



Centro de Investigación Científica de Yucatán, A.C.

Posgrado en Ciencias Biológicas

**MODELIZACIÓN DE LA DIVERSIDAD DE ESPECIES DE
PLANTAS LEÑOSAS EN BOSQUES TROPICALES SECOS
MEDIANTE IMÁGENES DE ALTA RESOLUCIÓN Y DATOS
LIDAR**

Tesis que presenta

STEPHANIE PATRICIA GEORGE CHACÓN

En opción al título de

MAESTRA EN CIENCIAS

(Ciencias Biológicas: Opción Recursos Naturales)

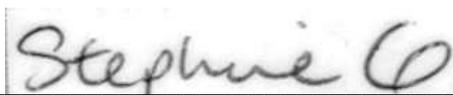
Mérida, Yucatán, México

Mayo, 2017

DECLARACIÓN DE PROPIEDAD

Declaro que la información contenida en la sección de Materiales y Métodos Experimentales, los Resultados y Discusión de este documento proviene de las actividades de experimentación realizadas durante el período que se me asignó para desarrollar mi trabajo de tesis, en las Unidades y Laboratorios del Centro de Investigación Científica de Yucatán, A.C., y que a razón de lo anterior y en contraprestación de los servicios educativos o de apoyo que me fueron brindados, dicha información, en términos de la Ley Federal del Derecho de Autor y la Ley de la Propiedad Industrial, le pertenece patrimonialmente a dicho Centro de Investigación. Por otra parte, en virtud de lo ya manifestado, reconozco que de igual manera los productos intelectuales o desarrollos tecnológicos que deriven o pudieran derivar de lo correspondiente a dicha información, le pertenecen patrimonialmente al Centro de Investigación Científica de Yucatán, A.C., y en el mismo tenor, reconozco que si derivaren de este trabajo productos intelectuales o desarrollos tecnológicos, en lo especial, estos se registrarán en todo caso por lo dispuesto por la Ley Federal del Derecho de Autor y la Ley de la Propiedad Industrial, en el tenor de lo expuesto en la presente Declaración.

Firma: _____



Nombre: STEPHANIE PATRICIA GEORGE CHACÓN

AGRADECIMIENTOS

A CONACYT por la beca 406447 otorgada para maestría.

A mi director de tesis José Luis Hernández Stefanoni por ser mi guía, por motivarme y apoyarme siempre. A mi comité tutorial el Dr. Juan Manuel Dupuy Rada y la Dra. Alicia Peduzzi por su tiempo, paciencia infinita y valiosos comentarios que enriquecieron mi trabajo de muchas maneras. A mis revisores, el Dr. Richard Feldman y el Dr. René Valdez, por su tiempo y observaciones para la revisión de esta tesis.

A la Dra. Celene Espadas por su apoyo incondicional, a Fernando Tun Dzul, Filogonio May Pat, y Juan Pablo Caamal Sosa por su apoyo con el trabajo de campo.

A mis amigos y a mis colegas, que más que amigos son la familia que encontré en el posgrado, por aguantar los malos humores, la poca paciencia y las prisas; por compartir desvelos y preocupaciones pero también, risas, momentos inolvidables y mucho cariño.

A la unidad de Recursos Naturales: su espacio y su gente.

Al Jardín Botánico y toda la gente que lo cuida.

Al **Fondo Sectorial Conacyt-Sener Sustentabilidad** por su apoyo económico otorgado en el marco del proyecto **Uso de biomasa leñosa como biocombustible sólido para la generación de energía eléctrica en zonas rurales** con clave **249581**.

DEDICATORIA

A mi familia, por comprender absolutamente todo, por ayudarme en todo siempre y por impulsarme a seguir adelante.

A mi hijo Sebastián, que me regaló el futuro.

ÍNDICE

ÍNDICE	ii
ÍNDICE DE CUADROS.....	viii
LISTADO DE ABREVIATURAS	viii
RESUMEN.....	xii
ABSTRACT	xiii
INTRODUCCIÓN.....	1
CAPÍTULO I: ANTECEDENTES	5
1.2 ANTECEDENTES.....	5
1.2.1 El bosque tropical seco	5
1.2.2 Bosque tropical subcaducifolio.....	6
1.2.3 Bosque tropical subperennifolio	7
1.2.4 Estructura de la vegetación.....	7
1.2.5 Sucesión secundaria.....	8
1.2.6 Diversidad.....	9
1.2.7 Heterogeneidad ambiental	10
1.2.8 Estimación de la diversidad	11
1.2.9 Inventarios de campo.....	11
1.2.10 Sitios de monitoreo intensivo de Carbono	12
1.2.11 Percepción remota	12
1.2.12 Imágenes de satélite	13

1.2.13 Imágenes RapidEye.....	15
1.2.14 Índices de vegetación	15
1.2.15 Medidas de textura	16
1.2.16 LiDAR	17
1.3 ESTRATEGIA DE INVESTIGACIÓN.....	18
1.4 OBJETIVOS.....	18
1.4.1 OBJETIVO GENERAL	18
1.4.2 OBJETIVOS ESPECÍFICOS.....	19
1.5 PREGUNTAS DE INVESTIGACIÓN	20
1.6 HIPÓTESIS.....	20
CAPÍTULO II. EVALUACIÓN DEL EFECTO DEL TAMAÑO DE LA PARCELA EN LA ESTIMACIÓN DE DIVERSIDAD DE ESPECIES DE PLANTAS USANDO PERCEPCIÓN REMOTA.	23
2.1 INTRODUCCIÓN	23
2.2 MATERIALES Y MÉTODOS.....	25
2.2.1 Área de estudio.....	25
2.2.2 Muestreo de datos en campo: riqueza y diversidad de especies.....	26
2.2.3 Análisis de imágenes	27
2.2.4 Procesamiento de datos LiDAR	28
2.2.5 Análisis de datos.....	29
2.3 RESULTADOS	32
Cuadro 2.1 Resumen del ajuste de los modelos de riqueza y diversidad con textura y	

métricas de LiDAR en Kaxil Kiuic (Ver Apéndice III para los modelos en detalle).	32
Cuadro 2.2 Resumen del ajuste de los modelos de variables de textura y métricas de LiDAR en Felipe Carrillo Puerto.	32
2.4 DISCUSIÓN.....	34
2.5 CONCLUSIÓN.....	36
CAPÍTULO III. MODELLING SPECIES DIVERSITY OF TROPICAL DRY FOREST COMBINING HIGH RESOLUTION SATELLITE IMAGERY AND LIDAR DATA.	37
3.1 INTRODUCTION	37
3.2 STUDY AREA AND METHODS.....	38
3.2.1 Study area	38
3.2.2 Field data.....	39
3.2.3 Remotely sensed data and imagery processing	40
3.2.4 LiDAR data processing	42
3.2.5 Data analysis	42
3.3 RESULTS	45
3.3.1 Estimation of diversity from texture metrics.....	45
Table 1: Model results for multiple regressions relating species richness and Shannon's Index and PCs from texture variables in Kaxil Kiuic.	45
Table 2: Model results for multiple regressions relating species richness and Shannon's Index and PCs from texture variables in Felipe Carrillo Puerto.	45
3.3.2 Estimation of diversity from LiDAR metrics.....	46
Table 3: Model results for multiple regressions relating species richness and Shannon's Index and PCs obtained from LiDAR metrics in Kaxil Kiuic.	47

Table 4: Model results for multiple regressions relating species richness and Shannon’s Index and PCs containing LiDAR metrics in Felipe Carrillo Puerto.....	47
3.3.3 Combined models	48
Table 5: Combined model results for multiple regressions relating species richness and Shannon’s Index and PCs from LiDAR metrics for the Kiuic site.....	48
Table 6. Combined model results for multiple regressions relating species richness and Shannon’s Index and LiDAR metrics for the FCP site.	48
3.3.7 Variation partitioning	49
Fig. 1 Bar plots for variation partitioning Kaxil Kiuic site.	49
Fig. 2 Bar plots for results of variation partitioning for Felipe Carrillo Puerto site	50
3.4 DISCUSSION	51
3.5 CONCLUSION.....	54
CAPÍTULO IV. DISCUSIÓN Y CONCLUSIONES GENERALES.....	55
4.1 DISCUSIÓN GENERAL.....	55
4.2 CONCLUSIONES	58
4.3 PERSPECTIVAS	60
BIBLIOGRAFÍA.....	63
ANEXO I.....	75
IMAGE TEXTURE FORMULAE	76
NOTATION.....	78
INDIVIDUAL MEASURE INTERPRETATION	78
ANEXO II.....	79

ANEXO II. Resultados del análisis de componentes principales.	80
Cuadro 1.- Importancia de componentes de los componentes principales de medidas de textura y proporción de varianza explicada por componente (Kaxil Kiuic).	80
Cuadro 2.- Composición de componentes de medidas de textura en Kaxil Kiuic: 20 variables más importantes.	80
Cuadro 3.- Importancia de componentes de los componentes principales de medidas de textura y proporción de varianza explicada por componente (Felipe Carrillo Puerto).	81
Cuadro 4.- Composición de componentes de medidas de textura en FCP: 20 variables más importantes.	81
Cuadro 5.- Importancia de componentes de los componentes principales de métricas de LiDAR y proporción de varianza explicada por componente (Kaxil Kiuic).	81
Cuadro 6.- Composición de componentes significativos de métricas de LiDAR en Kaxil Kiuic: 20 variables más importantes.	82
Cuadro 7.- Importancia de componentes de los componentes principales de métricas de LiDAR y proporción de varianza explicada por componente (FCP).	84
Cuadro 8.- Composición de componentes significativos de métricas de LiDAR en FCP: 20 variables más importantes.	84
ANEXO III	86
I. Resumen de resultados de prueba de autocorrelación espacial (Moran's I) de residuales de modelos de a) textura y b) LiDAR para estimar riqueza y diversidad de especies en 1000 m ²	87
a) Cuadro 1: Análisis de autocorrelación espacial para modelos de textura.	87
b) Cuadro 2: Análisis de Autocorrelación espacial para modelos de LiDAR.	87
II. Resumen de resultados de prueba de autocorrelación espacial (Moran's I) de residuales de modelos de a) textura y b) LiDAR para estimar riqueza y diversidad de especies en 400 m ²	88

a) Cuadro 1: Análisis de autocorrelación espacial para modelos de textura.....	88
b) Cuadro 2: Análisis de autocorrelación espacial para modelos de LiDAR.	88
III. Cuadro de resultados de modelos de riqueza y diversidad de especies en 400 m ² para Kaxil Kiuic. a)Medidas de textura, b) Métricas de LiDAR.	89
IV. Cuadro de resultados de modelos de riqueza y diversidad de especies en 400 m ² para Kaxil Kiuic. a)Medidas de textura, b) Métricas de LiDAR.	89
ANEXO IV	91
SCRIPTS DE CÁLCULO DE TEXTURA PARA KAXIL KIUIC	92
SCRIPTS DE CALCULO DE TEXTURA PARA FELIPE CARRILLO PUERTO	94

ÍNDICE DE CUADROS

CAPÍTULO II. EVALUACIÓN DEL EFECTO DEL TAMAÑO DE LA PARCELA EN LA ESTIMACIÓN DE DIVERSIDAD DE ESPECIES DE PLANTAS USANDO PERCEPCIÓN REMOTA...... 23

Cuadro 2.1 Resumen del ajuste de los modelos de riqueza y diversidad con textura y métricas de LiDAR en Kaxil Kiuic (Ver Apéndice III para los modelos en detalle). 32

Cuadro 2.2 Resumen del ajuste de los modelos de variables de textura y métricas de LiDAR en Felipe Carrillo Puerto. 32

CAPÍTULO III. MODELLING SPECIES DIVERSITY OF TROPICAL DRY FOREST COMBINING HIGH RESOLUTION SATELLITE IMAGERY AND LIDAR DATA. 37

Table 1: Model results for multiple regressions relating species richness and Shannon's Index and PCs from texture variables in Kaxil Kiuic. 45

Table 2: Model results for multiple regressions relating species richness and Shannon's Index and PCs from texture variables in Felipe Carrillo Puerto. 45

Table 3: Model results for multiple regressions relating species richness and Shannon's Index and PCs obtained from LiDAR metrics in Kaxil Kiuic. 47

Table 4: Model results for multiple regressions relating species richness and Shannon's Index and PCs containing LiDAR metrics in Felipe Carrillo Puerto..... 47

Table 5: Combined model results for multiple regressions relating species richness and Shannon's Index and PCs from LiDAR metrics for the Kiuic site..... 48

Table 6. Combined model results for multiple regressions relating species richness and Shannon's Index and LiDAR metrics for the FCP site. 48

ANEXO II. Resultados del análisis de componentes principales. 80

Cuadro 1.- Importancia de componentes de los componentes principales de medidas de textura y proporción de varianza explicada por componente (Kaxil Kiuic). 80

Cuadro 2.- Composición de componentes de medidas de textura en Kaxil Kiuic: 20 variables más importantes.	80
Cuadro 3.- Importancia de componentes de los componentes principales de medidas de textura y proporción de varianza explicada por componente (Felipe Carrillo Puerto).	81
Cuadro 4.- Composición de componentes de medidas de textura en FCP: 20 variables más importantes.	81
Cuadro 5.- Importancia de componentes de los componentes principales de métricas de LiDAR y proporción de varianza explicada por componente (Kaxil Kiuic).	81
Cuadro 6.- Composición de componentes significativos de métricas de LiDAR en Kaxil Kiuic: 20 variables más importantes.	82
Cuadro 7.- Importancia de componentes de los componentes principales de métricas de LiDAR y proporción de varianza explicada por componente (FCP).	84
Cuadro 8.- Composición de componentes significativos de métricas de LiDAR en FCP: 20 variables más importantes.	84
ANEXO III	86
I. Resumen de resultados de prueba de autocorrelación espacial (Moran's I) de residuales de modelos de a) textura y b) LiDAR para estimar riqueza y diversidad de especies en 1000 m ²	87
a) Cuadro 1: Análisis de autocorrelación espacial para modelos de textura.	87
b) Cuadro 2: Análisis de Autocorrelación espacial para modelos de LiDAR.	87
II. Resumen de resultados de prueba de autocorrelación espacial (Moran's I) de residuales de modelos de a) textura y b) LiDAR para estimar riqueza y diversidad de especies en 400 m ²	88
a) Cuadro 1: Análisis de autocorrelación espacial para modelos de textura.	88
b) Cuadro 2: Análisis de autocorrelación espacial para modelos de LiDAR.	88

III. Cuadro de resultados de modelos de riqueza y diversidad de especies en 400 m ² para Kaxil Kiuic. a) Medidas de textura, b) Métricas de LiDAR.	89
IV. Cuadro de resultados de modelos de riqueza y diversidad de especies en 400 m ² para Kaxil Kiuic. a) Medidas de textura, b) Métricas de LiDAR.	89

LISTADO DE ABREVIATURAS

BTS Bosque tropical seco

BTH Bosque tropical húmedo

CONAFOR Comisión Nacional Forestal

EVI Enhanced Vegetation Index

FAO Food and Agriculture Organization of the United Nations

GEI Gases de efecto invernadero

GLCM Gray-Level Cooccurrence Matrix

GPS Global Positioning System

IMU Inertial Measurement Unit

IAF Índice de área foliar

LiDAR Light Detection and Ranging

NDVI Normalized Difference Vegetation Index, Índice Normalizado de Vegetación

REDD+ Reducción de Emisiones por Deforestación y Degradación

SVH Spectral Variation Hypothesis

SMIC Sitios de Monitoreo Intensivo de Carbono

PCA Principal Component Analysis

PC Principal component

RESUMEN

Los bosques tropicales proveen una gran cantidad de servicios ambientales y recursos para las poblaciones humanas, sin embargo, son los ecosistemas forestales más amenazados del mundo. Dado que muchos de los servicios y recursos que estos bosques proveen dependen de su diversidad, es necesario obtener estimaciones precisas de ésta que puedan ser aplicadas a grandes extensiones para maximizar los esfuerzos de conservación. En este estudio se combinó la información de dos tipos de sensores remotos: imágenes de satélite RapidEye (sensores pasivos) y datos LiDAR (sensores activos) para estimar riqueza y diversidad de especies de plantas leñosas en dos bosques tropicales secos de la península de Yucatán. Dado que el tamaño de la parcela de campo puede tener un efecto en las estimaciones, se evaluó el efecto de utilizar parcelas de dos tamaños (400 y 1000 m²) en el cálculo número de especies y la diversidad (*i.e.* índice de Shannon). Posteriormente, se calcularon medidas de textura en la imagen usando imágenes RapidEye y se obtuvieron métricas de LiDAR correspondientes a las coordenadas de las parcelas de campo. Se realizó un análisis de componentes principales (PCA) para reducir la cantidad de variables. Los componentes obtenidos a partir de las medidas de textura capturan la variación de la textura entre las parcelas, y fueron usados como un sustituto de la heterogeneidad ambiental, mientras que los obtenidos de LiDAR se asocian principalmente con alturas y coberturas y fueron utilizadas como un sustituto de la estructura de la vegetación. Estos componentes fueron utilizados posteriormente un análisis de regresión lineal múltiple para estimar los valores de riqueza y diversidad observados en campo. Con los componentes significativos en ambos casos se produjo un modelo combinado que contiene ambos, heterogeneidad ambiental y estructura de la vegetación, y se realizó la partición de la varianza para determinar cuál es el aporte de cada factor por separado así como el aporte conjunto. Los resultados indican que la textura es un mejor predictor de la riqueza y diversidad en parcelas más grandes, por lo que el tamaño de parcela tiene una influencia en la precisión de las estimaciones. Se encontró que la heterogeneidad ambiental, por si misma, explica una mayor proporción de la variabilidad de la riqueza y diversidad en comparación con la estructura de la vegetación aún cuando la mayor parte de la variabilidad es compartida. Igualmente, se encontró evidencia de que la heterogeneidad ambiental se encuentra directamente asociada con la riqueza y la diversidad y se concluye, que la textura en las imágenes puede ser, por si misma, una herramienta efectiva para realizar estimaciones eficientes en estos bosques tropicales secos.

ABSTRACT

Tropical dry forests are fundamental for the subsistence of human populations; however, they are among the most threatened ecosystems in the world. Since many ecosystem goods and services they provide rely on their diversity, estimations of species diversity over large areas can provide information for improving conservation efforts. However, obtaining time and cost effective estimations on diversity will require an understanding of key drivers of species diversity and the evaluation of their accuracy. We combined information obtained from remote sensing RapidEye imagery (passive sensors) and LiDAR data (active sensors) in order to produce estimations of species diversity in two tropical dry forests in the Yucatan peninsula. Since estimations of species diversity are known to be more precise in larger than smaller plots, in this study, we tested the effect of plot size (400 vs. 1000 m²) on the accuracy of the estimation of species richness and diversity (*i.e.* Shannon's index) from field and remote sensing data. We calculated texture measures from RapidEye satellite images and obtained LiDAR metrics in two sizes to match our field plots. We reduced the amount of variables obtained via remote sensing with a Principal Component Analysis (PCA). The PC axes capture variation in texture among the plots, which we used as a proxy of habitat heterogeneity. A separate PCA of LiDAR produced axes that we used as a proxy of vegetation structure. We included our observed field data and the PC axes obtained from each group of variables in a multiple regression analysis to compare their ability to predict species richness and diversity separately. Furthermore, we constructed combined models with both texture and LiDAR axes and partitioned the variance in order to obtain the relative contribution of habitat heterogeneity and vegetation structure. In addition, we evaluated the ability of vegetation structure and habitat heterogeneity in predicting species diversity compared to species richness. We obtained more precise estimations of species richness and diversity for larger rather than smaller plots and more precise estimations of species diversity than species richness. The most important factor to explain both species richness and diversity, by itself, was habitat heterogeneity; even when a large portion of variation is shared in the combined models. We found evidence of a direct relationship between habitat heterogeneity and species diversity in these tropical dry forests and we conclude that by using texture in remotely sensed images it is possible to provide time and cost effective estimations of species diversity and therefore aid conservation efforts in these forests.

INTRODUCCIÓN

Se estima que los bosques del mundo albergan 3.04 trillones (10^{12}) de árboles, de los cuales, 1.30 trillones (10^{12}) se encuentran en las regiones tropicales y subtropicales del planeta (Crowther *et al.*, 2015). Sin embargo, más de 15 billones (10^9) de árboles son talados anualmente y se estima que el número global de árboles ha disminuido un 46% desde los inicios de la civilización humana (Crowther *et al.*, 2015). En particular, los bosques tropicales secos (BTS) son considerados como parte de los ecosistemas más amenazados del mundo (Miles *et al.*, 2006) ya que han sido sitios preferidos como zonas de establecimiento de comunidades humanas y debido a que la relativa simplicidad de su estructura facilita su aprovechamiento (Quesada *et al.*, 2009; Lamb *et al.*, 2005; Murphy y Lugo, 1986) Por esto mismo, su distribución ha sido reducida a una fracción de su extensión original (Miles *et al.*, 2006). La importancia de estos bosques radica en que contribuyen no sólo al bienestar de la población humana, sino que también a la diversidad global de plantas leñosas (Gillespie, 2005); contribuyen al funcionamiento de los ciclos biogeoquímicos y proporcionan diversos servicios ecológicos como el control de la calidad del agua; capturan carbono en su biomasa y son fuente y reservorio de recursos maderables y no maderables (Pan *et al.*, 2011; Bonan, 2008). Adicionalmente, los BTS se caracterizan como zonas de alto endemismo. En México, se estima que un 43% de las especies de estos bosques son endémicas (Rzedowski, 2006).

Dado que muchos bienes y servicios de los bosques dependen de su diversidad, el entendimiento de los patrones y la distribución espacial de la diversidad biológica de los bosques es crucial para su adecuado manejo, gestión y conservación (Gillespie *et al.*, 2008). Esto es de especial importancia en la actualidad, debido a que el medio ambiente se encuentra bajo una presión de cambio y transformación constante (Turner *et al.*, 2003; Nagendra, 2001). Estudios recientes de las tasas de conversión de suelos sugieren que la mayoría de los bosques maduros que existen en la actualidad eventualmente desaparecerán dejando como resultado una compleja matriz conformada por terrenos agrícolas y fragmentos de bosques en diferentes edades de sucesión (Quesada *et al.*, 2009). De hecho, los bosques secundarios, bosques que se encuentran en recuperación después de una perturbación (FAO, 2010), hoy por hoy, son los bosques más abundantes en los trópicos, y aunque son muy importantes en el presente, se estima que la mayoría de la población que ocupa éstas áreas dependerá exclusivamente de sus recursos en el

futuro (Quesada *et al.*, 2009). Por esta razón, existe una creciente necesidad de información actualizada y precisa de estas comunidades y su diversidad, de manera eficiente y rápida y que pueda aplicarse a grandes áreas y en intervalos periódicos de tiempo.

El estudio de la diversidad de comunidades de plantas requiere un entendimiento básico de la abundancia de individuos, el número de especies presentes y su distribución en un sitio (Chazdon *et al.*, 1998). Dado que el número de especies –riqueza de especies– en un ensamblaje es un índice natural intuitivo de la diversidad de las comunidades plantas y animales (Magurran, 2011), su estimación representa una herramienta importante para obtener una valoración del ecosistema en general. Sin embargo, es importante señalar que la diversidad se compone del número de especies (riqueza) y también de la distribución de la proporción de individuos de estas especies (equidad) (Magurran, 2011; 2004). Por esta razón, los índices de diversidad, estadísticos que incorporan ambas propiedades, son cada vez más utilizados como herramientas para estimar la diversidad en diferentes comunidades de plantas y animales. Típicamente, las estimaciones de diversidad son obtenidas a través de muestreos de vegetación en campo donde se obtiene información muy precisa de la riqueza, diversidad, abundancia y distintas variables de la estructura de la vegetación. Sin embargo, obtener información precisa de áreas extensas puede llegar a ser una tarea costosa tanto en tiempo como en recursos.

Un factor asociado a la eficiencia en las estimaciones es la selección de un tamaño de parcela de estudio adecuado, que permita obtener suficiente información y minimice los costos y los problemas logísticos involucrados en el trabajo de campo. Sumado a esto, la percepción remota puede complementar la información de campo para obtener estimaciones de diversidad de áreas extensas a intervalos regulares de tiempo y generalmente a un bajo costo (Gillespie *et al.*, 2008; Turner *et al.* 2003; Nagendra, 2001). Para obtener estimaciones precisas sobre la distribución de la diversidad de especies es necesario entender y analizar los factores que influyen en dicha distribución (Nagendra, 2001). La percepción remota puede apoyar esta tarea utilizando sustitutos de factores biofísicos de los cuales depende la distribución de los patrones de riqueza y diversidad de especies (Gillespie *et al.*, 2008; Nagendra, 2001). Dentro de estos factores, comúnmente, se incluyen la heterogeneidad ambiental, la productividad, las interacciones entre especies, los procesos evolutivos y los regímenes de perturbación (Oindo y Skidmore 2002; Nagendra, 2001; Gould, 2000; Palmer *et al.*, 2000). La mayoría de los trabajos

previos que realizan estimaciones de diversidad por medio de percepción remota, han explorado la relación directa entre el Índice Normalizado de Diferencia en la Vegetación o índice de verdor y (NDVI por sus siglas en inglés) y la riqueza de especies. Este índice es obtenido de imágenes de satélite y se utiliza como un sustituto de la productividad primaria neta (PPN), la energía resultante de restar la energía necesaria para manutención y la utilizada para la respiración de la energía total fijada en la fotosíntesis, y tiene una relación positiva con la riqueza de especies (Oindo y Skidmore, 2002; Box *et al.*, 1989). Otros trabajos han explorado el uso de la heterogeneidad espectral como un sustituto de la heterogeneidad ambiental para estimar diversidad en diversos taxones (Rocchini *et al.*, 2010; Foody y Cutler *et al.*, 2006; Fairbanks y McGwire, 2004; Oindo y Skidmore, 2002; Gould, 2000), mediante la relación directa entre la heterogeneidad ambiental y la riqueza de especies. En este sentido, en un bosque espectralmente heterogéneo, una mayor cantidad de elementos del paisaje son detectados por el sensor, lo cual refleja una mayor cantidad de nichos y por lo tanto una mayor diversidad de especies que pueden coexistir en un mismo sitio (Palmer *et al.*, 2002; 2000).

Por otra parte, otros estudios han sugerido una relación directa entre la edad del bosque y la riqueza de especies (Dupuy *et al.*, 2012; Ruiz *et al.*, 2005). Igualmente, en bosques de mayor edad, existe una mayor diversidad de estructuras y estrategias de vida (Lebrija-Trejos *et al.*, 2010), lo cual incrementa la complejidad estructural. Dado que los sensores activos como LiDAR (*Light Detection and Ranging*) son capaces de medir la estructura de la vegetación de manera muy precisa, han sido utilizados en estudios previos para medir riqueza de especies en BTS (Hernández-Stefanoni *et al.*, 2014).

