



COLEGIO DE POSTGRADUADOS

INSTITUCIÓN DE ENSEÑANZA E INVESTIGACIÓN EN CIENCIAS AGRÍCOLAS

CAMPUS MONTECILLO

PROGRAMA DE POSTGRADO EN BOTÁNICA

ANÁLISIS DE LA HETEROGENEIDAD DEL ÍNDICE NORMALIZADO DIFERENCIAL DE VEGETACIÓN (NDVI) DEL BOSQUE HÚMEDO DE MONTAÑA EN HIDALGO, MÉXICO.

CÉSAR MORENO GARCÍA

T E S I S

**PRESENTADA COMO REQUISITO PARCIAL
PARA OBTENER EL GRADO DE:**

MAESTRO EN CIENCIAS

MONTECILLO, TEXCOCO, EDO. DE MÉXICO

2017

CARTA DE CONSENTIMIENTO DE USO DE LOS DERECHOS DE AUTOR Y DE LAS REGALIAS COMERCIALES DE PRODUCTOS DE INVESTIGACION

En adición al beneficio ético, moral y académico que he obtenido durante mis estudios en el Colegio de Postgraduados, el que suscribe Cesar Moreno García, Alumno (a) de esta Institución, estoy de acuerdo en ser partícipe de las regalías económicas y/o académicas, de procedencia nacional e internacional, que se deriven del trabajo de investigación que realicé en esta institución, bajo la dirección del Profesor Lauro López Mata, por lo que otorgo los derechos de autor de mi tesis

Análisis de la heterogeneidad del índice normalizado diferencial de vegetación (NDVI) del bosque húmedo de montaña en Hidalgo, México

y de los productos de dicha investigación al Colegio de Postgraduados. Las patentes y secretos industriales que se puedan derivar serán registrados a nombre del colegio de Postgraduados y las regalías económicas que se deriven serán distribuidas entre la Institución, El Consejero o Director de Tesis y el que suscribe, de acuerdo a las negociaciones entre las tres partes, por ello me comprometo a no realizar ninguna acción que dañe el proceso de explotación comercial de dichos productos a favor de esta Institución.

Montecillo, Mpio. de Texcoco, Edo. de México, a 23 de noviembre de 2017



Firma del
Alumno (a)



Vo. Bo. del Consejero o Director de Tesis

La presente tesis titulada: Análisis de la heterogeneidad del índice normalizado diferencial de vegetación (NDVI) del Bosque Húmedo de Montaña en Hidalgo, México, realizada por el alumno: **César Moreno García** bajo la dirección del Consejo Particular indicado, ha sido aprobada por el mismo y aceptada como requisito parcial para obtener el grado de:

MAESTRO EN CIENCIAS
BOTÁNICA

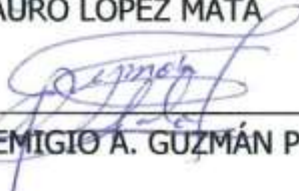
CONSEJO PARTICULAR

CONSEJERO



DR. LAURO LÓPEZ MATA

ASESOR



DR. REMIGIO A. GUZMÁN PLAZOLA

ASESOR

DR. JOSÉ LUIS VILLASEÑOR RIOS

ASESOR



DR. GUSTAVO CRUZ CÁRDENAS

ASESORA



DRA. LUCERO DEL MAR RUIZ POSADAS

ASESORA



DRA. HEIKE VIBRANS LINDEMANN

Montecillo, Texcoco, Estado de México, noviembre de 2017

**ANÁLISIS DE LA HETEROGENEIDAD DEL ÍNDICE NORMALIZADO
DIFERENCIAL DE VEGETACIÓN (NDVI) DEL BOSQUE HÚMEDO DE
MONTAÑA EN HIDALGO, MÉXICO.**

**César Moreno García, M. en C.
Colegio de Postgraduados, 2017**

RESUMEN

El Índice Normalizado Diferencial de la Vegetación (NDVI por sus siglas en inglés) es una medida que se obtiene de la combinación de la reflectancia de dos o más longitudes de onda en la superficie de la tierra, captadas en imágenes satelitales. Estas imágenes consideran características que incluyen temporalidad, resolución espacial y espectral. El NDVI resalta la presencia de vegetación saludable y con mayor actividad fotosintética y se ha usado ampliamente para evaluar impactos y alteraciones en la vegetación cuando no son tan evidentes. En México, el Bosque Húmedo de Montaña (BHM) es el bioma que contiene la más alta riqueza de especies por unidad de superficie y provee una amplia gama de servicios ecosistémicos; desafortunadamente las actividades antropogénicas y el cambio climático incrementan su vulnerabilidad en toda su distribución. En esta investigación se analiza la variabilidad espacio-temporal del NDVI del bosque húmedo de montaña en el Estado de Hidalgo y su relación con algunas variables ambientales. Para ello se hizo la delimitación geográfica de la distribución del BHM en Hidalgo usando percepción remota. Mediante el uso de imágenes de satélite Landsat se obtuvieron los valores del índice durante los meses de la época seca de los años 2013 a 2016. Se generaron 14 variables ambientales, tres de relieve, dos de suelo y nueve de clima para explicar la variabilidad del índice mediante modelos de regresión lineal múltiple. Todas las variables fueron integradas en un sistema de información geográfico (SIG), de donde se extrajo una matriz de puntos. Se generaron modelos de

regresión para intentar explicar el valor mensual del NDVI y un modelo general para toda la época seca del período analizado. Se identificó que en la mayoría de los modelos, las variables que explican la heterogeneidad del NDVI para los valores mensuales son el relieve y la precipitación anual, mientras que para la época seca las variables que explican el más alto porcentaje de la variabilidad en el NDVI son: la temperatura mínima y el relieve. La heterogeneidad del NDVI integrada a un SIG identificó la estacionalidad del BHM resultando en una excelente herramienta para analizar tanto su fragmentación como su distribución regional discontinua y las variables asociadas con ellas en Hidalgo.

Palabras clave: Variabilidad, cobertura, época seca, fenología, relieve, temperatura, precipitación anual.

**ANALYSIS OF THE HETEROGENEITY OF THE NORMALIZED
DIFFERENTIAL VEGETATION INDEX (NDVI) OF THE HUMID MOUNTAIN
FOREST IN THE STATE OF HIDALGO, MEXICO.**

**César Moreno García, M. en C.
Colegio de Postgraduados, 2017**

ABSTRACT

The Normalized Differential Vegetation index (NDVI) is a measure obtained from a combination of reflectance of two or more wavelengths from the surface of the earth, captured in satellite images. The NDVI stands out the presence of healthy vegetation and with more photosynthetic activity. The values of NDVI evaluates impacts and alterations in the vegetation even as they are not so evident. In Mexico, the HMF is the biome that holds the highest species richness per surface unit and it provides a wide range of environmental services. Unfortunately, the human activities and climatic change increases the vulnerability of the HMF throughout their natural range. In this research, we analyzed the NDVI variability of the HMF in the State of Hidalgo at spatial and temporal scales and its relationship with some environmental variables. We used satellite images of Landsat to define the geographic range limits of the HMF in Hidalgo, and to estimate the values of NDVI during the months of dry season of years 2013 to 2016. We generated 14 environmental variables, to explain the variability of NDVI applying multiple regression models; the variables were three of relief, two soil properties and nine of climate. All variables integrated in a geographical information system (GIS) served to extract a matrix data points. The generated regression models explained both, the value of NDVI for the complete dry season and for each month. Most of the regression models identified the relief and annual rainfall as the most important variables to explain the variability of the monthly NDVI values, while the minimum

temperature and relief explained heterogeneity of the complete dry season. The heterogeneity of NDVI integrated to a GIS, identified the seasonality of the BHM resulting in an excellent tool to analyze forest fragmentation and regional discontinuity, and the variables associated with them in the state of Hidalgo.

Key words: Variability, forest cover, dry season, phenology, relief, temperature, annual rainfall.

AGRADECIMIENTOS

Quiero expresar mi más sincero agradecimiento al pueblo mexicano por sus aportaciones y que a través del Consejo Nacional de Ciencia y Tecnología (CONACYT) se financió el proyecto (400595), para realizar mis estudios de Maestría en Ciencias.

Al Colegio de Postgraduados y al programa de Botánica porque gracias a su trascendental grupo de investigadores hacen posible la preparación académica de profesionistas y mexicanos investigadores.

Un sincero agradecimiento a mi consejero y amigo Dr. Lauro López Mata por permitirme el ingreso en su equipo de investigación. Sus valiosas recomendaciones ayudaron a mejorar el desarrollo de esta investigación. Sus consejos han mejorado mi preparación personal y profesional.

Gracias inmensas a los miembros de mi consejo particular que siempre mostraron interés y ayudaron a consolidar esta investigación. Gracias al Dr. Remigio Guzmán Plazola por compartir su tiempo y apoyar en todo momento este proyecto. Muchas gracias Dr. Gustavo Cruz Cárdenas y Dr. José Luis Villaseñor Ríos porque a pesar de la lejanía siempre hubo disponibilidad y voluntad para apoyar y mejorar esta investigación. Sinceros agradecimientos a las Dra. Heike Vibrans Lindemann y Dra. Lucero del Mar Ruíz Posadas por su contribución y comentarios tan importantes. Gracias a todos por sus cátedras y por compartir su experiencia y valioso conocimiento.

Gracias inmensas Papá, Mamá y hermanos porque siempre me han manifestado su amor incondicional. Los quiero.

Gracias a la familia Villaseca Lara amigos y compañeros de trabajo. Agradecido totalmente por su amistad, cariño y apoyo, siempre estarán en mi corazón.

Gracias también a alguien muy especial para mí, que tuvo que partir al cielo, pero que estoy seguro que quisiera compartir conmigo este logro.

DEDICACIÓN ESPECIAL.

A Claudia, Ramsés, Rafael y Juan Carlos

Ustedes son mi mejor motivación.

Sin su amor pude haber caído en el intento.

Los amo.

CONTENIDO

RESUMEN	iv
ABSTRACT	vi
LISTA DE CUADROS	xiii
LISTA DE FIGURAS	xv
INTRODUCCIÓN.....	1
MARCO TEÓRICO	2
El Bosque Húmedo de Montaña.	3
Percepción remota.....	5
Satélite Landsat 8.....	7
El Índice Normalizado Diferencial de la Vegetación (NDVI).....	10
Fotografías Hemisféricas	11
IMPORTANCIA DEL ESTUDIO	13
OBJETIVO	16
HIPÓTESIS	16
ÁREA DE ESTUDIO.....	16
MATERIALES Y MÉTODOS.....	18
Delimitación del área de estudio.....	18
Adquisición de imágenes de satélite.....	21
Cálculo del Índice Normalizado Diferencial de Vegetación	22
Muestreo de campo.....	23
Levantamiento de información de campo.....	24
Procesamiento de fotografías hemisféricas.....	27
Preparación de capas de información climática y edafológica	28
Análisis estadístico.	33
Análisis de datos de campo.....	36
RESULTADOS	37

Distribución del BHM	37
Valores mensuales de NDVI.....	37
Capas climáticas y ambientales	38
DISCUSIÓN.....	64
CONCLUSIONES.....	70
BIBLIOGRAFÍA	71

LISTA DE CUADROS

Cuadro 1. Principales aplicaciones asociadas a cada una de las bandas del sensor Landsat 8 (USGS 2015, Pettorelli 2013).	9
Cuadro 2. Ubicación de fotopuntos para la toma de fotografías hemisféricas.	25
Cuadro 3. Variables potenciales seleccionadas para explicar la variabilidad de los valores del NDVI en el BHM en Hidalgo, México.	32
Cuadro 4. Coeficientes de correlación de Pearson para las 14 variables regresoras.	34
Cuadro 5. Errores de predicción para las capas mensuales de temperatura mínima, obtenidos con el método de interpolación cokriging simple y método de ajuste gaussiano.	39
Cuadro 6. Errores de predicción para las capas mensuales de temperatura máxima, obtenidos con el método de interpolación cokriging simple y método de ajuste exponencial.	40
Cuadro 7. Errores de predicción para las capas mensuales de temperatura media, obtenidos con el método de interpolación cokriging simple y método de ajuste gaussiano.	41
Cuadro 8. Errores de predicción para las capas mensuales de precipitación, obtenidos con el método de interpolación cokriging ordinario y método de ajuste gaussiano.	42
Cuadro 9. Descripción de las 14 variables ambientales consideradas para explicar la variabilidad de los valores del NDVI en el BHM en Hidalgo, México.	43

Cuadro 10. Relación del Índice de vegetación NDVI, en el bosque húmedo de montaña del estado de Hidalgo de cobertura densa, con variables ambientales, coeficiente de determinación parcial (R^2 parcial y global) calculados durante el procedimiento Stepwise de selección de variables.....	60
Cuadro 11. Relación del Índice de vegetación NDVI, en el bosque húmedo de montaña del estado de Hidalgo de cobertura densa, con variables ambientales, coeficiente de determinación parcial (R^2 parcial y global) calculados durante el procedimiento Stepwise de selección de variables.....	62
Cuadro 12. Coeficiente de correlación para los valores de NDVI analizados y los valores extraídos del procesamiento de fotografías hemisféricas	63

LISTA DE FIGURAS

Figura 1. Región de estudio y distribución del BHM en el estado de Hidalgo y parte de los estados de Puebla y Veracruz.....	17
Figura 2. Distribución del bosque húmedo de montaña en la región de estudio.....	21
Figura 3. Fotografías hemisféricas tomadas para este estudio correspondientes al mes de abril (a) y julio (b) de 2016.....	26
Figura 4. Valores máximos extremos y promedios mensuales de NDVI en el periodo estudiado.	38
Figura 5. Distribución de la variable Aspecto de la pendiente (grados), que fue ingresada al modelo de regresión lineal múltiple.	45
Figura 6. Distribución de la variable pendiente (grados), que fue ingresada al modelo de regresión lineal múltiple.....	47
Figura 7. Distribución de la variable precipitación anual, que fue ingresada al modelo de regresión lineal múltiple.....	49
Figura 8. Distribución de la variable estacionalidad de la precipitación, que fue ingresada al modelo de regresión lineal múltiple.	51
Figura 9. Distribución de la variable carbono orgánico del suelo, que fue ingresada al modelo de regresión lineal múltiple.	53
Figura 10. Distribución de la variable pH del suelo, que fue ingresada al modelo de regresión lineal múltiple.....	55
Figura 11. Distribución de la variable Temperatura del Trimestre más frío, que fue ingresada al modelo de regresión lineal múltiple.	57

INTRODUCCIÓN

México tiene una alta diversidad biológica, que se manifiesta en una gran riqueza de especies y endemismos (CONABIO 2013). Uno de sus ecosistemas naturales con estas características es el Bosque Húmedo de Montaña (BHM), el cual es además una importante fuente de servicios ecosistémicos. Las condiciones naturales y procesos que se llevan a cabo en este tipo de vegetación tienen un valor ecológico muy particular, ya que es el tipo de vegetación más importante para la provisión tanto de agua como de nichos para la coexistencia de un número importante de especies animales y vegetales (Gual-Díaz & Rendón-Correa 2014). De acuerdo con Villaseñor (2010) el BHM aporta aproximadamente un 10% de plantas vasculares a la biodiversidad de México.

Las condiciones en que se encuentra este bioma lo colocan en una situación muy vulnerable. Se estima que a nivel mundial se ha perdido una proporción importante de la superficie del BHM, aunque son escasos los estudios cuantitativos (CONABIO 2010). En México el panorama es desalentador, ya que está ocurriendo pérdida de este tipo de vegetación debido principalmente a expansión de la frontera agrícola, la tala a pequeña escala, la ganadería, el crecimiento urbano y el aprovechamiento forestal. Se estima que actualmente existe solo 48% de la superficie que existía en 1976 (CONABIO 2010).

Es necesario diseñar métodos que permitan evaluar espacial y temporalmente la estructura y funcionamiento de los BHM. Actualmente existen técnicas de percepción remota basadas en la cuantificación y comparación de áreas en distintos tiempos y espacios. El uso de la tecnología satelital, a través de la obtención de datos por percepción remota, ayuda a evaluar los distintos procesos de la vegetación, ya que con ella se puede obtener datos periódicos y puntuales (Alcaraz-Segura *et al.* 2008). Las bandas contenidas en las imágenes provenientes de los satélites registran

la medición de la luz reflejada en varios intervalos de longitud de onda, donde cada intervalo puede diferenciar ciertas propiedades de la superficie. Básicamente el espectro es dividido en tres partes; 1) visible (400 - 750 μm) que es principalmente sensible a la actividad fotosintética y contenido de clorofila en las hojas, 2), infrarrojo cercano (0.75 – 1.3 μm) que indica la reflectancia de la luz respecto a la estructura de las hojas y el infrarrojo medio (1.3 – 2.5 μm) que ayuda a la explicación del contenido de agua, celulosa y lignina en las plantas. Es por ello, que la combinación de las reflectancias de las regiones del rojo e infrarrojo pueden distinguir procesos específicos de la vegetación, como la vigorosidad y la actividad fotosintética (Pettorelli 2013).

MARCO TEÓRICO

Las características ambientales muy particulares que hacen posible la presencia del BHM, son la causa también de que su distribución sea restringida. Es común que este tipo de vegetación esté presente sobre las vertientes y laderas donde inciden los vientos húmedos; por ello es común que allí se concentre una alta humedad y precipitación (CONABIO 2010, CONABIO 2013, Gual-Díaz & Rendón-Correa 2014).

Debido a la presencia de humedad y neblina en la mayor parte del año, el BHM es conocido internacionalmente como bosque de niebla o *cloud forest* (CONABIO 2010, Villaseñor 2010). De acuerdo con Williams-Linera (2015), en México este tipo de vegetación fue llamado bosque mesófilo de montaña por Miranda en (1947), para referirse a una formación vegetal de la cuenca del Río Balsas en la misma cota altitudinal y condiciones favorables de humedad atmosférica y de suelo que para los encinares, pero encontrada en las barrancas. Esta designación es ampliamente

usada en México. Pero, Villaseñor (2010) sugiere utilizar el término Bosque Húmedo de Montaña para referirse a esta formación vegetal, término adoptado para este estudio.

El Bosque Húmedo de Montaña.

El bosque húmedo de montaña, también conocido como bosque mesófilo de montaña (Rzedowski 1978), se localiza de manera fragmentaria en las serranías húmedas de México. Dadas sus características particulares de condensación de humedad, predominantes en este tipo de vegetación, su distribución suele ser angosta y pequeña (Villaseñor 2010, CONABIO 2010, Gual-Díaz & Rendón-Correa, 2014), ocupando menos del 1% del territorio nacional (Cruz-Cárdenas et al. 2012, Gual-Díaz & Rendón-Correa 2014), y se ubica principalmente en cañadas poco accesibles y laderas húmedas y conservadas. Una de las especies más representativas del BHM es *Fagus grandifolia* subsp. *mexicana* (haya), que es una especie endémica y esta considerada en riesgo de extinción. La zona con mayor extensión territorial de México está en el estado de Hidalgo.

La distribución natural del BHM se restringe a las cadenas montañosas de México (Gual-Díaz & Rendón-Correa 2014), entre altitudes de 800 a 2 200 metros, pero en su mayoría entre 1 000 y 1 500 m. El tipo de clima es C (fm), que corresponde a un templado húmedo, con lluvias todo el año y presencia de neblinas frecuentes (García 1973). La temperatura media anual fluctúa entre 12 y 23 °C; la precipitación media es de 2 000 mm anuales. Se desarrolla preferentemente en las zonas de barlovento, debido a la incidencia de vientos húmedos, condensación frecuente de nubes y formación de neblinas (Hernández-Cerda & Carrasco-Anaya 2004).

