3), 19.
- O'Loughlin, C. (2020). *THE EFFECT OF TIMBER REMOVAL ON THE STABILITY OF FOREST SOILS*. 15.
- Panta, M., Kim, K., & Joshi, C. (2008). *Forest Ecology and Management Temporal mapping of deforestation and forest degradation in Nepal: Applications to forest conservation*. 256, 1587–1595. <https://doi.org/10.1016/j.foreco.2008.07.023>

- Pisek, J., Chen, J. M., & Nilson, T. (2011). *Estimation of vegetation clumping index using MODIS BRDF data*. 14.
- Poorter, L., van der Sande, M. T., Thompson, J., Arets, E. J. M. M., Alarcón, A., Álvarez-Sánchez, J., Ascarrunz, N., Balvanera, P., Barajas-Guzmán, G., Boit, A., Bongers, F., Carvalho, F. A., Casanoves, F., Cornejo-Tenorio, G., Costa, F. R. C., de Castilho, C. V., Duivenvoorden, J. F., Dutrieux, L. P., Enquist, B. J., ... Peña-Claros, M. (2015). Diversity enhances carbon storage in tropical forests. *Global Ecology and Biogeography*, 24(11), 1314–1328. <https://doi.org/10.1111/geb.12364>
- Quintano, C., Fernández-Manso, A., & Fernández-Manso, O. (2018). Combination of Landsat and Sentinel-2 MSI data for initial assessing of burn severity. *International Journal of Applied Earth Observation and Geoinformation*, 64(July 2017), 221–225. <https://doi.org/10.1016/j.jag.2017.09.014>
- Rappaport, D. I., Morton, D. C., Longo, M., Keller, M., Dubayah, R., & dos-Santos, M. N. (2018). Quantifying long-term changes in carbon stocks and forest structure from Amazon forest degradation. *Environmental Research Letters*, 13(6), 065013. <https://doi.org/10.1088/1748-9326/aac331>
- Reiche, J., Verhoeven, R., Verbesselt, J., Hamunyela, E., Wielaard, N., & Herold, M. (2018). Characterizing tropical forest cover loss using dense Sentinel-1 data and active fire alerts. *Remote Sensing*, 10(5). <https://doi.org/10.3390/rs10050777>
- Romero-sanchez, M. E. (2017). *Assessing and Monitoring Forest Degradation in a Deciduous Tropical Forest in Mexico via Remote Sensing Indicators*. <https://doi.org/10.3390/f8090302>
- Saatchi, S., Marlier, M., Chazdon, R. L., Clark, D. B., & Russell, A. E. (2011). Impact of spatial variability of tropical forest structure on radar estimation of aboveground biomass. *Remote Sensing of Environment*, 115(11), 2836–2849. <https://doi.org/10.1016/j.rse.2010.07.015>
- Salinas-Melgoza, M. A., Skutsch, M., & Lovett, J. C. (2018). Predicting aboveground forest biomass with topographic variables in human-impacted tropical dry forest landscapes. *Ecosphere*, 9(1). <https://doi.org/10.1002/ecs2.2063>
- Santos, P. F., Garcia, P. O., Santos, R. M., Morel, J. D., Benício, M. H. M., Apgaua, D. M. G., & Tng, D. Y. P. (2017). Temporal changes in tree community structure and richness in a seasonally dry tropical forest in Minas Gerais, southeastern Brazil. *Bosque (Valdivia)*, 38(3), 535-543. <https://doi.org/10.4067/S0717-92002017000300011>
- Sasaki, N., & Putz, F. E. (2009). Critical need for new definitions of “forest” and “forest degradation” in global climate change agreements. *Conservation Letters*, 2(5), 226-232. <https://doi.org/10.1111/j.1755-263X.2009.00067.x>
- Seidel, D., Ehbrecht, M., Annighöfer, P., & Ammer, C. (2019). From tree to stand-level structural complexity—Which properties make a forest stand complex? *Agricultural and Forest Meteorology*, 278, 107699. <https://doi.org/10.1016/j.agrformet.2019.107699>
- Serrano, I. (2019). Avalancha de lodo en San Gabriel puede repetirse en distintos puntos de Jalisco. *Coordinación General de Comunicación Social, Universidad de*