En este estudio se estimaron y compararon medidas de riqueza de especies (número de especies presentes en un área) y diversidad (índice de Shannon) con el fin de comparar si existe un mejor ajuste y precisión al incorporar las abundancias relativas de las especies en la estimación. Estas medidas se calcularon para dos tamaños de parcela con el fin de evaluar el efecto del tamaño de la parcela de campo en el ajuste y precisión de la estimación. Aparte, se utilizó la textura calculada de imágenes de satélite como sustituto de la heterogeneidad ambiental y las métricas de LiDAR como sustituto de la estructura de la vegetación con el fin de conocer el aporte de cada factor en las estimaciones, y el efecto de su combinación en el ajuste y la precisión de las estimaciones.

Esta tesis se encuentra organizada de la siguiente manera: en el primer capítulo se

presentan los antecedentes, las preguntas de investigación, los objetivos (general y particulares), y las hipótesis planteadas de este trabajo. En el segundo capítulo se presenta la evaluación del efecto del tamaño de parcela mediante el uso de dos tamaños de parcela (400 y 1000 m²) para obtener estimaciones de riqueza y diversidad de especies utilizando métodos de percepción remota. En el tercer capítulo se presentan estimaciones de riqueza y diversidad de especies, utilizando el tamaño de parcela más efectivo obtenido en el capítulo anterior, mediante textura en la imagen de satélite y métricas de LiDAR y su combinación. Igualmente se presenta una partición de la varianza con el fin de conocer la importancia de los factores en la estimación. En el cuarto capítulo se presenta la discusión general y las conclusiones generales del trabajo.

CAPÍTULO I: ANTECEDENTES

1.2 ANTECEDENTES

1.2.1 El bosque tropical seco

Los bosques tropicales secos (BTS) se definen como comunidades vegetales donde predominan árboles deciduos, tolerantes a la sequía. Estas comunidades se distribuyen en áreas secas en donde la temperatura media anual se encuentra entre los 20 y 28 °C y la precipitación anual varía de 600 a 1800 mm (Murphy y Lugo, 1986). Además presentan una marcada distinción entre las temporadas de lluvias y secas. Los BTS pueden dividirse estructuralmente de acuerdo a sus alturas en selvas medianas, con árboles de 15 a 30 m de altura y bajas con árboles de tallas menores a los 15 m. Según la caída de sus hojas, son caducifolios cuando el 75% o más de los árboles pierden sus hojas durante la estación seca; son subcaducifolios cuando entre el 50 y 75% o más de los árboles pierden sus hojas; son subperennifolios cuando pierden del 25 al 50%; y perennifolios cuando el 25% o menos de los árboles pierden sus hojas (Rzedowski, 2006; Murphy y Lugo, 1986; Miranda y Hernández, 1963). Típicamente, estos bosques presentan uno o dos estratos, y una menor diversidad de especies que los bosques tropicales húmedos (BTH) por lo que son considerados bosques de menor complejidad estructural y composición florística que los BTH, que presentan dos o tres estratos y una diversidad más alta y se encuentran presentes en zonas donde la precipitación es más abundante (Murphy y Lugo, 1986).

Debido a la relativa simplicidad de su estructura y la relativa fertilidad de los suelos en los que se distribuyen, los BTS son ideales para el desmonte y para establecer áreas de producción agrícola y ganadera y se encuentran particularmente amenazados por la tala inmoderada (Alexandratos, 2012; 1995) y son considerados los más amenazados de todos los tipos de bosques en el mundo (Miles *et al.*, 2006). Estos bosques, presentan un alto grado de fragmentación y sus extensiones más grandes se encuentran en México, noreste de Brasil, Venezuela, norte de Colombia, sureste de Bolivia, Paraguay y norte de Argentina, con algunas zonas limitadas en Ecuador y Perú, (Murphy y Lugo, 1986). Sin embargo en México, únicamente el 27% de su extensión permanece intacto (Kalacska *et al.*, 2004), dado que ha sido aprovechado desde tiempos prehispánicos para la extracción de diversos productos no maderables: como leña, látex, plantas medicinales y fibras (Noriega-Trejo y Arteaga, 2010). En la península de Yucatán se encuentra una gran

cantidad de este tipo de bosques, siendo sus mayores representantes el bosque tropical subcaducifolio y el bosque tropical subperennifolio (Durán y Contreras, 2010), los dos tipos de bosque en los que se centra este trabajo. Las actividades más frecuentes en este tipo de bosques son el establecimiento de milpas, apicultura y meliponicultura y extracción de una gran diversidad de recursos forestales (Toledo *et al.*, 2008).

1.2.2 Bosque tropical subcaducifolio

El bosque tropical subcaducifolio se caracteriza por ser una comunidad vegetal donde el 50 al 75% o más de las especies pierden sus hojas en la época más seca (Miranda y Hernández, 1963; Rzedowski, 2006). Se distribuye en zonas de clima tropical cálido húmedo con una estación seca larga en invierno (Aw) (Köppen, 1948) donde la temperatura media anual es mayor a 20 °C y la precipitación es ligeramente superior a los 1200 mm (Rzedowski, 2006; Miranda y Hernández, 1963). Uno de los factores más importantes para la ocurrencia de este tipo de bosques es la distribución de la precipitación a lo largo del año, dado que se encuentran en zonas donde existe una larga temporada de sequía (5 a 7 meses) pero donde también existe una elevada humedad ambiental (Rzedowski, 2006). Estructuralmente, este bosque típicamente presenta dos estratos. El estrato superior puede medir de 8 a 15 m y está conformado por árboles de baja estatura, mientras que el estrato inferior típicamente está compuesto por plantas de diferentes formas de vida como trepadoras leñosas o lianas, herbáceas y arbustos (Rzedowski, 2006).

En México, el BTS subcaducifolio ocupa una superficie de alrededor de 4% y se distribuye desde el sur de Sinaloa hasta Chiapas principalmente en planicies de la vertiente del pacífico (Rzedowski, 2006; Miranda y Hernández, 1963). En la península de Yucatán el BTS se encuentra distribuido a lo largo un gradiente de humedad: en las zonas del norte con menor precipitación predomina el bosque caducifolio y subcaducifolio. En zonas intermedias predomina el bosque subcaducifolio y subperennifolio. En las zonas del sur, que presentan precipitación más abundante, predomina el bosque subperennifolio y perennifolio. Por esto, en la península de Yucatán el BTS subcaducifolio se intercala con áreas del bosque tropical perennifolio y subperennifolio (Rzedowski, 2006) y por lo general se encuentra conformando mosaicos con bosque caducifolio, palmar, sabana y otros tipos de vegetación (Rzedowski, 2006). Los árboles característicos en este tipo de bosque en la península de Yucatán son la Ceiba (*Ceiba pentandra* (L.) Gaertn.), el Pich

(*Enterolobium cyclocarpum* (Jacq.) Griseb.), el Chechem (*Metopium brownei* (Jacq.) Urb.), y el Ya'ax nik (*Vitex gaumeri* Greenm.) y sus árboles más abundantes son el Chakaj (*Bursera simaruba* (L.) Sarg., el Tsalam (*Lysiloma latisiliquum* (L.) Benth., y el Ja'abin (*Pisicidia piscipula* (L.) Sarg.).

1.2.3 Bosque tropical subperennifolio

El bosque tropical subperennifolio se caracteriza por ser una comunidad vegetal donde del 25 al 50% o menos de los árboles pierden sus hojas en la estación seca. Este tipo de bosque está presente en áreas cuyo clima presenta una temperatura media anual superior a los 20 °C (generalmente alrededor de 27 °C) y una precipitación media anual en un rango entre 1100 y 1500 mm (Rzedowski, 2006). En comparación con el BTS subcaducifolio, el BTS subperennifolio presenta árboles de mayores alturas (hasta 35 m), esto es ocasionado por una mayor disponibilidad de agua.

En la Península de Yucatán el BTS subperennifolio es abundante, cubre una gran parte del estado de Campeche y Quintana Roo, y se encuentra en la zona de transición entre el bosque subcaducifolio y el bosque perennifolio (Rzedowski, 2006).

Típicamente, este tipo de bosques se desarrolla en suelos de piedra caliza o *sahkab* en regiones poco habitadas y cultivadas donde productos forestales derivados de especies tales como la Caoba y el Chicle pueden ser extraídos fácilmente (Miranda y Hernández 1963). Debido a la extracción selectiva de estas y otras especies maderables y el establecimiento de prácticas agrícolas y ganaderas que se realizaron en estos bosques durante la primera mitad del siglo pasado, estos bosques ahora se encuentran distribuidos en parches de diferentes edades de crecimiento (Rzedowski, 2006).

1.2.4 Estructura de la vegetación

Los bosques son sistemas tridimensionales complejos en donde la estructura puede ser considerada tanto como un producto de la dinámica de la vegetación, como un factor que moldea la diversidad y funcionamiento del ecosistema (Spies, 1998). Igualmente, es afectada por procesos tanto antropogénicos: extracción de recursos maderables y/o no maderables y conversión de suelos para ganadería o agricultura (Ek-Díaz, 2011), como por fuerzas naturales: viento, fuego y sucesión (Spies, 1998).

La estructura del bosque engloba diversos componentes que son esenciales para el

funcionamiento y la diversidad de los ecosistemas. Por ejemplo: el dosel puede variar tanto en su estructura vertical como horizontal, presentando una variedad de alturas y copas de diferentes tamaños, lo que afecta directamente la disponibilidad y capacidad de captación de luz solar, controla el microclima y determina el hábitat para otras especies (Spies, 1998). Los atributos esenciales de la estructura del bosque son relativos a la forma, el tamaño y la distribución espacial (vertical u horizontal) de sus componentes. Los cuatro componentes esenciales de la estructura de la vegetación son: la distribución de edad/tamaño, la distribución horizontal, la distribución vertical y la madera muerta (Spies, 1998).

En la estructura característica de los BTS son árboles de mediana o baja estatura y con copas relativamente grandes. En el BTS de la península de Yucatán las formas de vida más comunes son árboles, en el estrato más alto, arbustos y lianas, en menor medida en el estrato intermedio y con escasas epífitas (Carnevali *et al.*, 2003).

1.2.5 Sucesión secundaria

En México, el BTS ha sufrido cambios en su estructura y composición debido tanto a la acción humana, en particular la práctica de agricultura de roza, tumba y quema y el establecimiento de zonas ganaderas, como a disturbios naturales como incendios forestales y huracanes (Ek-Díaz, 2011). Estos cambios estructurales que han ocurrido a través del tiempo dan como resultado un paisaje de BTS en sucesión secundaria, que se define como el cambio direccional de composición de especies a lo largo del tiempo y en escalas espaciales grandes en lugares donde ha ocurrido un disturbio (Chazdon, 2008).

En el proceso de sucesión en BTH, el cambio en la composición las especies está determinado por factores como la respuesta de las plantas a la disponibilidad de luz y la capacidad de captación de ésta, la colonización y la dispersión (Lohbeck *et al.*, 2013). En contraste, los BTS crecen en ambientes de abundante luz, donde existen otros factores limitantes como la disponibilidad de agua (Lohbeck *et al.*, 2013, la temperatura del aire y la humedad relativa (Lebrija-Trejos *et al.*, 2011). Los BTS son ambientes altamente estresantes por lo que el acervo de especies está limitado a las especies que puedan adaptarse y sobrevivir a condiciones de abundante radiación y escasez de agua (Poorter, 2009). Algunos estudios han reportado que durante las etapas tempranas de la sucesión, la radiación y la limitación por agua son mayores por lo que las especies que dominan son especies con estrategias “conservadoras” que pueden resistir o tolerar la sequía y la

irradiación. Por otra parte, en las etapas tardías las condiciones ambientales son más benignas y son dominadas por especies que tienen rasgos funcionales que les permiten una captura y transporte de recursos de manera más eficiente (Markestejn *et al.*, 2011). Los cambios más notorios en la vegetación a lo largo de un período de sucesión son cambios estructurales como el incremento en la altura del dosel, la densidad de árboles con DAP (diámetro a la altura del pecho) mayor a 10 cm, el área basal y la biomasa (Chazdon, 2008). Igualmente, se ha estimado que la mayor riqueza de especies en BTS se encuentra en bosques de edades mayores a 15 años (Dupuy *et al.*, 2012). Por lo tanto, medidas estructurales del dosel como la altura, y el área basal que incrementan con la edad, presentan una relación directa con la riqueza de especies. Igualmente, a medida que aumenta la edad, aumenta la diversidad de estrategias y formas de vida (Lebrija-Trejos *et al.*, 2010), esto refleja un aumento en la complejidad de la estructura del bosque, lo cual se asocia a una mayor variabilidad entre alturas y coberturas en los rodales de mayor edad.

1.2.6 Diversidad

La diversidad biológica se define como la variabilidad y abundancia de especies en una unidad de estudio y se compone de dos elementos: riqueza y equidad (Magurran, 2004). La riqueza consiste en el número de especies en un área determinada, mientras que la equidad incorpora la distribución de las abundancias de las especies (Magurran, 2004). A pesar de ser considerado un indicador natural e intuitivo de diversidad la riqueza de especies da igual peso a todas las especies de una comunidad sin importar si se encuentran en mayor o menor proporción (Jost, 2006).

Un índice de diversidad es un estadístico único que incorpora ambas características. Están basados en tres supuestos principales: El primer supuesto establece que todas las especies son iguales, lo que significa que especies de valor notable de conservación o especies que hacen una contribución desproporcionada al funcionamiento de las comunidades no tienen un mayor peso en la estimación, siendo la abundancia relativa de las especies en un ensamblaje el único factor que determina su importancia en la estimación. El segundo supuesto hace énfasis en que no se hacen distinciones por tamaño y/o volumen, a pesar de que el muestreo pueda ser selectivo. Finalmente, el tercer supuesto asume que la abundancia ha sido registrada utilizando medidas apropiadas y comparables. Algunos ejemplos son el índice de diversidad de Simpson, el

índice de diversidad de Shannon o el alpha de Fisher (Magurran, 2004).

El índice de Shannon (H) (también llamado entropía de Shannon) es un índice derivado de la teoría de la información. Este índice se utiliza comúnmente para caracterizar la diversidad de comunidades biológicas, incorporando la abundancia relativa de cada una de las especies en una comunidad (Legendre y Legendre, 2012, Magurran, 2004). Además, el Índice de Shannon incorpora las especies por medio de sus frecuencias o abundancias, por lo tanto no favorece desproporcionadamente a las especies raras o comunes (Jost, 2006). Esta característica, podría facilitar la asociación de información de campo con la información obtenida de sensores remotos, debido a que estos sensores tienen la capacidad de registrar a la especie junto con sus abundancias (Rochinni *et al.*, 2010; Oldeland *et al.*, 2010). Adicionalmente, el índice de Shannon se ve menos afectado por la presencia de especies raras, las cuales son relativamente incidentales y más variables en sus características que las especies comunes (Oldeland *et al.*, 2010).

El índice de Shannon es calculado mediante la siguiente fórmula:

$$H = - \sum_{i=1}^q p_i \ln p_i$$

Donde p_i es la frecuencia relativa o proporción de observaciones (en escala 0 – 1) de la especie i (Legendre y Legendre, 2012). H , adquiere un valor mínimo ($H = 0$) cuando la unidad de muestreo contiene una sola especie e incrementa conforme aumenta el número de especies. Para un número de especies determinado, H adquiere un valor máximo cuando los organismos se encuentran distribuidos equitativamente para un número de especies q (Legendre y Legendre, 2012).

1.2.7 Heterogeneidad ambiental

La heterogeneidad ambiental es uno de los factores más importantes y comúnmente asociados con la distribución de la diversidad de especies (Jones *et al.*, 2008; Palmer *et al.*, 2000). Ambientes altamente heterogéneos pueden albergar una mayor cantidad de especies, debido a que proporcionalmente presentan una mayor cantidad de nichos que permiten la coexistencia de diferentes especies en un mismo lugar (Palmer *et al.*, 2002; 2000; Harms *et al.*, 2001; Gaston, 2000). Igualmente, la composición de especies varía

conforme la distancia entre los ambientes aumente o disminuya (Nekola y White, 1999). Por lo tanto, en lugares más cercanos habrá composiciones similares y en lugares lejanos habrá más recambio de especies. Se ha documentado que la composición y abundancia de especies vegetales están relacionadas con la heterogeneidad de las propiedades del suelo, la topografía y la edad de sucesión forestal (Jones *et al.* 2008; Dupuy *et al.* 2012), y también con la heterogeneidad de cobertura de suelo, índices espectrales y variabilidad espectral derivada de imágenes de satélite (Rocchini, 2007). La Teoría de la Variación Espectral o “*Spectral Variation Hypothesis*” (Palmer *et al.*, 2000) relaciona la heterogeneidad ambiental con la heterogeneidad espectral, estableciendo que una mayor heterogeneidad espectral equivale a una mayor heterogeneidad ambiental y, en consecuencia, un mayor número de hábitats que pueden albergar una mayor diversidad de especies (Harms *et al.*, 2001; Gaston, 2000; Palmer *et al.*, 2000). Tomando en consideración estas premisas, diversos estudios se han enfocado en utilizar la relación entre la heterogeneidad ambiental y la variabilidad espectral obtenida de una imagen de satélite utilizando la variabilidad espectral, o heterogeneidad espectral, como un sustituto de la heterogeneidad ambiental (Oindo y Skidmore, 2002; Palmer *et al.*, 2002; 2000; Gaston, 2000).

1.2.8 Estimación de la diversidad

1.2.9 Inventarios de campo

Típicamente, la estimación de diversidad involucra datos obtenidos en inventarios de campo del sitio de estudio en los que se obtiene información precisa del número de especies presentes así como diversidad variables dasonómicas de la vegetación. El objetivo principal de los inventarios de campo es obtener información de riqueza de especies y variables dasométricas o atributos relacionados a la estructura de la vegetación como altura y diámetro a la altura del pecho (DAP). Aparte, es posible obtener la ubicación geográfica, el número de individuos y datos cualitativos de las condiciones físicas del sitio, por ejemplo: rasgos orográficos, altitud, pendiente, fisiografía, uso de suelo, profundidad de suelo, presencia de erosión y degradación. Dado que esta información se obtiene a intervalos regulares de tiempo es posible obtener datos de crecimiento, salud y cambio de los bosques.

1.2.10 Sitios de monitoreo intensivo de Carbono

En México, en el año 2012, se consolidó la red de “Sitios de Monitoreo Intensivo de Carbono (SMIC)” que se enfocan principalmente en obtener información necesaria para la calibración y validación de los modelos de dinámica de carbono forestal del país. Estos sitios se establecieron en áreas prioritarias para la REDD+ (Reducción de Emisiones de carbono por la Deforestación y Degradación) que cumplieran con las características de representar paisajes importantes para la contribución del balance neto de gases de efecto invernadero (GEI), donde se permita la participación de una diversidad de instituciones para la colecta y generación de datos, y que puedan contribuir a otras iniciativas nacionales e internacionales (CONAFOR, USFS, Alianza REDD+). Bajo este marco, estos sitios se relacionan directamente con el Proyecto México Noruega (PMN) mediante la “Consolidación Institucional de la estimación de los contenidos de carbono forestal y sus cambios en México” cuyos objetivos son generar información de los almacenes de carbono nacional, utilizar, valorar el uso de modelos de dinámica de carbono forestal y establecer líneas para la colecta de información mediante bases de dato de campo que puedan utilizarse a nivel nacional en los puntos de verificación de la estimación de carbono. De acuerdo con esto, el PMN desarrolló acuerdos institucionales para obtener datos de campo de los sitios de monitoreo intensivo. Aunque el enfoque principal de estos estudios es utilizar los datos para la calibración y evaluación de modelos de estimación de biomasa y carbono en los bosques se adquirieron igualmente variables dasométricas como: área basal, altura y cobertura y de diversidad (número de especies y abundancia), mediante la identificación de las especies presentes en el sitio. Mediante estos esfuerzos los datos obtenidos pueden ser utilizados en complemento con tecnologías de percepción remota y sistemas de información geográfica para obtener estimaciones de manera rápida, eficiente y costo-efectiva y que puedan abarcar grandes áreas.

1.2.11 Percepción remota

La percepción remota se define como la ciencia y arte de obtener información acerca de un objeto, área, o fenómeno a través del análisis de información adquirida por un dispositivo que no se encuentra en contacto con el objeto, área o fenómeno investigado (Lillesand y Kiefer, 1979). Más concretamente, se refiere a la detección de la energía electromagnética en las regiones del espectro electromagnético, desde la porción “óptica” (0.4 a 14 μm) y la región de “microondas” (14 μm – 1 mm) (Turner *et al.*, 2003). La

porción óptica contiene a su vez la porción del espectro visible (400 – 700 nm) y comprende las longitudes de onda correspondientes al color azul (450 – 495 nm), verde (495 – 570 nm), rojo (620 – 750 nm), y la porción de infrarrojo, la cual a su vez se subdivide en infrarrojo cercano (700 nm – 1 μ m), infrarrojo medio (1 μ m – 3 μ m) y termal (7 μ m – 14 μ m), mientras que la región de microondas obtiene longitudes de onda más largas (a partir de los 75 cm). Los sensores pasivos (imágenes de satélite) miden la radiación de la luz de los diferentes elementos del paisaje sin emitir ninguna radiación o pulso. Estos sensores captan la información en imágenes con valores continuos de números digitales (DN: Digital Numbers) contenidos en píxeles que pueden ser de diversos tamaños de acuerdo a la resolución del sensor. Por otro lado, los sensores activos emiten pulsos que rebotan en diferentes elementos del paisaje y regresan al sensor, donde se miden las alturas o distancias a las cuales se encuentran los objetos a partir del tiempo que tarda el pulso en regresar al sensor (Turner *et al.*, 2003).

Los estudios de percepción remota pueden ofrecer un complemento a la información obtenida de campo para los estudios de diversidad debido a que pueden abarcar grandes extensiones del terreno de una manera rápida, costo-efectiva y a diferentes intervalos de tiempo e incluso de áreas que de otra manera resultan inaccesibles (Turner *et al.*, 2003; Nagendra, 2001). Es importante señalar que la información obtenida de sensores remotos se encuentra sujeta a diferentes restricciones en la escala y resolución y por lo tanto la información es obtenida a diferentes niveles de detalle (Turner *et al.*, 2003; Nagendra, 2001). Un aspecto importante a considerar en los estudios que utilizan percepción remota es el “grano” y la “extensión” ambos, componentes de la escala o nivel que ocupa el estudio. En percepción remota, se entiende por grano el tamaño del pixel o la resolución espacial y la extensión se refiere al tamaño del área de estudio (Turner *et al.*, 2003; Nagendra, 2001). Dado que los procesos y patrones biológicos como los patrones de diversidad se encuentran sujetos a una escala, es muy importante la selección del producto (imágenes o datos) y la resolución que se debe utilizar (Nagendra, 2001).

1.2.12 Imágenes de satélite

Anteriormente se ha evaluado el potencial de utilizar imágenes de satélite, obtenidas mediante sensores pasivos, con el objetivo de estimar la diversidad de especies (Nagendra, 2001). A grandes rasgos, la estimación de biodiversidad por medio de imágenes de satélite se categoriza en tres aproximaciones: La primera consiste en el

mapeo directo de plantas individuales o de asociaciones de una sola especie en áreas grandes. La segunda categoría incluye el mapeo utilizando datos de percepción remota y predicciones de la distribución de especies mediante sus requerimientos de hábitat. La tercera categoría incluye relaciones directas entre valores de radiancia espectral obtenidos mediante sensores remotos y patrones de distribución obtenidos de estudios en campo, a lo que se conoce como “Hipótesis de variación espectral” o “Spectral Variation Hypothesis” (SVH: Palmer *et al.* 2000). Esta hipótesis, ha probado ser válida para estimar la diversidad de varios grupos como plantas vasculares, líquenes, hormigas, aves y mamíferos (Rocchini *et al.*, 2010; Oindo y Skidmore, 2002; Gould *et al.*, 2000). No obstante, la relación directa entre la heterogeneidad espectral y la diversidad ha mostrado correlaciones bajas a intermedias (Rocchini, 2007) en estudios con imágenes satelitales de mediana resolución (*e.g.* Landsat TM con resolución de 30 x 30 m) (Odeland *et al.*, 2010; Rocchini, 2007; Nagendra, 2001).

Dado que la información obtenida mediante estos sensores es altamente dependiente a la escala, la elección de imágenes con una resolución adecuada es importante a la hora de definir el tipo de herramienta a usar. La resolución en una imagen de satélite se refiere al detalle o definición que puede tener una imagen en diferentes términos, por ejemplo; la resolución espectral es el número y tamaño de las regiones del espectro de luz que el sensor registra como datos (azul, verde, roja, cercana a infrarroja, termal, etc.) y se representa por medio de bandas espectrales que abarcan una porción del espectro electromagnético; la resolución espacial es el tamaño del pixel representando una extensión del terreno y determina la cantidad de información de una imagen en un área definida (si es demasiado baja, la discriminación de objetos individuales o clases es complicada) (Nagendra, 2001); la resolución radiométrica se refiere a el número de niveles digitales o números digitales utilizados para expresar los datos del sensor (cuanto mayor sea dicha resolución, mayor será el detalle de la información que se puede expresar con dicho sensor y mayor será su habilidad de detectar diferencias sutiles en la energía que capta el sensor. Por último, la resolución temporal se refiere a la frecuencia con la cual el sensor adquiere los datos (Lillesand y Kiefer, 1979). Estudios utilizando resoluciones espaciales altas (< 5 x 5 m) podrían ser la clave para mejorar las estimaciones de riqueza y diversidad debido a que una mayor resolución ofrece información más detallada y precisa de los elementos y características del paisaje a escalas más finas (Nagendra y Rochinni, 2008; Kerr y Ostrovsky, 2003).

1.2.13 Imágenes RapidEye

Las imágenes RapidEye presentan una resolución espectral de 5 bandas: azul (440 - 510 nm), verde (520 - 590 nm), roja (630 - 685), borde rojo o “Red Edge” (690 - 730 nm) y infrarroja cercana (760 - 850 nm); resolución espacial de 5 m, y resolución radiométrica de 12 bits. Se ha sugerido anteriormente que el borde rojo puede proporcionar información útil para estudios de vegetación debido a que esta banda se encuentra en una zona de transición entre las regiones roja e infrarroja sin sobreponerse (Weichelt *et al.*, 2012). Estudios previos han demostrado que la región del espectro electromagnético que comprende entre el rojo y el infrarrojo es la más útil para diferenciar la vegetación y sus características de otros elementos del paisaje. Un claro ejemplo es que los índices de vegetación como el NDVI utilizan la diferencia en la respuesta de la vegetación hacia el espectro de luz visible (en especial la zona que comprende la región roja) y el reflejo de la longitud de onda infrarroja (o infrarroja cercana) para detectar la presencia de vegetación (Fairbanks y McGwire, 2004).