En México, estas formaciones generalmente tienen una marcada estacionalidad de la vegetación. Se presentan 1 a 4 meses secos, principalmente durante el invierno, con un porcentaje de precipitación anual del 20% aproximadamente; su periodo más húmedo se presenta entre los meses

de mayo a octubre (CONABIO 2010). Debido a esta estacionalidad climática, la mayoría de sus especies fisionómicamente dominantes son caducifolias durante la estación seca de año.

Se estima que en el BHM existen 6, 790 especies, que corresponden al 10% de las descritas para todo México. Dada su reducida superficie de distribución el BHM es el tipo de vegetación de México con mayor riqueza de especies por unidad de superficie. El BHM además aporta una importante proporción de endemismos, el 20.3% de los registrados para México (Villaseñor 2010) y es el tipo de vegetación con la mayor riqueza de especies por unidad de superficie (CONABIO 2013, Villaseñor 2010). Esta característica, es una de las razones por la que se considera como un tipo de vegetación de alta fragilidad.

Un número considerable de especies del BHM son una fuente importante de recursos para satisfacer necesidades alimenticias, medicinales, maderables y otros (CONABIO 2010). El establecimiento de agricultura y ganadería en las zonas altas de las montañas, la apertura de caminos, la tala ilegal y la presión demográfica de los asentamientos humanos cercanos al BHM contribuyen a acelerar su fragmentación y vulnerabilidad. Además, es posible, que la amenaza de mayor magnitud que puede tener el BHM es el cambio climático. Aparte de su vulnerabilidad a sequía, es un bioma de alta vulnerabilidad a los eventos climáticos extremos, dado que presenta una lenta recuperación a las perturbaciones (CONABIO 2010).

El BHM en México ha estado en constante amenaza, principalmente por la cercanía a los asentamientos humanos, los cuales, a pesar de la accidentada superficie hacen uso de esta vegetación mediante la extracción y tala, principalmente a pequeña escala, en especial en los bordes de bosque remanente. Allí también es importante el establecimiento de áreas productoras de café, ganadería, y en menor medida la producción forestal (Sanchez-Ramos & Dirzo 2014).

Es innegable la necesidad de desarrollar herramientas y protocolos capaces de estudiar y dar seguimiento a estas perturbaciones a gran escala y por periodos de tiempo prolongados. En algunos casos resulta difícil obtener datos de gran magnitud y temporalidad por el costo y el tiempo. Para cubrir estas desventajas podemos asistirnos de la toma de datos a través de la percepción remota.

Percepción remota

Los sensores remotos son instrumentos que obtienen información de la superficie terrestre a través de plataformas espaciales con instrumentos instalados con capacidad de medir la relación entre la energía recibida y la reflejada por la superficie. Esta medición se plasma en una imagen satelital, del que se obtienen datos temporales y espaciales de algunos fenómenos en la tierra (Chuvienco 1995). La percepción remota es una técnica de obtención de datos de la superficie terrestre sin tener contacto con ella (Bolstad 2012, Johnston 1998).

Las imágenes satelitales pueden tomar datos de la superficie a distintas escalas y tiempos, dependiendo del satélite y sensor, ya que cada uno contiene un sistema propio para la recolección de datos. Las variaciones de estas imágenes incluyen la superficie de toma, la resolución espacial, la resolución espectral o el número de bandas y la resolución temporal (Chuvienco 1995). La elección del tipo de sensor depende de las necesidades y los objetivos que se persiguen. Existen imágenes de baja resolución las generadas por los sensores, pero de cobertura amplia, que pueden ser usadas para estudios de grandes extensiones o para monitoreo de fenómenos meteorológicos; por ejemplo, las de MODIS, AVHRR y NOAA. Si el propósito es hacer estudios a escala regional, lo recomendable es emplear imágenes satelitales de alta resolución espacial, como las de los satélites LANDSAT o SPOT (Pettorelli 2013).

Las imágenes pueden ser tomadas con una combinación de parámetros, de acuerdo con el satélite que las toma. Estos parámetros o detalles podemos entenderlos como la capacidad de captar las variaciones de energía que detecta (resolución espectral), la temporalidad con la que el sensor es capaz de captar la misma porción de territorio (resolución temporal) y el detalle con el que el sensor puede captar la superficie de la tierra (resolución espacial) (Chuvieco 1995).

En particular la resolución espectral se refiere a la anchura y número de bandas que contiene el sensor para captar las diferencias entre las distintas coberturas de la tierra. Es decir, el sensor divide el espectro electromagnético en distintas bandas (intervalo del espectro), de tal forma que cada una de ellas capte la energía reflejada en distintas longitudes de onda. Cada una de estas bandas se convierte en una imagen. Las bandas incluidas en cada sensor dependen de los objetivos de los sensores. Cada una de las bandas tiene la capacidad de distinguir distintos detalles de la superficie (Schowengerdt 2007). En específico, para los de análisis de recursos naturales se necesitan más divisiones del espectro para diferenciar las distintas coberturas de la tierra (Chuvieco 1995).

La resolución espacial se refiere a la capacidad del satélite para captar detalles de la superficie; es decir, se refiere a la unidad de superficie en metros cuadrados que puede captar el satélite en una celda de la imagen. Se entiende también esta resolución como la unidad mínima del terreno que el satélite puede identificar en cada celda de la imagen (Johnston 1998).

La resolución temporal se refiere a la frecuencia con que la cobertura de la tierra captada en la imagen vuelve a ser tomada. En términos prácticos, la temporalidad de la imagen se entiende como el tiempo en que el satélite repite la toma de la misma cobertura de la tierra (Schowengerdt 2007).

Las características de los satélites varían de acuerdo a los propósitos con que fueron diseñados y son consideradas cuando necesitamos analizar ciertas particularidades como la temporalidad,

escala de trabajo o el tipo de estudio. La selección de la imagen a usar se determina de acuerdo con el detalle, temporalidad y tipo de análisis que se desea realizar (Chuvieco 1995). Para el caso de evaluaciones y estudios regionales sobre manejo de recursos naturales, se ha documentado ampliamente que las imágenes provenientes del satélite Landsat son buenas herramientas de apoyo y muy eficaces (Johnston 1998).

Una de las ventajas principales en el uso de información satelital, es que resulta una técnica poco costosa, explora grandes superficies terrestres y obtiene datos de áreas inaccesibles. De igual forma, la disponibilidad histórica de las imágenes permite hacer análisis retrospectivo a través o en grandes periodos de tiempo.

Satélite Landsat 8.

El primer satélite enviado por los Estados Unidos al espacio fue llamado ERTS-1 (Earth Resources Technology Satellite) en 1972. Actualmente Landsat es una constelación de 8 satélites equipados para captar información con mayor detalle y precisión de la superficie terrestre (Pettorelli 2013).

Las imágenes Landsat corresponden a un proyecto entre la Administración Nacional de Aeronáutica Espacial de los Estados Unidos de América (NASA, por sus siglas en inglés) y el Servicio Geológico de los Estados Unidos (USGS por sus siglas en inglés). Dicho satélite provee una serie de observaciones que abarca todo el mundo.

Las imágenes del primer satélite Landsat eran de menor calidad debido a las limitaciones tecnológicas de su época. Pero se diseñaron satélites para el mismo propósito con mejor tecnología. En la actualidad el satélite Landsat se considera uno de los satélites con mayor utilidad y calidad. De los 8 satélites puestos en órbita solamente 3 siguen en funcionamiento que son los satélites

Landsat 5, 7 y 8. El actual satélite Landsat en funcionamiento es el Landsat 8, fue diseñado y puesto en órbita para substituir a los satélites Landsat anteriores. Dicho satélite continúa con la misma consistencia en cuanto a su geometría, calibración y características espectrales y de toma que sus antecesores. Este satélite se terminó de fabricar en 2012 y fue puesto en órbita en abril de 2013 (USGS 2015).

El satélite Landsat 8, provee imágenes de alta calidad de la superficie del planeta. Llega a obtener 400 imágenes diarias y cubre el globo terráqueo en 15 días. Las imágenes son procesadas, corregidas y puestas al público de forma gratuita. Las imágenes disponibles son procesadas hasta el nivel L1T, lo que significa que tienen una imagen rectificadas geométricamente o libre de distorsiones causadas por el sensor, el satélite o la curvatura de la tierra y corregidas radiométricamente para remover diferencias relativas al detector y otros artefactos (USGS 2015).

Las imágenes Landsat 8 abarcan una escena de aproximadamente 183 kilómetros verticales y 106 km horizontales. Contienen 10 bandas espectrales y una pancromática, que corresponden a una división del espectro en distintas longitudes de onda, de tal forma que se pueda captar la mayor variación de la luz reflejada. Cada una de las bandas está diseñada para discriminar distintas coberturas (Cuadro 1). Posiblemente en la actualidad las imágenes Landsat sean las más utilizadas en estudios de ecología y conservación de recursos naturales (Pettorelli 2013).

Cuadro 1. Principales aplicaciones asociadas a cada una de las bandas del sensor Landsat 8 (USGS 2015, Pettorelli 2013).

Banda	Resolución (m)	Longitud de onda (μm)	Aplicación
1	30	0.435 - 0.451 (costa/aerosol)	Estudios costeros y color del océano
2	30	0.452 - 0.512 (azul)	Penetración de agua clara; mapeo de agua de costas, absorción de clorofila; distinción de vegetación caducifolia y perenne.
3	30	0.533 - 0.590 (verde)	Registros de los picos de reflectancia del verdor de la vegetación; evaluación del vigor en plantas; reflectancia de aguas turbias.
4	30	0.636 - 0.673 (rojo)	Trabaja en la región de la absorción de la clorofila y es el mejor para detectar caminos, suelo desnudo y tipos de vegetación.
5	30	0.851 - 0.879 (infrarrojo cercano)	Usada para estimar biomasa. Separa cuerpos de agua de vegetación y discrimina suelo húmedo.
6	30	1.566 - 1.651 (infrarrojo medio)	Discrimina caminos, suelo desnudo y agua. Provee contraste entre los distintos tipos de vegetación y buena penetración en la neblina y fenómenos atmosféricos. Capaz de discriminar nieve y nubes.
7	30	2.107 - 2.294 (infrarrojo medio)	Ideal para discriminar tipos de minerales y rocas y apoya para diferenciar cobertura vegetal y humedad.
8	15	0.503 - 0.676 (pancromática)	Crea gran contraste entre áreas con vegetación y sin vegetación
9	30	1.363 - 1.384 (cirrus)	Detección de nubes delgadas y áreas cubiertas de hielo
10	100	10.60 - 11.19 (infrarrojo térmico)	Las bandas 10 y 11 responden al calor de la radiación emitida. La radiación térmica está relacionada con la humedad de suelo y es un buen medidor del estrés de las plantas.
11	100	11.50 - 12.51 (infrarrojo térmico)	

El Índice Normalizado Diferencial de la Vegetación (NDVI)

La mayoría de los índices de vegetación existentes se diseñaron para evaluar las diferencias entre las propiedades de la vegetación y discriminar entre las coberturas de la superficie (Pettorelli 2013). Todos ellos utilizan en su mayoría los valores del espectro correspondiente a las bandas roja e infrarroja, por ser los de mayor sensibilidad ante cambios de la vegetación (Pettorelli 2013). Diversos autores concuerdan en que tanto la banda roja como la infrarroja pueden captar procesos de desarrollo y verdor de la vegetación, por ejemplo, De la Casa y Ovando (2006), Pettorelli *et al.* (2005), y Huete *et al.* (1999). La banda roja en particular es capaz de captar las variaciones del reflejo de la energía absorbida, debido a la actividad fotosintética de las hojas de las plantas. Por otro lado, los valores de la banda infrarroja se incrementan con el desarrollo de las plantas y es evidencia de la proliferación de las hojas sanas y turgentes (Huete 1999).

A partir de la generación del primer índice de vegetación, en la década de los 70's, se fueron desarrollando y mejorando otros de acuerdo con objetivos específicos, tratando de discriminar otras características en particular. En 1969, se propuso el primero de ellos, denominado RVI (Ratio Vegetation Index), con la finalidad de contrastar la vegetación de la superficie terrestre. El siguiente índice desarrollado en 1974 fue el NDVI (Normalized Diferencial Vegetation Index), el cual es un equivalente del RVI, pero mejora la discriminación, por usar un umbral más alto de reflectancia y absorción de la vegetación (Pettorelli 2013). Otros índices comenzaron a usarse posteriormente, principalmente tratando de mejorar los indicadores de discriminación; actualmente existen más de 150.

Pettorelli (2013) menciona que el NDVI es una buena herramienta para discriminar valores de cobertura vegetal y proporciona valores útiles en el análisis de vegetación densa. Sin embargo, se ha demostrado que existe saturación cuando se trata de discriminar densidades altas de cobertura. Tratando de mejorar esta problemática, surgió el EVI (Enhanced Vegetation Index), que fue diseñado para contrarrestar los problemas meteorológicos y de cobertura que comúnmente alteran la composición del NDVI. El EVI incrementa la discriminación del verdor natural de la vegetación, evidenciando la sensibilidad del sensor ante las distintas condiciones de la biomasa (Wardlow *et al.* 2007).

Pettorelli, (2013) y Wardlow *et al.* (2007) en distintos estudios encontraron que, mientras el NDVI es más sensible a los cambios de síntesis de clorofila, el EVI puede distinguir mejor las diferentes coberturas de la vegetación. El NDVI, identifica mejor, por ejemplo, la estacionalidad fenológica de los cultivos, mientras que el EVI, discrimina la cobertura y su verdor y es menos sensible a los máximos estacionarios. Con base en estas propiedades y de acuerdo con los objetivos, en esta investigación se utilizó el NDVI como indicador de estacionalidad y fenología del BHM.

Fotografías Hemisféricas

La fotografía hemisférica permite obtener una imagen del interior del dosel para conocer las condiciones de luz y la estructura del dosel de la vegetación (Mauro-Diaz *et al.* 2014). Dichas imágenes permiten hacer estimaciones de la fracción de huecos en el dosel, del índice de agrupamiento de la superficie foliar a distintos ángulos cenitales y del régimen de radiación solar incidente (Martínez *et al.* 2006).

Las fotografías hemisféricas han sido utilizadas ampliamente para estimar parámetros estructurales del dosel de los bosques y de la cubierta vegetal, ya que su toma permite obtener detalle de los

claros del dosel y la luz que penetra al interior del bosque vista desde el fotopunto (Mauro-Diaz *et al.* 2014). Diversos autores apoyan el uso de esta técnica para la estimación de parámetros estructurales del dosel de la vegetación (Martínez *et al.* 2006). Un proceso indispensable para conocer o medir la dinámica forestal es la fotosíntesis, ya que es el proceso en el que se desarrolla el intercambio masivo de materia y energía en la naturaleza. Es susceptible de análisis mediante el uso combinado de fotografías hemisféricas y percepción remota. (Aguirre-Salado *et al.* 2010).

IMPORTANCIA DEL ESTUDIO

La percepción remota es una técnica que puede utilizarse para obtener información de manera consistente en grandes superficies. Sin embargo, la adquisición de datos de percepción remota y de campo es complementaria. Los datos de campo georreferenciados apoyan a generar datos más certeros para la interpretación, clasificación y predicción de las características de la vegetación (Pettorelli 2013).

La vegetación contiene complejos procesos funcionales y estructurales que han sido analizados de distintas formas. El uso de percepción remota, en conjunto con la información de campo a través de la toma de fotografías hemisféricas, ha apoyado en la descripción de la estructura de la vegetación (Cruz-Leyva *et al.* 2010) y en la evaluación de parámetros funcionales a través de la medición de transmisión de luz en el bosque (Mauro-Diaz *et al.* 2014).

La vegetación y sus procesos ecológicos variantes en el espacio y tiempo han estimulado esfuerzos importantes para su mejor entendimiento, sobre todo cuando se trata de evaluar en grandes periodos y áreas (Galicia *et al.* 2014). Se ha demostrado en diversos estudios que el NDVI proveniente de la percepción remota, se relaciona directamente con los procesos vegetativos (Pettorelli *et al.* 2005) y puede ser un indicador para su monitoreo.

Los cambios en la productividad primaria neta, densidad de cobertura y fenología, pueden ser indicadores del funcionamiento y la dinámica de la vegetación (Galicia *et al.* 2014). Las fotografías hemisféricas permiten conocer desde el interior del bosque la fracción de claros de luz del dosel, lo que permite estimar la estructura y penetración de luz. Es posible entonces relacionar espacialmente dichos parámetros para conocer su distribución a gran escala mediante el procesamiento de imágenes satelitales. El estudio de estas respuestas a grandes escalas es útil para

analizar los procesos ecológicos y su variabilidad debido a perturbaciones y cambios como la disminución de cobertura del dosel (Rodríguez-Moreno & Bullock 2013).

La vegetación es un componente natural del territorio que tiene relación directa con otros factores como el clima, el relieve y el suelo (Qiu *et al.* 2014). Las distintas condiciones del terreno determinan los patrones de la vegetación, por lo que el estudio de sus variaciones puede indicarnos los cambios o impactos ocurridos en el ambiente (Soudani *et al.* 2012).

Adicionalmente, existen cambios periódicos, como los relacionados con el cambio climático, degradación, restauración, entre otros, que deben ser evaluados a través del tiempo. El monitoreo es necesario para entender los procesos de cambio en los ecosistemas y su relación con las alteraciones ambientales (Eastman *et al.* 2013). De igual forma, es posible conocer la dinámica estacional de la vegetación mediante el conocimiento de la fenología de las plantas, ya que los procesos de su ciclo de vida se reflejan en los valores temporales del NDVI (Martínez & Gilabert 2009). Mediante el uso de tecnología de percepción remota es posible evaluar la dinámica de la vegetación a grandes escalas (He *et al.* 2012). Esta tecnología es una solución de bajo costo para captar la variabilidad de la estructura y funcionalidad de la vegetación en periodos largos de tiempo (Soudani *et al.* 2012).

La valoración y entendimiento de los cambios en las comunidades vegetales pueden abordarse a través del análisis del grado y variación espacial. Dicho análisis debe considerar una descripción de la situación de cualquier característica o fenómeno natural y como varía con respecto al espacio (Gallardo 2006). La técnica que aborda estos conceptos es la geoestadística, que a través de mediciones puntuales puede integrar los datos del comportamiento continuo en distintas

direcciones y luego analizarlos. Para este estudio fue necesario considerar dicha técnica estadística para la descripción de la variabilidad espacial del NDVI en el BHM.

Así mismo, las variaciones del NDVI son susceptibles de analizarse, a través de técnicas estadísticas y de percepción remota. Por un lado, mediante la percepción remota podemos obtener datos consistentes a grandes escalas y de bajo costo. Por el otro lado, la medición temporal de los sitios a través del NDVI puede estimar una tendencia capaz de mostrar y cuantificar las variaciones respecto a los procesos fenológicos de la vegetación. En México, existen pocos estudios sobre la estadía fenológica y el NDVI extraído mediante percepción remota. Sin embargo, a nivel mundial se han incrementado los estudios sobre el tema (Pettorelli *et al.* 2005).

Recientemente han surgido diversas aplicaciones que relacionan el NDVI y los procesos ecológicos. Pettorelli *et al.* (2005), mencionan diversas aplicaciones, como el análisis de biodiversidad, la distribución de especies animales y vegetales, patrones de movimiento animal y comportamiento de poblaciones animales, el NDVI se aplica al estudio de productividad y fenología.

El NDVI es solo uno de muchos índices de vegetación producidos a través de la obtención de datos satelitales. Dicho índice está relacionado con otros parámetros de la vegetación como la radiación fotosintéticamente activa, la producción primaria neta, la asimilación de carbono o la evapotranspiración, entre otros (Pettorelli 2013).

