

UNIVERSIDAD DE CHILE  
FACULTAD DE CIENCIA AGRONÓMICAS  
ESCUELA DE PREGRADO

MEMORIA DE TÍTULO

**ANÁLISIS DE PREDICTORES AMBIENTALES DERIVADOS MEDIANTE  
TELEDETECCIÓN Y SU RELACIÓN CON EL CRECIMIENTO ANUAL  
PERIÓDICO DE RODALES DE *Nothofagus obliqua* EN LA PRECORDILLERA  
ANDINA DEL MAULE, CHILE.**

DIEGO GONZÁLEZ SANTANDER

Santiago, CHILE  
2017

UNIVERSIDAD DE CHILE  
FACULTAD DE CIENCIA AGRONÓMICAS  
ESCUELA DE PREGRADO

MEMORIA DE TÍTULO

**ANÁLISIS DE PREDICTORES AMBIENTALES DERIVADOS MEDIANTE  
TELEDETECCIÓN Y SU RELACIÓN CON EL CRECIMIENTO ANUAL  
PERIÓDICO DE RODALES DE *Nothofagus obliqua* EN LA PRECORDILLERA  
ANDINA DEL MAULE, CHILE.**

**ANALYSIS OF ENVIRONMENTAL PREDICTORS DERIVED BY REMOTE  
SENSING AND ITS RELATIONSHIP WITH PERIODIC ANNUAL GROWTH OF  
STANDS OF *Nothofagus obliqua* IN THE ANDEAN FOOTHILLS OF MAULE  
REGION, CHILE**

DIEGO GONZÁLEZ SANTANDER

Santiago, CHILE  
2017

**UNIVERSIDAD DE CHILE**  
**FACULTAD DE CIENCIAS AGRONÓMICAS**  
**ESCUELA DE PREGRADO**

**ANÁLISIS DE PREDICTORES AMBIENTALES DERIVADOS MEDIANTE  
TELEDETECCIÓN Y SU RELACIÓN CON EL CRECIMIENTO ANUAL  
PERIÓDICO DE RODALES DE *Nothofagus obliqua* EN LA PRECORDILLERA  
ANDINA DEL MAULE, CHILE.**

Memoria para optar al título profesional de:  
Ingeniero en Recursos Naturales Renovables.

**DIEGO GONZÁLEZ SANTANDER**

<b>Profesores Guías</b>	<b>Calificaciones</b>
Mauricio Galleguillos T. Ingeniero Agrónomo, M.S., Ph.D.	6,5
Patricio Corvalán V. Ingeniero Forestal, M.S.	6,8
<b>Profesores Evaluadores</b>	
Gerardo Soto M. Ingeniero Forestal, M.S., Dr.	6,3
Manuel Paneque C. Bioquímico, Dr.	6,8

**Santiago, Chile**

**2017**

## AGRADECIMIENTOS

Quisiera agradecer a mis profesores guía, primero a Mauricio Galleguillos por la enorme disponibilidad de enseñarme, retarme y empujarme cuando más lo necesité, sin usted nada de esto sería posible y le agradezco muchísimo, sobre todo porque es una de las personas de las que más he aprendido, a Patricio Corvalán que me acogió y con sabiduría y paciencia me enseñó materias de carácter forestal que yo no manejaba, incluso si se las preguntaba más de una vez, incluso me retó cuando realmente lo necesitaba y sin su apoyo y compañía no se habría logrado esto. Profes, fue una magnífica experiencia haber aprendido de ustedes, muchas, muchas gracias a ambos y discúlpenme por todos los atrasos y errores.

Segundo quiero agradecerles a todos mis amigos de la universidad y de la vida, la Nicky que está lejos, a la Gabi y al Pancho, al Feña que apaña en todo, al Ariel, al Zorro y a todos mis compañeros de la 2008, al Socri, al Inti y al Poggie que no los veo hace tiempo, a Mikel que me ayudo cuando estuve muy mal, a los cabros de rol, a Metal, Pini, Shade, Hans, a Pato mi amigo de hace tantas lunas y al Fernandito, que está lejos pero igual los quiero, al Riky, al Lord y al Lepez, a la Dani que nos hemos conocido hace poco, pero hemos hecho una amistad muy cercana.

Quiero agradecer a mi familia, en especial a mi hermana y su familia, Natucha, Nel, Sebita y Antonilla, que siempre han estado conmigo, los amo mucho.

Quiero darle las gracias a mis papas, Soledad y Miguel, sin ellos no estaría acá, aunque yo sé que los he decepcionado muchas veces, sé que están orgullosos de mí, no podría imaginar mi vida sin ustedes, son lo mejor del mundo, esto es para ustedes, este es el fruto de su amor y de su paciencia, espero que estén orgullosos de lo que sembraron porque yo estoy orgulloso de ustedes, son unos bakanes y son los mis ídolos y mi modelo a seguir.

Por ultimo y lo más importante le quiero agradecer a Esteban, mi compañero de vida, por ti he tratado de llegar a donde estoy, hemos pasado por muchas cosas, pero todas y cada una han valido la pena, gracias a ti no me siento solo nunca más, sé que estarás ahí cuando lo necesite, eres mi contención, mi compañero, mi amigo, mi fuente de vida, muchas gracias por protegerme, ayudarme, cocinarme comida rica, escucharme, soportarme, comprarme regalos de Zelda y todo lo que haces por mí.