1.2.14 Índices de vegetación

EL NDVI o índice normalizado de vegetación (NDVI: Goward *et al.*, 1985) es un índice que resalta la respuesta de la vegetación hacia la luz aprovechando una característica importante de las plantas verdes: la absorción de las longitudes de onda de la luz visible (400 a 700 nm) por medio de la clorofila y la reflexión de la infrarroja o cercana a infrarroja (0.7 μm a 1.1 μm). Este índice puede tener valores de -1 a +1 e indica la presencia de clorofila, característica por la cual se interpreta como una medida de “verdor” o “biomasa verde” (Box *et al.*, 1989). Es así que este índice resulta útil para detectar cambios fenológicos en la vegetación y tiene una utilidad para estimar el estado de salud de los bosques (Petorelli *et al.*, 2005). La interpretación de este índice típicamente consiste en que una vegetación sana presenta valores altos del NDVI (vegetación más verde) mientras que la vegetación más seca presenta valores más bajos.

Este índice puede ser obtenido mediante la información obtenida de sensores pasivos, es fácil de calcular y ha sido asociado en trabajos previos con la productividad primaria neta y riqueza de especies en escalas tanto locales como regionales (Gillespie, 2005; Oindo y Skidmore, 2002). La productividad primaria de la vegetación representa la base de la energía de un ecosistema. La productividad primaria neta (PPN) es la energía resultante de restar la energía necesaria para la manutención y respiración de la fijación total de la

energía fotosintética fijada a través de la fotosíntesis (Gross primary production, GPP) (Box *et al.*, 1989).

Se ha probado la existencia de una relación directa entre la productividad primaria neta y el número de especies de un área determinada (Oindo y Skidmore, 2002). En áreas de mayor productividad, se esperaría una mayor cantidad de especies (Gould, 2000; Walker *et al.*, 1992) y es debido a esto que la cantidad de energía disponible en un sistema, o productividad, es considerada como uno de los mayores determinantes de la biodiversidad, especialmente de la riqueza de especies (Gould, 2000). A pesar de que la relación PPN – NDVI ha sido una de las más exploradas para obtener estimaciones de riqueza de especies, el uso del NDVI debe ser tomado con cautela, debido a que en condiciones de alta biomasa éste índice tiende a saturarse.

1.2.15 Medidas de textura

Diversos autores han evaluado el uso de la textura en las imágenes como un sustituto de la heterogeneidad ambiental. La textura se define como la cuantificación en la variabilidad de los valores de reflectancia, sus píxeles vecinos y su arreglo espacial en un área determinada (Rocchini *et al.*, 2010; Haralick *et al.*, 1973).

La “textura” en la imagen está estrechamente relacionada con la heterogeneidad espectral y puede ser utilizada como un sustituto de la diversidad de especies (Rocchini *et al.*, 2010) a través de la SVH (Spectral Variation Hypothesis). De acuerdo a la SVH, la diferencia de los valores de reflectancia de una imagen (generalmente expresada en desviación estándar, varianza o entropía) y su arreglo espacial representa las diferencias entre los elementos del paisaje a través de la energía que reflejan (Palmer *et al.*, 2002; 2000). Las medidas de textura en la imagen son calculadas para un tamaño determinado de ventana (en número impar a partir de 3 píxeles: 3x3, 5x5, 7x7 píxeles, etc.) y se clasifican en dos grupos. Las medidas de textura de primer orden, o medidas de ocurrencia, son propiedades estadísticas que no consideran las relaciones entre píxeles vecinos y que son derivadas de los valores de reflectancia originales de la imagen. Las medidas de textura de segundo orden, o medidas de coocurrencia, consideran todas las relaciones espaciales entre grupos de dos píxeles adyacentes (Oldeland *et al.*, 2010; Haralick *et al.*, 1973). Típicamente, se calculan desde una matriz de coocurrencia en escala de grises (GLCM) conteniendo las probabilidades de coocurrencia de valores de píxel para pares de píxeles en una determinada dirección y distancia (Oldeland *et al.*,

2010). Las medidas de textura en la imagen nos proporcionan una clara idea de la homogeneidad o heterogeneidad mediante la similitud o diferencia de los píxeles dentro de la ventana del tamaño de nuestra elección. Dado que la textura en la imagen es una propiedad sujeta a cambios de acuerdo a la escala, es importante señalar que requiere una cuidadosa selección del tamaño de ventana.

1.2.16 LiDAR

LiDAR (Light Detection and Ranging) es una combinación de tecnologías de percepción remota comúnmente utilizada para estudiar la superficie de la tierra (Flood y Gautelis, 1997). Típicamente, el equipo consta de un escáner láser de diferentes longitudes de onda, un sistema especializado de GPS y un IMU (*Inertial Measurement Unit*) que se encarga de medir y compensar el movimiento linear y angular mediante tres giroscopios y acelerómetros, y puede estar montado en una aeronave (LiDAR aerotransportado) o en una plataforma terrestre (LiDAR terrestre).

Este método, emite luz en forma de pulsos láser para medir rangos o distancias variables en la superficie de la tierra por medio del tiempo que tardan en regresar y ser captados por el sensor. Estos pulsos, combinados con otra información obtenida por la plataforma, generan información precisa de la forma de la superficie terrestre y sus características en forma de puntos georeferenciados que puede ser utilizada para diversas aplicaciones, por ejemplo, generar modelos de elevación.

LiDAR es un sistema activo, emite luz, al contrario de los sensores pasivos, que reciben la información en forma de imágenes. Los sistemas “pasivos” de percepción remota nos muestran un mundo de dos dimensiones, los “activos” agregan la tercera dimensión, haciendo posible la medición de variables de estructura de hábitat, biomasa y topografía (Turner *et al.*, 2008). Los estudios topográficos típicamente utilizan un LiDAR de espectro cercano a infrarrojo e infrarrojo, aunque pueden utilizarse sensores de otras longitudes de onda (*e.g.* azul, verde, rojo). Recientemente se ha demostrado que LiDAR puede ser utilizado para estudios de estructura de la vegetación (Lefsky *et al.*, 2002) puesto que tiene la capacidad medir de forma precisa las alturas, coberturas y otros componentes estructurales como el área basal. LiDAR tiene algunas ventajas comparado con las imágenes de satélite. En primera instancia LiDAR tiene la capacidad de detectar la estructura tridimensional de los objetos debido a que la nube de puntos georeferenciados tienen coordenadas X (longitud), Y (latitud) y Z (altura) por lo que es posible estimar de

manera muy precisa patrones estructurales del dosel como de densidad de árboles, altura del dosel, cobertura del dosel, índice de área foliar (IAF), biomasa y volumen del bosque (Lefsky *et al.*, 2002). Al contrario de los sensores pasivos LiDAR no presenta saturación en condiciones de alta biomasa e índice de área foliar (Lefsky *et al.*, 2002) por lo cual puede ser útil para realizar estudios de estructura de la vegetación en sitios diversos y de alta biomasa como los bosques tropicales.

1.3 ESTRATEGIA DE INVESTIGACIÓN

Se obtuvieron valores de riqueza de especies e índice de diversidad de Shannon con información de campo de dos paisajes de BTS de la Península de Yucatán. Se calcularon los valores para 20 parcelas de 400 y 1000 m² en el bosque tropical subcaducifolio de Kaxil Kiuic y 28 parcelas de iguales tamaños en el bosque tropical subperennifolio de Felipe Carrillo Puerto. Mediante imágenes de satélite RapidEye, se obtuvieron índices de vegetación y medidas de textura de la imagen en las zonas de estudio y se extrajeron los valores correspondientes a las parcelas de campo. Adicionalmente se hicieron cortes de nubes de puntos de datos LiDAR de la zona de las parcelas de estudio y extrajeron métricas de altura y cobertura. Posteriormente, se hicieron regresiones lineales múltiples con las variables obtenidas de las imágenes de satélite como variables independientes y los valores de riqueza y diversidad obtenidos de campo como variables dependientes para las parcelas de 400 y 1000 m². Igualmente, se hicieron regresiones lineales múltiples con las métricas de LiDAR como variables independientes y los valores de riqueza y diversidad como variables dependientes para las parcelas de 400 y 1000 m². Se elaboraron modelos combinados con las variables que resultaron significativas en los modelos obtenidos de imágenes de satélite y datos LiDAR y se realizó una partición de la varianza con el fin de conocer la importancia relativa de los dos grupos de variables (heterogeneidad y estructura) y el aporte compartido en la variabilidad de los valores de riqueza y diversidad.

1.4 OBJETIVOS

1.4.1 OBJETIVO GENERAL

El objetivo general de este trabajo es estimar la riqueza y diversidad de especies leñosas en bosques tropicales secos utilizando dos tipos de sensores remotos: pasivos (imágenes de satélite) y activos (métricas de LiDAR) y evaluar la contribución de cada sensor cuando la estimación es realizada combinando ambos sensores.

1.4.2 OBJETIVOS ESPECÍFICOS

- Evaluar el efecto de aumentar el tamaño de parcela de 400 a 1000 m² en la exactitud y precisión de las estimaciones de riqueza y diversidad por medio de imágenes de satélite y datos LiDAR.
- Evaluar la relación entre la heterogeneidad ambiental, estimada a través de la textura de las imágenes de satélite, y los valores de riqueza y diversidad de especies calculados con datos de campo.
- Evaluar la relación entre la estructura de la vegetación, evaluada con métricas de altura y cobertura usando datos LiDAR, y los valores de riqueza y diversidad de especies calculados con datos de campo.
- Evaluar la importancia relativa de la heterogeneidad ambiental, estimada a través de sensores remotos pasivos y de la estructura del bosque obtenida mediante sensores activos en las estimaciones de riqueza de especies y diversidad en bosques tropicales secos.
- Evaluar si considerar las abundancias relativas en las estimaciones de diversidad de especies en BTS, por medio del índice de diversidad de Shannon calculado con datos de campo, aumenta el ajuste y la precisión de las estimaciones de diversidad con imágenes de satélite y datos LiDAR, comparado con la riqueza de especies.

1.5 PREGUNTAS DE INVESTIGACIÓN

- ¿Cuál tamaño de parcela, 400 m² o 1000 m², presenta un mayor ajuste en las estimaciones de riqueza y diversidad de especies en el BTS de estudio?
- ¿Cómo se relacionan las medidas de textura en la imagen de satélite con los valores de riqueza y diversidad de especies observados en campo?
- ¿Cómo se relacionan las métricas de LiDAR con los valores de riqueza y diversidad de especies observados en campo?
- ¿Qué proporción de la variabilidad de la riqueza y diversidad de especies es explicada por la heterogeneidad ambiental, medida a través de la heterogeneidad espectral?
- ¿Qué proporción de la variabilidad de la riqueza y diversidad de especies es explicada por la estructura de la vegetación medida a través de las métricas de alturas y coberturas de LiDAR?
- ¿Qué variables contribuyen de mejor manera a explicar la variabilidad en la riqueza y diversidad de especies en el BTS?
- ¿Comparado con la riqueza de especies, el considerar la abundancia relativa de las especies mediante el índice diversidad de Shannon, aumenta el ajuste y la precisión de las estimaciones de diversidad con métricas de textura o datos LiDAR?

1.6 HIPÓTESIS

1. Un incremento en el área muestreada, incrementará la relación perímetro – área, reduciendo el efecto de borde y el error en la estimación, por lo tanto, los modelos ajustados a las variables dependientes calculadas a partir de parcelas de 1000 m² presentarán mayor ajuste y modelos más precisos que los modelos calculados con las parcelas de 400 m².
2. Debido a que una mayor heterogeneidad ambiental representa una mayor variedad de nichos ecológicos, y dado que la heterogeneidad ambiental tiene una relación directa con la heterogeneidad espectral medida en las imágenes, se espera encontrar una relación significativa positiva de las medidas de textura de la imagen con los valores de riqueza y diversidad de especies calculados a partir de datos de campo.
3. Debido a que la complejidad en la estructura del bosque se encuentra directamente relacionada con la edad del bosque y ésta se encuentra

directamente relacionada con la riqueza y diversidad de especies, se espera una asociación significativa entre las métricas de LiDAR relacionadas con mayor complejidad estructural y los valores de riqueza y diversidad obtenidos de datos de campo.

4. Debido a que el índice de diversidad de Shannon tiene la capacidad de incorporar las abundancias relativas de las especies y que las abundancias de las especies son registradas por las imágenes satelitales y los datos LiDAR, se espera que los modelos de diversidad de Shannon tengan mayor precisión que aquellos modelos que utilizan la riqueza de especies como variable dependiente.
5. Dado que existe una relación directa entre la heterogeneidad ambiental y la diversidad de especies, la cual puede ser medida directamente mediante la heterogeneidad de los valores de reflectancia en una imagen de satélite, se espera que las medidas de textura, expliquen una mayor variabilidad de la riqueza y la diversidad de especies que las métricas de LiDAR.

CAPÍTULO II. EVALUACIÓN DEL EFECTO DEL TAMAÑO DE LA PARCELA EN LA ESTIMACIÓN DE DIVERSIDAD DE ESPECIES DE PLANTAS USANDO PERCEPCIÓN REMOTA.

2.1 INTRODUCCIÓN

La mayoría de la información que se tiene actualmente de los bosques ha sido obtenida por medio de inventarios o censos de campo en parcelas de estudio, o parcelas permanentes (Mahli *et al.*, 2002; Phillips *et al.*, 1998; Phillip, 1994). En estos estudios, se obtiene información precisa sobre diversos atributos del bosque que actúan como sus descriptores, los cuales pueden estar relacionados con su diversidad (número de especies y su abundancia), o también relacionados con su estructura física, como variables dasométricas (DAP, altura, cobertura, etc.) mediante las cuales es posible estimar variables relacionadas con el volumen, como la biomasa aérea (Chave *et al.*, 2014; 2005). La parcela de estudio de campo corresponde directamente al concepto de “grano”, la unidad de observación más pequeña indivisible, y representa la unidad de observación en los estudios ecológicos. Diversos autores han evaluado el efecto del tamaño y la forma de las parcelas de campo con el fin de obtener estimaciones más precisas y eficientes de diversidad (Kenkel y Podani, 1991; Bormann, 1953) y de biomasa aérea (Wagner *et al.*, 2010). El tamaño de la parcela tiene un efecto directo y positivo sobre la diversidad debido a que el área de observación, tiene una relación con la cantidad de especies, lo cual tiene su fundamento en la relación especies – área, uno de los patrones más estudiados en la ecología (McArthur y Wilson, 1967). En un sentido, esta relación también implica que a mayor área, tendremos una mayor heterogeneidad ambiental, otro factor directamente relacionado con la diversidad y composición de especies (Palmer *et al.*, 2002; 2000, Jones *et al.*, 2008). Típicamente, la estimación de diversidad mediante la relación especies – área es evaluada mediante curvas de especies – área, sin embargo es difícil evaluar su eficiencia estadística, por lo que Borman (1953), propuso el uso de parcelas de diferentes tamaños y la evaluación de su varianza. Sin embargo, la medición en parcelas de diferentes tamaños implica igualmente un aumento en el esfuerzo y tiempo en estudios de campo, por lo que la selección cuidadosa de un tamaño de parcela adecuado, que pueda ser utilizado en estudios futuros, es importante.

Diversos estudios han probado utilizar la percepción remota como un complemento a la información obtenida en censos de campo para realizar estimaciones de riqueza y diversidad de especies (Turner *et al.*, 2003; Nagendra, 2001). En estos estudios, es

importante tener en cuenta que la resolución o tamaño de *pixel* (en datos de sensores pasivos e.g. imágenes de satélite), o la unidad vectorial más pequeña de mapeo (el polígono más pequeño) tendrá un efecto directo sobre la estimación. Es importante considerar que en percepción remota se puede obtener una mayor cantidad de información considerando *pixeles* más pequeños o imágenes de mayor resolución (Turner *et al.*, 2003).

La textura en la imagen, definida como la cuantificación de la variabilidad de los niveles de gris en una imagen y su arreglo espacial (Haralick *et al.*, 1973), ha sido utilizada previamente para obtener estimaciones de riqueza de especies y diversidad (St-Louis *et al.*, 2006) como sustituto de la heterogeneidad ambiental, directamente relacionada con la diversidad (SVH *Spectral Variation Hypothesis*. Palmer *et al.*, 2002; 2000). La textura en la imagen es calculada mediante una ventana en movimiento, de un tamaño previamente definido, donde se calculan valores de homogeneidad y heterogeneidad de los *pixeles* (Hall-Beyer, 2007; Haralick *et al.*, 1973). En este sentido, la selección del tamaño de ventana apropiado es un aspecto a considerar, debido a que el tamaño de ventana, con una cuidadosa consideración de la resolución de la imagen, debe corresponder al área de la parcela de campo para que el valor de la textura calculado en la imagen corresponda directamente a la homogeneidad o heterogeneidad de la parcela de campo.

Los datos obtenidos de sensores activos como LiDAR (Light Detection and Ranging) consisten en nubes de puntos georeferenciados que pueden ser cortadas en tamaños y formas diferentes. Por lo tanto, es posible obtener estadísticas de las medidas de alturas y coberturas del dosel en diferentes tamaños y formas que correspondan al tamaño y forma de la parcela en campo. Por una parte, se ha encontrado que en estimaciones de biomasa por medio de sensores activos como LiDAR los errores tienden a reducirse utilizando tamaños de parcela más grandes (Ruiz *et al.*, 2014; Chave *et al.*, 2004). Esto es debido a que al aumentar el tamaño de la parcela aumenta la relación perímetro-área y se reduce el efecto de borde, donde las especies que se encuentran en los límites no son registradas de manera adecuada por el sensor (Chave *et al.*, 2004). Asimismo, existe una tendencia a que los errores en general disminuyan al aumentar los tamaños de parcela debido a que en parcelas más grandes es posible disminuir el error del GPS al haber una mayor superposición de los puntos GPS obtenidos en campo con los datos LiDAR (Chave *et al.*, 2004). Sin embargo estos sensores, han sido poco utilizados en estimaciones de riqueza y diversidad de especies (Li *et al.*, 2013; Leutner *et al.*, 2012; Jones *et al.*, 2010) y

existen aún menos estudios que evalúen el tamaño de parcela en modelos utilizando datos LiDAR e información de campo (Hernández–Stefanoni *et al.*, 2014) por lo que la evaluación del efecto del tamaño de parcela sigue siendo importante. Además de que aumentar el tamaño de parcela implica un aumento en esfuerzo, consideraciones logísticas y costos en estudios de campo (Nagendra, 2001), en los sistemas de información igualmente implica una mayor cantidad de datos y una mayor dificultad de almacenamiento y procesamiento. Por esta razón, la evaluación del efecto de diferentes tamaños de parcela es importante para encontrar el tamaño más efectivo, con el fin asegurar resultados más precisos sin incrementar los costos y la dificultad indiscriminadamente. En este estudio se evaluó el efecto del tamaño de parcela en la estimación de la riqueza y la diversidad de especies de plantas por medio de percepción remota en dos sitios de bosque tropical seco en la Península de Yucatán mediante dos métodos: el primer método consiste en la estimación de la riqueza de especies e Índice de diversidad de Shannon (H') mediante medidas de textura en la imagen de dos diferentes tamaños de ventana y en parcelas de dos diferentes tamaños. El segundo método consiste en la estimación de la riqueza e Índice de Shannon por medio de métricas de LiDAR para parcelas de dos diferentes tamaños. En este trabajo se espera encontrar que las estimaciones de riqueza y diversidad de especies hechas a partir de información obtenida en parcelas de mayor tamaño permitan obtener mejores estimaciones comparadas con las estimaciones a partir de las parcelas de menor tamaño.

2.2 MATERIALES Y MÉTODOS

2.2.1 Área de estudio

El área de estudio comprende dos tipos de bosque tropical seco de la península de Yucatán. El primer sitio abarca 9 km² y se encuentra en la Reserva Biocultural Kaxil Kiuic (20°04' N - 89°32' W), al sur del estado de Yucatán dentro de una zona protegida que abarca un total de 1800 ha. El segundo sitio se encuentra en la porción media del estado de Quintana Roo, en el municipio Felipe Carrillo Puerto (18°53' N - 88°14' W). La vegetación de ambos sitios corresponde al Bosque Tropical Seco (BTS) con clima cálido tropical con lluvias en verano y una estación seca de noviembre a abril y temperatura media de 26°C. En el sitio de Kaxil Kiuic la precipitación media anual varía entre 1000 y 1100 mm y la topografía del paisaje consiste en colinas de piedra caliza con una pendiente de 10°- 25° alternándose con áreas planas y la elevación varía entre 60 y 180

m. El tipo de vegetación principal es bosque tropical seco subcaducifolio, donde la mayoría de las especies (del 50 al 75%) tiran las hojas durante la estación seca (noviembre a abril). El dosel tiene una altura relativamente baja (de 8 a 13 m) con unos cuantos parches con árboles prominentes de 15 a 18 m en la edad de sucesión más vieja. El paisaje está compuesto de parches de bosque tropical seco en diferentes edades de sucesión tras su uso para agricultura de roza, tumba y quema (Hernández-Stefanoni *et al.*, 2014). Las especies más abundantes en este sitio son *Bursera simaruba* (L.) Sarg., *Neomillspaughia emarginata* (H. Gross) S.F. Blake, *Gymnopodium floribundum* Rolfe, *Piscidia piscipula* (L.) Sarg. y *Lysiloma latisiliquum* (L.) Benth.

El sitio de Felipe Carrillo Puerto es relativamente plano y su precipitación media varía entre 1000 y 1300 mm. El tipo de vegetación pertenece al bosque tropical subperennifolio y únicamente el 25% al 30% de las especies pierden sus hojas durante la estación seca. La vegetación puede alcanzar alturas hasta de 25 m y el dosel puede llegar a tener varios niveles, aumentando la complejidad de la estructura. Las especies más abundantes son *Manilkara zapota* (L.) P. Royen, *Vitex gaumeri* Greenm., *Bursera simaruba* (L.) Sarg., *Metopium brownei* (Jacq.) Urb. y *Cecropia obtusifolia* Bertol. El uso de suelo más común es la agricultura de roza, tumba y quema, aunque también se lleva a cabo extracción selectiva de madera (Hernández-Stefanoni *et al.*, 2014).

2.2.2 Muestreo de datos en campo: riqueza y diversidad de especies

Los datos de campo para los dos sitios fueron obtenidos mediante un muestreo de vegetación llevado a cabo durante la estación de lluvias de 2013 en un área de 3 x 3 km (9 km²). En el sitio de Kaxil Kiuic, 20 parcelas de muestreo fueron colocadas de manera sistemática estratificada alrededor de una torre de flujo. En FCP, fueron colocadas 28 parcelas equidistantes en una gradilla uniforme. Las coordenadas X y Y correspondientes a la ubicación del punto central de la parcela fueron obtenidas mediante una unidad GPS GARMIN con un error medio por debajo de 3 m.

En cada parcela, en un círculo concéntrico que conforma la subparcela de 80 m² todas las especies de plantas leñosas mayores a 2.5 en DAP (1.30 m) fueron muestreadas. Las especies fueron identificadas y posteriormente se midió el diámetro, la altura total y se registró el número de individuos y el número de tallos.

Posteriormente, para un área que conforma la subparcela de 400 m² se muestrearon de

igual manera todas las plantas mayores a 7.5 cm de DAP. Se incluyó una tercera subparcela con un aumento de 600 m² dónde todas las especies leñosas mayores a 20 cm en DAP fueron muestreadas de la misma manera. De esta manera se obtiene un área total de 1000 m².

Posteriormente, se calculó la riqueza de especies (número de especies presentes) y el índice de diversidad de Shannon considerando todas las especies de plantas vivas presentes en la parcela dividida en dos: la primera corresponde a todas las especies que se encuentren en la subparcela central de 400 m² y la segunda considerando el área total de 1000 m².

2.2.3 Análisis de imágenes

Se utilizaron dos imágenes de satélite RapidEye con resolución espacial de 5 m y resolución radiométrica de 12 bits. Las dos imágenes se encuentran georreferenciadas a la proyección de Universal Traverse Mercator (WGS 84) y corresponden al mes de abril en Kaxil Kiuic y marzo para Felipe Carrillo Puerto, ambas del año 2012. De estas imágenes se extrajeron los valores correspondientes a los píxeles localizados en las coordenadas de los puntos correspondientes a cada una de las parcelas (20 para Kaxil Kiuic y 28 para Felipe Carrillo Puerto) de la banda 3 o banda roja (630 -685 nm) y banda 4 o borde rojo (690-730 nm).

Igualmente, con estas bandas se obtuvo el Índice Normalizado de la Diferencia en la Vegetación (Normalized Difference Vegetation Index, NDVI) y el EVI (Enhanced Vegetation Index) mediante las fórmulas:

$$\text{NDVI} = (\text{Banda 4} - \text{Banda 3}) / (\text{Banda 4} + \text{Banda 3})$$

$$\text{EVI} = G \left((\text{Banda 4} - \text{Banda 3}) / (L + \text{Banda 4} + C_1 * \text{Banda 3} - C_2 * \text{Banda 1}) \right)$$

El EVI incorpora los parámetros $C_1=6$ y $C_2=7.5$, la banda azul (de 440 a 510 nm) para corrección atmosférica de aerosoles, L , la minimización de la variación en la reflectancia del suelo, y el factor $G=2.5$ (Jiang, 2008; Huete *et al.*, 2002; Gao *et al.*, 2000), para minimizar la diferencia entre el EVI y EVI 2, o EVI de dos bandas que incorpora únicamente las bandas verde y roja (Jiang *et al.*, 2008). El procesamiento de las imágenes, los índices de vegetación y los cálculos de textura fueron obtenidos en GRASS GIS 7.0 (GRASS Development Team, 2015).

En este estudio se midió la heterogeneidad ambiental utilizando métricas de textura en la imagen, definida como la cuantificación de la variabilidad de los valores de reflectancia de los píxeles y su arreglo espacial en un área determinada (Haralick *et al.*, 1973). Se calcularon siete medidas de primer orden y seis de segundo orden para las bandas roja, y borde rojo y ambos índices de vegetación utilizando el programa GRASS GIS 7.0 (GRASS Development Team, 2015) (**Ver ANEXO IV**). Las medidas de textura de primer orden fueron calculadas a partir de los valores originales de reflectancia de la imagen dentro de un tamaño de ventana determinado y no consideran las relaciones entre píxeles vecinos. Estas medidas incluyen: Mean (media), Range (rango), Variance (varianza), Entropy (entropía), Standard Deviation (desviación estándar), Sum Average (suma de la media), Difference Entropy (diferencia de la entropía) y Sum Variance (suma de varianza) (Haralick *et al.* 1973) (**Ver ANEXOS I y IV**).

Las medidas de textura se calculan utilizando tamaños de ventana impares (1 x 1 píxeles, 3 x 3 píxeles, 5 x 5 píxeles, etc.). En este estudio se utilizaron tamaños de ventana de 3 x 3 píxeles para las parcelas de 400 m² debido a que el píxel de RapidEye tiene una resolución de 5 m por lo que una medida de textura representaría un área de 225 m² (56.25% del área) lo cual es el área más cercana a 400 m² que se puede calcular por medio de textura, sin exceder el área total de la parcela. Bajo este mismo procedimiento para la parcela de 1000 m² se utilizó una ventana de 5 x 5 para abarcar un área de 625 m² (62.5% del área de la parcela). Las medidas de textura de segundo orden consideran las relaciones entre píxeles vecinos (Haralick *et al.*, 1973) y fueron calculadas con base en una matriz de coocurrencia (GLCM: Gray Level Cooccurrence Matrix). Las medidas de segundo orden calculadas fueron: Angular Second Moment (Uniformidad), Inverse Difference Moment (Homogeneidad), Contrast (Contraste), Correlation (Correlación) e Information Measures of Correlation. Estas medidas fueron calculadas a 0°, 45°, 90° y 135° y se calculó el promedio para obtener una única medida de textura espacialmente invariable (Haralick *et al.*, 1973).