OBJETIVO

Estudiar la variabilidad espacial y temporal del NDVI del bosque húmedo de montaña que se distribuye en el estado de Hidalgo y analizar su relación con la fenología del BHM y algunas variables ambientales.

HIPÓTESIS

Las variaciones en la reflectancia de la cobertura vegetal medidas a través del NDVI en el BHM, se relacionan con su fenología y las condiciones ambientales que determinan su presencia.

ÁREA DE ESTUDIO

La región de estudio se encuentra en el centro occidental de México, dentro de la provincia fisiográfica de la Sierra Madre Oriental. El material parental predominante en la región pertenece a rocas volcánicas y los suelos son de origen volcánico del tipo andosol (Godínez-Ibarra 2007). El gradiente altitudinal de la región fluctúa entre los 50 y 2800 m. Presenta una temperatura media anual 12 a 25°C. En este estudio, la región fue delimitada de acuerdo con la distribución del BHM identificado en las capas de información de Rzedowski (1978) e INEGI (2013) y su distribución potencial (Cruz-Cárdenas *et al.* 2012). Se agruparon los municipios en los que se encuentra el BHM y se delimitó una zona de mayor superficie de acuerdo a los límites administrativos.

La Figura 1 muestra la superficie de estudio que se encuentra en el estado de Hidalgo y parte de los estados de Puebla y Veracruz, a lo largo de una franja relativamente continua de vegetación de BHM.

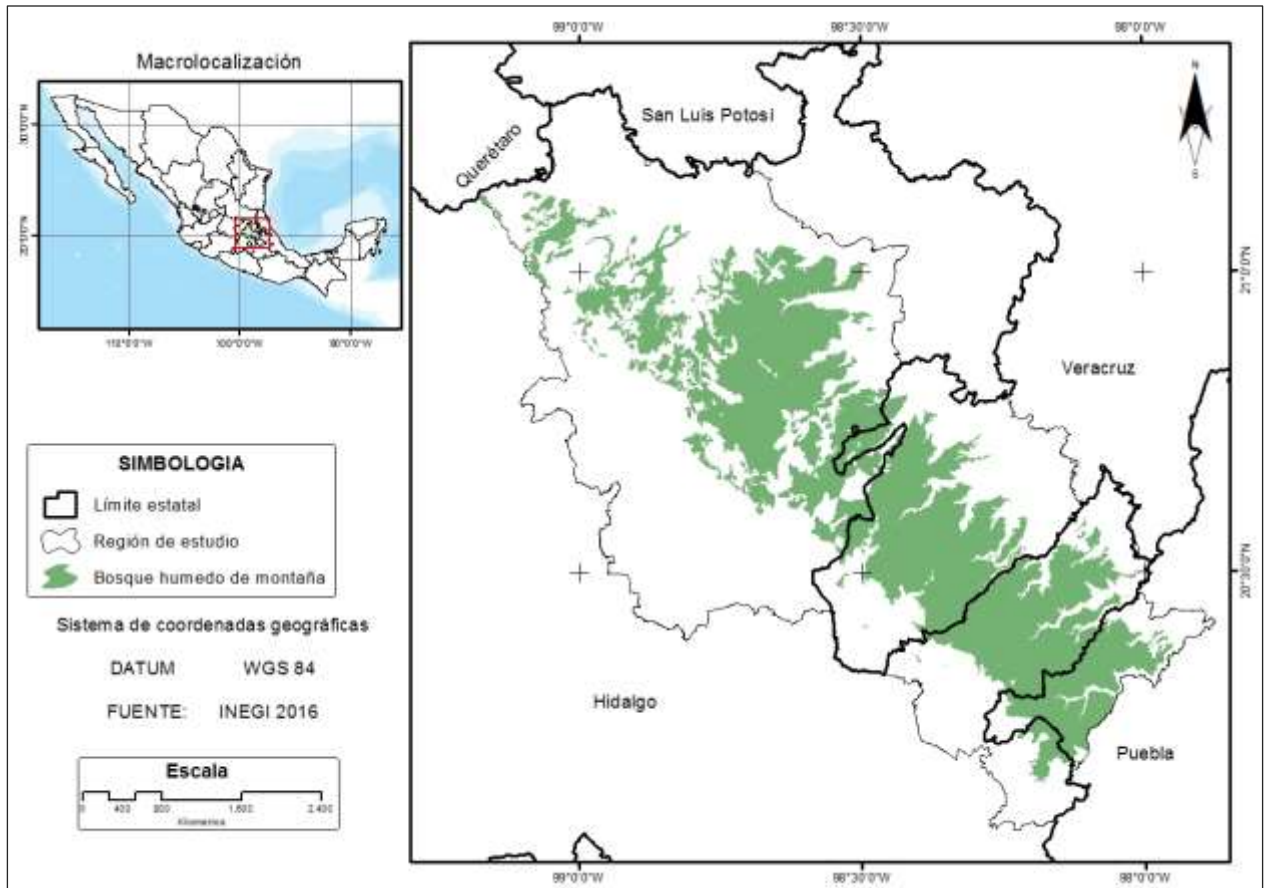


Figura 1. Región de estudio y distribución del BHM en el estado de Hidalgo y parte de los estados de Puebla y Veracruz.

MATERIALES Y MÉTODOS.

Delimitación del área de estudio.

Para enmarcar a detalle la zona de estudio del presente trabajo, se elaboró una delimitación propia usando los distintos modelos vectoriales de información que se encuentran disponibles y que representan su distribución. Se integraron tres modelos vectoriales para el BHM: 1) capa de distribución de BMM de acuerdo con la propuesta de Rzedowski (1978), disponible en formato digital en la página de la CONABIO, 2) la carta de uso de suelo y vegetación, escala 1:250 000 serie V de INEGI (2013), 3) mapa de distribución potencial del BHM de Cruz-Cárdenas *et al.* (2012). Dicho proceso permitió incluir todo el territorio identificado como BHM en distintos estudios y evitar excluir algún fragmento.

Un proceso inicial considerado fue el separar dentro del mismo bosque dos distintas densidades de cobertura. Para ello, se realizó una clasificación no supervisada de la imagen correspondiente a la escena 026-046, tomada el 13 de abril de 2016 del satélite Landsat 8, como insumo más reciente de las características del terreno.

La clasificación no supervisada es un proceso de agrupamiento en la que se toman en cuenta los valores de reflectancia de la imagen y se realiza la diferenciación de clases agrupándolas en distintos conjuntos espectrales, y luego se interpretan (Eastman 2012). Esta agrupación es automatizada, y considera que las celdas con valor similar de reflectancia corresponden a una clase de vegetación homogénea. Para ello es necesaria la interpretación posterior, para definir el tipo de clase a la que pertenece con el apoyo de otra información o datos de campo.

La clasificación no supervisada se realizó en el software IDRISI selva 17.1 (Eastman 2012), en su módulo *CLUSTER*. Incluyó las bandas 2, 3, 4, 5 y 6 de la imagen Landsat 8, y se eligieron 25 como el máximo número de clases. La asignación del número de clases no obedece a ninguna regla o modelo, más bien depende de la experiencia del usuario y la cantidad de clases que se espera diferenciar.

En la primera clasificación solo se diferenciaron las clases de cobertura densa y abierta para las zonas boscosas, además de delimitar aquellas clases como agua, poblados, suelo desnudo y otros. Complementario a este proceso se realizó una interpretación de las imágenes para visualizar el resultado del proceso de separación de las clases e identificar su correspondencia con los mapas utilizados. Además, se realizó una recodificación de clases con el módulo *RECODE* de IDRISI, que permitió recategorizar las distintas clases identificadas en solamente dos clases de densidad dentro del mismo BHM, una de cobertura densa y otra de cobertura abierta.

Un criterio adicional para la diferenciación de clases de cobertura es conocer la textura de la imagen; con ello podemos analizar la homogeneidad de los valores espectrales de las celdas con los valores vecinos e identificar grupos dentro de la imagen. Esta técnica de análisis es un proceso automatizado para la medición de paisajes y es una herramienta importante para diferenciar patrones ecológicos (Johnston 1998). Se trabajó con el módulo *TEXTURE* de IDRISI, ingresando un análisis de variabilidad y diferenciación de número de clases. El resultado de este proceso fue la categorización de la imagen en valores continuos de variabilidad entre 2 y 3. La imagen resultante se reagrupó, considerando como clase de cobertura densa a los valores de 2 a 2.5 (mayor homogeneidad) y de cobertura abierta los valores mayores a 2.5 y menores a 3 (menor homogeneidad).

Los resultados del proceso de recodificación fueron vectorizados en un archivo de polígonos en formato “shp”. Acto seguido, se interpretó visualmente de la zona mediante el software ArcGIS 10.3 (Environmental Research Systems Institute, Redlands, California) y la sobreposición de las imágenes satelitales de alta resolución de *World Imagery with Metadata web map* de 2014, disponibles libremente en la web para el programa (ESRI 2014). La finalidad de esta interpretación fue delimitar con mayor detalle las clases obtenidas y excluir otras coberturas innecesarias y que pueden identificarse fácilmente, como suelo desnudo, asentamientos humanos, cuerpos de agua o agricultura, entre otras.

Otro criterio incorporado para delimitar la cobertura fue a través de la identificación de los umbrales de altitud máxima y mínima en la que se distribuye el BHM. A través del modelo digital de elevación (MDE) se delimitaron los umbrales de altitud en el que se ha localizado el BHM y que corresponde a 800 y 2200 m.s.n.m. (CONABIO 2010, Gual-Diaz & Rendón-Correa 2014). Los mencionados autores reportan que este es el intervalo de altitud en el que se ha localizado el BHM en la región de la Sierra Madre Oriental.

El proceso siguiente consistió en delimitar el territorio del BHM que corresponde a la región. Con la delimitación resultante de la clasificación se eligió la franja relativamente continua y se realizó un proceso de selección por localización (en el software ArcGIS), para integrar como límite de la región los municipios en los cuales existe BHM. La delimitación resultante de este proceso se muestra en la Figura 2.

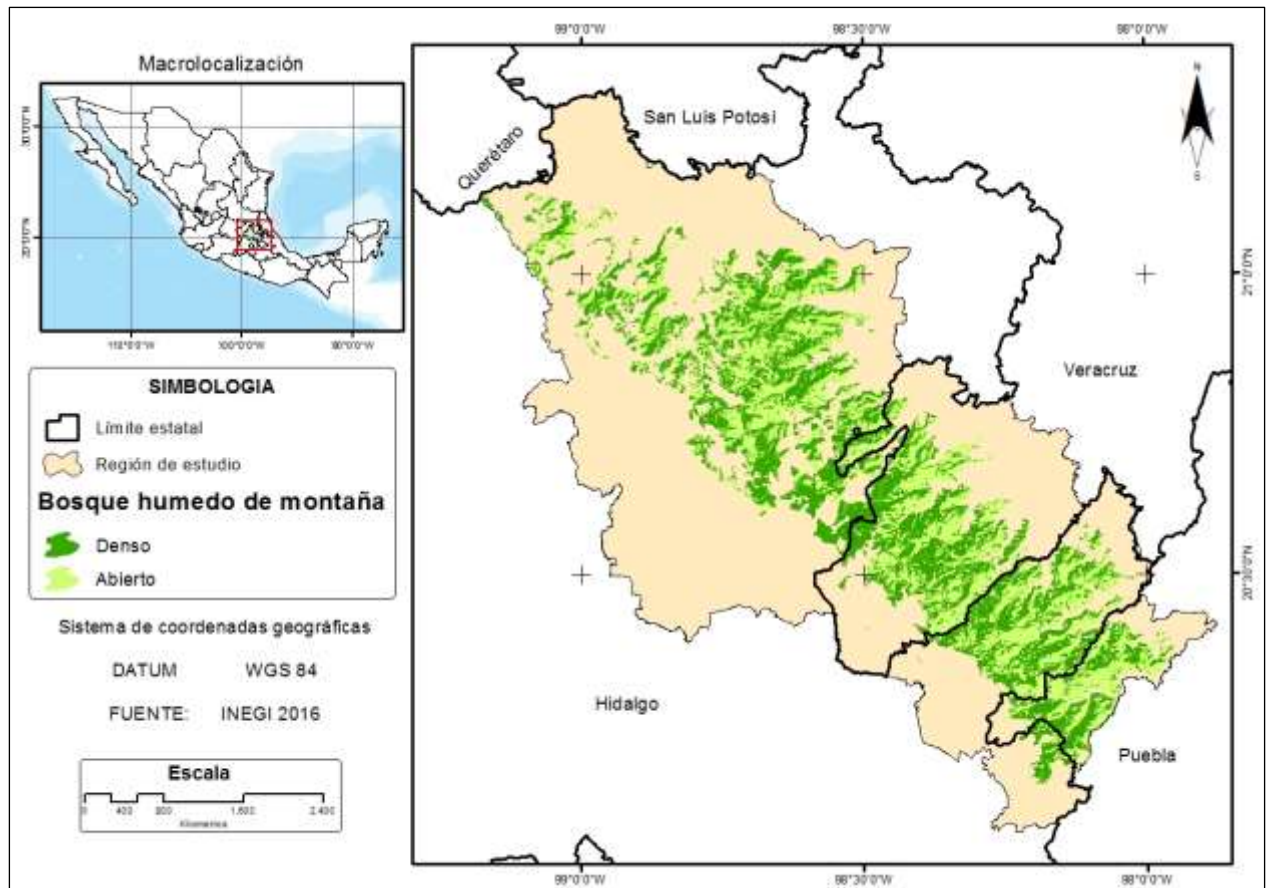


Figura 2. Distribución del bosque húmedo de montaña en la región de estudio.

Adquisición de imágenes de satélite.

Se obtuvieron las imágenes satelitales a través del repositorio de información satelital del Servicio Geológico de los Estados Unidos (USGS), que dispone de un banco de información de 1972 a la fecha (USGS 2015). La escena utilizada para el presente estudio correspondió a la 026 – 046 del satélite Landsat 8, dentro del periodo de 2013 a 2016.

Se obtuvieron las imágenes mediante el servidor earth explorer (<http://earthexplorer.usgs.gov/>). Las imágenes se seleccionaron considerando la fecha de toma, la escena y la calidad de la imagen de acuerdo con el cubrimiento de nubes. Se obtuvieron las imágenes que contienen menos del 15% de cubrimiento de nubes y que dicha nubosidad no cubriera la región de estudio. El periodo que se considera para la evaluación es durante el periodo de secas (noviembre a mayo) desde abril de 2013 a mayo de 2016.

Las imágenes extraídas contienen un nivel de procesamiento L1T, que consta de tratamiento previo de corrección geométrica, que consiste en disminuir los errores de desplazamiento en el terreno y de efectos del relieve. Además, contiene un proceso de evaluación de calidad para minimizar los efectos de nubosidad (USGS 2015).

Cálculo del Índice Normalizado Diferencial de Vegetación

La ecuación ocupada para estimar el NDVI, fue propuesta por Rouse (citado por Pettoreli 2013).

La expresión es la siguiente:

$$\text{NDVI} = \text{NIR} - \text{Red} / \text{NIR} + \text{Red}$$

Donde:

NDVI = Índice Normalizado Diferencial de Vegetación

NIR = Valor para la banda infrarroja cercana

Red = Valor para la banda roja

Se obtuvieron los índices normalizados de vegetación a través del software IDRISI, mediante el módulo VEGINDEX, utilizando las bandas 4 (roja) y la banda 5 (infrarojo) de las imágenes satelitales.

Muestreo de campo

Para la identificación de los sitios a muestrear se utilizaron dos insumos. El primero de ellos fue la delimitación del área de estudio generada para este trabajo, que permitió ubicar geográficamente la faja de distribución del BHM susceptible de ser estudiada. El segundo insumo fue la revisión bibliográfica de publicaciones relacionadas al BHM dentro de la región de estudio, con lo cual se identificaron las características de los sitios e identificación de algunas especies existentes que pudieran explicar la variabilidad del NDVI.

Los sitios de muestreo fueron seleccionados considerando las distintas condiciones del BHM, tanto aquellos que han sido intervenidos como los que han sido conservados; esto se pudo identificar mediante el conocimiento de la descripción histórica del sitio (Ortiz-Quijano *et al.* 2015) y la clasificación previa de la imagen. Los sitios de muestreo usados en el trabajo de Ortiz-Quijano *et al.* (2015) corresponden a los ejidos La Mojonera, municipio de Zacualtipán, Medio Monte, municipio de San Bartolo Tutotepec y El Gosco, municipio de Tenango de Doria. El bosque en el ejido Medio Monte se encuentra perturbado, pero aún conserva vestigios de bosque natural en algunas cañadas. Las áreas boscosas cercanas a la comunidad han perdido sus condiciones, debido a la extracción de madera y materiales. En la actualidad existe explotación maderera, pero de forma controlada, respetando árboles antiguos como *Fagus grandiflora* Ehrenb. subsp. *mexicana* (Martínez) A. E. Murray (haya), del cual solamente se extraen semillas para alimento (Ortiz-Quijano *et al.* 2015).

Las perturbaciones en el ejido El Gosco han sido más continuas y con mayor impacto; probablemente la consecuencia del gran deterioro es que el territorio está dividido en pequeñas propiedades y su explotación está condicionada a las necesidades de sus dueños. Aunque se ha logrado conservar en algunos lugares el bosque antiguo, para los jóvenes sucesores de la tierra en este lugar no es redituable y en la actualidad siguen explotando el bosque indistintamente (Ortiz-Quijano *et al.* 2015). Por otro lado, en el ejido La Mojonera se distinguen aún vestigios de BHM dominados por *Fagus grandiflora* subsp. *mexicana*, en casi 45 ha de su territorio. Dicha región es considerada como la mejor conservada y de mayor extensión de bosque de haya del país (Godinez-Ibarra *et al.* 2007). En todos los sitios mencionados, estructuralmente hablando, *Fagus grandiflora* subsp. *mexicana* es la especie dominante, aunque la altura de los árboles encontrados es distinta entre los sitios, dadas las condiciones del bosque y su historial ambiental en cada lugar (Ortiz-Quijano *et al.* 2015).

En los sitios de La Mojonera y Medio Monte, las principales especies asociadas son *Clethra macrophylla* M. Martens & Galeotti, *Magnolia shiedeana* Schlttdl. y *Quercus delgadoana* Valencia-Avalos, Nixon & L.M. Kelly como dominante solo en la Mojonera. En El Gosco dominan *Liquidambar styraciflua* L. y *Podocarpus matudae* Lundell (Ortiz-Quijano *et al.* 2015).

Levantamiento de información de campo.

Se hicieron recorridos de campo en los sitios identificados previamente y además en los sitios en los que aún existen relictos de BHM. Para estos sitios se establecieron fotopuntos de muestreo, en los que se tomaron fotografías hemisféricas y otros datos de cada localidad. El establecimiento de los fotopuntos consistió en la ubicar geográficamente los sitios mediante el uso de un

Geoposicionador (GPS, Garmin eTrex Legend) y marcarlos con cinta y estacas para la toma de fotografías.

Se establecieron 7 puntos, cuatro de ellos en Medio Monte y tres en el Gosco separados aproximadamente a 15 metros y orientados hacia donde se ubicaba la ladera a lo largo del BHM. De esta manera obtuvimos una mejor variabilidad del sitio y aseguramos tener por lo menos 2 puntos por sitio en cada fotopunto.

Cuadro 2. Ubicación de fotopuntos para la toma de fotografías hemisféricas.