- Guadalajara. <http://udg.mx/es/noticia/avalancha-lodo-san-gabriel-puede-repetirse-distintos-puntos-jalisco>.
- Sharma, R., Hara, K., & Tateishi, R. (2017). High-Resolution Vegetation Mapping in Japan by Combining Sentinel-2 and Landsat 8 Based Multi-Temporal Datasets through Machine Learning and Cross-Validation Approach. *Land*, 6(3), 50. <https://doi.org/10.3390/land6030050>
- Simula, M. (2009). FOOD AND AGRICULTURE ORGANIZATION TOWARDS DEFINING FOREST DEGRADATION : COMPARATIVE ANALYSIS OF EXISTING. *Consultant*, September.
- Sinha, S., Jeganathan, C., Sharma, L. K., & Nathawat, M. S. (2015). A review of radar remote sensing for biomass estimation. *Int. J. Environ. Sci. Technol.*, 14.
- Sinha, Suman, Mohan, S., Das, A. K., Sharma, L. K., Jeganathan, C., Santra, A., Santra Mitra, S., & Nathawat, M. S. (2019). Multi-sensor approach integrating optical and multi-frequency synthetic aperture radar for carbon stock estimation over a tropical deciduous forest in India. *Carbon Management*, 11(1), 39–55. <https://doi.org/10.1080/17583004.2019.1686931>
- Solórzano, J. V., Meave, J. A., Gallardo-Cruz, J. A., González, E. J., & Hernández-Stefanoni, J. L. (2017). Predicting old-growth tropical forest attributes from very high resolution (VHR)-derived surface metrics. *International Journal of Remote Sensing*, 38(2), 492–513. <https://doi.org/10.1080/01431161.2016.1266108>
- Song, C., & Dickinson, M. B. (2008). *Extracting forest canopy structure from spatial information of high resolution optical imagery: Tree*. 19.
- Southworth, J. (2004). An assessment of Landsat TM band 6 thermal data for analysing land cover in tropical dry forest regions. *International Journal of Remote Sensing*, 25(4), 689-706. <https://doi.org/10.1080/0143116031000139917>
- Souza, C. M., Siqueira, J. V., Sales, M. H., Fonseca, A. V., Ribeiro, J. G., Numata, I., Cochrane, M. A., Barber, C. P., Roberts, D. A., & Barlow, J. (2013). Ten-year landsat classification of deforestation and forest degradation in the brazilian amazon. *Remote Sensing*, 5(11), 5493–5513. <https://doi.org/10.3390/rs5115493>
- Sturrock, R. N., Frankel, S. J., Brown, A. V., Hennon, P. E., Kliejunas, J. T., Lewis, K. J., Worrall, J. J., & Woods, A. J. (2011). Climate change and forest diseases. *Plant Pathology*, 60(1), 133–149. <https://doi.org/10.1111/j.1365-3059.2010.02406.x>
- Thompson, C. G., Kim, R. S., Aloe, A. M., & Becker, B. J. (2017). Extracting the Variance Inflation Factor and Other Multicollinearity Diagnostics from Typical Regression Results. *Basic and Applied Social Psychology*, 39(2), 81-90. <https://doi.org/10.1080/01973533.2016.1277529>
- Thompson, I. D., Guariguata, M. R., Okabe, K., Bahamondez, C., Nasi, R., Heymell, V., & Sabogal, C. (2013). An operational framework for defining and monitoring forest degradatio. *Ecology and Society*, 18(2).
- Townsend, P. A. (2002). Estimating forest structure in wetlands using multitemporal SAR. *Remote Sensing of Environment*, 79(2-3), 288-304. [https://doi.org/10.1016/S0034-4257\(01\)00280-2](https://doi.org/10.1016/S0034-4257(01)00280-2)

- Trejo, I., & Dirzo, R. (2000). Deforestation of seasonally dry tropical forest: A national and local analysis in Mexico. *Biological Conservation*, *94*(2), 133–142. [https://doi.org/10.1016/S0006-3207\(99\)00188-3](https://doi.org/10.1016/S0006-3207(99)00188-3)
- Ustin, S. L., & Gamon, J. A. (2010). Remote sensing of plant functional types: Tansley review. *New Phytologist*, *186*(4), 795-816. <https://doi.org/10.1111/j.1469-8137.2010.03284.x>
- Velázquez, A., Mas, J. F., Díaz Gallegos, J., Mayorga Saucedo, R., Alcántara, P., Castro, R., Fernández, T., Bocco, G., Ezcurra, E., & Palacio, J. (2002). Patrones y tasas de cambio de uso del suelo en México. *Gaceta Ecológica*, *062*, 21–37. <https://doi.org/10.4067/S0718-23762009000200004>
- Wang, Q., Blackburn, G. A., Onojeghuo, A. O., Dash, J., Zhou, L., Zhang, Y., & Atkinson, P. M. (2017). Fusion of Landsat 8 OLI and Sentinel-2 MSI Data. *IEEE Transactions on Geoscience and Remote Sensing*, *55*(7), 3885–3899. <https://doi.org/10.1109/TGRS.2017.2683444>
- Wekesa, C., Kirui, B. K., Maranga, E. K., & Muturi, G. M. (2019). Variations in forest structure, tree species diversity and above-ground biomass in edges to interior cores of fragmented forest patches of Taita Hills, Kenya. *Forest Ecology and Management*, *440*(November 2018), 48–60. <https://doi.org/10.1016/j.foreco.2019.03.011>
- Zhang, L., Dawes, W. R., & Walker, G. R. (1999). *Predicting the effect of vegetation changes on catchment average water balance* (p. 42).
- Zhou, Z., & Wang, C. (2018). *Effects of forest degradation on microbial communities and soil carbon cycling: A global meta-analysis*. November 2016, 110–124. <https://doi.org/10.1111/geb.12663>
- Zolkos, S. G., Goetz, S. J., & Dubayah, R. (2013). A meta-analysis of terrestrial aboveground biomass estimation using lidar remote sensing. *Remote Sensing of Environment*, *128*, 289-298. <https://doi.org/10.1016/j.rse.2012.10.017>