2.2.4 Procesamiento de datos LiDAR

Se adquirieron datos LiDAR para los sitios de Kaxil Kiuc y Felipe Carrillo Puerto para agosto del 2012 y enero 2013 respectivamente. Los datos fueron tomados desde una aeronave Cessna T202 por medio de CartoData, un proveedor particular. Se utilizó un escáner RIEGL-QV-480 LiDAR equipado con un GPS/IMU NovAtel y una cámara RGB de

16-mpx. La aeronave fue operada a una altura promedio de 396.2 m sobre el nivel del terreno a 30° y la frecuencia de repetición de pulsos fue de 200 kHz, para lo que el aeronave mantuvo una velocidad promedio de entre 80 y 90 kph. Los vuelos tienen una sobreposición de aproximadamente el 50% entre líneas de vuelo adyacentes. Incluyen más de 5 pulsos por metro cuadrado y 5 retornos por cada pulso (Hernández-Stefanoni *et al.*, 2014).

Los datos LiDAR fueron procesados utilizando el software del Servicio Forestal USFS FUSION software version 3.5 (McGaughey, 2015). Las nubes de puntos fueron cortadas para un área de 400 y 1000 m² alrededor de las coordenadas X y Y que corresponden a la coordenada GPS del punto central de la parcela para cada una de las 20 parcelas de Kaxil Kiuic y 28 parcelas de Felipe Carrillo Puerto. Los datos fueron normalizados a la superficie del terreno antes de cortarse con el objetivo de obtener las alturas de los árboles en lugar de la altura sobre el nivel del mar. Se calcularon un total de 61 métricas de las nubes de puntos resultantes.

Las métricas pertenecen a dos categorías, la primera categoría son métricas basadas en estadísticos de altura, incluyendo elevación media, mínima y máxima, variabilidad de las alturas de los retornos (Variance coefficient of variation) y percentiles estadísticos 1,5...10 y L-moments, entre otras. La segunda categoría fue utilizada para estimar cobertura vegetal e incluye un grupo de métricas de densidad del dosel que se estiman de acuerdo a la proporción de retornos por encima de una altura definida (Hernández-Stefanoni *et al.*, 2014). Se utilizó un umbral de 1.5 m como altura mínima sobre el suelo para reducir el ruido de las nubes de retornos cercanos al suelo ocasionados por vegetación baja e imperfecciones del suelo y un umbral del dosel de 4 m para calcular las métricas de cobertura (Hernández-Stefanoni *et al.*, 2014). Las métricas de LiDAR fueron utilizadas como variables predictoras en los modelos de riqueza de especies e índice de Shannon.

2.2.5 Análisis de datos

Se realizó un análisis de componentes principales (PCA) con las variables independientes (44 variables de textura de primer y segundo orden obtenidas de la banda roja, el borde rojo, NDVI y EVI y 61 métricas de LiDAR que corresponden a estadísticas de alturas y coberturas) por separado, con el fin de construir variables ortogonales y así reducir la cantidad de variables para ajustar los modelos. De acuerdo al criterio *Kaiser-Guttman* se eligieron los componentes cuyos *eigenvalues* superan la media para cada grupo de

variables independientes por separado y para cada tamaño de parcela (Legendre y Legendre, 2008). Se eligieron 5 componentes de las medidas textura y 6 para LiDAR en el sitio de Kaxil Kiuc y 6 componentes tanto para textura como para LiDAR en el sitio de Felipe Carrillo Puerto para las parcelas de 1000 m². Para las parcelas de 400 m² se eligieron 5 componentes para riqueza y 3 para LiDAR en Kaxil Kiuc y 6 componentes tanto para riqueza como para LiDAR en Felipe Carrillo Puerto. Una vez elegidos los componentes, el procedimiento se realizó de la siguiente manera: primero se ajustó un modelo de regresión múltiple entre las variables dependientes (valores de Riqueza y Shannon por separado) con las variables independientes (PCs obtenidos de las medidas de textura) para 400 y 1000 m². Dado que los PCs obtenidos representan la variación entre las medidas de textura de las parcelas, estos modelos representan la variabilidad de la heterogeneidad del hábitat. Después, se ajustó un modelo de regresión múltiple entre las variables de respuesta (PCs obtenidos de las métricas de LiDAR) para 400 y 1000 m² por separado para obtener la variabilidad explicada por la estructura de la vegetación. Se probó posteriormente la multicolinealidad y normalidad de residuales entre variables explicativas para seleccionar las variables que presentaron poca o nula correlación, expresado por un factor de inflación de varianza (VIF) menor a 2.0 en todos los casos. La evaluación del mejor tamaño se llevó a cabo comparando el ajuste del modelo obtenido con parcelas de 400 m² y el modelo obtenido con parcelas de 1000 m². Adicionalmente, se realizó un análisis de validación cruzada con el objetivo de conocer la capacidad que tiene el modelo de predecir la variable dependiente utilizando un set independiente de datos. En el análisis de validación cruzada, una observación fue removida temporalmente de la estimación y se calculó el modelo nuevamente. Esta acción fue repetida por todos los valores que tenga la variable dependiente hasta obtener un valor estimado o predicho por cada valor observado. Posteriormente se ajustó una regresión lineal simple entre los valores observados y predichos y con esto se obtuvo el ajuste de la validación cruzada del modelo. Igualmente para evaluar la precisión del modelo, se calculó la raíz cuadrada del error cuadrático medio o RMSE (Root Mean Square Error) el cual es una medida de dispersión entre valores observados y predichos y se calculó mediante la siguiente fórmula:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_{obs,i} - X_{model,i})^2}{n}}$$

Donde X_{obs} representa los valores observados y X_{model} representa los valores predichos de riqueza de especies e índice de diversidad de Shannon.

La autocorrelación espacial es un factor que igualmente debe ser tomado en cuenta en los análisis de variables que se distribuyen en el espacio. En esencia, la autocorrelación nos puede definir a qué grado la ocurrencia de un evento en el espacio determina la ocurrencia de otro evento en un área cercana (Ackerman, 2010). Dado que el efecto espacial se encuentra estrechamente ligado con las variables ambientales, patrones de atributos como la riqueza de especies pueden verse afectadas por la autocorrelación espacial. Con el fin de saber si todos los supuestos de la regresión se han cumplido, en este estudio se probó la autocorrelación espacial en los residuales de los modelos mediante la prueba de Moran's I para probar su independencia. No se encontró correlación para riqueza ni para la diversidad de especies en ningún tamaño (**Ver ANEXO III**). Todos los análisis: PCA, regresión múltiple, pruebas de multicolinealidad, validación cruzada y autocorrelación espacial fueron realizados en **R 2.4.1** (R Development Core Team, 2015).

2.3 RESULTADOS

Se encontró un total de 1705 individuos pertenecientes a 83 especies en el área muestreada en el sitio de Kaxil Kiuic con una riqueza media de 20 (± 0.92) especies. En Felipe Carrillo Puerto se encontró un total de 1834 individuos pertenecientes a 106 especies con una riqueza media de 29 (± 1.22) especies. Igualmente, se encontró una mayor diversidad en el sitio de bosque tropical subperennifolio de Felipe Carrillo Puerto ($H' = 2.81$) que en el bosque subcaducifolio de Kaxil Kiuic ($H' = 2.52$).

Se presenta una tabla resumen de los modelos para mostrar la diferencia conforme al tamaño de parcela.

Cuadro 2.1 Resumen del ajuste de los modelos de riqueza y diversidad con textura y métricas de LiDAR en Kaxil Kiuic (Ver Apéndice III para los modelos en detalle).

Sitio	Área de parcela (m ²)	Variables Independientes	Variable Dependiente	R ²	R ² Validación	RMSE	
Kaxil Kiuic	1000	PCs Textura	Riqueza	0.479	0.355	4.123	
			Shannon	0.576	0.253	0.252	
	400	PCs LiDAR	Riqueza	0.441	0.215	4.877	
			Shannon	0.463	0.455	0.274	
	Kaxil Kiuic	1000	PCs Textura	Riqueza	0.350	0.310	3.270
				Shannon	0.380	0.240	0.250
400		PCs LiDAR	Riqueza	0.275	0.107	3.828	
			Shannon	0.487	0.286	0.248	

Cuadro 2.1 R²: Coeficiente de determinación del modelo, **R² Validación:** Coeficiente de determinación obtenido en la validación cruzada, **RMSE:** (Root Mean Square Error) raíz del error medio cuadrático.

Cuadro 2.2 Resumen del ajuste de los modelos de variables de textura y métricas de LiDAR en Felipe Carrillo Puerto.

Sitio	Área de parcela (m ²)	Variables Independientes	Variable Dependiente	R ²	R ² Validación	RMSE	
FCP	1000	PCs Textura	Riqueza	0.582	0.339	4.610	
			Shannon	0.606	0.294	0.263	
	400	PCs LiDAR	Riqueza	0.486	0.126	6.601	
			Shannon	0.432	0.047	0.507	
	FCP	1000	PCs Textura	Riqueza	0.371	0.080	5.664
				Shannon	0.447	0.164	0.290
400		PCs LiDAR	Riqueza	0.479	0.375	8.289	
			Shannon	0.462	0.101	0.489	

Cuadro 2.2. R²: Coeficiente de determinación del modelo, **R² Validación:** Coeficiente de determinación obtenido en la validación cruzada, **RMSE:** (Root Mean Square Error) raíz del error medio cuadrático.

Los modelos de textura predijeron mejor la riqueza y diversidad calculada para parcelas 1000 que para 400 m² en ambos sitios (**Cuadro 2.1 y 2.2**). Este patrón se repitió igualmente al utilizar las métricas de LiDAR, sin embargo no existe una evidencia clara de que el tamaño tuviese una influencia en las estimaciones de diversidad (**Cuadro 2.1 y 2.2**). En general, los modelos ajustaron mejor al utilizar el índice de Shannon como variable dependiente que la riqueza.

Los resultados presentan tres medidas para evaluar el ajuste y la precisión. El análisis de validación cruzada (**R² Validación: Cuadro 2.1 y 2.2**) muestra el ajuste entre los valores observados y predichos de riqueza y diversidad. Al igual que el ajuste (R^2) Este análisis muestra igualmente que el modelo de textura predice mejor los valores de riqueza y diversidad en las parcelas de 1000 m² que en las parcelas de 400 m². El RMSE indica que los modelos más precisos de riqueza y diversidad son de parcelas de 1000 m² tanto de textura como de LiDAR ya que presentan un menor error que los modelos de 400 m² en el sitio de Felipe Carrillo Puerto (**Cuadro 2.2**). Sin embargo este patrón no se observó en el sitio de Kaxil Kiuic (**Cuadro 2.1**).

2.4 DISCUSIÓN

La evaluación del tamaño de parcela es importante para obtener estimaciones más precisas de riqueza y diversidad de especies y por lo tanto maximizar tiempo, esfuerzo y recursos al plantear estudios de conservación (Kenkel y Podani, 1991; Borman 1953). Los resultados obtenidos en este trabajo indican que el tamaño de parcela tiene una influencia sobre el ajuste y la precisión de las estimaciones de riqueza y diversidad de especies, sin embargo, la magnitud de la diferencia en el ajuste puede variar de acuerdo al tipo de variables tanto dependientes como independientes.

En este estudio se encontró un mejor ajuste en los modelos de textura tanto para riqueza como para diversidad en 1000 m² en ambos sitios (**Cuadro 2.1 y 2.2**). Sin embargo, existen algunas diferencias entre los dos sitios. En el sitio de Felipe Carrillo Puerto existe un mejor ajuste y una disminución en el error en los modelos de 1000 m² tanto en los modelos de textura como en LiDAR. Sin embargo, en el sitio de Kaxil Kiuic, la validación cruzada de los modelos de textura indica que no existe una clara diferencia en el ajuste de las estimaciones de diversidad. Igualmente, el error del modelo no disminuye para el modelo ajustado a 1000 m². Es importante señalar que los modelos de parcelas de 1000 m² utilizan ventanas más grandes (5 x 5 píxeles) en comparación con los modelos de parcelas de 400 m² (3 x 3 píxeles), por lo que incluyen una mayor cantidad de píxeles en la estimación. Asimismo, es importante señalar que el área representada por una ventana de 3 x 3 píxeles corresponde a una representación del 56.25% del área de la parcela de 400 m² mientras que una ventana de 5 x 5 píxeles corresponde a un 62.5% del área total de la parcela de 1000 m², por lo cual existe una mayor representación del área mediante la ventana de 5 x 5 m y esto podría tener un efecto positivo en el ajuste global del modelo. Esto concuerda con el trabajo realizado por Palmer *et al.* (2002; 2000) en estimación de diversidad por medio de sensores remotos, donde se encontró que a mayor área captada por el sensor (mayor cantidad de píxeles) es posible captar la heterogeneidad de una mejor manera y obtener mayor ajuste en las estimaciones. De la misma manera, Kenkel y Podani (1991) encontraron que el ajuste y la precisión en las estimaciones de riqueza de especies aumenta conforme aumenta el tamaño de parcela.

Por otra parte, al evaluar la validación cruzada de los modelos, no se encontró una mejora en el ajuste de los modelos de LiDAR para todos los casos. Esto concuerda con lo reportado por Hernández-Stefanoni *et al.*, (2014) dónde se encontró que las estimaciones

de riqueza de especies no presentan una mejora al incrementar el tamaño de parcela de 400 a 1000 m² utilizando datos LiDAR, sin embargo, el incremento del número de parcelas produce una mejor estimación. Lo reportado por Hernández-Stefanoni *et al.*, (2014) sugiere que mientras que el tamaño de parcela no tiene un efecto en la estimación, la inclusión de un mayor número de parcelas puede traducirse en una mayor representación de la heterogeneidad ambiental local y por ende una mejor asociación con la diversidad de especies. En este mismo sentido, varios estudios han reportado una asociación entre la heterogeneidad y la riqueza de especies (Rocchini *et al.*, 2007; Levin *et al.* 2007; Gillespie, 2005; Palmer *et al.*, 2002; 2000). En este estudio se utilizó la textura en la imagen RapidEye como sustituto de la heterogeneidad ambiental y se encontró que los modelos de textura obtienen un mejor ajuste para estimar tanto riqueza de especies como el índice de diversidad de Shannon y que el tamaño de la parcela tiene una influencia sobre el ajuste final del modelo. Esto concuerda con estudios que sugieren que la mayor inclusión de la heterogeneidad local resultará en una mayor precisión en las estimaciones de la riqueza de especies (Kenkel y Podani, 1991).

Sin embargo, es importante señalar que existen otros factores que pueden ser evaluados con el objetivo de mejorar el ajuste en la estimación. Por ejemplo: la forma de las parcelas. En este estudio se utilizaron parcelas circulares, que tienen una mejor relación perímetro-área y reducen el efecto de borde. Sin embargo, otros estudios indican que parcelas de forma rectangular tienen la capacidad de captar mayores diferencias en el terreno (topografía, caminos, parches de diferente tipo de vegetación), y por lo tanto, podrían mejorar las estimaciones de diversidad (Oldeland *et al.*, 2010; Borman, 1953). Aunque en este estudio se demuestra el potencial de mejorar las estimaciones utilizando tamaños de parcela más grandes, una cuidadosa selección del tamaño y la forma adecuados podría ser la clave para estudios futuros de diversidad de especies. Es importante señalar que aunque en gran medida se recomienda utilizar los tamaños de parcela más grandes que las restricciones de tiempo y logística permitan (Kenkel y Podani 1991), al incluir otros parámetros como el número de parcelas o la forma, es posible aumentar la eficiencia y ahorrar tanto en tiempo como en recursos.

2.5 CONCLUSIÓN

La evaluación de diferentes tamaños de parcela es un factor importante para estudios de estimación de riqueza y diversidad de especies. El incremento del tamaño de parcela puede ser un factor importante para la mejora de las estimaciones de riqueza y diversidad, sin embargo, es importante analizar la dependencia de otros factores asociados al estudio. Este estudio encuentra que el incremento de un tamaño de parcela produce una mejor estimación utilizando medidas de textura de la imagen como predictores y el índice de Shannon como medida de diversidad. Esto es debido a que un incremento en el área de la parcela produce una mejor representación de la heterogeneidad ambiental, que presenta una fuerte asociación con la diversidad de especies (Palmer *et al.*, 2000; 2002). Las estimaciones de modelos que utilizan métricas LiDAR no presentan un aumento en el ajuste total al incrementar el tamaño de parcela. Sin embargo, para estudios futuros la inclusión de un mayor número de parcelas y el análisis de diferentes formas de parcelas podrían resultar de gran importancia para obtener estimaciones más precisas de la riqueza y diversidad de los bosques secos.

CAPÍTULO III. MODELLING SPECIES DIVERSITY OF TROPICAL DRY FOREST COMBINING HIGH RESOLUTION SATELLITE IMAGERY AND LIDAR DATA.

3.1 INTRODUCTION

Secondary forests, forests regenerating naturally after a disturbance, represent over half of the world's tropical forests (FAO, 2010). Many inhabitants of tropical forest areas depend exclusively on the resources obtained from these forests (Quesada *et al.*, 2009). Therefore, accurate information on the diversity, structure and composition of tropical secondary forest communities is needed in order to ensure effective conservation policies that preserve these forests (Turner *et al.*, 2003; Nagendra, 2001). Ecological studies have estimated plant diversity through information obtained from field surveys or inventories. However, sufficient information cannot always be obtained exclusively by these means, due to time, logistical and/or monetary constraints (Nagendra, 2001). Remote sensing can be a viable source of information to assess plant diversity because it gathers information over large areas, at regular time intervals, and it is generally less expensive (Gillespie *et al.*, 2008; Turner *et al.*, 2003; Nagendra, 2001).

One of the challenges in using remote sensing to estimate diversity is coming up with a measure of species diversity that can be adequately estimated through remote sensing and also interpreted ecologically. The most common measure of diversity used in ecological studies is species richness (*i.e.* the number of species present in a given location *sensu* Magurran, 2004). However, this diversity measure is insensitive to species frequencies or abundances. Thus, it disproportionately favors rare species (Jost, 2006), providing little information about the dominance of the community. Shannon's Diversity Index, on the other hand, incorporates not only information of the number of species present, but also their relative abundances in one single number. In this manner, the index provides more information on the distribution of the relative abundances (Oldeland *et al.*, 2010) without favoring either rare or common species (Jost, 2006). Consequently, the use of Shannon's diversity index is encouraged amongst ecologists not only because of the comparability of the results with other studies but also because it makes more ecological sense (Jost, 2006). In tropical forests it has been previously tested as a way to incorporate both species richness and abundance data, with positive results on the estimation of plant diversity coupled with remote sensing techniques (Oldeland *et al.*, 2010; Foody & Cutler, 2003).

A common approach to estimate species richness and diversity through remotely sensed data is to use parameters or indicators obtained from the imagery as surrogates of factors that are commonly associated with the distribution of species diversity (Nagendra, 2001). According to the SVH, heterogeneity of reflectance values in a satellite image might characterize different habitats at a site and, thus, the different niches in which multiple species can exist (*Spectral Variation Hypothesis*: Palmer *et al.* 2000; 2002). Meanwhile, LiDAR obtains precise 3D information on vegetation structure including height, tree cover, basal area, and stem density (Næsset & Okland, 2002). These variables are associated to stand age, which has been found to be positively related to species richness (Dupuy *et al.*, 2012). Surrogate indicators of forest structure obtained with LiDAR have proven to be good predictors species richness and diversity (Hernández-Stefanoni *et al.*, 2014; Simonson *et al.*, 2013; Leutner *et al.*, 2012). Therefore, the inclusion of structural vegetation attributes may enhance the accuracy of predicting diversity compared to texture, alone. However, few studies have combined texture measures and LiDAR data in order to assess species richness or other vegetation attributes. These, have mainly focused on structural variables such as biomass (Lu *et al.*, 2012), tree height and crown diameter (Falkowski *et al.*, 2006). Therefore the potential of combining these two different sources of data to predict species richness and diversity remains unexplored.

This study aims to test the relative contribution of both habitat heterogeneity obtained through spatial heterogeneity of satellite image data and vegetation structure, using height and cover metrics obtained from LiDAR data, in explaining variation in species richness and diversity. While we expect that both, species richness and diversity will be most correlated with habitat heterogeneity through image texture (Palmer *et al.*, 2002, 2000), our goal is to test whether LiDAR metrics can improve prediction and /or make a substantial contribution to the estimates of plant diversity in tropical dry forests. Another objective in this study is to test whether remotely sensed data more accurately and precisely predicts species diversity (*i.e.* Shannon index) compared to species richness for TDF.

3.2 STUDY AREA AND METHODS

3.2.1 Study area

This study was conducted in two different types of Tropical Dry Forests (TDF) in the

Yucatan Peninsula, Mexico. The first site is located in Kaxil Kiuic Biocultural Preserve, a private reserve located south of the city of Merida (20°04' N – 89°32' W). At this site there is some variation in the elevation, ranging from 60 to 180 m, as well as topography, which consists of Cenozoic limestone hills with a moderate slope (10° – 25°) alternating with flat areas (Hernandez-Stefanoni *et al.*, 2014). Mean annual temperature is 26 °C and rainfall occurs during the wet season (typically from May to October) and ranges between 1000 and 1100 mm. The landscape is dominated by seasonally dry semi-deciduous tropical forests (50 – 75% of species drop their leaves during the dry season) (Miranda & Hernández, 1963). The forest was previously subjected to slash and burn agriculture, with different times of abandonment, forming a mosaic of different successional ages. The resulting structure is a low canopy (8 – 15 m) with a few taller patches (15 – 18 m) corresponding to the oldest stands (60 years old or older). The most abundant species are *Neumillspaughia emarginata* (H. Gross) S.F. Blake, *Gymnopodium floribundum* Rolfe., *Bursera simaruba* (L.) Sarg., *Piscidia piscipula* (L.) Sarg. and *Lysiloma latisiliquum* (L.) Benth. (Hernández-Stefanoni *et al.*, 2014). The second site, Felipe Carrillo Puerto (FCP), is located in communal land in the state of Quintana Roo (18°53' N - 88°14' W). This site consists mainly of a seasonally dry semi-evergreen TDF (25 – 50% of the species drop their leaves during the dry season) (Miranda & Hernández, 1963). The forest is structurally more complex than the Kiuic site, with two or three canopy layers, and with a higher canopy stature (25 m). The topography is fairly flat, mean annual temperature is 26 °C, average annual rainfall ranges between 1000 and 1300 mm and occurs primarily from June to October. The general landscape consists of a mosaic of open fields and vegetation in different successional ages due to abandonment after slash and burn agriculture practices (Yépez *et al.*, 2016). The most abundant species are *Manilkara zapota* (L.) P. Royen, *Vitex gaumeri* Greenm., *Bursera simaruba* (L.) Sarg., *Metopium brownei* (Jacq.) Urb., and *Cecropia obtusifolia* Bertol. (Hernández-Stefanoni *et al.*, 2014).

3.2.2 Field data

We acquired field data from a survey conducted from November to March 2013 in an area of 9 km² in both study sites. At Kaxil Kiuic, 20 sampling units were placed in a stratified systematic arrangement around an eddy covariance flux tower. At FCP, 28 evenly spaced sampling units were placed on a fixed grid. Each sampling unit consisted of three concentric circular plots. The first subplot was 80 m² (5.04 m radius), the second subplot was 400 m² (11.28 m radius), and the last plot had 1000 m² (17.84 m radius). The center

locations for all plots were recorded with a GPS (≤ 3 m error). At each sampling unit, all woody plants > 2.5 cm DBH (Diameter Breast Height) of 1.30 m were sampled in the smallest subplot (80 m²), in the 400 m² plot all plants > 7.5 cm, and in 1000 m² plot all species > 20 cm in DBH were sampled. In all cases, the plants were measured at DBH of 1.30 m, identified to species level and the number of individuals for each species was recorded along with the estimated tree height and number of stems of each individual (Hernández-Stefanoni *et al.*, 2014). Both species richness and Shannon's Diversity Index were calculated for all woody plant species > 2.5 cm DBH in the whole sampling unit (1000 m²).

3.2.3 Remotely sensed data and imagery processing

We acquired two scenes of RapidEye satellite imagery with spatial resolution of 5 m during the months of May of 2012 for FCP site and March of 2012 for Kaxil Kiuic site. The imagery was previously radiometrically and atmospherically corrected. We identified and extracted the values of the pixels contained in the 48 sampling plots (20 in Kaxil Kiuic and 28 in Felipe Carrillo Puerto) of two bands, corresponding to the Red (630-685 nm) and Red Edge band (690-730 nm). These bands were selected because the Red band, Near Infrared and/or Middle infrared bands have been previously recommended for vegetation analysis and for discriminating species assemblages and have been found to have the strongest association between plant species richness and spectral reflectance (Nagendra, 2001). However, in our study we include the use of the Red Edge, instead of the Near Infrared because the Red Edge is located between the Red and Near Infrared without overlapping, thus covering the portion of the spectrum where reflectance increases from the red portion to the Near Infrared without losing information (Weichelt *et al.*, 2012).

The "Red Edge NDVI" was calculated from RapidEye images and extracted according to the following formula:

$$\text{Red Edge NDVI} = (\text{Red edge} - \text{Red band}) / (\text{Red edge} + \text{Red band})$$

We also calculated and extracted the Enhanced Vegetation Index (EVI). This index does not saturate under dense canopy conditions and is supposed to be more sensitive to

structural characteristics of vegetation (Gao *et al.* 2000). EVI was calculated with the following formula:

$$\text{EVI} = G \left(\frac{\text{Red edge} - \text{Red band}}{\text{Red edge} + C_1 * \text{Red band} - C_2 * \text{Blue band} + L} \right).$$

EVI includes constants $C_1=6$ and $C_2=7.5$, which are coefficients of the aerosol resistance term and the Blue band (440 – 510 nm) for atmospheric correction. It also incorporates L, the sensitivity minimization of soil background reflectance variation and a gain factor ($G=2.5$) to minimize the difference between EVI and EVI 2, the two band EVI (Jiang *et al.*, 2008; Huete *et al.*, 2002; Gao *et al.*, 2000). These procedures were performed with GRASS GIS 7.0 (GRASS Development Team, 2015). Habitat heterogeneity has commonly been used as a potential predictor of species diversity. The argument is that a greater spatial heterogeneity reflects a mosaic of biotic and environmental features that are able to capture a wider variety of niches and consequently a greater number of species (Rocchini *et al.*, 2010; Palmer *et al.*, 2002; Nekola & White, 1999). Here we measured spatial heterogeneity by using texture metrics as a surrogate. Textural features are defined as the quantification of the variability in the reflectance values of neighboring pixels and its spatial arrangement in a given area (Haralick *et al.*, 1973). Seven first-order and six second order textural measures were calculated for both bands and vegetation indices using GRASS GIS 7.0 (GRASS Development Team, 2015) (**Appendix I and IV**). First-order textural measures are calculated from original values obtained directly from the image within a certain window size and do not consider neighboring pixel relationships whereas second-order textural measures are calculated based on a grey level co-occurrence matrix (also called a Gray Tone Spatial Dependency Matrix) and consider relationships between neighboring pixels (Haralick *et al.*, 1973). Here we used a window size of 5 x 5 pixels because RapidEye images have a spatial resolution of 5 m hence a window size of 5 would account for 625 m², the closest we can get to the total area of the plot without exceeding 1000 m². These measures were calculated at 0, 45, 90 and 135 degrees and the average value of the four directions was calculated to obtain a single spatially invariant texture value (Haralick *et al.*, 1973).