Sitio	Fotopunto	Latitud	Longitud
El Gosco	F1	20.32589	-98.25053
	F2	20.32592	-98.25068
	F3	20.32602	-98.25079
Medio Monte	F1	20.41539	-98.24614
	F2	20.41540	-98.24628
	F3	20.41540	-98.24643
	F4	20.41538	-98.24601
La Mojonera	F1 - 1	20.63458	-98.61717
	F1 - 2	20.63458	-98.61736
	F1 - 1	20.63389	-98.61861
	F1 - 2	20.63404	-98.61875
	F1 - 1	20.63488	-98.61899
	F1 - 2	20.63504	-98.61916
	F1 - 1	20.63544	-98.61933
	F1 - 2	20.63537	-98.61911

En la Mojonera se establecieron 4 sitios más, con 2 fotopuntos cada uno, ubicados a lo largo de la ladera donde se encuentra el BHM. De esta manera aseguramos también tener un fotopunto de buena calidad en cada sitio. En todos los sitios se levantó información de referencia y se tomaron

fotografías hemisféricas y color de hojas de los árboles de dosel. La ubicación de sitios y sus coordenadas enlistan en el Cuadro 2.

Para la toma de la fotografía hemisférica se utilizó una cámara fotográfica NIKON equipada con un lente con ángulo de visión de 180°. Esta fotografía permite medir el porcentaje de claros en el dosel a partir de la toma de adentro del bosque y hacia el zenith.




Figura 3. Fotografías hemisféricas tomadas para este estudio correspondientes al mes de abril (a) y julio (b) de 2016.

La figura 3 muestran los ejemplos de las fotografías hemisféricas que se utilizaron para el análisis. Podemos resaltar en ellas las diferencias de huecos del dosel, que pueden condicionar la penetración directa de luz y la sombra.

Procesamiento de fotografías hemisféricas

Para los tres sitios de campo se tomaron datos de color de las hojas y fotografías hemisféricas mensuales durante 5 meses (abril a agosto de 2016) en los mismos fotopuntos. Todos los datos obtenidos fueron integrados como atributos al archivo geográfico para ser ubicados de forma espacial en el territorio.

La toma de la fotografía hemisférica, primero se ubicó el sitio de toma mediante el uso del receptor GPS y se marcó el suelo y los árboles con cintas distintivas para la toma periódica. En el sitio, primeramente, se niveló la cámara fotográfica sobre el monopie y el suelo y se orientó una marca del lente hacia el norte. Esto tenía la finalidad de orientar la fotografía correctamente a la hora de procesarla en gabinete. Al momento de tomar la fotografía, nuevamente se niveló en todas direcciones con la finalidad de que la toma sea en ángulo cenital cero.

La fotografía hemisférica fue procesada mediante el software Hemiview, para obtener otras variables que puedan explicar la variabilidad temporal del NDVI. El procesamiento de las fotografías hemisféricas calcula índices de tres distintos tipos: índices de geometría, índices de radiación solar e índices de cobertura, con los cuales se pueden obtener hasta 24 parámetros distintos. Fueron incluidas en el análisis seis variables provenientes del procesamiento de las fotografías: VisSky (cielo visible), DSF (factor directo de sitio), ISF (factor indirecto de sitio), GSF (factor global de sitio), LAI (índice de área foliar) y Gndcover (cobertura de suelo).

De los parámetros mencionados, existen dos de ellos, relacionados con los claros de la vegetación; el primero es VisSky que indica la proporción de claros o proporción de cielo que es visible del punto donde se toma y Gndcover indica la proporción de huecos cubiertos por vegetación. Tres de ellos están totalmente con la luz incidente en el bosque que son: El factor directo de sitio, que

constituye la cantidad de luz directa recibida en el punto donde se toma la foto, el factor indirecto de sitio que consta de la luz difusa que llega al punto donde es tomada la foto después de ser reflejada por otros componentes de la atmósfera como las nubes y polvo y el factor global de sitio que es la relación de la luz directa respecto a la difusa (Mauro Diaz 2014).

El color de las hojas se tomó en el árbol más cercano al punto de toma de la fotografía a la especie dominante *Fagus grandiflora* subsp. *mexicana*. Se empleó la tabla de colores Munsell para material vegetal. Las hojas seleccionadas correspondieron a las hojas de la punta de las ramas y el color se tomó en el haz de las hojas. Para tomar el color seco de las hojas se colectaron las hojas caídas y se dejaron secar al aire libre.

Preparación de capas de información climática y edafológica

Se acudió al repositorio de información climatológica del Servicio Meteorológico Nacional (CONAGUA 2016). De la base de datos se obtuvieron los datos de información de las normales climatológicas para el periodo 1981 – 2010. Los datos obtenidos pertenecen a los datos promedio mensuales de precipitación mensual, temperatura máxima mensual (temperatura máxima registrada), temperatura mínima mensual (temperatura mínima registrada), temperatura media mensual, evaporación mensual y días con neblina.

El total de estaciones meteorológicas que se consideraron fueron 87, las cuales se encuentran en un cuadrante que abarca la región de estudio, con coordenadas extremas de -99.45 Oeste y 21.33 N y -97.70 Oeste y 20.03 N. Cabe señalar, que este cuadrante es un poco más amplio de los límites de la región de estudio, para poder interpolar los datos en toda la región.

La base de datos fue organizada en una tabla y puesta en un archivo geográfico digital en el Software ArcGIS, con la finalidad de interpolar los datos y generar una capa continua en formato raster. El método de interpolación usado fue el cokriging, ya que este proceso considera a la altitud del terreno como una covariable que apoya a la predicción de los factores climáticos y es uno de los mejores estimadores de datos continuos (Vera-Morales 2012).

El método de interpolación kriging es un estimador robusto e insesgado, que minimiza la varianza considerando tanto la distancia de la muestra como su variabilidad a distintas direcciones (anisotropía), logrando reducir la incertidumbre de predicción (Guerra *et al.* 2009). El método cokriging es una variante del kriging, pero considera una variable auxiliar con mayor cantidad de muestras para explicar la continuidad de la variable predicha con el menor error posible (Gallardo 2006).

Como variable auxiliar en la predicción, se usó el valor de la altitud proveniente del modelo digital de elevación, ya que es una variable que está relacionado con la determinación del clima (Diaz-Padilla *et al.* 2008). El modelo digital de elevación se obtuvo del repositorio de información de datos de relieve de (INEGI 2015). La resolución espacial de dicho modelo es de 30 metros.

Para la elección del método de interpolación óptimo se tuvieron tres etapas 1) el análisis exploratorio de datos, que se refiere a la identificación de los datos atípicos para excluirlos y la transformación de datos, 2) el análisis estructural, que permite obtener el mejor modelo de ajuste de los datos disminuyendo el error de predicción, y 3) la predicción de las superficies, que se refiere a la predicción continua de los datos y la validación cruzada obteniendo errores de predicción de la capa (Pacheco-Nivelo 2014).

Las capas de información de datos climáticos mensuales generadas para la temperatura mínima y media se obtuvieron a través del método cokriging simple, mediante un modelo de ajuste gaussiano. Para la interpolación de las variables de temperatura mensual máxima se usó el método cokriging simple y un modelo de ajuste exponencial. Para las capas de los datos mensuales de precipitación se utilizó el método de cokriging ordinario y un modelo de ajuste gaussiano. Previamente se calculó una aproximación de ajuste a la normalidad de datos mediante una transformación con la base logaritmo (10) para los datos de precipitación y temperatura máxima. Una forma común para mejorar la estimación de datos es identificar datos atípicos en la interpolación y eliminarlos del modelo para mejorar la precisión (Ryan 1996). El método de eliminar los datos atípicos es útil para eliminar los errores de estimación en datos calculados, ya que minimiza el error cuadrático medio (Ryan 1996).

Para identificar los datos atípicos y mejorar la predicción de los datos se hizo un diagnóstico previo mediante interpolación y se identificaron los datos que tenían mayor error para excluirlos del modelo final. Es por ello que, para la estimación de las capas continuas de precipitación y temperatura máxima, se usaron solamente datos de estaciones respectivamente.

Al término de la interpolación, las capas mensuales de precipitación y de temperatura máxima, fueron regresadas a sus unidades originales aplicando la función antilogaritmo.

Se generaron 48 capas de clima correspondientes a valores mensuales promedios de temperatura máxima, temperatura mínima, temperatura media y precipitación mensual. Las capas generadas fueron evaluadas considerando las estimaciones de errores generados por las interpolaciones, Error medio (EM), cuadrado medio del error (RMS), error medio estandarizado (EME) y error promedio estándar obtenido de la gráfica de datos medidos contra predichos (R^2). Se sabe que para los valores

de los tres primeros errores mencionados, los valores deben estar cercanos a cero. El último error es considerado por Medina-Peralta *et al.* (2010) como una medida objetiva para la medición de la certidumbre del modelo, ya que es equivalente al coeficiente de determinación y debe estar cercano a uno.

Las capas de información, obtenidas a través de la interpolación fueron utilizadas para generar otras capas de información ambiental que se asociaron al modelo estadístico como variables explicativas de la variabilidad del NDVI. Mediante la herramienta de álgebra de mapas de ArcGIS se obtuvieron de las capas de información climáticas. Las variables provenientes del modelo digital de elevación fueron generadas mediante el módulo *Surface* de ArcGIS.

La revisión de información bibliográfica identificó algunas variables ambientales que han sido utilizadas para explicar algunos procesos ecológicos en el BHM, como la predicción de la riqueza de especies (López-Mata *et al.* 2011) y su distribución potencial (Cruz-Cárdenas *et al.* 2012); el estudio de la relación espacial del NDVI y factores climáticos en zonas de transición (Zhiqiang *et al.* 2015); y el análisis de patrones espacio temporales de vegetación forestal (Qiu *et al.* 2014 y Rodríguez-Moreno & Bullock 2013). Con la finalidad de que dichas variables pudieran apoyar a explicar la variabilidad del NDVI en el presente estudio. Las variables identificadas se muestran en el cuadro 3.

La información edafológica considerada fue extraída de la propuesta de Cruz-Cárdenas *et al.* (2014), donde se interpolaron los suelos escala 1: 1,000,000 para México. En este estudio, se interpolaron 4,400 sitios de muestreo obteniendo nueve capas distintas de variables de suelo. En el presente estudio se utilizaron los datos de muestreo de suelos, pero acotados a la región de trabajo para la obtención de las variables de pH y carbono orgánico del suelo. La información edafológica

se complementó con los datos de perfiles de suelo para México, dispuestos en el repositorio de información de INEGI. El total de puntos de perfiles de suelo usado fue de 113 en toda la región. Cabe señalar que solamente se usaron los perfiles de suelo del horizonte A.

Cuadro 3. Variables potenciales seleccionadas para explicar la variabilidad de los valores del NDVI en el BHM en Hidalgo, México.

- 1) Altitud
 - 2) Pendiente
 - 3) Aspecto
 - 4) Temperatura media anual
 - 5) Precipitación anual
 - 6) Precipitación pluvial de los meses húmedos del año (mayo a octubre)
 - 7) Precipitación del mes más húmedo
 - 8) Precipitación del trimestre más húmedo
 - 9) Estacionalidad de la precipitación (coeficiente de variación)
 - 10) Contenido de carbono orgánico de suelo
 - 11) Ph del suelo
 - 12) Evapotranspiración
 - 13) Trimestre más frío
 - 14) Trimestre más cálido
-

Evapotranspiración calculada a partir del modelo de Turc's, 1954 (citado por Cruz-Cardenas 2012), donde

$$ETRA = P / [0.9 + (P/L)^2]^{1/2}; \quad P = \text{Precipitación anual (mm)}; \quad L = 300 + 25T + 0.05T^3; \text{ y}$$

T = Temperatura media anual (°C)

El método de interpolación usado en estas capas fue el descrito por Cruz-Cárdenas *et al.* (2014).

De acuerdo con este estudio, el mejor método de estimación en dichas variables corresponde al kriging simple mediante un modelo de ajuste exponencial. Para la interpolación de los datos se ajustaron los datos aproximándolos a la normalidad mediante el cálculo de raíz cuarta de los datos.

De igual forma se regresaron a los datos a su forma original después de terminada la interpolación.

Análisis estadístico.

Para las dos clases de densidad de cobertura densa y abierta, se extrajeron 10,000 puntos aleatorios para cada una. Este tamaño de muestra corresponde a la sugerencia de Congalton (1988) que propone un tamaño de muestra de 1% sobre la evaluación de mapas extraídos de percepción remota. De igual forma Cruz – Cárdenas (2010), recomienda un tamaño de muestra de 10% a 25% del total para obtener estimaciones de mayor precisión estadística. Dichos puntos fueron puestos en un Sistema de Información Geográfica y se sobrepusieron geográficamente con 14 capas ambientales.

Extrayendo los valores de cada punto, se obtuvo una tabla de atributos para los puntos, correspondientes al valor de cada una de las variables de acuerdo con su localización geográfica. Los valores extraídos para cada punto corresponden al valor temático de cada una de las capas temáticas de acuerdo con el pixel que se sobrepone con su ubicación geográfica. De igual forma se obtuvieron los valores de NDVI para cada uno de los puntos aleatorios obtenidos.

La matriz de datos obtenida para cada una de las coberturas fue ingresada al paquete estadístico SAS (SAS 2008) y se procesó con el comando (PROC REG) para una regresión múltiple, mediante el método *stepwise*. Además, como parte del diagnóstico de los datos se hizo un análisis de correlación lineal simple de *Pearson* para identificar las variables que mostraban multicolinealidad.

La identificación de multicolinealidad entre las variables es parte determinante del diagnóstico y tratamiento previo de los datos, ya que, si las variables conservan esta relación, pueden arrojar datos erróneos para la predicción en el modelo (Ryan 1996). Para la identificación de multicolinealidad se utilizó el cálculo de la matriz de correlaciones entre variables independientes,

ya que se considera que las variables con alta correlación (Cuadro 4) pueden indicar multicolinealidad (Ryan 1996, Carbonell *et al.* 1983).

Cuadro 4. Coeficientes de correlación de Pearson para las 14 variables regresoras.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1) Aspecto	1.00	0.05	-0.08	0.07	0.04	0.05	0.05	0.05	0.00	0.02	0.02	0.06	0.07	0.07
2) Pendiente		1.00	-0.24	0.25	0.16	0.17	0.16	0.16	-0.04	0.07	0.02*	0.24	0.24	0.27
3) Altitud			1.00	-0.99	-0.70	-0.69	-0.69	-0.66	0.29	-0.36	-0.10	-0.94	-0.99	-0.98
4) TM anual				1.00	0.70	0.69	0.69	0.66	-0.29	0.36	0.10	0.95	1.00	0.99
5) PP anual					1.00	1.00	0.98	0.98	-0.31	0.36	-0.06	0.79	0.69	0.71
6) PP 6M húmedo						1.00	0.98	0.99	-0.24	0.31	-0.11	0.79	0.68	0.70
7) PP mes más húmedo							1.00	0.96	-0.24	0.38	-0.03	0.77	0.68	0.70
8) PP 3M más húmedo								1.00	-0.11	0.18	-0.23	0.78	0.65	0.67
9) EST de la PP									1.00	-0.82	-0.63	-0.27	-0.29	-0.30
10) CO del suelo										1.00	0.76	0.31	0.35	0.36
11) pH del suelo											1.00	-0.04	0.10	0.09
12) ETRA												1.00	0.93	0.95
13) TM 3M más frío													1.00	0.98
14) TM 3M más cálido														1.00

TM = Temperatura media; PP = Precipitación; 6M = Semestre; 3M = Trimestre;

EST =

Estacionalidad; CO = Carbono orgánico; ETRA = Evapotranspiración.

Todos los valores son altamente significativos $p < 0.01$.

*Valores con significancia $p > 0.01$ y $p < 0.05$

En negritas valores con $p > 0.05$

En la matriz de correlaciones obtenida para las 14 variables, se identificaron las variables independientes con mayor valor de correlación y las variables con las que se correlacionan, para decidir si las variables deben ser excluidas del modelo y así mejorar la predicción. Primeramente, se eligieron las variables que contenían un valor de correlación > 0.5 y que fueran estadísticamente significativas ($p < 0.01$).

Aunque la correlación lineal entre variables está directamente relacionada con la multicolinealidad, no es recomendable basarse solamente en el valor de correlación para elegir las variables regresoras. Como estimación directa de la multicolinealidad se estimaron modelos de regresión de diagnóstico, obteniendo el valor de VIF (Factor de inflación de la variancia) como indicador numérico de las variables con mayor multicolinealidad.

Este ejercicio consiste en generar un modelo previo con los valores de multicolinealidad para cada variable e identificar las regresoras con valores mayores. Estas variables pueden ser susceptibles de ser excluidas. Este proceso es interactivo ya que la eliminación de una podría perjudicar la explicación de la variable dependiente sin aporte sustantivo. En este proceso se van eliminando variables con mayor valor de VIF e identificando que no altere sustancialmente los valores de estimación. Este proceso se repite hasta tener el mejor valor de estimación y con valores de $VIF \leq 10$ para todas las variables (Der y Everitt 2002).

Las variables incluidas pueden explicar una porción de la variabilidad del NDVI. Para mejorar la estimación que explique una mayor porción de la varianza, se decidió explorar la interacción entre pares y tercias de variables. La forma en la que las interacciones de variables fueron elegidas fue mediante varias repeticiones del modelo con distintas interacciones entre variables e identificando las que no fueron incluidas y las variables e interacciones que aportaron mayor proporción de R^2 . Mediante este método se generaron dos nuevas variables para mejorar la explicación de la variación del NDVI. Las interacciones incluidas fueron las variables de Aspecto×Pendiente, y Aspecto×Carbono orgánico del suelo×Trimestre más frío.

Los modelos de regresión lineal múltiple se construyeron a partir de 9 variables explicativas. Los valores de la variable dependiente (NDVI) corresponden a las mediciones de los meses de abril,

mayo y diciembre de 2013; enero, febrero y abril de 2014; abril y mayo de 2015 y enero, marzo y abril de 2016. Además, se generaron los promedios para los meses de abril 2013 a 2016, mayo de 2013 a 2015, enero de 2014 y 2015 y datos de promedio para cada periodo analizado en el año. Por otra parte, se calcularon variables generales para todo el periodo, como promedio, varianza y coeficiente de variación de 2013 a 2016. Para cada valor de NDVI correspondiente se generó un modelo de regresión lineal múltiple.

Análisis de datos de campo.

Para todos los puntos de campo existen fotografías hemisféricas mensuales que fueron procesadas mediante el software HemiView. Mediante al procesamiento digital de las fotografías podemos extraer valores numéricos sobre las condiciones de luz, cobertura y huecos del dosel forestal, que pueden apoyar la descripción de la estructura del dosel forestal. Se extrajeron seis valores que corresponden a VisSky (cielo visible), ISF (Factor indirecto de sitio), DSF (factor directo de sitio), GSF (factor global de sitio), LAI (índice de área foliar), y Gndcover (cobertura de suelo). Estas medidas están fuertemente relacionadas con los valores de reflectancia que el sensor puede captar en una imagen de satélite (Aguirre-Salado *et al.* 2010), principalmente los relacionados con la cobertura forestal y el índice de área foliar.

Para todos los fotopuntos se extrajeron los valores de NDVI mensuales obtenidos previamente, los valores de las variables independientes y se anexaron a los valores puntuales del procesamiento de la fotografía. Con el uso del programa SAS se analizó la correlación para cada par de variables posibles. Con ello se pudo identificar si existe relación lineal con los valores de NDVI.

RESULTADOS

Distribución del BHM

En la región de estudio se estimó una superficie de 283,379 ha de BHM, incluyendo bosque denso y abierto, que contiene una franja continua de BHM localizada en la parte sur de la zona de estudio (Figura 2), principalmente en los municipios colindantes entre los estados de Hidalgo y Veracruz. Por el contrario, el bosque se encuentra más disperso y fragmentado en la zona norte, en los límites de Hidalgo y Querétaro.