3.2.4 LiDAR data processing

We acquired LiDAR data in August 2012 (Kaxil Kiuic) and January 2013 (FCP). Data acquisition was done from a private contractor, CartoData, using an airborne laser scanner, RIEGL-QV-480 LiDAR, equipped with a NovAtel GPS/IMU and a 16-mpx RGB nadir looking camera mounted on a Cessna T202 aircraft. The aircraft was operated at an average height of 396.2 m above ground level, with a 30° field of view and a pulse repetition of frequency of 200 kHz, for which the aircraft maintained a ground speed between 80 and 90 kph. Adjacent flight lines had a 50% overlap, which averaged more than 5 pulses per square meter and included 5 returns for each pulse (Hernández-Stefanoni *et al.* 2014).

LiDAR data were processed using USFS FUSION software version 3.50 (McGaughey, 2015). Clouds of points were clipped for an area of 1000 m² around the X and Y coordinates in order to correspond with the center of the sampling plot area. Data were normalized to the ground surface before the clipping in order to express the heights of trees above the ground instead of the elevation above sea level. A total of 61 LiDAR metrics were calculated from the resulting cloud of points within each of the 1000 m² plots.

We used LiDAR metrics as predictor variables in the models to estimate species richness and diversity. The metrics belong to two categories, the first are based on height statistics including mean, minimum and maximum elevation, variability of return heights (variance and coefficient of variation), statistics of percentiles 1, 5, 10, ...100 and L-moments among others. The second category was used to estimate vegetation cover and included a set of canopy density metrics. Since ground returns can be affected by low vegetation and ground imperfections it is useful to filter the height above ground for which we chose a threshold of 1.5 m as a minimum to reduce the noise within the near-ground cloud of returns. Then, we chose a canopy threshold of 4.0 m in order to calculate LiDAR canopy cover metrics (Hernández-Stefanoni *et al.*, 2014).

3.2.5 Data analysis

We used a Principal Component Analysis to reduce the dimensionality of our dataset and construct rotated orthogonal variables or principal components (PCs) from texture and LiDAR metrics using “varimax” rotation. Afterward, we used multiple regression to quantify the effects of spatial heterogeneity (from PCs obtained from first and second order texture

metrics derived from red, red edge band, NDVI and EVI), and vegetation structure (from PCs obtained from LiDAR metrics that correspond to height statistics and canopy density metrics) in explaining species richness and Shannon's diversity index. The general procedure involved the following steps. First, we obtained the PCs from texture and LiDAR metrics and according to the *Kaiser-Guttman* criterion we selected the PCs whose eigenvalues were above the mean for each group of variables (Legendre & Legendre, 2012). Then we fit a multiple regression model between richness and Shannon's Index separately and used the same PCs obtained from texture for each site. These models represent the variability explained by habitat heterogeneity (a + b). Where (a) represents variation assigned exclusively to habitat heterogeneity (texture measurements) and (b) corresponds to shared variation (variation explained by both, texture measurements and LiDAR metrics). Then, we fit a multiple regression model between response variables and vegetation structure PCs obtained from LiDAR metrics (b + c). In the same manner, (c) corresponds to variation explained exclusively by vegetation structure and (b) corresponds to shared variation. Finally, a combined model was selected using the best of both satellite imagery and LiDAR data models. These models explain the total amount of variation in species richness and diversity (a + b + c). We assessed multicollinearity between predictor variables by Variance Inflation Factor, which was less than 2.0 in all cases.

We assessed model performance using leave-one-out cross validation. In this procedure, one observation is temporally removed from the data set, and the remaining observations are used to construct the regression model that predicts the held-out observation. The cross validation yields estimated values of species richness and diversity that can be compared to the observed values. We ranked the different models by the R^2 obtained from a simple regression between observed and estimated values of species richness and diversity. We calculated root mean squared error in order to assess discrepancy between our observed and predicted values of species richness and Shannon's Index and thus evaluate the precision of the model.

Since one of the main goals of this study was to assess the importance of habitat heterogeneity measured through texture and vegetation structure through LiDAR metrics and to evaluate the contribution of each factor, we performed a variation partitioning analysis. To determine the relative importance of the different groups of variables, from the total variation explained by the combined model (a + b + c) we calculated habitat heterogeneity from variation explained by texture as $(a=(a + b + c)-(b + c))$, then,

vegetation structure, variation explained by LiDAR metrics, as $(c=(a + b + c) - (a + b))$ and shared variation (both texture and LiDAR metrics) as $(b=(a + b + c)-(a)-(c))$ (Borcard *et al.*, 2004). In this manner, we were able to obtain the contribution of both factors separately as well as the shared contribution between both.

3.3 RESULTS

3.3.1 Estimation of diversity from texture metrics.

A total of 1705 individuals belonging to 83 species were recorded in the 20 plots at the Kaxil Kiuic site. At the Felipe Carrillo Puerto site, a total of 1834 individuals belonging to 106 species were sampled in 28 sampling plots.

In general, texture models fit better diversity (*i.e.* Shannon's index) than species richness (**Table 1**). We found that species richness and diversity were both significantly and negatively related to PC1 which is represents a gradient from heterogeneous to homogeneous plots (See **Appendix II** for PCA scores and results). Also, species richness and diversity were and negatively to PC2 which represents the opposite gradient (from homogeneous to heterogeneous plots) (**Appendixes I and II**). In addition, at the FCP site Shannon's index showed a statistically significant positive relationship with PC6, mainly associated to heterogeneity measures (**Table 2**).

Table 1: Model results for multiple regressions relating species richness and Shannon's Index and PCs from texture variables in Kaxil Kiuic. Estimate: Parameters estimate, **SE:** Standard Error, **RMSE:** Root Mean Square Error.

Dependent Variable	Independent Variables	Estimate	SE	R ²	R ² Cross Validation	RMSE
Species Richness	Intercept***	20.300	0.775	0.479	0.355	4.123
	PC1.	-1.229	0.578			
	PC2*	1.292	0.578			
	PC3	0.375	0.578			
	PC4	0.977	0.578			
	PC5	0.128	0.578			
Shannon's Index	Intercept***	2.526	0.049	0.576	0.253	0.252
	PC1*	-0.132	0.036			
	PC2	0.060	0.036			
	PC3	0.020	0.036			
	PC4	0.053	0.036			
	PC5	0.029	0.036			

*** p<0.001, **p<0.01, *p<0.05

Table 2: Model results for multiple regressions relating species richness and Shannon's Index and PCs from texture variables in Felipe Carrillo Puerto. Estimate: Parameters estimate, **SE:** Standard Error, **RMSE:** Root Mean Square Error.

Dependent Variable	Independent Variables	Estimate	SE	R ²	R ² Cross Validation	RMSE
Species Richness	Intercept***	27.643	0.782			
	PC1	1.019	0.796			
	PC2*	-2.054	0.796			
	PC3.	-1.558	0.796	0.582	0.338	4.610
	PC4	0.559	0.796			
	PC5	0.491	0.796			
Shannon's Index	Intercept***	2.812	0.042			
	PC1	0.021	0.042			
	PC2.	-0.083	0.042			
	PC3.	-0.080	0.042	0.606	0.294	0.263
	PC4.	0.084	0.042			
	PC5	-0.007	0.042			
	PC6***	0.193	0.042			

*** p<0.001, **p<0.01, *p<0.05

3.3.2 Estimation of diversity from LiDAR metrics.

At both sites, multiple regression analysis showed species richness is positively associated with height metrics (contained in PC4 in Kiuic, PCs 1 and 5 in FCP) while diversity showed a negative relationship with cover metrics (PC6) in Kiuic and a positive relationship in FCP. Similar to the results from texture models, models fitting species diversity showed a higher R² than models fitting species richness. However, in general, models using PC axes from LiDAR metrics obtained a lower fit than models using texture PCs.

Table 3: Model results for multiple regressions relating species richness and Shannon's Index and PCs obtained from LiDAR metrics in Kaxil Kiuic. Estimate: Parameters estimate, **SE:** Standard Error, **RMSE:** Root Mean Square Error.

Dependent Variable	Independent Variables	Estimate	SE	R ²	R ² Cross Validation	RMSE
Species Richness	Intercept***	20.300	0.832			
	PC1	0.948	0.854			
	PC2	0.615	0.854			
	PC3	-0.843	0.854	0.441	0.215	4.877
	PC4*	1.909	0.854			
	PC5	0.362	0.854			
	PC6	-1.312	0.854			
Shannon's Index	Intercept*	2.526	0.057			
	PC1	0.072	0.058			
	PC2	0.047	0.058			
	PC3	-0.065	0.058	0.463	0.455	0.274
	PC4	0.086	0.058			
	PC5	0.016	0.058			
	PC6*	-0.136	0.058			

*** p<0.001, **p<0.01, *p<0.05

Table 4: Model results for multiple regressions relating species richness and Shannon's Index and PCs containing LiDAR metrics in Felipe Carrillo Puerto. Estimate: Parameters estimate, **SE:** Standard Error, **RMSE:** Root Mean Square Error.

Dependent Variable	Independent Variables	Estimate	SE	R ²	R ² Cross Validation	RMSE
Species Richness	Intercept***	29.464	0.999			
	PC1*	0.929	1.017			
	PC2*	-0.482	1.017			
	PC3.	-1.758	1.017	0.486	0.126	6.601
	PC4	1.531	1.017			
	PC5**	-3.516	1.017			
	PC6	1.276	1.017			
Shannon's Index	Intercept***	2.815	0.075			
	PC1	-0.018	0.076			
	PC2.	0.016	0.076			
	PC3.	-0.134	0.076	0.432	0.047	0.507
	PC4.	0.042	0.076			
	PC5	-0.265	0.076			
	PC6***	0.052	0.076			

estimate, **SE:** Standard Error, **RMSE:** Root Mean Square Error.

*** p<0.001, **p<0.01, *p<0.05

3.3.3 Combined models

Using our texture and LiDAR models as stepping stones, we constructed a set of combined models in which we included only significant PCs from texture and LiDAR metrics. All three measures of fit (R^2 , Validation R^2 , and RMSE) show that the combined models more accurately and precisely predict variation in Shannon's Index than Richness (Tables 5 and 6).

Table 5: Combined model results for multiple regressions relating species richness and Shannon's Index and PCs from LiDAR metrics for the Kiuc site. Estimate: Parameters estimate, **SE:** Standard Error, **RMSE:** Root Mean Square Error.

Dependent Variable	Independent Variables	Estimate	SE	R^2	R^2 Cross Validation	RMSE
Richness	Intercept***	20.300	0.644	0.589	0.359	3.268
	PC1 Texture**	-1.500	0.488			
	PC2 Texture*	1.054	0.486			
	PC4 LiDAR**	2.053	0.680			
Shannon's Index	Intercept***	2.526	0.043	0.630	0.415	0.217
	PC1 Texture***	-0.147	0.032			
	PC2 Texture	0.046	0.032			
	PC4 LiDAR*	0.113	0.045			

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

Table 6. Combined model results for multiple regressions relating species richness and Shannon's Index and LiDAR metrics for the FCP site. Estimate: Parameters estimate, **SE:**

Dependent Variable	Independent Variables	Estimate	SE	R^2	R^2 Cross Validation	RMSE
Richness	Intercept	29.464	0.986	0.452	0.205	5.853
	PC3 Texture	-1.275	0.919			
	PC6 Texture	-1.270	0.863			
	PC3 LiDAR	-1.515	1.014			
	PC5 LiDAR	-2.448	1.159			
Shannon	Intercept	2.815	0.061	0.607	0.308	0.391
	PC4 Texture	-0.116	0.051			
	PC5 Texture	-0.084	0.051			
	PC6 Texture	-0.095	0.053			
	PC3 LiDAR	-0.121	0.062			
	PC5 LiDAR	-0.229	0.066			

Standard Error, **RMSE:** Root Mean Square Error.

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

3.3.7 Variation partitioning

In both sites, the majority of variation in both richness and diversity could be explained by the combination of texture and LiDAR metrics (**Figs 1, 2**). However, LiDAR metrics made little (Kaxil Kiuic) or no (FCP) independent contribution to species richness and diversity estimates (**Figs 1,2**). Meanwhile, texture independently explained 11 and 17% of the variation in richness and diversity in Kaxil Kiuic, whereas in FCP richness was explained totally by the combination of texture and LiDAR.

Fig. 1 Bar plots for variation partitioning Kaxil Kiuic site. Including Shared variation (dark green), Variation explained by Vegetation Structure (green), exclusively and variation explained by habitat heterogeneity variables exclusively (light green).

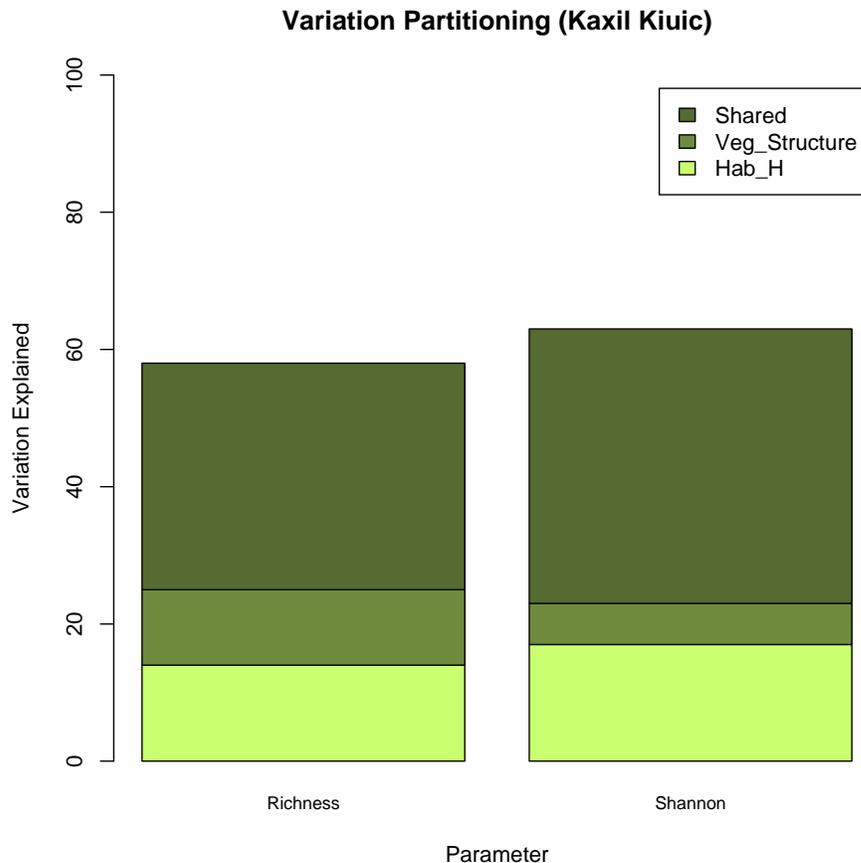
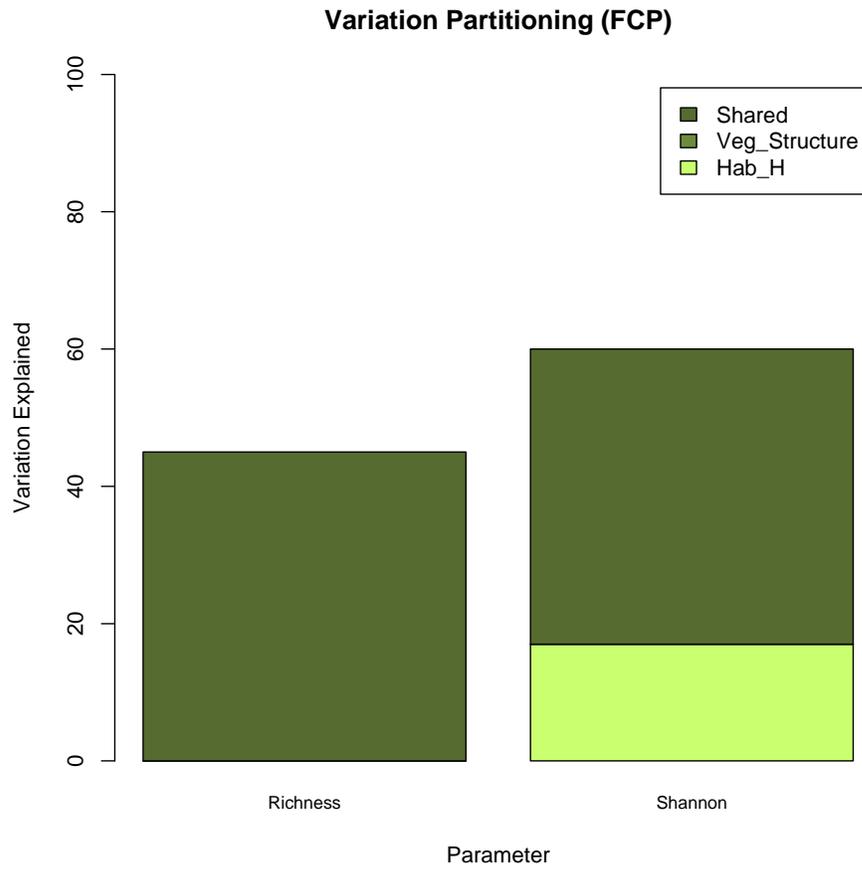


Fig. 2 Bar plots for results of variation partitioning for Felipe Carrillo Puerto site. Including Shared variation (dark green), Variation explained by Vegetation Structure (green), exclusively and variation explained by habitat heterogeneity variables exclusively (light green).



3.4 DISCUSSION

As expected, species richness and diversity were more strongly related to texture measures obtained from RapidEye imagery than LiDAR data. In the Kaxil Kiuic site, the principal components containing texture measures exclusively explained a higher percentage of the variation in species richness and of Shannon's diversity index compared to LiDAR components. In a similar way, at the FCP site, texture alone explained a high portion of the variation in diversity (though not for richness, which was explained only by the variation shared between texture and LiDAR metrics). These results suggest that by using texture information as a surrogate of habitat heterogeneity we are able to capture a range of environmental variation and thus explain a high proportion of variation in both, species richness and diversity. However, variation explained by vegetation structure, through LiDAR metrics, alone, is insufficient to justify the use of such an expensive technology in estimating species richness and diversity in these tropical dry forests. LiDAR has proven useful for assessing vegetation structure and biomass (Hernández-Stefanoni *et al.*, 2014; Li *et al.*, 2012; Lefsky *et al.*, 2002), however our results show that when using LiDAR metrics as surrogates for vegetation structure for the purpose of estimating diversity in combination with texture, most of the variation is, in fact, shared. Although texture has been previously used in most cases as a proxy of environmental heterogeneity in the estimation of species diversity, other studies have found that texture measures can also be related to vegetation structure (Wood *et al.*, 2012), which could partly explain why variation is mostly shared. However, in a practical sense we were able to explain a higher proportion of the variability of species richness and diversity by means texture measures alone.

Even though the potential for texture measures to be proxy for environmental heterogeneity has been widely explored (Hernández-Stefanoni *et al.*, 2012; Gallardo-Cruz *et al.*, 2012; St-Louis *et al.*, 2006; Oindo & Skidmore, 2002; Gaston, 2000), there is very little consensus on the type or direction of their relationship: positive or negative. In our case, the negative association with the principal component that includes texture measures such as Correlation, Inverse Difference Moment and Angular Second Moment or "Uniformity" and the positive association with the principal components mainly associated with heterogeneity (variance, Entropy or standard deviations) in our model suggest a positive relationship between species richness and spectral heterogeneity. Although negative relationships between species richness and spatial heterogeneity have

been previously found at local scale in several studies in TDF (Hernandez-Stefanoni *et al.*, 2012; 2011; Gallardo-Cruz *et al.*, 2012) and other vegetation types (Constanza *et al.*, 2010), the most common pattern regarding spatial heterogeneity and species diversity is expected to be a positive relationship based on the spectral variation hypothesis (SVH, Palmer *et al.*, 2012). This study agrees with the general hypothesis that habitat heterogeneity positively influences diversity (Foody & Cutler, 2006; St-Louis *et al.*, 2006; Palmer *et al.*, 2002; Gaston, 2000). This concurs with a wide range of studies, which have found a positive relationship across different environments (Gaston, 2000: tundra vegetation; Palmer *et al.*, 2002 and Kumar *et al.*, 2006: prairie vegetation; Oldeland *et al.*, 2010: savannas) and taxa (St-Louis *et al.*, 2006: birds; Oindo & Skidmore, 2002: mammals). And even for tree richness in other TDF around the world (Gillespie, 2005: Florida, USA: Rochinni *et al.*, 2009: India). The generality of this result highlights its importance and suggests that using remotely sensed surrogates of habitat heterogeneity is useful under a wide range of circumstances.

However it is important to keep in mind that the relationship may change when scales are reduced as unimodal or even negative relationships have been observed at different scales (Turner *et al.*, 2001; Constanza *et al.*, 2010). As it has been previously stated by Turner *et al.* (2013), the main challenge is to ensure that the scale of the imagery matches the scale of the species richness data and that both are scaled appropriately for the theory that is being tested. Therefore, one of the main issues, particularly with the use of passive sensors (*i.e.* satellite imagery) to assess diversity, is the difficulty in matching the size of the pixel and the size of the field plot (or sampling unit). In our case, as texture calculation involves a moving window analysis the complexity of the issue increases. However, the high resolution in our RapidEye images (5 m) permitted us to represent over 60% of our field plot area in the texture analysis.

As we expected, our results suggest that species richness and diversity are positively associated to the variation of overall tree height. The variation within the elevation of the upper canopy layer and the percentage of returns above a diversity of measures of height (mean, mode height and 4 m) showed a direct relationship with diversity, which also suggests that a greater complexity in the structure of vegetation, indicated by a greater difference in the heights of layers, is correlated to a greater species diversity. Principal components positively associated with metrics such as the percentage of returns above mode height as well as other cover metrics showed a positive relationship with species

richness and Shannon's index. This indicates that there is a direct relationship between the structure and height of the upper canopy layer (bigger crowns or denser canopy) and species richness and diversity.

Overall the R^2 values of the Kaxil Kiuc site were consistently higher compared to the FCP site ($R^2 = 0.58$ richness, 0.63 Shannon's Diversity Index in the Kaxil Kiuc Site and $R^2 = 0.45$ richness and 0.60 Shannon in the FCP site). There is considerable difference in the forest structure and land use history between the Kaxil Kiuc site, a semi-deciduous forest, and FCP site, a semi evergreen forest. The Kaxil Kiuc site is a protected area, where slash and burn agriculture was practiced and almost all of the plots are the same age, whereas FCP site has been intervened in different ways. A percentage of the land has been converted to pastures for cattle raising, but also slash and burn agriculture and wood extraction have also been practiced in the area (Hernandez-Stefanoni *et al.*, 2014). This could explain the slight difference in both the fit and accuracy of estimations between sites. Our remotely sensed data may have a discrepancy with our field data in FCP if either the images, or the field data, were acquired prior to an intervention or vice versa. In contrast, the site of Kaxil Kiuc is a protected natural reserve, where fragmentation processes promoted by these activities are less likely to increase variability in the observed or estimated richness and diversity and consequently the overall error of the estimations due to interventions or disturbance is likely to be reduced.

In general, in agreement with other studies (Gallardo-Cruz *et al.*, 2012; Oldeland *et al.*, 2010; Dogan & Dogan, 2006; Foody & Cutler, 2003), our models predicting diversity were more accurate and precise than those predicting species richness. This may be because Shannon's index may be less affected by rare species, which introduce greater variability in estimations as their abundances are not representative of the dominance structure of a community, in comparison to species richness (Jost, 2006). Since field surveys generally gather information on species abundances it could be used to aid diversity estimations by using remotely sensed data in a more efficient way.

3.5 CONCLUSION

In this study we found that by using texture metrics as a surrogate of habitat heterogeneity we were able to produce accurate estimations of species richness and, additionally, improve such estimations by using relative abundance data through Shannon's diversity index. Most of the studies relating diversity and remotely sensed data have focused on the relationship between productivity and species richness (Gillespie, 2005; Fairbanks & McGwire, 2004; Turner *et al.*, 2003; Oindo & Skidmore, 2002; Nagendra, 2001), however, we found that spectral variability through image texture can also be useful when analyzing complex ecological community attributes such as species diversity (Ludholm *et al.*, 2009; Palmer *et al.* 2002; 2000). When we incorporated LiDAR metrics we found little improvement over the model that only used texture metrics as independent variables. Given that most of the variation is shared between texture and LiDAR, texture can be used to produce estimations of diversity without losing valuable information. Although our combined model is in general, less biased, we conclude that image texture alone can be used for diversity assessment as a surrogate of habitat heterogeneity. Considering the simpler procedure to acquire and process satellite imagery as opposed to the more complicated processing and lower availability of LiDAR data, we suggest to explore image processing for diversity estimates in TDF. This procedure shows potential for producing efficient estimations of diversity and aid future conservation efforts in these forest landscapes

CAPÍTULO IV. DISCUSIÓN Y CONCLUSIONES GENERALES

4.1 DISCUSIÓN GENERAL

El objetivo de utilizar la percepción remota como complemento a la información de campo es obtener una mayor precisión en un menor tiempo y a un menor costo para obtener estimaciones de riqueza y diversidad, es decir, incrementar su eficiencia. Igualmente, es importante obtener estimaciones que puedan ser aplicadas a grandes áreas para ayudar a los esfuerzos de conservación, para lo que es importante evaluar su ajuste y precisión. La información de campo de riqueza y diversidad de especies es obtenida por medio de parcelas de estudio y es bien sabido que las estimaciones más precisas son obtenidas de parcelas más grandes (Kenkel y Podani, 1991; Borman, 1953). Sin embargo, el muestreo de parcelas grandes aumenta el esfuerzo, tiempo y costo de las estimaciones, por lo que es importante conocer el efecto que tiene el área de la parcela sobre el ajuste y la precisión en la estimación de riqueza y diversidad. En este trabajo el mayor ajuste y precisión en las estimaciones, tanto de riqueza como de diversidad, se encontró a partir de la textura en las parcelas más grandes (1000 m²). Existen diversas razones para pensar que un mayor tamaño de parcela implica una mejora en la precisión de la estimación. En primera instancia, la concordancia entre los datos obtenidos por los sensores remotos y los datos de campo, depende en gran medida de la precisión de las coordenadas obtenidas del GPS en campo, que por lo general, presentan un error asociado (< 10m). En el caso de las estimaciones por medio de métricas de LiDAR, el GPS del vehículo aerotransportado que toma los datos tiende a tener un menor error que el error del GPS utilizado en campo. Por lo que en parcelas más grandes existe una mayor probabilidad de sobre-posición de los datos obtenidos en campo con los datos obtenidos por el escáner de LiDAR (Chave *et al.*, 2004). Sin embargo, en concordancia con estudios previos (Hernández-Stefanoni *et al.*, 2014) el ajuste total en la estimación de riqueza con métricas de LiDAR no presenta una mejora drástica al incrementar el tamaño de la parcela.

En cuanto a las estimaciones por medio de la textura en la imagen, es importante considerar que el tamaño de la ventana y el tamaño de la parcela deben estar en concordancia para lograr una representación de la parcela de campo en las medidas de textura obtenidas. En este estudio, las ventanas más grandes no sólo incluyen una mayor cantidad de píxeles (5 x 5 vs. 3 x 3) si no que igualmente representan un mayor

porcentaje del área de la parcela de campo (62.5 % vs. 56.25%). En gran medida, otros estudios han encontrado igualmente que la inclusión de un mayor número de píxeles en la estimación conlleva a una mejor estimación debido a que una mayor inclusión de niveles de reflectancia permite obtener una representación más adecuada de la heterogeneidad de un sitio (Rochinni *et al.*, 2007; Palmer *et al.*, 2002).

En segunda instancia se probó la combinación de dos sensores (pasivos y activos) para estimar riqueza y diversidad de especies y evaluar su aporte individual y el aporte compartido en las estimaciones. La textura en la imagen RapidEye (obtenida de un sensor pasivo) se utilizó como un sustituto de la heterogeneidad ambiental, mientras que las métricas de LiDAR (sensor activo) se utilizaron como un sustituto de la estructura de la vegetación. Se encontró que la riqueza y diversidad de especies observadas en campo están estrechamente relacionadas con la información que proporcionan las medidas de textura obtenidas a partir la banda roja, el borde rojo o RedEdge, NDVI y EVI. Para ambos sitios, los componentes principales calculados a partir de las medidas de textura explicaron una mayor proporción de la variación de riqueza y diversidad de especies en el sitio de estudio. Las medidas de textura en la imagen reflejan la heterogeneidad u homogeneidad local (Haralick *et al.*, 1973) y han sido relacionadas directamente con la heterogeneidad ambiental (Palmer *et al.*, 2002; 2000). En este caso, la relación encontrada entre los componentes asociados a medidas de textura que reflejan la heterogeneidad de los valores espectrales de la imagen, es positiva; al aumentar métricas tales como varianza, entropía y desviación estándar, igualmente aumentan los valores de riqueza y diversidad de especies. Por esta razón, en general, los resultados sugieren una relación directa entre diversidad y heterogeneidad ambiental. Este estudio concuerda con lo propuesto por la SVH, donde la variación espacial (expresada por lo general en desviación estándar) de los valores de reflectancia de una imagen se encuentra directamente correlacionada con la heterogeneidad ambiental (Palmer *et al.*, 2002) y donde a mayor heterogeneidad ambiental existe también una mayor cantidad de nichos y por tanto un mayor número de especies. Sin embargo, resultados de otros trabajos han sugerido una relación negativa entre la heterogeneidad ambiental y la diversidad de especies a nivel local. (Hernández-Stefanoni *et al.*, 2011; Gallardo-Cruz *et al.*, 2012). Esto parece sugerir que la hipótesis de la relación positiva entre heterogeneidad ambiental y diversidad es visible a ciertas escalas.

En la estimación por medio de LiDAR, por otra parte la variación en las alturas y coberturas, así como en la altura total y la proporción de retornos a una cierta altura se relacionaron positivamente con la riqueza y diversidad en ambos sitios. Esto indica que existe una relación positiva entre la complejidad estructural (la variación entre las alturas y tamaños de copa) y la riqueza y diversidad, como se esperaba. Igualmente, se encontró una relación directa entre las alturas y la proporción de retornos por encima de cierta altura con la riqueza y diversidad, indicando que en parcelas con árboles más altos y copas más densas, existe también una mayor riqueza y diversidad. Esto concuerda en parte con estudios que han encontrado que en parcelas de mayor edad existe un mayor número de especies en BTS (Ruiz *et al.*, 2005; Dupuy *et al.*, 2012) debido a que también en las parcelas de mayor edad, por lo general, se espera encontrar árboles de mayor altura y copas más grandes. Sin embargo, las estimaciones de riqueza y diversidad por medio de LiDAR presentan un menor ajuste en comparación con las estimaciones por medio de medidas de textura. A pesar de esto, LiDAR ha probado ser uno de los mejores métodos para estimar otras variables de la estructura de la vegetación como área basal y biomasa y obtener estimaciones de los almacenes de carbono de los bosques (Asner *et al.*, 2011).

Un resultado importante, es que al combinar los dos factores (heterogeneidad ambiental y estructura de la vegetación) la mayor parte de la variación explicada es la variación compartida por ambos factores. Esto puede ser explicado en parte porque, aunque la mayoría de los estudios que utilizan la textura en las imágenes, la han utilizado como un sustituto de la heterogeneidad ambiental, otros estudios han encontrado que también puede utilizarse, al igual que las métricas de LiDAR, como un sustituto de la estructura de la vegetación (Wood *et al.*, 2012). Por lo cual, es posible que ambos factores expliquen la misma variación. Sin embargo, a grandes rasgos, este resultado sugiere que las medidas de textura como sustituto de la heterogeneidad ambiental son suficientes para explicar la variación de la riqueza y diversidad en los bosques de estudio por sí mismas, dado que LiDAR no hace un aporte sustancial a las estimaciones de diversidad (para ambos sitios) e incluso ningún aporte en el caso de riqueza en FCP.

Otro de los resultados más generales de este trabajo es que, en general, se obtuvieron mejores estimaciones en términos de ajuste y precisión, para la diversidad de especies en comparación con la riqueza de especies. Se encontró para ambos sitios en casi todos los casos a (excepción de la validación cruzada del modelo de LiDAR en FCP donde el valor

de la R^2 disminuye) lo cual indica que el considerar las abundancias relativas de las especies, por medio de un índice de diversidad, puede ser de ayuda para obtener mejores estimaciones de diversidad de especies en los BTS. En gran medida, los índices de diversidad que incorporan las abundancias relativas de las especies proporcionan más información sobre la comunidad y su dominancia (Oldeland *et al.*, 2012; Foody y Cutler *et al.*, 2003). Es posible que los sensores, sobre todo los sensores pasivos, capturen la mayoría de la información sobre las especies más abundantes en una comunidad, por lo que es posible que por esta razón se haya encontrado un mayor ajuste y precisión en los modelos del índice de Shannon con las medidas de textura. Dado que en general los estudios de campo obtienen información de las abundancias de las especies, es posible incorporar esta información de una manera relativamente sencilla a las estimaciones de diversidad por medio de índices de diversidad para realizar estimaciones precisas con la ayuda de la percepción remota.

4.2 CONCLUSIONES

En este estudio se analizaron factores que pueden jugar un papel importante para mejorar las estimaciones de la riqueza y diversidad de especies en BTS. En primera instancia se analizó el tamaño de parcela en estimaciones de riqueza y diversidad de especies por medio de la textura de imágenes de satélite y métricas de LiDAR, encontrando soporte para la teoría general que indica que en mayores tamaños de muestra (parcela) habrá una mejora en el ajuste de las estimaciones. Sin embargo, no se encontró un incremento en el ajuste en el modelo al incrementar el tamaño de la parcela de campo en el modelo utilizando métricas de LiDAR en todos los casos.

Igualmente, en este trabajo se analizó la importancia relativa de dos tipos de sensores para obtener estimaciones de diversidad de especies en BTS: los sensores pasivos como sustitutos de la heterogeneidad ambiental y los sensores activos como sustitutos de la estructura de la vegetación. Los resultados principales de este trabajo sugieren que la heterogeneidad espectral, obtenida de sensores pasivos, se asocia de una manera más fuerte a la diversidad de especies. Por lo tanto, se concluye que la textura de las imágenes, por sí misma, es una herramienta eficiente para realizar estimaciones de riqueza y diversidad en el BTS con sustento en la teoría ecológica. En este estudio se observó una relación directa entre las medidas de textura como sustitutos de la heterogeneidad ambiental, y la riqueza y diversidad observadas, lo cual concuerda con la

hipótesis general de que a mayor heterogeneidad ambiental, habrá mayor diversidad. Sin embargo, dado que otro tipo de relaciones (unimodales y negativas) han sido observadas en diversos estudios (Tamme *et al.*, 2010; Ludholm, 2009), este estudio es un acercamiento al entendimiento de los factores que afectan la diversidad. Es necesario un análisis exhaustivo de los parámetros y su evaluación a diferentes escalas con la finalidad de esclarecer el tipo de relaciones que pueden ser encontradas y obtener, de esta manera, estimaciones más precisas de la diversidad que puedan ser aplicadas a diferentes escalas.

4.3 PERSPECTIVAS

Este trabajo presenta una propuesta para mejorar las estimaciones de riqueza y diversidad de especies en el BTS. Aunque con los resultados de este trabajo pudimos obtener una idea del efecto que el tamaño de parcela puede tener en el ajuste y la precisión de las estimaciones, en este trabajo no se evaluaron otros aspectos como el efecto de la forma de parcela o el número de parcelas. Considerar la forma de la parcela de campo puede ser un factor de importancia para mejorar las estimaciones de riqueza y diversidad. Por ejemplo, en parcelas rectangulares existe una mayor probabilidad de encontrar diferentes condiciones ambientales, tales como variaciones topográficas, que puedan promover una mayor heterogeneidad ambiental (Palmer *et al.*, 2002). Aunque en este trabajo no se encontró un aporte importante en el uso de las métricas de estructura de la vegetación con LiDAR, es posible que existan otros factores, como lo es el uso de parcelas rectangulares, que puedan captar una mayor variación en las alturas de los retornos y esto pueda asociarse de una manera más fuerte a las medidas de riqueza y diversidad.

Igualmente, debido a que en un mayor número de parcelas existe una mayor posibilidad de captar un mayor rango de condiciones ambientales y por lo tanto una mayor heterogeneidad, el número de parcelas puede ser otro factor evaluado en las estimaciones de riqueza y diversidad de especies.

Además, se ha probado en trabajos anteriores que la relación positiva entre heterogeneidad ambiental y riqueza de especies, como fue encontrada en este trabajo, no es la única relación que existe, y que en parte esto puede deberse a la escala del estudio (Laanisto *et al.*, 2013; Tamme *et al.*, 2010; Ludholm *et al.*, 2009). Por lo tanto, un estudio que evalúe el concepto de escala, tanto ecológica como en términos de la información obtenida de percepción remota, puede dar continuidad a este trabajo y obtener información más fina sobre el efecto de la escala en el tipo de relación entre la diversidad y la heterogeneidad ambiental.

Igualmente, en este trabajo se encontró que la incorporación de las abundancias relativas de las especies por medio del índice de Shannon, puede ser de utilidad para mejorar el ajuste en la precisión de las estimaciones de diversidad en BTS. Sin embargo, existe una gran diversidad de índices (índice de Simpson, entropías de Rényi, alpha de Fisher, entre otros) que pueden ser calculados y evaluados para comparar el efecto en el ajuste o, incluso, encontrar un índice que pueda ser aplicado en todos los casos dado que en este

estudio se encontró una excepción donde el índice de Shannon no obtuvo un mejor ajuste como variable dependiente.

Es importante tomar en cuenta que aunque se presenta un método con potencial para obtener estimaciones de riqueza y diversidad de especies en el BTS este estudio es un avance al entendimiento de la relación heterogeneidad-diversidad, muchos otros factores pueden ser probados para esclarecer la relación y sus complicaciones y complementar el conocimiento de los factores que determinan la diversidad de especies en el bosque seco.

BIBLIOGRAFÍA

- Ackerman J. D. (2010). *Spatial and Temporal Analysis in Ecology: A primer*. (IBIO*6000 Advances in Ecology and Behaviour: A Class Project). Department of Integrative Biology. University of Guelph, Canada. 99 pp.
- Alexandratos, N. (2012). *World Agriculture Towards: 2030-2050. The 2012 Revision*. Rome, Italy. 154 pp.
- Anderson, T.M., McNaughton, S.J. y M.E. Richie (2004). Scale-dependent relationships between the spatial distribution of a limiting resource and plant species diversity in an African grassland ecosystem. *Oecologia*, 139: 277-287.
- Asner, G., Mascar, J., Muller-Landau, H.C., Vieilledent, G., Vaudry, R., Rasamoelina, M., Hall, J.S. y M.van Bruegel (2012). A universal airborne LiDAR approach for tropical forest mapping. *Oecologia*, 168(4): 1147-1160.
- Borcard, D., Legendre, P., Avois-Jacquet, C. y H. Tuomisto (2004). Dissecting the spatial structure of ecological data at multiple scales. *Ecology*, 85: 1826-1832.
- Borman, F.H. (1953). The statistical efficiency of Sample Plot Size and Shape in Forest Ecology. *Ecology*, 34: 474-487.
- Box, E.O., Holben, B.N. y V. Kalb. (1989). Accuracy of the AVHRR vegetation index as a predictor of biomass, primary productivity and net CO₂ – flux. *Vegetatio*, 80: 71.
- Bruegel, M., Martínez-Ramos, M., y F. Bongers (2006). Community dynamics during early secondary succession in Mexican tropical rain forests. *Journal of Tropical Ecology*, 22: 663-674.
- Carnevali-Concha G., Ramírez, I. y J. Gonzales-Iturbide (2003). Flora y vegetación de la Península de Yucatán. En: *Naturaleza y Sociedad en el Área Maya. Pasado, Presente y Futuro*. Colunga-García Marín, P., Larqué, S.A. Academia Mexicana de Ciencias – Centro de Investigación Científica de Yucatán, A.C. (ed) México. pp 53-68.
- Chazdon, R. L., Colwell R. K., Denslow J. S., M. y M. Guariguata (1998). Statistical

- estimation of species richness of woody regeneration in primary and secondary rainforests of NE Costa Rica. In F. Dallmeier and J. Comisky (ed.). *Forest biodiversity in North, Central and South America and the Caribbean: Research and monitoring*, Parthenon Press. pp. 285-309.
- Chazdon, R.L. (2008). Chance and determinism in tropical forest succession. En: *Tropical Forest Community Ecology*. Carson W. P. y Schnitzer S. A.. Wiley-Blackwell. Oxford (ed) pp 384-408.
- Chazdon, R. L., Letcher, S. G., Van Breugel, M., Martínez-Ramos, M., Bongers, F., y B. Finegan (2007). Rates of change in tree communities of secondary Neotropical Following major disturbances. *Philosophical Transactions of the Royal Society*, 362: 273-289.
- Chave, J. (2008). Spatial variation in tree species composition across tropical forests: patterns and process. En: *Tropical Forest Community Ecology Stocks*. Carson W.P. y Schnitzer S. A. (eds). Wiley-Blackwell. Oxford. pp. 11-30.
- Chesson, P. (1998). Recruitment Limitation: A theoretical perspective. *American Journal of Ecology*, 23: 234-240.
- Constanza, J.K., Moody, A. y R.K. Peet (2010). Multi-scale environmental heterogeneity as a predictor of plant species richness. *Landscape Ecology*, 26: 851-864.
- Désilets, P. y G. Houle (2005). Effects of resource availability and heterogeneity on the slope of the species–area curve along a floodplain–upland gradient. *Journal of Vegetation Science*, 16: 487-496.
- Dogan, H. M. y M. Dogan (2006). A new approach to diversity indices - Modeling and mapping plant biodiversity of Nallihan (A3-Ankara/Turkey) forest ecosystem in frame of geographic information systems. *Biodiversity and Conservation*, 15(3): 855-878.
- Dupuy, J.M., Hernandez-Stefanoni, J.L., Hernández-Juárez, R.A., Tetella-Rangel, E., Lopez-Martinez, J.O., Leyequien-Abarca, E., Tun-Dzul, F. y F. May-Pat (2012). Patterns and Correlates of Tropical Dry Forest Structure and Composition in a

- Highly Replicated Chronosequence in Yucatan, Mexico. *Biotropica* 44(2): 151-162.
- Durán G. R., Contreras, C.G. (2010). Distribución espacial de la vegetación. En: *Biodiversidad y Desarrollo Humano en Yucatán*. Durán, R. y Méndez M. Donaciones (PPD-FMAM), Comisión Nacional para el Conocimiento y Uso de la Biodiversidad (CONABIO), Secretaría de Desarrollo Urbano y Medio Ambiente (SEDUMA) (ed.). pp. 62-73.
- Ek-Díaz, A. (2011). Vegetación. EN: *Riqueza Biológica de Quintana Roo. Un Análisis para su Conservación*, Tomo I. Pozo, C., M. Armijo Canto y Calmé S. El Colegio de la Frontera Sur (ECOSUR), Comisión Nacional para el Conocimiento y Uso de la Biodiversidad (CONABIO), Gobierno del estado de Quintana Roo y Programa de Pequeñas Donaciones (ed.). México, D.F. pp. 62-73.
- Fairbanks, H.K. y K.C. McGwire (2004). Patterns of floristic richness in vegetation communities of California: regional scale analysis with multi-temporal NDVI. *Global Ecology and Biogeography*, 13: 221-235.
- Falkowski, M. J., Smith, A. M. S., Hudak, A. T., Gessler, P. E., Vierling, L. A. y N. L. Crookston (2006). Automated estimation of individual conifer tree height and crown diameter via Two-dimensional spatial wavelet analysis of LiDAR data. *Canadian Journal of Remote Sensing*, 32(2): 153-161.
- FAO. *Global Forest Resources Assessment*. (2010). (FAO Forestry Paper 163. Food and Agriculture Organization of the United Nations, Rome, 2010).
- Foody, G.M., y M.E.J Cutler (2006). Mapping the species richness and composition of tropical forests from remotely sensed data and neural networks. *Ecological Modeling*, 195: 37-42.
- Freestone, A. y S. Harrison (2006). Regional enrichment of local assemblages is robust to variation in local productivity, abiotic gradients, and heterogeneity. *Ecology Letters*, 9: 95-102.
- Gao X., Huete A.R., Ni W.G. y T. Miura (2000). Optical-biophysical relationships of vegetation spectra without background contamination. *Remote Sensing of*

Environment, 74: 609-620.

Gallardo-Cruz, J.A., Meave, J.A., Gonzalez, E.J., Lebrija-Trejos, E.E., Romero-Romero, M.A., Perez-Garcia, E.A., Gallardo-Cruz, R., Hernandez-Stefanoni, J.L. y C. Martorell (2012). Predicting Tropical Dry Forest Successional Attributes from Space: Is the Key Hidden in Image Texture? PLoS ONE 7(2) e30506.

Gaston, K. J. (2000). Global patterns in biodiversity. Nature, 405: 220-227.

Gillespie T.W. (2005). Predicting woody plant species richness in tropical dry forests: A case study from South Florida, USA. Ecological Applications, 15(1): 27-37.

Gillespie, T.W., Foody, G.M., Rocchini, D., Giorgi, A.P. y S. Saatchi (2008). Measuring and modelling biodiversity from space. Progress in Physical Geography, 32: 203-221.

Gould, W. (2000) Remote sensing of vegetation, plant species richness, and regional biodiversity hot spots. Ecological Applications, 10:1861-1870.

GRASS Development Team (2015). Geographic Resources Analysis Support System (GRASS) Software, Version 7.0. Open Source Geospatial Foundation. Disponible en: <http://grass.osgeo.org>

Hall-Beyer, M. (2007). The GLCM Tutorial Home Page (Grey-Level Co-occurrence Matrix texture measurements). University of Calgary, Canada.
Disponible en: <http://www.fp.ucalgary.ca/mhallbey/tutorial.htm>

Haralick, R.M., Shanmugam, K. e I. Dinstein (1973). Textural features for image classification. IEEE Transactions on Systems, Man and Cybernetics, 3:610-621.

Hernandez-Stefanoni, J.L., Dupuy, J.M. y M.A, Castillo-Santiago (2009). Assessing species density and abundance of tropical trees from remotely sensed data and geostatistics. Applied Vegetation Science, 12: 398-414.

Hernandez-Stefanoni J.L. y J.M. Dupuy-Rada (2008). Effects of landscape patterns on species density and abundance of trees in a tropical subdeciduous forest of the Yucatan Peninsula. Forest Ecology and Management, 255: 3797-3805.

- Hernandez-Stefanoni, J.L. y J.M. Dupuy (2007). Mapping species density of trees, shrubs and vines in a tropical forest, using field measurements, satellite multispectral imagery and spatial interpolation. *Biodiversity Conservation*, 16: 3817-3833.
- Hernandez-Stefanoni J.L., Gallardo-Cruz, J.A., Meave, J.A. y J.M. Dupuy-Rada (2011). Combining geostatistical models and remotely sensed data to improve tropical tree richness mapping. *Ecological Indicators*, 11: 1046-1056.
- Hernández-Stefanoni, J.L., Gallardo-Cruz, J.A., Meave, J.A., Rocchini, D., Bello-Pineda, J. y J.O. Lopez-Martinez (2012). Modeling α - and β -diversity in a tropical forest from remotely sensed and spatial data. *International Journal of Applied Earth Observation and Geoinformation*, 19: 359-368.
- Hernández-Stefanoni, J.L., Dupuy, J.M., Johnson, K.D., Birdsey, R., Tun-Dzul, F., Peduzzi, A., Caamal-Sosa, J.P., Sánchez-Santos, G. y D. Lopez-Merlin (2014). Improving Species Diversity and Biomass Estimates of Tropical Dry Forests Using Airborne LiDar. *Remote Sensing*, 6: 4741-4763.
- Huete, A., Didon, K., Miura, T., Rodriguez, E.P., Gao, X. y L.G. Ferreira (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83:195-213.
- Jiang, Z., Huete, A., Didan, K. y K. Miura (2008). Development of a two band enhanced vegetation index without a blue band. *Remote Sensing of Environment*, 112: 3833-3845.
- Jost, L. (2006). Entropy and Diversity. *Oikos*, 113(2): 363–375.
- Kalacska, M., Sanchez-Azofeifa, G.A., Calvo-Alvarado, J.C., Quesada, M., Rivard, B. y D.H. Janzen (2004). Species composition, similarity and diversity in three sucesional stages of a seasonally dry tropical forest. *Forest Ecology and Management*, 200: 227-247.
- Köppen, W. (1900). Versuch einer Klassifikation der Klimate, vorzugsweise nach ihren Beziehungen zur Pflanzenwelt. *Geographische Zeitschrift*, 6: 593-611, 657-679

- Kenkel N.C. y J. Podani (1991). Plot Size and Estimation Efficiency in Plant Community Studies. *Journal of Vegetation Science*, 2(4): 539-544.
- Kumar, S., Stohlgren, T.J. y G.W. Chong (2006). Spatial Heterogeneity influences native and nonnative species richness. *Ecology*, 87: 3186-3199.
- Laanisto, L., Tamme R., Hiiesalu, I., Szava-Kovats, R.Gazol A., y M. Pärtel (2013) Microfragmentation concept explains non positive heterogeneity–diversity relationships. *Oecologia*, 171: 217-226.
- Lamb, D., Erskine, P.D. y J.A. Parotta (2005). Restoration of degraded tropical forest Landscapes. *Science*, 3102: 1628-1632.
- Legendre, P. y L. Legendre (2012). *Numerical ecology: Third English edition. Developments in environmental modeling*, 24 990 pp.
- Lebrija-Trejos, E., Pérez, García, E.A., Meave, J.A., Bongers, F. y L. Poorter (2010). Functional traits and environmental filtering drive community assembly in a species-rich tropical landscape. *Ecology*, 91(2): 386-398.
- Lebrija-Trejos, E., Pérez, García, E.A., Meave, J.A. y F. Bongers (2011). Environmental changes during secondary succession in a tropical dry forest in Mexico. *Journal of Tropical Ecology*, 27:477-489.
- Lefsky, M.A., Cohen, W.B., Parker, G.G. y D.J. Harding (2002). LiDAR remote sensing for ecosystem studies. *BioScience*, 52(1): 19-30.
- Leutner, B., Reineking, B., Müller, J., Bachmann, M., Beierkuhnlein, C., Dech, S., y M. Wegmann (2012). Modelling Forest α -Diversity and Floristic Composition —On the Added Value of LiDAR plus Hyperspectral Remote Sensing. *Remote Sensing*, 4: 2818-2845.
- Li, Y., Andersen H.E. y R.J. McGaughey (2008). A comparison of statistical methods for estimating forest biomass from light detection and ranging data. *Western Journal of Applied Forestry*, 23 (4), pp. 223-231

- Lohbeck, M., Poorter, L., Lebrija-Trejos, E., Martínez-Ramos, M., Meave, J.A., Paz, H., Pérez-García, E.A., Romero-Pérez, I.E., Tauro, A. y F. Bongers (2013). Successional changes in functional composition contrast for dry and wet tropical forest. *Ecology*, 94:1211-1216.
- Lundholm, J.T. (2009). Plant species diversity and environmental heterogeneity: spatial scale and competing hypotheses. *Journal of Vegetation Science*. 20: 377-391.
- Magurran, A.E. (2004). *Measuring Biological Diversity*. Blackwell Science Ltd. 256 pp.
- Malhi Y., Phillips O.L., Lloyd J., Baker T.R., Wright J., Almeida S., Arroyo L., Frederiksen T., Grace, J., Higuchi, N., Killeen, T., Laurance, W.F., Leño, C., Lewis, S.L., Meir, P., Monteagudo, A., Neill, D., Núñez-Vargas, P., Panfil, S.N., Patiño, S., Pitman, N., Quesada, C.A., Rudas, L. A., Salomão, R., Saleska, S., Silva, N., Silveira, M., Sombroek, W.G., Valencia, R., Vásquez-Martínez, R., Vieira, I.C.G. y B. Vincenti (2002). An international network to monitor the structure, composition and dynamics of Amazonian forests (RAINFOR). *Journal of Vegetation Science*. 13: 439-450
- Markesteyn, L., Poorter, L., Paz, H., Sack, L. y F. Bongers (2011). Ecological differentiation in xylem cavitation resistance is associated with stem and leaf structural traits. *Plant, Cell & Environment*, 34: 137–148.
- McArthur, R.H. y E.O. Wilson (1967). *The Theory of Island Biogeography*. Princeton University Press. 224 pp.
- McGaughey, R.J. (2015). *FUSION/LDV: Software for LiDAR Data Analysis and visualization*. USDA United States Forest Service.
- McGaughey, R.J. (2014). *FUSION/LDV: Software for LiDAR Data Analysis and visualization manual*. USDA United States Forest Service.
- Miles, L., Newton, A. C., Defries, R. S., Ravilious, C., May, I., Blyth, S. y J.E. Gordon (2006). A global overview of the conservation status of tropical dry forests. *Journal of Biogeography*, 33: 491-505.