Los municipios con mayor superficie de BHM son San Bartolo Tutotepec, Hidalgo y Huayacocotla, Veracruz; sumada a estos dos, un poco más del 50% de la superficie se localiza en los municipios de Zacualpan, Tlanchinol del estado de Veracruz y Xochicoatl, Zacualtipán, Tenango de Doria y Tianguistengo del estado de Hidalgo.

Valores mensuales de NDVI

En la Figura 4 se muestra la fluctuación de los valores promedio y los máximos del NDVI obtenidos para los meses de abril, mayo y diciembre de 2013, se incluyen también los datos para enero, febrero y abril de 2014, abril y mayo de 2015 y enero, marzo y abril de 2016. Los valores máximos extremos de NDVI son similares entre los meses analizados; sin embargo, existe un máximo extremo en el mes de mayo de 2015 y el menor valor de 0.6 para los meses de diciembre 2013, enero 2014 y marzo 2016.




Figura 4. Valores máximos extremos y promedios mensuales de NDVI en el periodo estudiado.

Capas climáticas y ambientales

Se trabajó con 48 capas de clima que incluyeron las variables mensuales de temperatura mínima, máxima y media, así como la precipitación mensual. El modelo de interpolación utilizado generó nuevos datos, estimados para hacer una validación cruzada y evaluar los resultados mediante el análisis de los errores de predicción y el coeficiente de determinación. El modelo de ajuste del semivariograma empírico utilizado para la interpolación, se eligió a partir de la identificación de la curva del mejor ajuste en el semivariograma considerando que este ajuste automático se basa en la minimización de la suma de los cuadrados de los residuales (Gallardo 2006).

En el Cuadro 5 se muestran los errores de predicción para las capas de temperatura mínima, resultantes del método de interpolación. El modelo interpolador utilizado fue el cokriging simple

con un ajuste gaussiano. Los valores del coeficiente de determinación (R^2) extremos variaron de 0.88 (enero) a 0.93, el máximo en los meses de junio a octubre. Los valores de error obtenidos para esta interpolación fueron inferiores a 0.83 para el error medio (EM); el máximo error cuadrático medio (RMSE) fue de 1.81 para el mes de marzo y el máximo error medio estandarizado (EME) de -9.575 y los valores para el error promedio estandarizado (EPE) fueron inferiores a 0.14.

Cuadro 5. Errores de predicción para las capas mensuales de temperatura mínima, obtenidos con el método de interpolación cokriging simple y método de ajuste gaussiano.

Mes	Errores de predicción				R^2
	EM	RMSE	EME	EPE	
Enero	-0.656	1.643	-8.865	0.094	0.88
Febrero	-0.769	1.727	-9.575	0.099	0.88
Marzo	-0.837	1.812	-9.440	0.110	0.89
Abril	-0.548	1.720	-5.870	0.120	0.90
Mayo	-0.651	1.725	-5.966	0.136	0.93
Junio	-0.726	1.745	-6.255	0.136	0.93
Julio	-0.724	1.686	-6.324	0.135	0.93
Agosto	-0.683	1.778	-6.033	0.138	0.93
Septiembre	-0.675	1.706	-6.111	0.131	0.93
Octubre	-0.621	1.646	-6.006	0.132	0.93
Noviembre	-0.636	1.711	-7.011	0.116	0.91
Diciembre	-0.718	1.670	-9.003	0.102	0.89

El Cuadro 6 muestra los errores de predicción de los modelos de interpolación para las capas mensuales de temperatura máxima. El mejor modelo de predicción resultó ser el cokriging simple de ajuste exponencial. Los valores del coeficiente de determinación extremos mínimo y máximo, fluctuaron entre 0.43 (febrero) y 0.85 (agosto), respectivamente. Los errores de EM, RMSE y EPE fueron inferiores a 0.1, mientras que los valores de EME variaron entre 0.03 y 12.6.

Cuadro 6. Errores de predicción para las capas mensuales de temperatura máxima, obtenidos con el método de interpolación cokriging simple y método de ajuste exponencial.

Mes	Errores de predicción				R ²
	EM	RMSE	EME	EPE	
Enero	0.000	0.035	0.031	0.014	0.47
Febrero	-0.009	0.040	-3.980	0.001	0.43
Marzo	-0.013	0.041	-7.047	0.001	0.52
Abril	-0.015	0.039	-10.675	0.001	0.64
Mayo	-0.018	0.039	-11.647	0.001	0.76
Junio	-0.018	0.037	-11.318	0.001	0.84
Julio	-0.019	0.038	-11.227	0.002	0.85
Agosto	-0.019	0.039	-11.432	0.002	0.85
Septiembre	-0.019	0.039	-10.786	0.002	0.85
Octubre	-0.018	0.038	-11.077	0.001	0.81
Noviembre	-0.020	0.042	-12.597	0.001	0.67
Diciembre	-0.013	0.040	-8.251	0.001	0.45

El mejor modelo de predicción para la generación de la temperatura media correspondió al modelo cokriging con ajuste gaussiano. Los errores de predicción para esta variable se muestran en el Cuadro 7. Los valores extremos del coeficiente de determinación fluctuaron entre 0.80 (agosto) y 0.93 (julio). El valor máximo extremo de EM fue para el mes de junio 0.6197 y para el RMSE fue de 2.2778 en agosto. Los valores máximos extremos para EME y EPE fueron de -7.5993 y de 1.5030 respectivamente.

Cuadro 7. Errores de predicción para las capas mensuales de temperatura media, obtenidos con el método de interpolación cokriging simple y método de ajuste gaussiano.

Mes	Errores de predicción				R ²
	EM	RMSE	EME	EPE	
Enero	-0.5280	1.2613	-7.5993	0.0720	0.85
Febrero	-0.3930	1.2900	-4.8054	0.0736	0.85
Marzo	-0.4369	1.3575	-4.7056	0.0826	0.87
Abril	-0.5072	1.4218	-4.8890	0.0953	0.89
Mayo	-0.6067	1.4886	-5.1035	0.1137	0.92
Junio	-0.6197	1.5311	-5.1083	0.1250	0.93
Julio	-0.6153	1.4913	-5.1694	0.1276	0.93
Agosto	-0.1884	2.2778	-0.1364	1.5030	0.80
Septiembre	-0.5101	1.4224	-4.3052	0.1281	0.93
Octubre	-0.5531	1.3485	-5.0388	0.1152	0.93
Noviembre	-0.4841	1.2852	-4.7835	0.0958	0.91
Diciembre	-0.2652	1.2199	-3.6870	0.0805	0.86

Se obtuvieron las capas mensuales de precipitación a través del modelo de predicción cokriging ordinario con un método de ajuste gaussiano. El valor mínimo del coeficiente de determinación corresponde a 0.75 para el mes de febrero y el máximo extremo para el mes de diciembre, con un valor de 0.86. Los valores resultantes de los errores de predicción se muestran en el Cuadro 8.

Cuadro 8. Errores de predicción para las capas mensuales de precipitación, obtenidos con el método de interpolación cokriging ordinario y método de ajuste gaussiano.

Mes	Errores de predicción				R ²
	EM	RMSE	EME	EPE	
Enero	-0.0203	0.1514	-0.3032	0.0696	0.81
Febrero	-0.0138	0.1712	-0.0967	0.1236	0.73
Marzo	-0.0084	0.1606	-0.1555	0.0699	0.80
Abril	-0.0299	0.1781	-0.7743	0.0531	0.57
Mayo	-0.0270	0.1560	-0.4937	0.0747	0.55
Junio	-0.0074	0.1253	-0.0487	0.1033	0.76
Julio	-0.0066	0.1131	-0.0448	0.0732	0.84
Agosto	-0.0040	0.1263	-0.0284	0.0917	0.81
Septiembre	-0.0042	0.1229	0.3338	0.0268	0.85
Octubre	-0.0047	0.1532	0.0005	0.0303	0.79
Noviembre	-0.0219	0.1904	-0.1130	0.1048	0.81
Diciembre	-0.0435	0.2538	-0.1623	0.1635	0.80

A partir de las capas de información climática mencionadas anteriormente, se obtuvieron 9 capas de clima para ser usadas como variables ambientales en el modelo de regresión lineal múltiple. Además, se generaron 3 variables de pendiente con el uso del modelo de elevación digital y dos variables edafológicas a partir de la información de los perfiles de suelos. Las variables ambientales seleccionadas para integrar el modelo de regresión lineal múltiple se muestran en el Cuadro 9.

Cuadro 9. Descripción de las 14 variables ambientales consideradas para explicar la variabilidad de los valores del NDVI en el BHM en Hidalgo, México.

1	Aspecto de la pendiente	Orientación en grados de la pendiente
2	Pendiente	Medición de la pendiente en grados
3	Altitud	Metros sobre el nivel del mar
4	Temperatura media anual	Promedio de las temperaturas medias mensuales (°C)
5	Precipitación anual	Sumatoria de las precipitaciones mensuales (mm)
6	Precipitación del semestre más húmedo del año	Sumatoria de la precipitación de los meses de mayo a octubre (mm)
7	Precipitación del mes más húmedo	Precipitación del mes de septiembre (mm)
8	Precipitación del trimestre más húmedo	Sumatoria de la precipitación de los meses de agosto a octubre (mm)
9	Estacionalidad de la precipitación	El coeficiente de variación de la precipitación
10	Carbono orgánico de suelo	Contenido de carbono en el suelo en kg/m ²
11	pH del suelo	Valor de pH en el suelo
12	Evapotranspiración	Calculada a partir del modelo de Turc's (1954)
13	Trimestre más frío	Promedio de la temperatura de los meses de octubre, noviembre y diciembre (°C)
14	Trimestre más cálido	Promedio de la temperatura de los meses de abril, mayo y junio (°C)

Evapotranspiración = $P / [0.9 + (P/L)^2]^{1/2}$; P= Precipitación anual (mm); L = 300 + 25T + 0.05T³; y T = Temperatura media anual (°C).

Un diagnóstico previo del modelo que identificó las variables con multicolinealidad, excluyó las variables autocorrelacionadas con valores de factor de inflación de la varianza (VIF) > 10 (Ryan 1996).

Las variables seleccionadas para incluir en el modelo de regresión fueron el aspecto y el valor de la pendiente, el pH, el carbono orgánico del suelo, la precipitación anual, la estacionalidad de la precipitación y la temperatura del trimestre más frío (Figura 4).

El aspecto de la pendiente en la región osciló desde los 0 a 359 °. La figura 5 muestra el aspecto de la pendiente, el cual predomina con orientación hacia el este y noreste en la parte central de la región, que también corresponde a las elevaciones más altas.

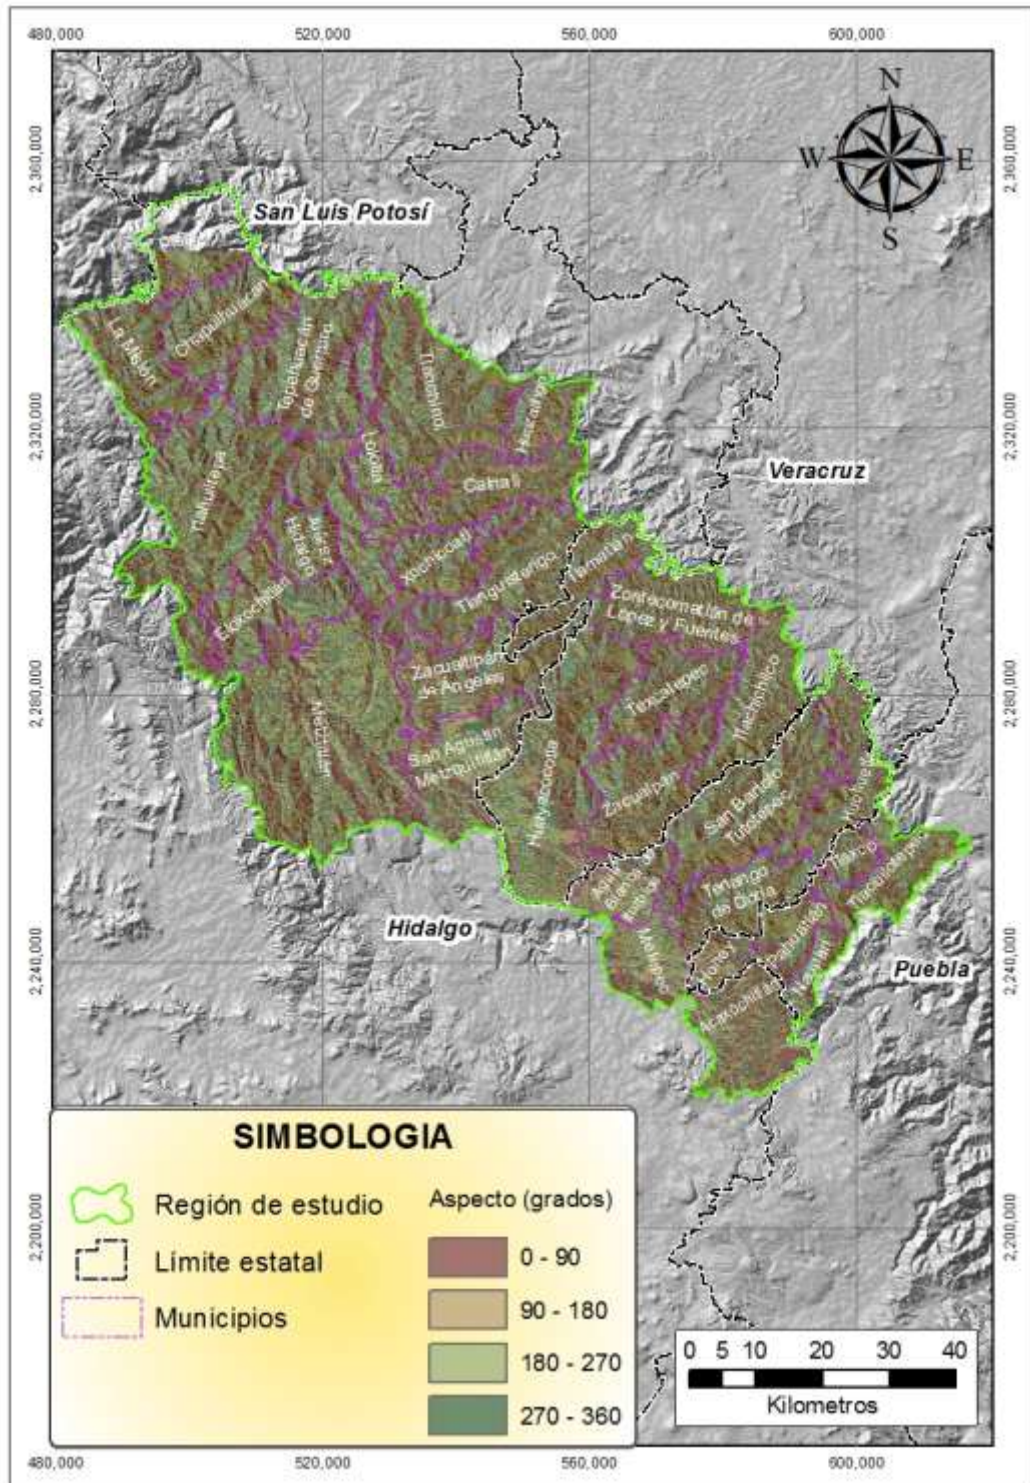


Figura 5. Distribución de la variable Aspecto de la pendiente (grados), que fue ingresada al modelo de regresión lineal múltiple.

La pendiente del terreno varió entre 1 a 66 grados. La mayor pendiente se ubica en las partes altas del terreno, principalmente en los municipios colindantes con el estado de Veracruz y San Luis Potosí. La mayor pendiente se localiza en la parte sur de la región, principalmente en los municipios de Metepec, Mezquititlán, Acaxochitlán y Agua Blanca de Iturbide (Figura 6), así como en la parte sur de los municipios de Honey y Huayacocotla.

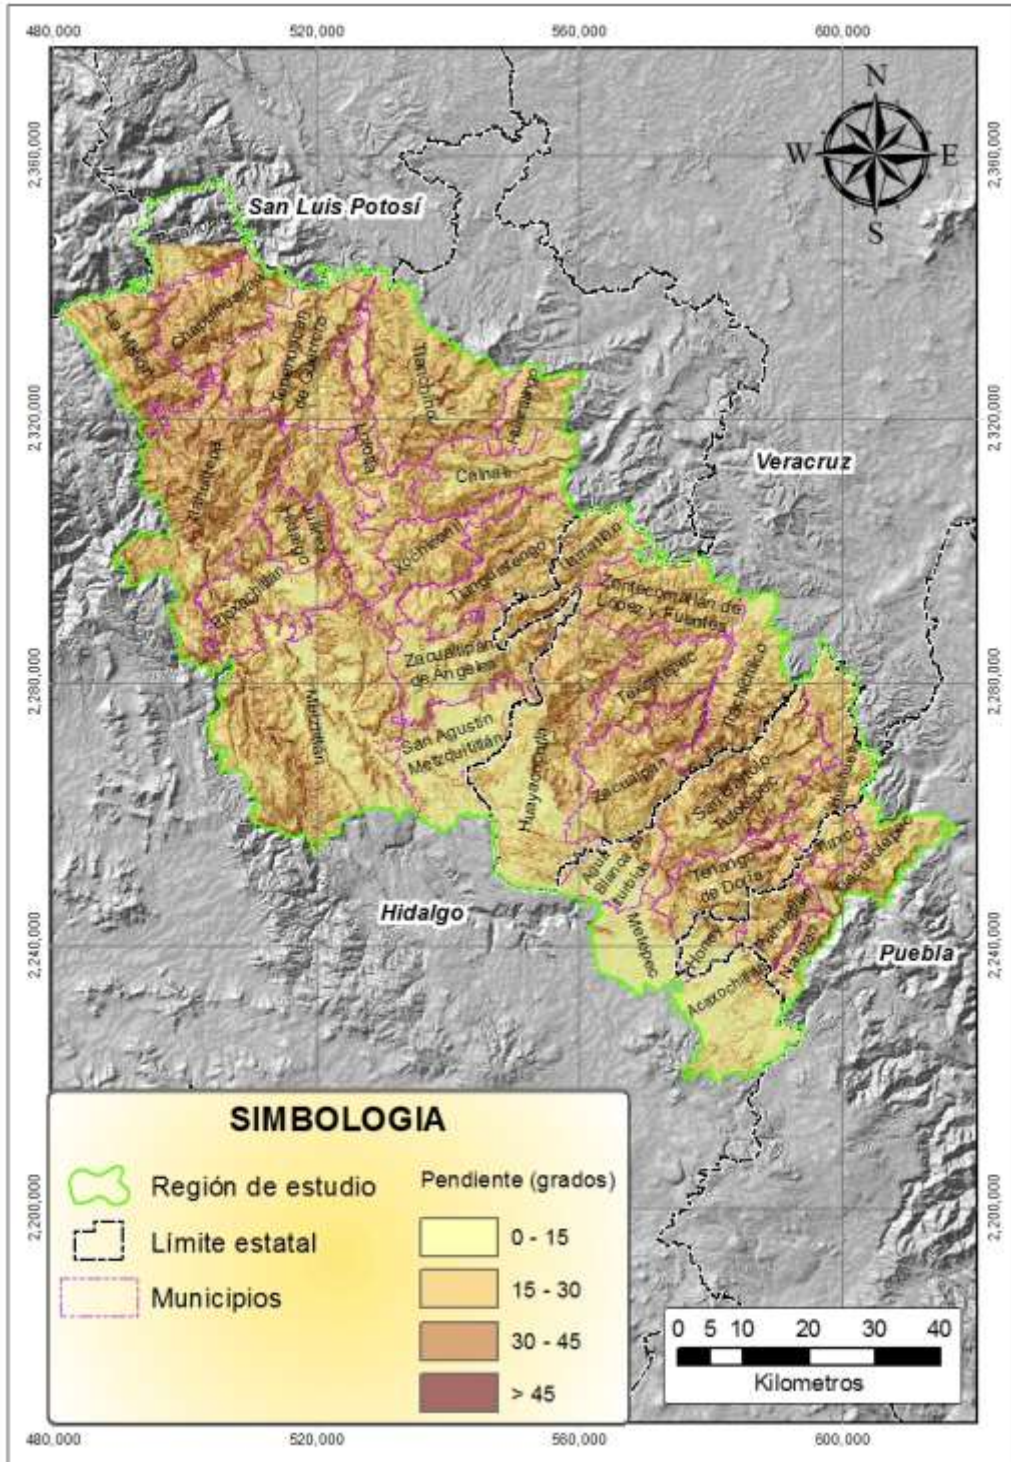


Figura 6. Distribución de la variable pendiente (grados), que fue ingresada al modelo de regresión lineal múltiple.