- Miranda, F. y E. Hernández-X (1963). Los tipos de vegetación de México y su clasificación. FCE Ediciones Científicas Universitarias, 220 p.
- Murphy, P. G. y A. E. Lugo (1986). Ecology of tropical dry forest. *Annual Review of Ecology and Systematics*, 17: 67-88.
- Nagendra, H (2001). Using remote sensing to assess biodiversity. *International Journal of Remote Sensing*, 22: 2377-2400.
- Næsset, E. y T. Okland (2002). Estimating tree height and tree crown properties using airborne scanning laser in a boreal nature reserve. *Remote Sensing of Environment*, 79: 105-115.
- Nekola, J. C., White, P. S., Carolina, N., Hill, C., Hill, C. y N. Carolina (1999). The distance decay of similarity in biogeography and ecology. *Journal of Biogeography*, 867-878.
- Noriega-Trejo, R y A. Arteaga (2010). Diversidad de Ecosistemas. En: *La Biodiversidad en Campeche: Estudio de Estado*. Comisión Nacional para el Conocimiento y Uso de la Biodiversidad (CONABIO), Gobierno del Estado de Campeche, Universidad Autónoma de Campeche, México. 730 pp.
- Oldeland, J., Wesuls, D., Rocchini, D., Schmidt, M. y N. Jürgens (2010). Does using species abundance data improve estimates of species diversity from remotely sensed spectral heterogeneity? *Ecological Indicators*, 10: 390-396.
- Oindo, B.O. y A.K. Skidmore (2002). Interannual variability of NDVI and species richness in Kenya. *International Journal of Remote Sensing*, 23: 285–298.
- Palmer, M.W., Earls, P.G., Hoagland, B.W., White, P.S., y T. Wohlgemuth (2002). Quantitative tools for perfecting species lists. *Environmetrics*, 137: 121-137.
- Pettorelli, N., Vik J.O, Mysterud A., Gaillard, J., Tucker, C.J. y N.C. Stenseth (2005). Using the satellite-derived NDVI to assess ecological responses to environmental change. *Trends in Ecology & Evolution*, 20(9): 503–510
- Phillip, M.S. (1994). *Measuring trees and forests*. 2nd ed. CAB International, Wallingford,

UK.

Phillips O.L., Malhi Y., Higuchi N., Laurance W.F., Núñez P.V., Vásquez R.M., Laurance S.G., Ferreira L.V., Stern M., Brown S. y J. Grace (1998). Changes in the carbon balance of tropical forest: evidence from long-term plots. *Science*, 282: 439-444.

Phillips O.L., Baker T.R., Arroyo L., Higuchi N., Killeen T.J., Laurance W.F., Lewis S.L., Lloyd J., Malhi Y., Monteagudo A., Neill D.A., Núñez Vargas P., Silva J.N.M., Terborgh J., Vásquez Martínez R., Alexiades M., Almeida S., Brown S., Chave J., Comiskey J.A., Czimczik C.I., Di Fiore A., Erwin T., Kuebler C., Laurance S.G., Nascimento H.E.M., Olivier J., Palacios W., Patiño S., Pitman N.C.A., Quesada C.A., Saldias M., Torres Lezama A. y B. Vinceti (2004). Pattern and process in Amazon tree turnover, 1976–2001. *Philosophical Transactions Royal Society London*. 359: 381-407.

Pineda-García, F., Paz, H., y C. Tinoco-Ojanguren (2011). Morphological and physiological differentiation of seedlings between dry and wet habitats in a tropical dry forest *Plant, Cell & Environment*, 34: 1536-1547

Poorter, H., Niinemets, Ü., Poorter, L., Wright, I. J. y R. Villar (2009). Causes and consequences of variation in leaf mass per area (LMA): a meta-analysis. *New Phytologist*, 182: 565-588.

Powers J.S., Becknell, J. Irving, J. y D. Pérez-Avilés (2009). Diversity and structure of regenerating forests of Costa Rica: Geographic patterns and environmental drivers. *Forest Ecology and Management*, 258, 959 – 970.

Quesada, M., Sanchez-Azofeifa, G. A., Alvarez-Añorve, M., Stoner, K.E., Avila-Cabadilla, L., Calvo-Alvarado, J., Castillo, A., Espírito-Santo, M.M., Fagundes, M., Fernandes, G.W., Gamon, J., Lopezaraiza-Mikel M., Lawrence, D., Cerdeira Morellato, L.P., Powers, J., Neves F., Rosas-Guerrero, V., Sayago, R. y G. Sanchez-Montoya, (2009). Succession and management of tropical dry forests in the Americas: Review and new perspectives. *Forest Ecology and Management*, 258(6): 1014-1024.

- R Development Core Team (2012). A Language and Environment for Statistical Computing. R Foundation for Statistical Computing, Vienna, Austria, ISBN 3-900051-07-0. <http://www.Rproject.org>.
- Ricklefs, R.E. (2004). A comprehensive framework for global patterns in biodiversity. *Ecology Letters*, 2004 7: 1-15.
- Rocchini, D. (2007). Effects of spatial and spectral resolution in estimating ecosystem α -diversity by satellite imagery. *Remote Sensing of Environment*, 111: 423-434.
- Rocchini, D., Balkenhol, N., Carter, G.A., Foody, G.M., Gillespie, T.W., He, K.S., Kark, S., Levin, N., Lucas, K., Luoto, M., Nagendra, H., Oldeland, J., Ricotta, D., Southworth, K., y M. Neteler (2010). Remotely sensed spectral heterogeneity as a proxy of species diversity: recent advances and open challenges. *Ecological Informatics*, 5: 318-329.
- Ruiz, J., Fandiño M.C. y R. Chazdon (2005). Vegetation structure, composition and species richness across a 56-year chronosequence of dry tropical forest on Providencia Island, Colombia. *Biotropica*, 37: 520-530.
- Rzedowski, J. (2006). *Vegetación de México*. 1ª Edición digital, Comisión Nacional para el Conocimiento y Uso de la Biodiversidad. México.
- Sanchez-Azofeifa G.A., Quesada, M., Rodríguez, J.P., Nassar, J.M., Stoner, K.E., Castillo, A., Garvin, T., Zent, E.L., Calvo-Alvarado, J.C., Kalacska, M.E.R., Fajardo, L., Gamon, J.A. y P. Cuevas-Reyes (2005). Research priorities for neotropical dry forests. *Biotropica*, 37: 477–485.
- Simonson, W. D., Allen, H. D. y D.A. Coomes (2012). Use of an Airborne LiDAR System to Model Plant Species Composition and Diversity of Mediterranean Oak Forests. *Conservation Biology*, 26(5): 840–850.
- Spies, T.A. (1998) Forest structure a key to the ecosystem. Trofymow y A. MacKinnon (ed.) *Proceedings of a workshop on Structure, Process, and Diversity in Successional Forests of Coastal British Columbia*, Northwest Science, 72 (special issue No. 2).

- St-Louis, V., Pidgeon, A.M., Radeloff V.C., Hawbaker, T.J. y M.K. Clayton (2006). High resolution image texture as a predictor of bird species richness. *Remote Sensing of Environment*, 105: 299-312.
- Tamme, R., Hiiesalu, I., Laanisto, L., Szava-Kovats, R. and Pärtel, M. (2010), Environmental heterogeneity, species diversity and co-existence at different spatial scales. *Journal of Vegetation Science*, 21: 796–801.
- Thomson, A., Calvin, K., Chini, L., Hurt, G., Edmonds, J., Bond-Lamberty, B., Folkring, S., Wise, M.A. y A.C. Janetos (2010). Climate mitigation and the future of tropical landscapes. *Proceedings of the National Academy of Science*, 107: 19633-19638.
- Toledo, V.M., Barrera-Bassols, N., García-Frapolli, E. y P. Alarcón-Chairesm (2008). Uso múltiple y biodiversidad entre los Mayas Yucatecos (México). *INTERCIENCIA* 33:5.
- Turner, W., Spector, S., Gardiner, N., Fadeland, M., Sterling, E. y M. Steiniger (2003). Remote sensing for biodiversity science and conservation. *Trends in Ecology and Evolution*, 18: 306-314.
- Venterink, H. O., Wassen M. J., Verkroost A. W. M. y P.C. DeRuiter (2003). Species Richness-Productivity Patterns Differ between N-, P-, and K- Limited Wetlands. *Ecology*, 84: 2191–2199.
- Waide, R. B., Willig, M. R., Steiner, C. F., Mittelbach, G., Gough, L., Dodson, S. I., Juday, G.P. y R. Parmenter (1999). The Relationship Between Productivity and Species Richness. *Annual Reviews in Ecology and Systematics*, pp. 257–300.
- Weichelt, H., Rosso, P., Marx, A., Reigber, S., Douglass, K. y M. Heynen (2012). The RapidEye Red Edge Band, 1–6.
- Wijesinghe, D., John, E.A. y M.J. Hutchings (2005). Does pattern of soil resource heterogeneity determine plant community structure? An experimental investigation. *Journal of Ecology*, 93: 99–112.
- Wilson, S.D. (2000). Heterogeneity, diversity and scale in plant communities. In: Hutchings, M.J., John, E.A., & Stewart, A.J.A. (ed.). *The Ecological Consequences*

of Environmental Heterogeneity. Blackwell Science, Oxford, pp. 53-69.

Wood, E.M., Pidgeon, A.M., Randeloff, V.C. y N.S. Keuler (2012). Image texture as a remotely sensed measure of vegetation structure. *Remote Sensing of Environment*, 121: 516-526.

Yépez, E.A., Olgúin, M., Maldonado, V. y G. Ángeles (2016). Consolidación de la Red Mexicana de Sitios de Monitoreo Intensivo del Carbono en Ecosistemas Forestales Estratégicos de México. Fondo Sectorial CONAFOR-CONACYT, pp. 31.

ANEXO I

IMAGE TEXTURE FORMULAE

Angular Second Moment (ASM)

$$f = \sum_i \sum_j [p(i, j)]^2$$

Contrast

$$f_2 = \sum_{n=0}^{Ng-1} n^2 \left[\sum_{i=1}^{Ng} \sum_{j=1}^{Ng} p(i, j) \right]$$

Correlation

$$f_3 = \frac{\sum_i \sum_j (ij) p(i, j) - \mu_x - \mu_y}{\sigma_x \sigma_y}$$

Sum of Squares: Variance

$$f_4 = \sum_i \sum_j (i - \mu)^2 p(i, j)$$

Inverse Difference Moment (IDM)

$$f_5 = \sum_i \sum_j \frac{1}{1 + (i + j)^2} p(i, j)$$

Sum Average

$$f_6 = \sum_{i=2}^{2Ng} i p_{x+y}^{(i)}$$

Sum Variance

$$f_7 = \sum_{i=2}^{2Ng} (i - f_6)^2 p_{x+y}^{(i)}$$

Sum Entropy

$$f_8 = \sum_{i=2}^{2Ng} p_{x+y}^{(i)} \log \{ p_{x+y}^{(i)} \}$$

Entropy

$$f_9 = \sum_i \sum_j p(i, j) \log(p(i, j))$$

Difference Variance

$$f_{10} = \text{variance of } p_x - y$$

Difference Entropy

$$f_{11} = - \sum_{i=0}^{N_g-1} p_{x-y^{(i)}} \log \{ p_{x-y^{(i)}} \}$$

Information Measures of Correlation 1

$$f_{12} = \frac{H_{XY} - H_{XY1}}{\max \{ H_X, H_Y \}}$$

Information Measures of
Correlation 2

$$f_{13} = (1 - \exp[-2.0(H_{XY2} - H_{XY})])^{1/2}$$

Where:

$$H_{XY} = - \sum_i \sum_j p(i, j) \log(p(i, j))$$

$$H_{XY1} = - \sum_i \sum_j p(i, j) \log \{ p_x^{(i)} p_y^{(j)} \}$$

$$H_{XY2} = - \sum_i \sum_j p_x^{(i)} p_y^{(j)} \log \{ p_x^{(i)} p_y^{(j)} \}$$

NOTATION

All notation and formulae were taken from Haralick *et al.* 1973.

p_i : frequency of gray tone i

p_j : frequency of gray tone j

$p_{(i,j)}$: Matrix of relative frequencies. (i,j) entry in a normalized gray-tone spatial dependence matrix.

$p_x^{(i)}$: i th entry in the marginal probability matrix obtained by summing rows of $p_{(i,j)}$

N_g : Number of gray levels in the image.

INDIVIDUAL MEASURE INTERPRETATION

Angular Second Moment (ASM): This measure is also called “Uniformity”. ASM measures local homogeneity and it is the opposite of Entropy. A high value of this measure will occur when pixels in the moving window are very similar. The square root of this is called “Energy” (Haralick *et al.* 1973, Grass 7.0 Manual).

Contrast: This measure analyses the local gray-level variations (image contrast) in an image and it will be high when values of neighboring pixels are different (Haralick *et al.* 1973, Grass 7.0 Manual).

Inverse difference moment (IDM): This measure is also called “homogeneity” and it is inversely related to the contrast measure. As ASM, it is a direct measure of local homogeneity and local values are associated with low homogeneity (Haralick *et al.* 1973, Grass 7.0 Manual).

Correlation and information measures of correlation: These measures analyze gray-tone linear dependencies in the image. They are typically high when a value of pixel “ x ” corresponds to a value in pixel “ y ” (Haralick *et al.* 1973, Grass 7.0 Manual).

Entropy, Sum Entropy and Difference Entropy: These measures analyze randomness. They are high in complex images and typically low when pixels in the local moving window are uniform (Haralick *et al.* 1973, Grass 7.0 Manual).

Variance, Sum Variance and Difference Variance: These features measure gray tone variability or “variance” within the moving window, also known as the second order moment about the mean (Haralick *et al.* 1973, Grass 7.0 Manual).

ANEXO II

ANEXO II. Resultados del análisis de componentes principales.

Cuadro 1.- Importancia de componentes de los componentes principales de medidas de textura y proporción de varianza explicada por componente (Kaxil Kiuc).

Importance of components :					
	PC1	PC2	PC3	PC4	PC5
Eigenvalue	27.2749	9.6791	7.2173	5.35478	4.30688
Proportion Explained	0.4011	0.1423	0.1061	0.07875	0.06334
Cumulative proportion	0.4011	0.5434	0.6496	0.72833	0.79166

Cuadro 2.- Composición de componentes de medidas de textura en Kaxil Kiuc: 20 variables más importantes.

	PC1		PC2		PC3		PC4		PC5
DV_evi	0.646	DV_band4	0.637	Corr_band4	0.558	band3	0.609	Contr_ndvi	0.353
MOC1_ndvi	0.639	ASM_band4	0.575	Contr_ndvi	0.390	mean_band3	0.549	MOC1_band3	0.349
MOC1_evi	0.633	IDM_band4	0.449	IDM_band4	0.304	band4	0.530	ndvi	0.289
ASM_band3	0.568	SE_ndvi	0.322	Contr_evi	0.291	mean_band4	0.509	evi	0.288
IDM_band3	0.549	Var_ndvi	0.304	Contr_band3	0.269	DE_ndvi	0.392	SA_ndvi	0.277
DV_band3	0.531	Entr_ndvi	0.238	ASM_evi	0.268	Entr_ndvi	0.288	SV_ndvi	0.252
DV_ndvi	0.519	MOC1_band4	0.232	Entr_band3	0.248	Contr_ndvi	0.247	DE_ndvi	0.236
MOC1_band3	0.518	SV_ndvi	0.223	range_band3	0.236	SA_band3	0.198	DV_band3	0.221
ASM_evi	0.458	DE_evi	0.195	DE_ndvi	0.215	SV_band4	0.193	ASM_band3	0.220
IDM_evi	0.452	Var_evi	0.191	DE_band3	0.210	SV_band3	0.189	Contr_band4	0.218
DE_band3	-0.602	Contr_band4	-0.439	Entr_evi	-0.285	IDM_evi	-0.125	IDM_band4	-0.230
Var_evi	-0.634	DE_band4	-0.484	DV_band3	-0.288	MOC1_band4	-0.164	range_band3	-0.251
sd_band3	-0.634	nvar_band4	-0.487	SE_ndvi	-0.328	Corr_ndvi	-0.165	SE_band3	-0.274
nvar_ndvi	-0.653	sd_band4	-0.516	IDM_band3	-0.328	ASM_ndvi	-0.268	SV_band3	-0.278
range_ndvi	-0.654	SV_band4	-0.554	Contr_band4	-0.391	DV_ndvi	-0.343	Corr_band4	-0.285
nvar_evi	-0.656	SA_band4	-0.572	DE_band4	-0.423	IDM_ndvi	-0.348	IDM_ndvi	-0.289
range_evi	-0.662	range_band4	-0.615	SE_evi	-0.487	mean_ndvi	-0.356	SA_band3	-0.297
Var_band3	-0.663	Entr_band4	-0.622	MOC1_band4	-0.538	mean_evi	-0.356	Corr_evi	-0.312
sd_ndvi	-0.670	SE_band4	-0.624	Corr_ndvi	-0.554	ndvi	-0.370	Corr_ndvi	-0.344
sd_evi	-0.672	Var_band4	-0.649	Corr_evi	-0.571	evi	-0.371	Corr_band3	-0.450

Cuadro 3.- Importancia de componentes de los componentes principales de medidas de textura y proporción de varianza explicada por componente (Felipe Carrillo Puerto).

Importance of components :						
	PC1	PC2	PC3	PC4	PC5	PC6
Eigenvalue	15.8319	12.6039	9.7955	4.98097	3.29709	2.5835
Proportion Explained	0.2639	0.2101	0.1633	0.08302	0.05495	0.04306
Cumulative proportion	0.2639	0.4739	0.6372	0.7202	0.77516	0.81821

Cuadro 4.- Composición de componentes de medidas de textura en FCP: 20 variables más importantes.

	PC1	PC2	PC3	PC4	PC5	PC6					
DV_evi2	0.68628	MOC1_band4	0.621	nvar_band3	0.743	Entr_band4	0.292	SE_ndvi	0.475	SA_ndvi	0.457
DV_ndvi	0.637998	IDM_band4	0.585	Var_band3	0.743	band4	0.286	Entr_ndvi	0.400	SA_evi2	0.410
ASM_evi2	0.635412	DV_band4	0.540	sd_band3	0.730	band3	0.285	Corr_band3	0.363	SV_ndvi	0.409
MOC1_evi2	0.611228	DE_band3	0.462	SV_band3	0.637	DE_band3	0.279	SE_band3	0.251	SV_evi2	0.353
MOC1_ndvi	0.542155	Entr_band3	0.451	SA_band3	0.619	SE_band4	0.269	Entr_band3	0.251	DE_band3	0.210
IDM_evi2	0.507886	ASM_band4	0.391	Contr_band3	0.608	Contr_band3	0.258	sd_band3	0.195	IDM_ndvi	0.166
ASM_ndvi	0.468458	Entr_ndvi	0.387	SE_band3	0.607	sd_band4	0.227	nvar_band4	0.194	Entr_band3	0.131
band3	0.426754	Contr_band3	0.350	Entr_band3	0.530	Contr_ndvi	0.225	DV_evi2	0.183	ASM_evi2	0.128
IDM_ndvi	0.396139	Entr_evi2	0.342	DE_band3	0.465	Contr_evi2	0.209	sd_band4	0.180	IDM_evi2	0.101
DV_band4	0.387876	DE_ndvi	0.342	Corr_band3	0.361	MOC1_band3	0.197	Corr_evi2	0.174	Contr_band3	0.100
SV_ndvi	-0.590896	IDM_band3	-0.482	ASM_band4	-0.190	ndvi	-0.302	evi2	-0.205	MOC1_band4	-0.160
DE_ndvi	-0.59716	Corr_band4	-0.498	SV_ndvi	-0.191	nvar_ndvi	-0.302	DV_ndvi	-0.213	ASM_band4	-0.161
SA_evi2	-0.607533	SV_band4	-0.545	SE_ndvi	-0.211	evi2	-0.302	IDM_ndvi	-0.226	Var_evi2	-0.192
Contr_evi2	-0.625051	Entr_band4	-0.554	Entr_ndvi	-0.228	sd_ndvi	-0.315	Var_evi2	-0.228	Contr_evi2	-0.200
SV_evi2	-0.633461	DE_band4	-0.575	Contr_ndvi	-0.257	nvar_evi2	-0.336	SA_evi2	-0.256	SA_band3	-0.212
Contr_ndvi	-0.634206	SE_band4	-0.638	Var_ndvi	-0.264	sd_evi2	-0.345	SV_evi2	-0.264	DV_band3	-0.213
DE_evi2	-0.639216	Contr_band4	-0.648	ASM_band3	-0.431	Corr_band3	-0.392	ASM_band3	-0.295	SV_band3	-0.213
Entr_evi2	-0.656796	sd_band4	-0.682	IDM_band3	-0.522	IDM_evi2	-0.401	Contr_evi2	-0.306	SE_evi2	-0.288
Var_ndvi	-0.6599	nvar_band4	-0.702	DV_band3	-0.576	Corr_evi2	-0.657	MOC1_ndvi	-0.309	band3	-0.388
Var_evi2	-0.676703	Var_band4	-0.729	MOC1_band3	-0.653	Corr_ndvi	-0.667	ASM_ndvi	-0.436	SE_ndvi	-0.408

Cuadro 5.- Importancia de componentes de los componentes principales de métricas de LiDAR y proporción de varianza explicada por componente (Kaxil Kiuc).

Importance of components :						
	PC1	PC2	PC3	PC4	PC5	PC6
Eigenvalue	26.1175	13.3214	10.0741	4.45157	3.42915	1.35669
Proportion Explained	0.4282	0.2184	0.1651	0.07298	0.05622	0.02224
Cumulative proportion	0.4282	0.6465	0.8117	0.88466	0.94088	0.96312

Cuadro 6.- Composición de componentes significativos de métricas de LiDAR en Kaxil Kiuc: 20 variables más importantes.

	PC1		PC2
Total.return.count	0.393	Percentage.first.returns.above.mean	0.635
Total.all.returns	0.393	X.All.returns.above.mean.....Total.first.returns....100	0.572
Total.first.returns	0.374	Percentage.all.returns.above.mean	0.488
Return.1.count.above.1.50	0.367	Canopy.relief.ratio	0.441
Total.return.count.above.1.50	0.353	X.All.returns.above.4.00.....Total.first.returns....100	0.394
First.returns.above.mean	0.333	First.returns.above.mean	0.382
First.returns.above.4.00	0.331	Return.3.count.above.1.50	0.380
All.returns.above.mean	0.328	Return.2.count.above.1.50	0.376
Return.2.count.above.1.50	0.288	Percentage.first.returns.above.4.00	0.372
First.returns.above.mode	0.286	All.returns.above.mean	0.372
Elev.P40	-0.715	Elev.L2	-0.460
Elev.P80	-0.724	Elev.variance	-0.467
Elev.P50	-0.724	Elev.IQ	-0.480
Elev.P60	-0.726	Elev.MAD.median	-0.494
Elev.P70	-0.727	Elev.MAD.mode	-0.539
Elev.P75	-0.727	Elev.L3	-0.542
Elev.CURT.mean.CUBE	-0.731	Elev.L.skewness	-0.587
Elev.mean	-0.731	Elev.skewness	-0.613
Elev.L1	-0.731	Elev.CV	-0.674
Elev.SQRT.mean.SQ	-0.734	Elev.L.CV	-0.675

	PC3		PC4
First.returns.above.mode	0.594	Elev.L.kurtosis	0.473
All.returns.above.4.00	0.586	Percentage.first.returns.above.mode	0.458
All.returns.above.mode	0.584	X.All.returns.above.mode.....Total.first.returns....100	0.439
First.returns.above.4.00	0.568	Return.4.count.above.1.50	0.393
Total.return.count.above.1.50	0.566	Percentage.all.returns.above.mode	0.363
Return.1.count.above.1.50	0.556	Elev.kurtosis	0.345
Total.first.returns	0.551	Elev.L4	0.300
Total.return.count	0.540	X.All.returns.above.4.00.....Total.first.returns....100	0.269
Total.all.returns	0.540	Elev.L3	0.241
Return.2.count.above.1.50	0.518	Elev.L.skewness	0.213
Elev.P40	0.051	Elev.MAD.mode	-0.208
Elev.P50	0.050	Elev.AAD	-0.209
Elev.CV	0.020	All.returns.above.mean	-0.222
Elev.L.CV	0.019	First.returns.above.mean	-0.243
Canopy.relief.ratio	-0.104	First.returns.above.4.00	-0.254
X.All.returns.above.mean.....Total.first.returns....100	-0.184	Return.1.count.above.1.50	-0.256
Percentage.all.returns.above.mean	-0.203	Elev.MAD.median	-0.258
Elev.mode	-0.227	Total.first.returns	-0.263
Percentage.first.returns.above.mean	-0.228	Elev.mode	-0.282
Elev.minimum	-0.308	Elev.IQ	-0.289

	PC5		PC6
Canopy.relief.ratio	0.424	Elev.minimum	0.424
Percentage.all.returns.above.mode	0.337	Percentage.all.returns.above.4.00	0.333
Percentage.first.returns.above.mode	0.300	Percentage.all.returns.above.mean	0.268
X.All.returns.above.mode.....Total.first.returns....100	0.292	Elev.L.kurtosis	0.178
All.returns.above.mode	0.285	Elev.L3	0.161
First.returns.above.mode	0.275	Elev.L4	0.153
Elev.P05	0.215	Percentage.first.returns.above.4.00	0.139
Elev.P01	0.193	Elev.P01	0.108
Elev.P10	0.152	Elev.skewness	0.106
Percentage.all.returns.above.4.00	0.139	Elev.L.skewness	0.102
Return.2.count.above.1.50	-0.193	Elev.P70	-0.060
Elev.kurtosis	-0.200	Elev.MAD.mode	-0.069
Elev.maximum	-0.212	Elev.MAD.median	-0.089
Elev.L.CV	-0.214	Return.2.count.above.1.50	-0.093
X.All.returns.above.mean.....Total.first.returns....100	-0.240	Return.4.count.above.1.50	-0.107
Elev.CV	-0.241	Percentage.first.returns.above.mode	-0.109
Elev.L.kurtosis	-0.313	X.All.returns.above.mode.....Total.first.returns....100	-0.115
Elev.L4	-0.317	X.All.returns.above.4.00.....Total.first.returns....100	-0.168
Return.3.count.above.1.50	-0.377	X.All.returns.above.mean.....Total.first.returns....100	-0.173
Return.4.count.above.1.50	-0.439	Return.3.count.above.1.50	-0.246

Cuadro 7.- Importancia de componentes de los componentes principales de métricas de LiDAR y proporción de varianza explicada por componente (FCP).