La Figura 7 muestra la distribución de la precipitación anual y se distingue fácilmente la zona de sotavento en la región. La precipitación varió entre los 500 y 2500 milímetros anuales. Las zonas de mayor precipitación se encuentran en los municipios orientales y en las regiones de mayor altitud. La precipitación muestra una ligera disminución a medida que se desciende en altitud hacia el occidente.

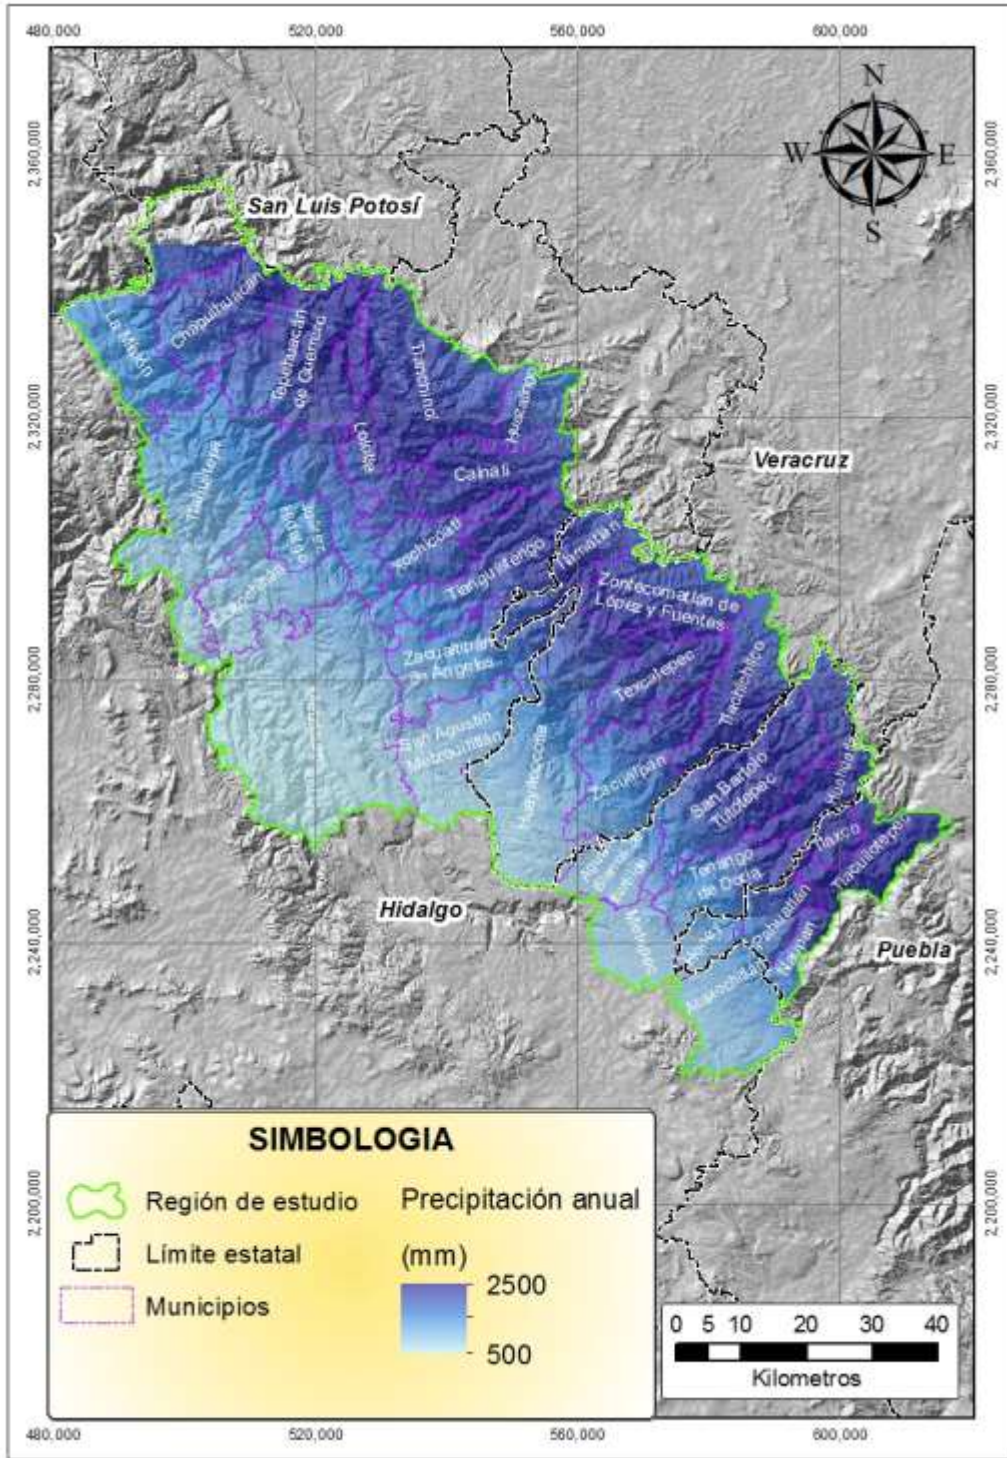


Figura 7. Distribución de la variable precipitación anual, que fue ingresada al modelo de regresión lineal múltiple.

La estacionalidad de la precipitación (coeficiente de variación) fluctúa entre 0.63 y 0.85 y nos indica qué tanto varía la precipitación durante el periodo (Figura 8). La región de mayor variación se encuentra en la zona norte de la región, que corresponde a los municipios de Tepehuacán de Guerrero, Tlalchinol, Calnali, Lolotla y Huazaingo. La parte centro y sur de la región muestra un valor más cercano a 1, que significa que la estacionalidad de la precipitación tiende a ser más alta.

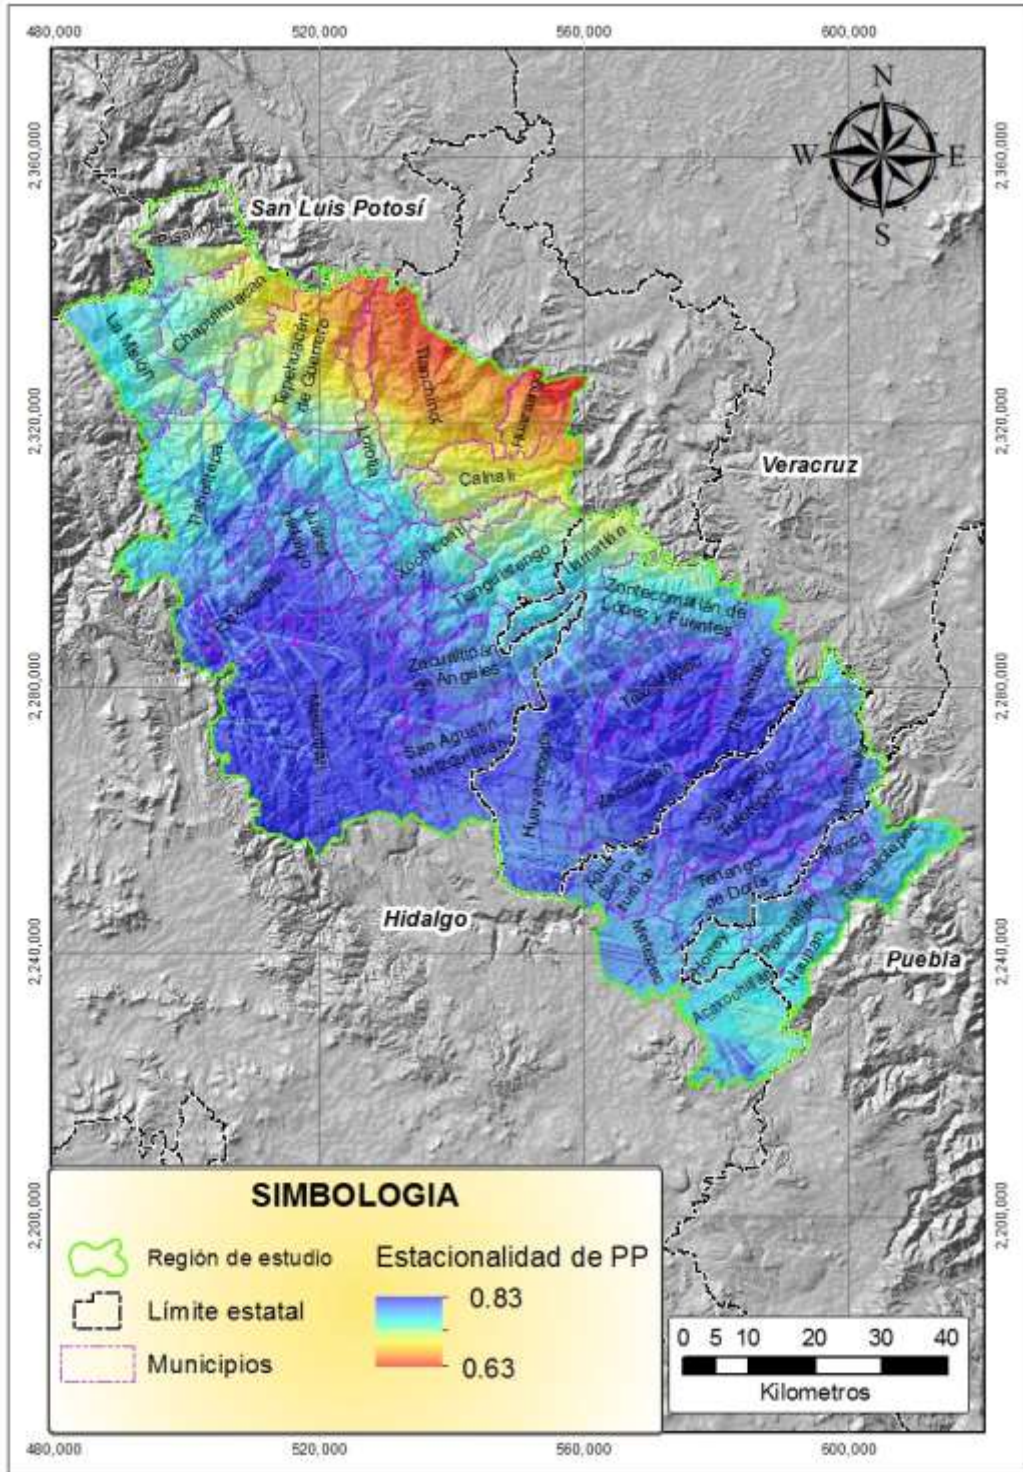


Figura 8. Distribución de la variable estacionalidad de la precipitación, que fue ingresada al modelo de regresión lineal múltiple.

El carbono orgánico del suelo varió de 2.7 a 11.4 kg/m². La Figura 9 muestra que los valores más altos de contenido de carbono orgánico del suelo se localizan en la parte noreste de la zona, en los municipios de Tepehuacán de Guerrero, Tlalchinol, Calnali, Lolotla y Huazalingo. En cambio, la concentración de carbono orgánico en los suelos tiende a ser menor en la porción sur de la región, principalmente en los municipios colindantes con Puebla y Veracruz.

La Figura 10 muestra la distribución del pH del suelo, el cual varía de 4.6 a 7.4. Los municipios de la parte sur tienen suelos más bien ácidos, mientras que en la parte norte y oeste predominan valores neutros y ligeramente básicos. Esta variación es explicable por la ocurrencia de precipitación alta que puede lavar y acidificar el suelo, aunado a la incorporación de materia orgánica.

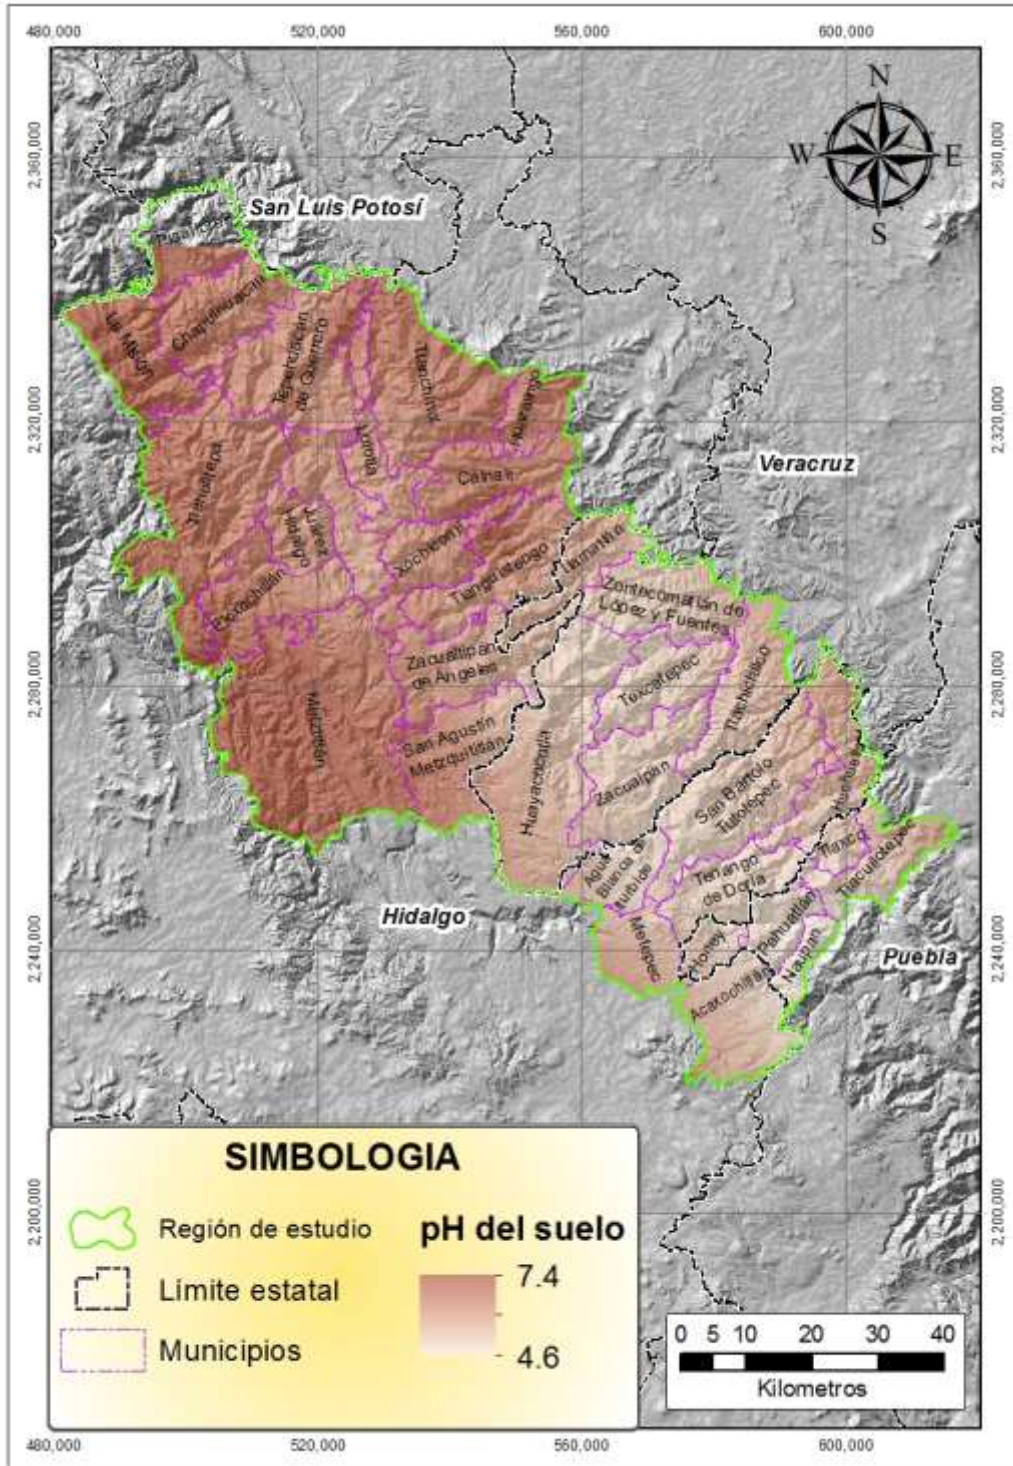


Figura 10. Distribución de la variable pH del suelo, que fue ingresada al modelo de regresión lineal múltiple.

La Figura 11 muestra la variación de la temperatura del trimestre más frío, donde la presencia de una franja continua con menor temperatura se corresponde con la zona de mayor altitud. De igual forma, la temperatura incrementa a medida que se disminuye en altitud hacia el oriente de la región.