Importance of components :						
	PC1	PC2	PC3	PC4	PC5	PC6
Eigenvalue	33.3401	11.1058	4.98796	4.2454	3.02834	1.5192
Proportion Explained	0.5466	0.1821	0.08177	0.0696	0.04964	0.0249
Cumulative proportion	0.5466	0.7286	0.81039	0.88	0.92963	0.9545

Cuadro 8.- Composición de componentes significativos de métricas de LiDAR en FCP: 20 variables más importantes.

	PC1		PC2
Elev.L.skewness	0.785	Elev.AAD	0.566
Elev.L3	0.779	Elev.IQ	0.563
Elev.skewness	0.778	Elev.L2	0.533
Elev.CV	0.725	Elev.stddev	0.533
Elev.L.CV	0.682	Elev.variance	0.532
Elev.kurtosis	0.473	Elev.MAD.median	0.529
Elev.L.kurtosis	0.320	Elev.MAD.mode	0.488
All.returns.above.mode	0.307	Elev.L.CV	0.322
First.returns.above.mode	0.292	Elev.CV	0.218
X.All.returns.above.mode.....Total.first.returns....100	0.289	Elev.P80	0.144
Elev.P80	-0.792	First.returns.above.mode	-0.476
Elev.P40	-0.793	All.returns.above.4.00	-0.491
Elev.CURT.mean.CUBE	-0.796	Elev.L.kurtosis	-0.498
Elev.P75	-0.797	Elev.L4	-0.503
Elev.P50	-0.802	First.returns.above.4.00	-0.522
Elev.SQRT.mean.SQ	-0.803	Total.first.returns	-0.600
Elev.P70	-0.804	Return.1.count.above.1.50	-0.614
Elev.mean	-0.805	Total.return.count.above.1.50	-0.623
Elev.L1	-0.805	Total.return.count	-0.625
Elev.P60	-0.806	Total.all.returns	-0.625

	PC3		PC4
All.returns.above.mode	0.500	Percentage.first.returns.above.mode	0.476
X.All.returns.above.mode.....Total.first.returns....100	0.493	X.All.returns.above.mode.....Total.first.returns....100	0.458
Percentage.all.returns.above.mode	0.475	Percentage.all.returns.above.mode	0.447
Percentage.first.returns.above.mode	0.438	All.returns.above.mode	0.265
First.returns.above.mode	0.435	First.returns.above.mode	0.238
Return.2.count.above.1.50	0.390	X.All.returns.above.4.00.....Total.first.returns....100	0.211
Elev.IQ	0.371	Elev.P01	0.210
Elev.MAD.mode	0.368	Percentage.first.returns.above.4.00	0.210
Elev.MAD.median	0.346	Elev.P05	0.183
Return.3.count.above.1.50	0.310	Elev.P10	0.177
Elev.maximum	-0.153	First.returns.above.4.00	-0.232
Elev.P10	-0.155	Elev.CV	-0.232
Elev.P30	-0.156	Elev.mode	-0.235
Elev.P25	-0.165	Elev.stddev	-0.283
Elev.P20	-0.175	Elev.variance	-0.293
Elev.minimum	-0.263	Total.return.count.above.1.50	-0.363
Elev.mode	-0.310	Return.1.count.above.1.50	-0.425
Elev.kurtosis	-0.401	Total.return.count	-0.440
Elev.L.kurtosis	-0.466	Total.all.returns	-0.440
Elev.L4	-0.490	Total.first.returns	-0.472

	PC5		PC6
Return.3.count.above.1.50	0.374	Elev.minimum	0.284
Return.4.count.above.1.50	0.330	Return.1.count.above.1.50	0.199
Return.2.count.above.1.50	0.274	Total.first.returns	0.171
X.All.returns.above.4.00.....Total.first.returns....100	0.227	First.returns.above.4.00	0.154
X.All.returns.above.mean.....Total.first.returns....100	0.178	Percentage.all.returns.above.mean	0.144
Elev.mode	0.164	First.returns.above.mean	0.143
Percentage.first.returns.above.4.00	0.121	Canopy.relief.ratio	0.113
Percentage.first.returns.above.mean	0.107	All.returns.above.mean	0.091
All.returns.above.4.00	0.084	Percentage.all.returns.above.4.00	0.075
Total.return.count	0.075	Elev.IQ	0.068
Elev.L4	-0.270	Elev.kurtosis	-0.115
Elev.stddev	-0.276	Elev.skewness	-0.124
Elev.variance	-0.284	Return.2.count.above.1.50	-0.132
Percentage.first.returns.above.mode	-0.289	X.All.returns.above.4.00.....Total.first.returns....100	-0.154
All.returns.above.mode	-0.290	Elev.L.kurtosis	-0.176
First.returns.above.mode	-0.313	Elev.L4	-0.220
Elev.maximum	-0.326	Elev.maximum	-0.292
Elev.P95	-0.327	Elev.P99	-0.318
Percentage.all.returns.above.mode	-0.353	Return.3.count.above.1.50	-0.320
Elev.P99	-0.412	Return.4.count.above.1.50	-0.499

ANEXO III

I. Resumen de resultados de prueba de autocorrelación espacial (Moran's I) de residuales de modelos de a) textura y b) LiDAR para estimar riqueza y diversidad de especies en 1000 m².

a) Cuadro 1: Análisis de autocorrelación espacial para modelos de textura.

Kaxil Kiuic		Felipe Carrillo Puerto	
Species Richness		Species Richness	
Observed	-0.006	Observed	-0.041
Expected	-0.053	Expected	-0.037
SD	0.029	SD	0.032
P. Value	0.103	P. Value	0.912
Shannon's Index		Shannon's Index	
Observed	-0.024	Observed	-0.002
Expected	-0.053	Expected	-0.037
SD	0.030	SD	0.032
P. Value	0.336	P. Value	0.264

b) Cuadro 2: Análisis de Autocorrelación espacial para modelos de LiDAR.

Kaxil Kiuic		Felipe Carrillo Puerto	
Species Richness		Species Richness	
Observed	-0.044	Observed	-0.082
Expected	-0.053	Expected	-0.037
SD	0.029	SD	0.032
P. Value	0.781	P. Value	0.170
Shannon's Index		Shannon's Index	
Observed	-0.023	Observed	-0.071
Expected	-0.053	Expected	-0.037
SD	0.030	SD	0.031
P. Value	0.323	P. Value	0.273

II. Resumen de resultados de prueba de autocorrelación espacial (Moran's I) de residuales de modelos de a) textura y b) LiDAR para estimar riqueza y diversidad de especies en 400 m².

a) Cuadro 1: Análisis de autocorrelación espacial para modelos de textura.

Kaxil Kiuc		Felipe Carrillo Puerto	
Species Richness		Species Richness	
Observed	-0.044	Observed	-0.020
Expected	-0.053	Expected	-0.037
SD	0.029	SD	0.032
P. Value	0.781	P. Value	0.603
Shannon's Index		Shannon's Index	
Observed	-0.040	Observed	-0.071
Expected	-0.053	Expected	-0.037
SD	0.030	SD	0.031
P. Value	0.668	P. Value	0.273

b) Cuadro 2: Análisis de autocorrelación espacial para modelos de LiDAR.

Kaxil Kiuc		Felipe Carrillo Puerto	
Species Richness		Species Richness	
Observed	-0.044	Observed	-0.082
Expected	-0.053	Expected	-0.037
SD	0.029	SD	0.032
P. Value	0.781	P. Value	0.170
Shannon's Index		Shannon's Index	
Observed	-0.023	Observed	-0.071
Expected	-0.053	Expected	-0.037
SD	0.030	SD	0.031
P. Value	0.323	P. Value	0.273

III. Cuadro de resultados de modelos de riqueza y diversidad de especies en 400 m² para Kaxil Kiuic. a) Medidas de textura, b) Métricas de LiDAR.

a)

Dependent Variable	Independent Variables	Estimate	SE	R ²	R ² Cross Validation	RMSE
Species Richness	Intercept***	16.300	0.795	0.350	0.310	3.270
	PC1	-1.010	0.593			
	PC2*	0.490	0.593			
	PC3	-0.238	0.593			
	PC4	0.792	0.593			
	PC5	0.432	0.593			
Shannon's Index	Intercept***	2.526	0.049	0.380	0.243	0.250
	PC1	-0.132	0.036			
	PC2*	0.060	0.036			
	PC3	0.020	0.036			
	PC4	0.053	0.036			
	PC5	0.029	0.036			

b)

Dependent Variable	Independent Variables	Estimate	SE	R ²	R ² Cross Validation	RMSE
Species Richness	Intercept***	19.700	0.838	0.275	0.107	3.828
	PC1**	2.092	0.860			
	PC2	-0.227	0.860			
	PC3	0.249	0.860			
Shannon's Index	Intercept***	2.494	0.051	0.487	0.286	0.248
	PC1**	0.181	0.052			
	PC2	-0.091	0.052			
	PC3	-0.025	0.052			

IV. Cuadro de resultados de modelos de riqueza y diversidad de especies en 400 m² para Kaxil Kiuic. a) Medidas de textura, b) Métricas de LiDAR.

a)

Dependent Variable	Independent Variables	Estimate	SE	R ²	R ² Cross Validation	RMSE
Species Richness	Intercept***	27.643	0.960	0.371	0.080	5.664
	PC1*	1.857	0.800			
	PC2	-1.370	0.800			
	PC3.	-1.403	0.800			
	PC4	-0.479	0.800			
	PC5	-0.406	0.800			
	PC6	0.490	0.800			
Shannon's Index	Intercept***	2.812	0.042	0.447	0.164	0.290
	PC1*	0.021	0.042			
	PC2	-0.083	0.042			
	PC3**	-0.080	0.042			
	PC4.	0.084	0.042			
	PC5	-0.007	0.042			
	PC6	0.193	0.042			

b)

Dependent Variable	Independent Variables	Estimate	SE	R ²	R ² Cross Validation	RMSE
Species Richness	Intercept***	29.464	1.005			
	PC1	0.740	0.838			
	PC2.	1.451	0.838			
	PC3*	-2.253	0.838	0.479	0.375	8.289
	PC4	-1.328	0.838			
	PC5	-0.793	0.838			
	PC6*	-1.863	0.838			
Shannon's Index	Intercept***	2.815	0.073			
	PC1	0.098	0.061			
	PC2.	0.060	0.061			
	PC3.	-0.083	0.061	0.462	0.101	0.489
	PC4.	-0.106	0.061			
	PC5	-0.113	0.061			
	PC6***	-0.150	0.061			

ANEXO IV

SCRIPTS DE CÁLCULO DE TEXTURA PARA KAXIL KIUIC

```
## TEXTURE CALCULATION KAXIL KIUIC #####  
#Set computational region to raster  
#Set colors  
g.region raster=kaxil.ndvi  
r.colors map=kaxil.ndvi color=ndvi  
g.region raster=kaxil.evi  
r.colors map=kaxil.evi color=evi  
#Create texture maps (13 texture variables)  
g.region raster=kaxil_kiuc.3  
r.texture -a input=kaxil_kiuc.3 output=band3.texture size=5 --overwrite  
g.region raster=kaxil_kiuc.4  
r.texture -a input=kaxil_kiuc.4 output=band4.texture size=5 --overwrite  
g.region raster=kaxil.ndvi  
r.texture -a input=kaxil.ndvi output=ndvi.texture size=5 --overwrite  
g.region raster=kaxil.evi  
r.texture -a input=kaxil.evi output=kaxilevi.texture size=5 --overwrite  
#Create texture maps with r.neighbors  
g.region raster=kaxil_kiuc.3  
r.neighbors input=kaxil_kiuc.3 method=average output=mean_kiuc.3 size=5 --overwrite  
r.neighbors input=kaxil_kiuc.3 method=range output=range_kiuc.3 size=5 --overwrite  
r.neighbors input=kaxil_kiuc.3 method=variance output=var_kiuc.3 size=5 --overwrite  
r.neighbors input=kaxil_kiuc.3 method=stddev output=stddev_kiuc.3 size=5 --overwrite  
g.region raster=kaxil_kiuc.4  
r.neighbors input=kaxil_kiuc.4 method=average output=mean_kiuc.4 size=5 --overwrite  
r.neighbors input=kaxil_kiuc.4 method=range output=range_kiuc.4 size=5 --overwrite  
r.neighbors input=kaxil_kiuc.4 method=variance output=var_kiuc.4 size=5 --overwrite  
r.neighbors input=kaxil_kiuc.4 method=stddev output=stddev_kiuc.4 size=5 --overwrite  
g.region raster=kaxil.ndvi
```

```
r.neighbors input=kaxil.ndvi method=average output=mean_kaxilndvi size=5 --overwrite
r.neighbors input=kaxil.ndvi method=range output=range_kaxilndvi size=5 --overwrite
r.neighbors input=kaxil.ndvi method=variance output=var_kaxilndvi size=5 --overwrite
r.neighbors input=kaxil_ndvi method=stddev output=stddev_kaxilndvi size=5 --overwrite
g.region raster=kaxil.evi
r.neighbors input=kaxil.evi method=average output=mean_kaxilevi size=5 --overwrite
r.neighbors input=kaxil.evi method=range output=range_kaxilevi size=5 --overwrite
r.neighbors input=kaxil.evi method=variance output=var_kaxilevi size=5 --overwrite
r.neighbors input=kaxil.evi method=stddev output=stddev_kaxilevi size=5 --overwrite
```

SCRIPTS DE CALCULO DE TEXTURA PARA FELIPE CARRILLO PUERTO

```
#First set computational region to red band

#set colors

g.region raster=fcp.ndvi

r.colors map=fcp.ndvi color=ndvi

g.region raster=fcp.evi

r.colors map=fcp.evi color=evi

#Calculate texture with r.texture and r.neighbors

g.region raster=fcpband.3

r.texture -a input=fcpband.3 output=band3.texture size=5 --overwrite

r.neighbors input=fcpband.3 method=average output=mean_band3 size=5 --overwrite

r.neighbors input=fcpband.3 method=range output=range_band3 size=5 --overwrite

r.neighbors input=fcpband.3 method=variance output=Var_band3 size=5 --overwrite

r.neighbors input=fcpband.3 method=stddev output=sd_band3 size=5 --overwrite

g.region raster=fcpband.4

r.texture -a input=fcpband.4 output=band4.texture size=5 --overwrite

r.neighbors input=fcpband.3 method=average output=mean_band4 size=5 --overwrite

r.neighbors input=fcpband.3 method=range output=range_band4 size=5 --overwrite

r.neighbors input=fcpband.4 method=variance output=Var_band4 size=5 --overwrite

r.neighbors input=fcpband.4 method=stddev output=sd_band4 size=5 --overwrite

g.region raster=fcp.ndvi

r.texture -a input=fcp.ndvi output=fcpndvi.texture size=5 --overwrite

r.neighbors input=fcp.ndvi method=average output=mean_ndvi size=5 --overwrite

r.neighbors input=fcp.ndvi method=range output=range_ndvi size=5 --overwrite

r.neighbors input=fcp.ndvi method=variance output=Var_ndvi size=5 --overwrite

r.neighbors input=fcp.ndvi method=stddev output=sd_ndvi size=5 --overwrite

g.region raster=fcp.evi

r.texture -a input=fcp.evi output=fcpevi.texture size=5 --overwrite

r.neighbors input=fcp.evi method=average output=mean_evi size=5 --overwrite
```

```
r.neighbors input=fcp.evi method=range output=range_evi size=5 --overwrite
```

```
r.neighbors input=fcp.evi method=variance output=Var_evi size=5 --overwrite
```

```
r.neighbors input=fcp.evi method=stddev output=sd_evi size=5 --overwrite
```

SCRIPTS DE EXTRACCIÓN DE VALORES

```
#Copy vector map
g.copy vector=sitioskaxil_selection9P3,parcelaskaxil

##### NDVI #####

#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="ndvi double precision"

#set region
g.region raster=kaxil.ndvi

#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=kaxil.ndvi column=ndvi

#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="mean_ndvi double precision"

#set region
g.region raster=mean_kaxilndvi

#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=mean_kaxilndvi column=mean_ndvi

#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="range_ndvi double precision"

#set region
g.region raster=range_kaxilndvi

#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=range_kaxilndvi column=range_ndvi

#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="nvar_ndvi double precision"

#set region
g.region raster=var_kaxilndvi

#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=var_kaxilndvi column=nvar_ndvi

#Add column to vector attribute table
```

```
v.db.addcolumn map=parcelaskaxil column="sd_ndvi double precision"
#set region
g.region raster=stddev_kaxilndvi
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=stddev_kaxilndvi column=sd_ndvi
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="Var_ndvi double precision"
#set region
g.region raster=ndvi.texture_Var
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=ndvi.texture_Var column=Var_ndvi
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="SV_ndvi double precision"
#set region
g.region raster=ndvi.texture_SV

#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=ndvi.texture_SV column=SV_ndvi
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="SE_ndvi double precision"
#set region
g.region raster=ndvi.texture_SE
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=ndvi.texture_SE column=SE_ndvi
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="SA_ndvi double precision"
#set region
g.region raster=ndvi.texture_SA
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=ndvi.texture_SA column=SA_ndvi
```

```
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="MOC2_ndvi double precision"
#set region
g.region raster=ndvi.texture_MOC-2
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=ndvi.texture_MOC-2 column=MOC2_ndvi
```

```
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="MOC1_ndvi double precision"
#set region
g.region raster=ndvi.texture_MOC-1
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=ndvi.texture_MOC-1 column=MOC1_ndvi
```

```
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="IDM_ndvi double precision"
#set region
g.region raster=ndvi.texture_IDM
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=ndvi.texture_IDM column=IDM_ndvi
```

```
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="Entr_ndvi double precision"
#set region
g.region raster=ndvi.texture_Entr
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=ndvi.texture_Entr column=Entr_ndvi
```

```
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="DV_ndvi double precision"
#set region
g.region raster=ndvi.texture_DV
```

```

#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=ndvi.texture_DV column=DV_ndvi
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="DE_ndvi double precision"
#set region
g.region raster=ndvi.texture_DE
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=ndvi.texture_DE column=DE_ndvi
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="Corr_ndvi double precision"
#set region
g.region raster=ndvi.texture_Corr
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=ndvi.texture_Corr column=Corr_ndvi
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="Contr_ndvi double precision"
#set region
g.region raster=ndvi.texture_Contr
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=ndvi.texture_Contr column=Contr_ndvi

#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="ASM_ndvi double precision"
#set region
g.region raster=ndvi.texture_ASM
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=ndvi.texture_ASM column=ASM_ndvi
##### EVI #####

```

```
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="evi double precision"

#set region
g.region raster=kaxil.evi

#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=kaxil.evi column=evi

#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="mean_evi double precision"

#set region
g.region raster=mean_kaxilevi

#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=mean_kaxilevi column=mean_evi

#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="range_evi double precision"

#set region
g.region raster=range_kaxilevi

#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=range_kaxilevi column=range_evi

#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="nvar_evi double precision"

#set region
g.region raster=var_kaxilevi

#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=var_kaxilevi column=nvar_evi

#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="sd_evi double precision"

#set region
g.region raster=stddev_kaxilevi

#Extract values from raster and upload them to attribute table (v.what.rast)
```

```
v.what.rast map=parcelaskaxil raster=stddev_kaxilevi column=sd_evi
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="Var_evi double precision"
#set region
g.region raster=kaxilevi.texture_Var
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=kaxilevi.texture_Var column=Var_evi

#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="SV_evi double precision"
#set region
g.region raster=kaxilevi.texture_SV
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=kaxilevi.texture_SV column=SV_evi
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="SE_evi double precision"
#set region
g.region raster=kaxilevi.texture_SE
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=kaxilevi.texture_SE column=SE_evi
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="SA_evi double precision"
#set region
g.region raster=kaxilevi.texture_SA
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=kaxilevi.texture_SA column=SA_evi
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="MOC2_evi double precision"
#set region
g.region raster=kaxilevi.texture_MOC-2
```

```
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=kaxilevi.texture_MOC-2 column=MOC2_evi

#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="MOC1_evi double precision"

#set region
g.region raster=kaxilevi.texture_MOC-1

#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=kaxilevi.texture_MOC-1 column=MOC1_evi

#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="IDM_evi double precision"

#set region
g.region raster=kaxilevi.texture_IDM

#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=kaxilevi.texture_IDM column=IDM_evi

#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="Entr_evi double precision"

#set region
g.region raster=kaxilevi.texture_Entr

#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=kaxilevi.texture_Entr column=Entr_evi

#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="DV_evi double precision"

#set region
g.region raster=kaxilevi.texture_DV

#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=kaxilevi.texture_DV column=DV_evi

#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="DE_evi double precision"
```

```

#set region
g.region raster=kaxilevi.texture_DE
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=kaxilevi.texture_DE column=DE_evi
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="Corr_evi double precision"
#set region
g.region raster=kaxilevi.texture_Corr
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=kaxilevi.texture_Corr column=Corr_evi
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="Contr_evi double precision"
#set region
g.region raster=kaxilevi.texture_Contr
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=kaxilevi.texture_Contr column=Contr_evi
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="ASM_evi double precision"
#set region
g.region raster=kaxilevi.texture_ASM
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=kaxilevi.texture_ASM column=ASM_evi

##### BAND 4 #####
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="band4 double precision"
#set region
g.region raster=kaxil_kiui.4
#Extract values from raster and upload them to attribute table (v.what.rast)

```

```
v.what.rast map=parcelaskaxil raster=kaxil_kiuc.4 column=band4

#Add column to vector attribute table

v.db.addcolumn map=parcelaskaxil column="mean_band4 double precision"

#set region

g.region raster=mean_kiuc.4

#Extract values from raster and upload them to attribute table (v.what.rast)

v.what.rast map=parcelaskaxil raster=mean_kiuc.4 column=mean_band4

#Add column to vector attribute table

v.db.addcolumn map=parcelaskaxil column="range_band4 double precision"

#set region

g.region raster=range_kiuc.4

#Extract values from raster and upload them to attribute table (v.what.rast)

v.what.rast map=parcelaskaxil raster=range_kiuc.4 column=range_band4

#Add column to vector attribute table

v.db.addcolumn map=parcelaskaxil column="nvar_band4 double precision"

#set region

g.region raster=var_kiuc.4

#Extract values from raster and upload them to attribute table (v.what.rast)

v.what.rast map=parcelaskaxil raster=var_kiuc.4 column=nvar_band4

#Add column to vector attribute table

v.db.addcolumn map=parcelaskaxil column="sd_band4 double precision"

#set region

g.region raster=stddev_kiuc.4

#Extract values from raster and upload them to attribute table (v.what.rast)

v.what.rast map=parcelaskaxil raster=stddev_kiuc.4 column=sd_band4

#Add column to vector attribute table

v.db.addcolumn map=parcelaskaxil column="Var_band4 double precision"
```

```
#set region
g.region raster=band4.texture_Var
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band4.texture_Var column=Var_band4
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="SV_band4 double precision"
#set region
g.region raster=band4.texture_SV
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band4.texture_SV column=SV_band4
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="SE_band4 double precision"
#set region
g.region raster=band4.texture_SE
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band4.texture_SE column=SE_band4
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="SA_band4 double precision"
#set region
g.region raster=band4.texture_SA
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band4.texture_SA column=SA_band4
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="MOC2_band4 double precision"
#set region
g.region raster=band4.texture_MOC-2
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band4.texture_MOC-2 column=MOC2_band4
#Add column to vector attribute table
```

```
v.db.addcolumn map=parcelaskaxil column="MOC1_band4 double precision"
#set region
g.region raster=band4.texture_MOC-1
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band4.texture_MOC-1 column=MOC1_band4
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="IDM_band4 double precision"
#set region
g.region raster=band4.texture_IDM
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band4.texture_IDM column=IDM_band4

#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="Entr_band4 double precision"
#set region
g.region raster=band4.texture_Entr
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band4.texture_Entr column=Entr_band4
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="DV_band4 double precision"
#set region
g.region raster=band4.texture_DV
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band4.texture_DV column=DV_band4
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="DE_band4 double precision"
#set region
g.region raster=band4.texture_DE
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band4.texture_DE column=DE_band4
```

```

#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="Corr_band4 double precision"

#set region
g.region raster=band4.texture_Corr
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band4.texture_Corr column=Corr_band4
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="Contr_band4 double precision"
#set region
g.region raster=band4.texture_Contr
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band4.texture_Contr column=Contr_band4
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="ASM_band4 double precision"
#set region
g.region raster=band4.texture_ASM
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band4.texture_ASM column=ASM_band4

##### BAND 3 #####
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="band3 double precision"
#set region
g.region raster=kaxil_kiuc.3

#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=kaxil_kiuc.3 column=band3
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="mean_band3 double precision"

```

```

#set region
g.region raster=mean_kiuc.3
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=mean_kiuc.3 column=mean_band3
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="range_band3 double precision"
#set region
g.region raster=range_kiuc.3
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=range_kiuc.3 column=range_band3
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="nvar_band3 double precision"
#set region
g.region raster=var_kiuc.3
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=var_kiuc.3 column=nvar_band3
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="sd_band3 double precision"
#set region
g.region raster=stddev_kiuc.3
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=stddev_kiuc.3 column=sd_band3
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="Var_band3 double precision"
#set region
g.region raster=band3.texture_Var
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band3.texture_Var column=Var_band3
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="SV_band3 double precision"

```

```
#set region
g.region raster=band3.texture_SV
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band3.texture_SV column=SV_band3
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="SE_band3 double precision"
#set region
g.region raster=band3.texture_SE

#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band3.texture_SE column=SE_band3
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="SA_band3 double precision"
#set region
g.region raster=band3.texture_SA
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band3.texture_SA column=SA_band3
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="MOC2_band3 double precision"
#set region
g.region raster=band3.texture_MOC-2
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band3.texture_MOC-2 column=MOC2_band3
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="MOC1_band3 double precision"
#set region
g.region raster=band3.texture_MOC-1
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band3.texture_MOC-1 column=MOC1_band3
```

```
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="IDM_band3 double precision"
#set region
g.region raster=band3.texture_IDM
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band3.texture_IDM column=IDM_band3
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="Entr_band3 double precision"
#set region
g.region raster=band3.texture_Entr
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band3.texture_Entr column=Entr_band3
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="DV_band3 double precision"
#set region
g.region raster=band3.texture_DV
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band3.texture_DV column=DV_band3
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="DE_band3 double precision"
#set region
g.region raster=band3.texture_DE
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band3.texture_DE column=DE_band3
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="Corr_band3 double precision"
#set region
g.region raster=band3.texture_Corr
#Extract values from raster and upload them to attribute table (v.what.rast)
```

```
v.what.rast map=parcelaskaxil raster=band3.texture_Corr column=Corr_band3
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="Contr_band3 double precision"
#set region
g.region raster=band3.texture_Contr
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band3.texture_Contr column=Contr_band3
#Add column to vector attribute table
v.db.addcolumn map=parcelaskaxil column="ASM_band3 double precision"
#set region
g.region raster=band3.texture_ASM
#Extract values from raster and upload them to attribute table (v.what.rast)
v.what.rast map=parcelaskaxil raster=band3.textureASM column=ASM_band3
```