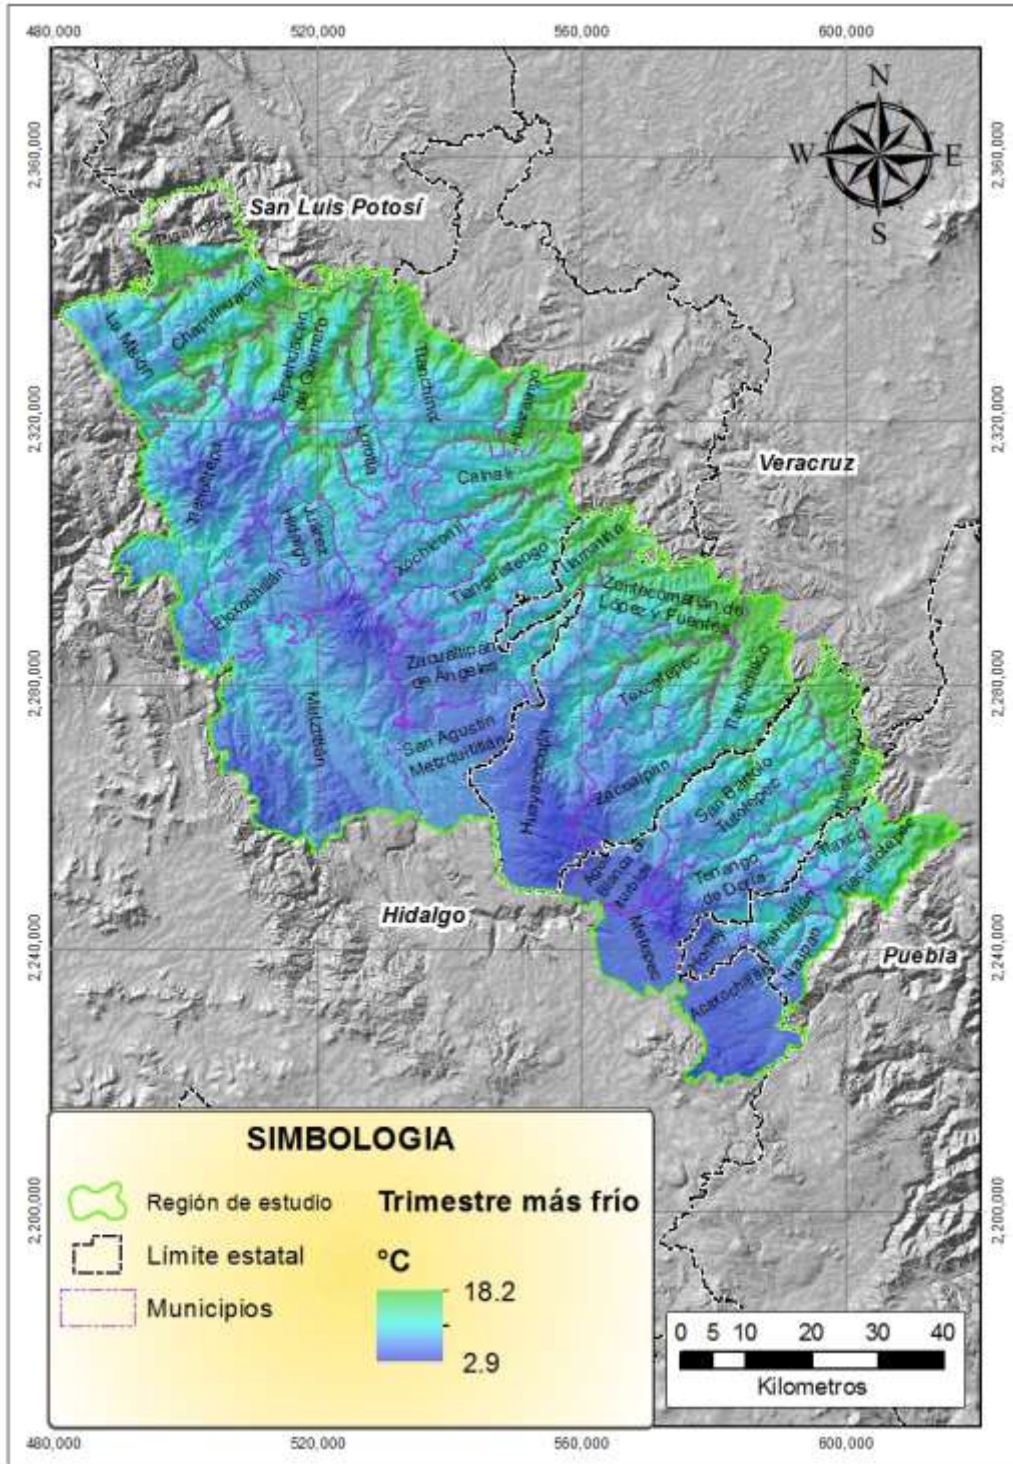


Figura 11. Distribución de la variable Temperatura del Trimestre más frío, que fue ingresada al modelo de regresión lineal múltiple.

En los modelos generados para los datos mensuales en la cobertura densa, la variabilidad del NDVI se explica entre el 15% para el mes de abril de 2016 y 40% para el mes de marzo de 2016. Las variables que mejor explican la variabilidad del NDVI son las variables que corresponden a la interacción de la pendiente y el aspecto de la pendiente y en algunos casos a la variable de precipitación. En tres de los valores mensuales, el carbono orgánico del suelo representa la variable que explica la mayor proporción de la variabilidad del NDVI de mayo de 2015 y marzo y abril de 2016. Es importante mencionar también que la temperatura del trimestre más frío, en la mayoría de los modelos fue la segunda variable en importancia para explicar la variación en el NDVI (Cuadro 10).

Para los meses de abril y mayo de 2013, los modelos pueden explicar entre 16 y 15% respectivamente, mientras que para el promedio de estos meses se puede explicar 22%. Ambos modelos generados tienen particularidades distintas, ya que las variables independientes difieren en importancia para explicar cada modelo.

Para la época seca de 2014, los modelos explican 26, 30 y 32% de la variabilidad mensual (diciembre, enero y febrero) respectivamente y en todos los casos la variable explicativa más importante fue la interacción de aspecto y pendiente.

En el año 2015 se incluyeron solo los meses de abril y mayo. Para el mes de abril la variable que explica la mayor cantidad de varianza es la precipitación anual, mientras que para el mes de mayo resultó ser el carbono orgánico del suelo. En ambos casos se incluyó en segundo lugar de proporción la variable de trimestre más frío. La proporción que explica el modelo general correspondió de 18.5% para el mes de abril y 19% para el mes de mayo.

Los meses incluidos en la época de secas de 2016 fueron a enero, marzo y abril. Los modelos mensuales explicaron 29%, 39% y 15% de la varianza mensual, respectivamente. El promedio de los tres meses explicó un 36%. La interacción de aspecto y pendiente explica la mayor proporción de la varianza para el mes de enero, mientras que para marzo y abril resultó ser más importante la de carbono orgánico del suelo. Para el promedio anual la precipitación anual resultó ser la que explica la mayor parte de la varianza.

Para las temporadas comprendidas en distintos años no existe un patrón para explicar la variabilidad, ya que incluyen variaciones no consideradas en los presentes datos; sin embargo, resalta una tendencia que incluye en la mayoría de los modelos la interacción de aspecto×pendiente como una de las más importantes en la explicación de la variabilidad del NDVI.

Cuadro 10. Relación del Índice de vegetación NDVI, en el bosque húmedo de montaña del estado de Hidalgo de cobertura densa, con variables ambientales, coeficiente de determinación parcial (R^2 parcial y global) calculados durante el procedimiento Stepwise de selección de variables.

	Aspecto (X_1)	Pendiente (X_2)	PP anual (X_3)	EST de la PP (X_4)	CO del suelo (X_5)	pH del suelo (X_6)	Trimestre más frío (X_7)	Interacciones		Global ajustado
								$X_1 \times X_2$	$X_1 \times X_5 \times X_7$	
NDVI dic 2013	0.001	0.039	0.037	-	0.003	-	0.012	0.163	-	0.26
NDVI ene 2014	0.002	0.019	0.007	0.003	-	-	0.046	0.226	-	0.30
NDVI feb 2014	0.015	0.001	0.008	0.003	-	-	0.066	0.227	-	0.32
NDVI abril 2014	-	-	0.112	0.001	0.019	0.012	-	0.014	-	0.16
NDVI promedio 2014	0.003	0.020	-	-	-	0.007	0.016	0.227	-	0.27
NDVI abril 2015	0.007	0.001	0.088	0.013	-	0.001	0.062	0.008	-	0.18
NDVI mayo 2015	-	-	0.036	0.001	0.091	0.003	0.057	0.007	-	0.19
NDVI promedio 2015	-	0.003	0.113	0.001	0.040	0.001	0.067	0.008	-	0.23
NDVI ene 2016	0.002	0.026	0.006	-	0.004	-	0.036	0.221	-	0.29
NDVI marzo 2016	0.001	0.000	0.048	0.034	0.203	0.058	0.000	0.042	-	0.39
NDVI abril 2016	0.020	0.003	0.013	0.001	0.083	0.014	0.010	0.002	-	0.15
NDVI promedio 2016	0.004	-	0.135	0.014	0.004	0.087	-	0.120	-	0.36
NDVI varianza	0.004	0.127	0.005	0.005	-	0.006	0.033	0.014	-	0.19
NDVI promedio	0.001	0.002	0.003	0.001	0.006	-	0.038	0.200	-	0.25
NDVI CV	0.004	0.009	0.005	0.005		0.002	0.012	0.169	0.065	0.27

PP = Precipitación EST = Estacionalidad CO = Carbono Orgánico

Con letras en negritas se resaltan las dos variables que explican la mayor proporción de la varianza del NDVI

Las variables que explican la mayor parte de la variabilidad del NDVI en todo el periodo a la pendiente y aspecto de la pendiente y en segundo lugar de importancia fue la temperatura del trimestre más frío.

La variabilidad del NDVI que explican los modelos generados para la zona de cobertura abierta, se encuentra entre 12% para el mes de abril de 2014 y 46% para el mes de marzo de 2016. Las variables que mayor proporción de varianza explican son la pendiente y la precipitación. Los modelos pueden explicar la importancia de las variables de clima durante el periodo de sequía, ya

que al igual también se encuentra la variable de la temperatura del trimestre más frío en segundo término. El contenido de carbono orgánico del suelo resultó la variable que explica la mayor proporción de la varianza para los meses de mayo 2015 y marzo y abril de 2016.

Para los meses de época seca de 2014, los modelos explican 22, 25 y 24% de la variabilidad mensual respectivamente y en todos los casos la variable que explica la mayor cantidad de variabilidad es la variable de pendiente y, en segundo caso, la variable de trimestre más frío.

En el año 2015 se incluyeron solo los meses de abril y mayo. Para el mes de abril la variable que explica la mayor cantidad de varianza es la precipitación anual, mientras que para el mes de mayo resultó ser el carbono orgánico del suelo. En ambos casos se incluyó en segundo lugar de proporción la variable de trimestre más frío. La proporción que explica el modelo general correspondió de 17% para el mes de abril y 20% para el mes de mayo.

Para los meses de enero, marzo y abril de 2016 se explicó 22, 46 y 19% de la varianza mensual respectivamente, mientras que el promedio anual de los tres meses incluidos se explicó en un 39%. El carbono orgánico del suelo explica la mayor proporción de la varianza para marzo y abril, mientras que para el mes de enero, la variable más importante fue la temperatura del trimestre más frío. Para el promedio anual la variable precipitación total anual resultó ser la que explica la mayor parte de la varianza.

Para los distintos periodos analizados en este estudio se mostraron resultados diversos para explicar la variabilidad del NDVI. Sin embargo, existe una variable en común para la mayoría de los modelos que es la interacción de aspecto×pendiente como una de las más importantes para explicar la variabilidad del NDVI.

Cuadro 11. Relación del Índice de vegetación NDVI, en el bosque húmedo de montaña del estado de Hidalgo de cobertura densa, con variables ambientales, coeficiente de determinación parcial (R^2 parcial y global) calculados durante el procedimiento Stepwise de selección de variables.

	Aspecto (X_1)	Pendiente (X_2)	PP anual (X_3)	EST de la PP (X_4)	CO del suelo (X_5)	pH del suelo (X_6)	Trimestre más frío (X_7)	Interacciones		Global ajustado
								$X_1 \times X_2$	$X_1 \times X_5 \times X_7$	
NDVI dic 2013	0.002	0.107	0.015	-	-	-	0.088	0.002	0.003	0.217
NDVI ene 2014	0.016	0.123	0.017	-	-	-	0.094	-	-	0.251
NDVI feb 2014	0.001	0.072	0.024	-	-	-	0.125	0.024	-	0.245
NDVI abril 2014	-	-	0.088	0.007	0.009	0.013	0.003	0.002	-	0.122
NDVI promedio 2014	0.015	0.082	0.002	0.001	0.001	0.002	0.049	-	-	0.152
NDVI abril 2015	-	0.001	0.124	0.016	-	-	0.030	0.002	0.001	0.174
NDVI mayo 2015	-	0.003	0.066	0.002	0.100	0.003	0.022	0.001	0.001	0.196
NDVI promedio 2015	-	0.001	0.143	-	0.043	0.001	0.035	0.001	0.001	0.224
NDVI ene 2016	0.001	0.084	0.018	-	-	0.001	0.102	-	0.017	0.222
NDVI marzo 2016	0.013	0.004	0.080	0.074	0.227	0.058	-	0.004	-	0.459
NDVI abril 2016	-	0.013	0.034	0.005	0.070	0.010	0.011	0.009	0.036	0.188
NDVI promedio 2016	0.031	0.040	0.157	0.017	0.017	0.126	-	-	0.001	0.388
NDVI varianza	0.001	0.006	-	0.004	0.011	0.099	0.023	0.006	0.001	0.150
NDVI promedio	-	0.067	0.025	0.004	0.005	0.009	0.002	0.053	-	0.165
NDVI CV	-	-	0.001	0.016	0.113	0.017	0.021	-	0.001	0.169

El Cuadro 11 muestra las variables que explican en mayor proporción la variabilidad, el coeficiente de variación y promedio del NDVI de todo el periodo, resaltan el pH del suelo, la pendiente y el carbono orgánico del suelo respectivamente.

Los datos extraídos del procesamiento de fotografías hemisféricas muestran una relación para algunas de las variables con los datos del NDVI. El Cuadro 12, muestra los valores de las variables y los valores de NDVI que mostraron un valor mayor a 0.6 del factor de correlación de Pearson y con un nivel de significancia menor a 0.05. Se observa que el valor de NDVI del mes de mayo de 2015 tuvo una alta correlación (0.8), con los valores de factor directo de sitio (DSF) para el mes de agosto y (0.8) con el factor global de sitio (GSF) del mes de agosto.

El valor promedio de NDVI en el año 2015 tuvo un valor de correlación de 0.7 con los valores de factor directo de sitio (DSF) para el mes de agosto y con el factor global de sitio (GSF) del mes de agosto. Por otro lado, en el Cuadro 11 resaltamos la correlación de los valores de NDVI del mes de abril de 2016, que resultaron tener alta correlación con todos los valores de visión del cielo (entre 0.7 – 0.87). De igual forma, los valores promedios para el periodo de 2016 resultaron ser altos (0.65 – 0.84).

Cuadro 12. Coeficiente de correlación para los valores de NDVI analizados y los valores extraídos del procesamiento de fotografías hemisféricas

Parámetro	NDVI mayo 2015	NDV promedio 2015	NDVI abril 2016	NDVI promedio 2016
VisSky Abr			- 0.704	- 0.667
VisSky Mayo			- 0.764	- 0.721
VisSky Jun			- 0.702	- 0.654
VisSky Jul			- 0.871	- 0.841
VisSky Ags			- 0.727	- 0.691
ISF Abr			- 0.695	- 0.654
ISF Jun			- 0.648	
ISF Jul			- 0.862	- 0.831
ISF Ags	- 0.622		- 0.676	- 0.640
DSF Jul			- 0.725	- 0.689
DSF Ags	- 0.817	- 0.723		
GSF Jul			- 0.739	- 0.703
GSF Ags	- 0.803	- 0.706		
LAI May			0.713	0.685
LAI Jun			0.658	0.626
LAI Jul			0.758	0.720
LAI Ags			0.680	0.630
GndCov Abr			0.640	
GndCov May	0.710			
GndCov Jul			0.838	0.815
GndCov Ags	0.720	0.613		

VisSky = Cielo visible; ISF = Factor indirecto de sitio; DSF = Factor directo de sitio;
 GSF = Factor global de sitio; LAI = Índice de área foliar; Gndcover = Cobertura de suelo
 Abr = Mes de Abril; Jun = Mes de Junio; Jul = Mes de Julio y Ags = Mes de agosto

DISCUSIÓN

En la región de estudio se estimó una superficie de 283,379 ha de BHM incluyendo bosque denso y abierto. Esta superficie fue inferior a las 363,362 ha reportadas por Cruz-Cárdenas *et al.* (2012) y superior a las 122,950 ha estimadas por Rzedowski (1978) y a las 124,315 ha estimadas por INEGI (2013), para el mismo tipo de vegetación y en la misma región.

La distribución del BHM resultante de este estudio coincide espacialmente en un 70% con el mapa de distribución reportado por El BHM en México se distribuye de manera fragmentada en las serranías y laderas del sistema montañoso mexicano. Lo anterior debido a sus características muy particulares, por un lado, la importancia de la presencia de nubes la mayor parte del año y las elevadas pendientes y cañadas en las que se comúnmente se presenta. En el BHM inciden múltiples condiciones ambientales que hacen particular su estructura y funcionamiento (CONABIO 2010).

La distribución del BHM en la región coincide en su mayoría, con los trabajos de (Cruz-Cárdenas *et al.* 2012) en un 70%, con la delimitación descrita en el mapa de Uso de Suelo y vegetación, SERIE V (INEGI, 2013) y con la superficie delimitada por (Rzedowski, 1978) en un 73%. El presente estudio fue realizado a una escala mayor usando imágenes satelitales de alta resolución, por lo que el detalle es más preciso, mientras que en las publicaciones anteriormente mencionadas fueron generadas para escala de trabajo más general.

Cruz-Cárdenas *et al.* (2012), en tanto que, la superficie de BHM reportada en los mapas de Uso de Suelo y Vegetación, serie V de INEGI (2013) y en el trabajo de Rzedowski (1978), coinciden espacialmente en un 73%.

Diversos estudios (CONABIO 2010, Cruz-Cárdenas *et al.* 2012, CONABIO 2013 y Gual-Díaz & Rendón-Correa 2014) coinciden en que la distribución de este tipo de vegetación está en forma de fragmentos sobre las montañas; sin embargo, en los mapas de distribución antes mencionados podemos identificar que existen franjas continuas de gran tamaño, principalmente en la región colindante entre Veracruz e Hidalgo, que posiblemente pueden conectarse en forma de corredores continuos. Es evidente también que en la parte norte y sur de la región de estudio, el grado de fragmentación del BHM es mayor.

La CONABIO (2010) identifica la región de estudio como la Huasteca Alta Hidalguense y reporta que presenta una constante amenaza a su permanencia y a su funcionalidad, debido a la presencia permanente de actividades antropogénicas y eventualidades provocadas por el cambio climático global. Podemos asegurar que la zona norte de la región de estudio es la que presentó la más alta fragmentación y por lo tanto es la más amenazada.

El proceso de kriging permite obtener valores de una variable en puntos no conocidos a través de una correlación espacial (Guerra *et al.* 2009). Más aún, el método de interpolación cokriging, como una extensión del método kriging, además de ser un método robusto, es un método insesgado y permite utilizar una variable secundaria para mejorar la estimación de la variable dependiente (Díaz-Padilla *et al.* 2008). En este sentido, Rocha *et al.* (2012), encontraron que en el método cokriging, el uso de una variable secundaria que está fuertemente correlacionada con la variable primaria puede traer resultados más certeros y con menor error de predicción. En el presente estudio el valor de elevación resultó ser buen apoyo para la estimación de los valores climáticos, ya que los patrones climáticos tanto de temperatura como de precipitación están directamente asociados con el relieve y su altitud (Gómez *et al.* 2008, Hernández-Cerda & Carrasco-Anaya 2004).

Bayala *et al.* (2013) y Diaz-Padilla *et al.* (2008), coinciden en que la mejor forma de evaluar los datos generados a través de la interpolación, son mediante el análisis de los errores generados a partir de la validación cruzada, como el error medio (EM), la raíz del error cuadrático medio (RMSE), la media estandarizada del error (EME) y el coeficiente de determinación obtenido de la gráfica de datos medidos contra predichos (R^2). Estos errores residuales fueron considerados para evaluar los resultados de esta investigación.

Para las capas de temperatura mínima, los valores del error medio variaron entre 0.5 a 0.8, los valores de la raíz del error cuadrático medio tuvieron un intervalo de 1.6 a 1.8 y el valor del promedio estandarizado del error entre 6 a 9.6. Todos los valores fueron superiores a los que presentan Cuervo-Robayo *et al.* (2014). Sin embargo, la medición del coeficiente de determinación para evaluar las estimaciones varió entre 0.8 a 0.93, por lo que se considera como buen modelo predictivo.

Para los datos de temperatura máxima, los valores de error medio fueron similares a los valores reportados por Cuervo-Robayo *et al.* (2014), mientras que los valores de RMSE fueron inferiores. De igual forma, los valores obtenidos para el promedio estandarizado del error variaron entre 0.3 a 12.6, que son muy superiores a los reportados por Cuervo-Robayo *et al.* (2014). Los valores del coeficiente de determinación calculados por mes se encuentran entre 0.43 y 0.85.

Los valores del coeficiente de determinación para los valores obtenidos de la precipitación mensual oscilaron entre 0.57 para el mes de abril a 0.85 en el mes de septiembre. Estos meses corresponden a los meses de menor y mayor precipitación respectivamente. Es probable que esta variación se deba a las condiciones del relieve, ya que es un factor determinante para la definición el clima.

Como se muestra en la figura 4(e), los mapas obtenidos muestran la línea de limitación de las zonas de barlovento y sotavento y es más evidente en los meses extremos de precipitación máxima y mínima mensual. Además, la precipitación en el mes de septiembre se ve influenciada por los ciclones y huracanes, mientras que para los meses de estiaje esta situación se ve influenciada de los vientos monzónicos con menor humedad (Hernández-Cerda y Carrasco-Anaya 2004).

El coeficiente de variación de la precipitación es menor en la parte noreste de la región. Esto significa que existe mayor variación de la precipitación con respecto a la media. La menor variación se concentra en la parte alta de la zona, donde existe un periodo seco más corto. Mientras que la parte baja de mayor altura tiene un periodo más largo de sequía y menor concentración de vientos húmedos, debido a las temperaturas cálidas, esto coincide con la descripción de los patrones climáticos descritos por Hernández-Cerda y Carrasco-Anaya (2004).

Se realizó un modelo de regresión lineal múltiple con cada una de las variables mensuales de NDVI. Para escoger las variables regresoras se realizó un análisis de multicolinealidad, a través de un análisis de correlación de pares y la extracción del valor de inflación de la varianza. Según del Valle Moreno y Guerra Bustillo (2012), se deben considerar dos o más formas para la identificación de la multicolinealidad. Se eligieron siete variables ambientales para los modelos de regresión, para los modelos generados para la cobertura densa se seleccionaron principalmente variables relacionadas con la pendiente y en segundo lugar la temperatura del trimestre más frío, como variables de mayor magnitud para explicar el comportamiento de la variable dependiente.

En el estudio de los bosques de altas latitudes, reportado por Jiang *et al.* (2006), se encontraron variaciones de NDVI inferiores al máximo valor encontrado en este estudio para la cobertura densa del BHM. Dichos valores varían entre 0.001 a 0.59 como valores extremos. Es posible que los

valores bajos de NDVI estén relacionados con claros en el dosel, que son reflejados en la imagen de satélite. Los modelos explicaron entre 15 y 39% de la variabilidad del NDVI en toda la zona. El menor porcentaje de explicación se presenta en los meses de abril de 2014 y 2016 y la variable que explica mayor cantidad de la variabilidad es la precipitación anual y el carbono orgánico de suelo.

El mes de abril corresponde al mes de menor precipitación, que representa además el término de la época de estiaje en la región, por lo que esta condición es determinante para la variación. Por otro lado, el carbono orgánico del suelo está condicionado a la disposición de hojarasca y su descomposición, misma que es menor en este mes por la disminución de humedad. La precipitación y el carbono orgánico en el suelo suelen ser variables útiles para la predicción de la distribución del BHM (Cruz-Cárdenas *et al.* 2012); sin embargo, en este estudio tales variables explican menor porción de varianza.

Por otro lado, la mayor cantidad de varianza se explica en los modelos para los meses de febrero de 2014 y marzo de 2016. En general los meses de enero, febrero y marzo presentan los valores de explicación de varianza más altos. En estos meses coincide que la variable que explica la mayor cantidad de varianza es la interacción de las variables de aspecto y pendiente. Podemos inferir que esta variabilidad está influida principalmente por la condición de sombra que está presente principalmente en las regiones de orientación norte y que provocan condiciones particulares en los regímenes climáticos (Hernández-Cerda & Carrasco-Anaya 2004). Las mismas condiciones y variables son las de mayor peso para explicar la varianza del promedio general y el coeficiente de variación del NDVI en todo el periodo estudiado.

Los valores de NDVI para cobertura abierta en el BHM variaron entre 0.03 y 0.63, los cuales son similares a los encontrados para la cobertura densa. Posiblemente esto se deba a que el valor de NDVI pierde sensibilidad en las coberturas más densas, como lo reportan Wardlow *et al.* (2007).

Los modelos generados para evaluar la variabilidad del NDVI produjeron resultados que pueden explicar del 14 al 46% de la varianza. Igualmente, los índices de los meses de abril muestran los valores más bajos, mientras que el mes de marzo de 2016 resultó ser el que explica la mayor proporción de varianza. No existe un patrón para describir las variables que explican la mayor cantidad; sin embargo, podemos mencionar que en la mayoría de los modelos se consideró las variables de precipitación anual y de pendiente como segunda variable explicativa. Para el modelo que explica la mayor proporción de la varianza (marzo de 2016), resalta la variable carbono orgánico del suelo, que explica 23% de la varianza y en conjunto con las variables de precipitación anual y estacionalidad de la precipitación explican el 38%. Esto puede complementar las aseveraciones sobre la importancia de las variables de humedad y energía en la distribución y estructura del BHM (López-Mata *et al.* 2011; Gual-Díaz & Rendón-Correa 2014).

CONCLUSIONES

El BHM se distribuye a través de una faja continua en la región de estudio, fragmentado en porciones, principalmente en su zona norte.

El método de estimación cokriging, con apoyo de la variable auxiliar de la altitud, resultó ser un buen modelo predictivo para las variables continuas de clima.

Los coeficientes de determinación, obtenidos de las interpolaciones para las capas de temperatura y precipitación, demuestran que ambas variables tienen poco sesgo y error, por lo que podemos usarlas para la explicación de la variabilidad de NDVI.

Los modelos de regresión lineal múltiple generados describen a las variables de pendiente y aspecto como las que explican la mayor porción de la varianza del NDVI en la mayoría de los modelos.

En algunos casos las variables de temperatura y precipitación apoyan la explicación de una porción importante de la varianza, principalmente en el bosque con cobertura abierta.

La variación del NDVI, medido con las imágenes satelitales, puede ser un buen apoyo para identificar la variación de la fenología a través del tiempo, ya que se identifican los picos de variación en los periodos medidos.

Las variables ambientales pueden explicar un porcentaje importante de la varianza del NDVI, pero no son determinantes en todos los modelos.

BIBLIOGRAFÍA

- Aguirre-Salado CA, Valdez-Lazalde JR, Ángeles-Pérez G, de los Santos-Posadas HM, Aguirre-Salado AI. 2010. Mapeo del índice de área foliar y cobertura arbórea mediante fotografía hemisférica y datos SPOT 5: Regresión y K-NN. *Agrociencia* 45: 105-109.
- Alcaraz-Segura D, Baldi G, Durante P, Garbulsky MF. 2008. Análisis de la dinámica temporal del NDVI en áreas protegidas: tres casos de estudio a distintas escalas espaciales, temporales y de gestión. *Ecosistemas* 3: 108-117.
- Bayala MI, Rivas RE, Scavuzzo M. 2013. Generación de mapas de temperatura de alta resolución mediante técnicas de remuestreo. *Interciencia* 38: 502-508. DOI: 0378.1844/13/07/502-07.
- Bolstad P. 2012. *GIS Fundamentals: A First Text on Geographic Information Systems*. (Fourth ed.). Minnesota.
- Carbonell E, Denis JB, Calvio R, González F, Pruñonosa V. 1983. *Regresión Lineal. Un enfoque conceptual y práctico*. Madrid, España: Instituto nacional de investigaciones agrarias. Ministerio de agricultura, pesca y alimentación.
- Chuvieco E. 1995. *Fundamentos de la Teledetección Espacial* (Segunda ed.). Madrid: Rialp.
- CONABIO. 2010. *El bosque mesófilo de montaña en México; Amenazas y oportunidades para su conservación y manejo sostenible*. México D. F: Comisión Nacional para el Conocimiento y uso de la Biodiversidad.
- CONABIO. 2013. *Capital Natural de México, Vol I: Conocimiento Actual de la Biodiversidad*. México D. F: Comisión Nacional Para el Conocimiento y Uso de la Biodiversidad (CONABIO). UNAM-CIGA.

CONAGUA. 2016. Normales Climatológicas por estado. Servicio Meteorológico Nacional.

Consultado el 14 de abril de 2016.

<http://smn.cna.gob.mx/es/component/content/article?id=42>

Congalton RG. 1988. A comparison of sampling scheme use in generating error matrices for assessing the accuracy of maps generated from remotely sensed data. *Photogrammetric Engineering and Remote Sensing*, 54(5):593-600. DOI: 0099-1112/88/5405-593\$02.25/0.

Cruz-Cárdenas G, López-Mata L, Ortiz-Solorio CA, Villaseñor JL, Ortiz E, Silva JT, Estrada-Godoy F. 2014. Interpolation of Mexican soil properties at a scale of 1:1,000,000. *Geoderma* 213: 29-35. DOI: 10.1016/j.geoderma.2013.07.014

Cruz-Cárdenas G, Villaseñor JL, López-Mata L, Ortiz L. 2012. Potential Distribution of Humid Mountain Forest in Mexico. *Botanical Sciences*, 90: 331 - 340.

Cruz-Leyva IH, Valdez-Lazalde JR, Ángeles-Pérez G, de los Santos-Posadas HM. 2010. Modelación espacial de área basal y volumen de madera en bosques manejados de *Pinus patula* y *P. teocote* en el ejido Atopixco, Hidalgo. *Madera y Bosques* 16: 75-97.

Cuervo-Robayo AP, Téllez-Valdéz O, Gómez-Albores MA, Venegas-Barrera CS, Manjarrez J, Martínez-Meyer E. 2014. An update of high-resolution monthly climate surfaces for Mexico. *International Journal of Climatology* 34: 2427-2437. DOI: 10.1002/joc.3848.

De la Casa A, & Ovando G. (2006). Relación entre la precipitación e índices de vegetación durante el comienzo del ciclo anual de lluvias en la provincia de Córdoba, Argentina. *RIA. Revista de Investigaciones Agropecuarias*, 35(1), 67-85.

Del Valle-Moreno J & Guerra-Bustillo CW. 2012. La multicolinealidad de los modelos de regresión lineal múltiple. *Revista Ciencias Técnicas Agropecuaria* 21: 80-83.

- Díaz-Padilla G, Sánchez-Cohen I, Quiroz R, Garatuza-Payán J, Watts-Thorp C, Cruz-Medina, IR. 2008. Interpolación espacial de la precipitación pluvial en la zona de barlovento y sotavento del Golfo de México. *Agricultura Técnica en México* 34: 279-287.
- Eastman JR. 2012. IDRISI Selva. Guía para SIG y Procesamiento de Imágenes. Massachusetts: Manual versión 17.
- Eastman, J, Sangermano F, Machado EA, Rogan J, Anyamba A. (2013). Global trends in seasonality of Normalized Difference Vegetation Index (NDVI), 1982-2011. *Remote Sensing* 5: 4799-4818. DOI: 10.3390/RS5104799.
- ESRI. 2014. ArcMap or the World Imagery with Metadata web map, Consultado 1 de Febrero de 2016, http://services.arcgisonline.com/ArcGIS/rest/services/World_Imagery/MapServer
- Galicia L, Cuevas-Fernandez ML, González-Ramírez LM, Couturier S. 2014. Detección de cambio ambiental en selvas y bosques de México con Percepción Remota: un enfoque multiescalar en espacio y tiempo. *Interciencia* 39: 368-374. DOI: 0378-1844/14/06/368-07.
- Gallardo A. 2006. Geoestadística. *Revista Ecosistemas* 15 (3): 48-58.
<http://www.revistaecosistemas.net/articulo.asp?Id=431>
- García E. 1973. Modificaciones al Sistema de Clasificación Climática de Köppen (Quinta edición ed.). México: Instituto de Geografía. Universidad Nacional Autónoma de México (UNAM).
- Gómez JD, Etchevers J, Monterroso AI, Gay C, Campo J, Martínez M. 2008. Spatial estimation of mean temperature and precipitation in areas of scarce meteorological information. *Atmosfera*, 21: 35-56.

- Gual-Díaz M, Rendón-Correa A. 2014. Los bosques mesófilos de montaña en México. Diversidad, ecología y manejo. (págs. 27-67). Distrito Federal: Comisión Nacional para el Conocimiento y Uso de la Biodiversidad.
- Guerra F, Gómez H, González J, Zambrano Z. 2009. Modelización de la distribución de la precipitación para el estado Táchira utilizando SIG's y Geoestadística. *Geoenseñanza*, 14: 293-318.
- He Y, Guo X, Dixon P, Wilmshurst JF. 2012. NDVI variation and its relation to climate in Canadian ecozones. *The Canadian Geographer / Le Geographe canadien*, 56: 492-507. DOI: 10.1111/J1541-0064.2012.00441.x.
- Hernández-Cerda ME, Carrasco-Anaya G. 2004. Climatología. En Luna I, Morrone JJ, Espinosa D. (Edits.), *Biodiversidad de la Sierra Madre Oriental* (págs. 63-110). Distrito Federal: CONABIO.
- Huete AJ, Justice C, Leeuwen W. 1999. *Modis Vegetation Index (MOD13) Algorithm Theoretical basis Document (Thirirth ed.)*. Tucson Arizona: University of Arizona.
- INEGI. 2013. *Conjunto de datos vectoriales de uso de suelo y vegetación Serie V: escala 1:250 000*. Distrito Federal, México: Instituto Nacional de Estadística y Geografía.
- INEGI. 2015. *Datos de elevaciones del territorio mexicano*. México D. F: Instituto Nacional de Estadística y Geografía.
- Jiang Z, Huete AR, Chen J, Chen Y, Li J, Yan G, Zhang X. (2006). Analysis of NDVI and scaled difference vegetation index retrievals of vegetation fraction. *Remote Sensing of Environmental* 101: 366-378. DOI: 10.1016/JRSE.2006.01003.
- Johnston C. 1998. *Geographic Information Systems in Ecology*. Minnesota: Blackwell Science.

- López-Mata L, Villaseñor JL, Cruz-Cárdenas G, Ortiz E, Ortiz-Solorio C. 2011. Predictores ambientales de la riqueza de especies de plantas del bosque húmedo de montaña de México. *Botanical Sciences* 90: 27-36.
- Martínez B, Camacho-de Coca F, García-Haro FJ. 2006. Estimación de parámetros biofísicos de vegetación utilizando el método de la cámara hemisférica. *Teledetección* 26: 5-17.
- Martínez B. & Gilabert MA. 2009. Vegetation dynamics from NDVI time series analysis using the wavelet transform. *Remote Sensing of Environmental* 113: 1823-1842. DOI: 10.1016/J.RSE.2009.04.016.
- Mauro-Díaz G, Lencinas JD, Del Valle H. 2014. Introducción a la fotografía hemisférica en ciencias forestales. *Madera y Bosques* 20: 109-117.
- Medina-Peralta S, Vargas-Villamil L, Navarro-Alberto J, Canul-Pech C, Peraza-Romero S. 2010. Comparación de medidas de desviación para validar modelos sin sesgo, sesgo constante o proporcional. *Universidad y Ciencia. Trópico húmedo* 3: 255-263.
- Miranda F. 1947. Estudios sobre la vegetación de México. V. Rasgos de la vegetación en la Cuenca del Río de las Balsas. *Revista de la Sociedad Mexicana de Historia Natural* 8:95-114.
- Ortiz-Quijano AB, Cuevas-Cardona MD, Sánchez-González A. 2015. Historia ambiental de tres bosques de haya del estado de Hidalgo, México. *Historia* 2.0 10: 25-41.
- Pacheco-Nivelo J. 2014. Análisis de interpolación geoestadísticos para la estimación espacio-temporal de la precipitación en la cuenca del río Paute. Cuenca Ecuador: Tesis de Maestría: Universidad del Azuay.
- Pettorelli N. 2013. *The Normalized Difference Vegetation Index*. Oxford: Oxford University Press.

- Pettorelli N, Vik, JO, Mysterud A, Gaillard JM, Tucker CJ, Stenseth NC. 2005. Using the satellite-derived NDVI to assess ecological responses to environmental change. *TRENDS in Ecology and Evolution* 20: 503-510. DOI:10.1016/tree.2005.05.011.
- Qiu YS, Gao J, Zhan QL. 2014. Forest vegetation spatial and temporal pattern analysis based on NDVI in Jiuzhaigou. *Applied Mechanics and Materials*, Vol: 675-676: 1163-1170. DOI: 10.4028/www.scientific.net/AMM.675-677.1163
- Rocha MM, Yamamoto JK, Watanave J, Fonseca PP. 2012. Studying the influence of a secondary variable in Collocated Cokriging estimates. *Annals of the Brazilian Academy of Sciences*, 84 (2): 335-346. DOI: <http://dx.doi.org/10.1590/S0001-37652012005000017>.
- Rodríguez-Moreno VM, Bullock SH. 2013. Comparación espacial y temporal de índices de la vegetación para verdor y humedad y aplicación para estimar LAI en el desierto Sonorense. *Revista Mexicana de Ciencias Agrícolas* 4: 611-623.
- Ryan TP. 1996. *Modern Regression Methods* (First edition ed.). United States of America: Wiley-Interscience Publication.
- Rzedowski J. 1978. *Vegetación de México* (Cuarta ed.). México D. F.: Limusa.
- Sanchez-Ramos G, Dirzo R. 2014. El bosque mesófilo de montaña: Un ecosistema prioritario amenazado. En R.-C. A. Gual-Diaz M (Ed.), *Bosques mesófilos de montaña en México: diversidad ecología y manejo*. (págs. 109 - 137). Distrito Federal: Comisión Nacional para el Conocimiento y Uso de la Biodiversidad.
- SAS Institute. 2008. *Statistical Analysis System 9.0*. SAS Institute.
- Schowengerdt RA. 2007. *Remote Sensing: Models and Methods for Image Processing*. (Third Edition). Academic Press. University of Arizona. Tucson, Arizona.

- Soudani K, Hmimina G, Delpierre N, Pontauiller JY, Aubinet M, Bonal D, Caquet, de Grandcourt A, Burban B, Flechard C, Guyon D, Granier A, Gross P, Heinesh B, Longdoz B, Loustau D, Moureaux C, Ourcival JM, Rambal S, Saint André L, Dufrene E. 2012. Ground-based Network of NDVI measurements for tracking temporal dynamics of canopy structure and vegetation phenology in different biomes. *Remote Sensing of Environmental* 123: 234-245. DOI: 10.1016/J.RSE.2012.03.012.
- USGS 2015. LANDSAT 8 (L8). Data Users Handbook. Sioux Falls, South Dakota: Department of the Interior U. S. Geological Survey.
- Vera-Morales JM. 2012. Incertidumbre y confiabilidad de métodos de interpolación espacial en el complemento de registros hidrológicos. Tesis de Maestría en recursos hídricos y Ambiental. Facultad de Ingeniería, Universidad Autónoma de Querétaro. Querétaro, Querétaro.
- Villaseñor JL. 2010. El bosque húmedo de montaña en México y sus plantas vasculares: catálogo florístico-taxonómico. México, D. F.: Comisión Nacional para el Conocimiento y Uso de la Biodiversidad. Universidad Nacional Autónoma de México.
- Wardlow B, Egbert SL, Kastens JH. 2007. Analysis of time-series MODIS 250 m vegetation index data for crop classification in the U.S. Central Great Plains. *Remote Sensing of Environmental* 108: 290-310.
- Williams-Linera G. 2015. El bosque mesófilo de montaña, veinte años de investigación ecológica ¿qué hemos hecho y hacia dónde vamos? *Madera y Bosques* 21: 51-61.
- Zhiqiang Z, Jiangbo G, Yanglin W, Jianguo L, Shuangcheng L. 2015. Exploring spatially variable relationships between NDVI and climatic factors in a transition zone using geographically weighted regression. *Theoretical and Applied Climatology*, 120 (3); 507-519. DOI: 10.1007/s00704-014-1188-x