## ÍNDICE

<b>RESUMEN</b> .....	<b>1</b>
<b>ABSTRACT</b> .....	<b>2</b>
<b>INTRODUCCIÓN</b> .....	<b>3</b>
OBJETIVOS.....	5
<i>Objetivo general</i> .....	5
<i>Objetivos específicos</i> .....	5
<b>MATERIALES Y MÉTODOS</b> .....	<b>7</b>
ÁREA DE ESTUDIO .....	7
ESTABLECIMIENTO DEL MODELO DE CRECIMIENTO .....	9
<i>Datos de terreno del inventario forestal</i> .....	9
<i>Diagrama de Manejo de densidad</i> .....	10
<i>Toma de muestras de tarugos</i> .....	11
<i>Procesamiento de los tarugos</i> .....	12
<i>Calculo de variables dasométricas de años anteriores</i> .....	14
<i>Calculo del Crecimiento Anual Periódico por hectáreas</i> .....	15
<i>Construcción del modelo de crecimiento</i> .....	15
OBTENCIÓN DE PREDICTORES AMBIENTALES DERIVADOS DE TELEDETECCIÓN .....	16
<i>Información derivada de teledetección pasiva</i> .....	16
<i>Información derivada de teledetección activa</i> .....	18
<i>Obtención de los predictores derivados de LiDAR y ASTER</i> .....	18
SELECCIÓN DE PREDICTORES .....	22
<i>Algoritmos de minería de datos</i> .....	22
<i>Comparación entre residuos y predictores ambientales</i> .....	24
<b>RESULTADOS Y DISCUSIÓN</b> .....	<b>25</b>
DIAGRAMA DE MANEJO DE DENSIDAD .....	25
SELECCIÓN DE PREDICTORES.....	26
COMPORTAMIENTO DE LOS PREDICTORES BAJO DIFERENTES NIVELES DE DENSIDAD DE RODAL.....	34
<b>CONCLUSIONES</b> .....	<b>37</b>
<b>BIBLIOGRAFÍA</b> .....	<b>38</b>
<b>APÉNDICES</b> .....	<b>47</b>
APÉNDICE I: CÁLCULO DE PREDICTORES LiDAR .....	47
<i>Predictores topográficos:</i> .....	47
<i>Predictores hidrológicos:</i> .....	48
<i>Predictores de geoforma:</i> .....	49

<i>Predictores de iluminación:</i> .....	50
APÉNDICE II: CÁLCULO DE PREDICTORES CON IMÁGENES ASTER .....	52
APÉNDICE III: CÁLCULO DE TEXTURAS DE PRIMER Y SEGUNDO ORDEN .....	53
APÉNDICE IV: LISTA DE PREDICTORES .....	55
APÉNDICE V: EVALUACIÓN DE SUPUESTOS DEL GLM .....	58
APÉNDICE VI: GRÁFICOS DESCRIPTIVOS DEL COMPORTAMIENTO DE LOS RESIDUOS DEL GLM .....	59
APÉNDICE VII: SUMARIO DE SALIDA DEL GLM .....	60
APÉNDICE VIII: MODELOS LINEALES ANALIZADOS .....	61
APÉNDICE IX: GRÁFICOS DE CORRELACIÓN DE PEARSON PARA DIFERENTES CRITERIOS DE DENSIDAD RELATIVA .....	62

## ÍNDICE DE CUADROS

Cuadro 1. Parámetros de ajuste para el Modelo de Chapman-Richards.

Cuadro 2. Parámetros estimados para el modelo de volumen bruto sólido con corteza.

Cuadro 3. Especificación de las escenas ASTER utilizadas.

Cuadro 4. Resumen de predictores ambientales derivados de las imágenes ASTER y LiDAR.

Cuadro 5. Listado de los 5 predictores seleccionados por el algoritmo RFE y su sigla asociada.

Cuadro 6. Listado de los 6 predictores seleccionados por el algoritmo Boruta y su sigla asociada.

Cuadro 7. Modelos lineales para la predicción de residuos del modelo en base a los predictores seleccionados por los algoritmos RFE-RF y Boruta.

Cuadro 8. Estadísticos de los análisis de correlación de Pearson.

Cuadro 9. Listado de predictores utilizados en los algoritmos de minería para determinar la relación con los residuos del modelo.

Cuadro 10. Evaluación de supuestos del GLM y validación del análisis de regresión.

Cuadro 11. Sumario de salida del ajuste cuadrático realizado al GLM.

Cuadro 12. Modelos lineales para los residuos del modelo en base a los predictores seleccionados por los algoritmos RFE y Boruta.

## ÍNDICE DE FIGURAS

- Figura 1. Área de estudio y ubicación de parcelas de muestreo. A) Ubicación geográfica del área de estudio. B) Fotografía aérea del área de estudio, límite predial y ubicación de parcelas de muestreo.
- Figura 2. Diagrama de flujo metodológico. Resumen de la metodología a seguir para el cálculo del crecimiento anual periódico por hectáreas y la creación del diagrama de manejo de densidades. En paréntesis se muestra la ecuación utilizada para el cálculo de la variable.
- Figura 3. Diseño de muestreo del inventario del año 2013. En A se muestra el diseño de las parcelas concéntricas, en B se muestra el “cluster” de parcelas como unidad muestral y la grilla de 200 metros.
- Figura 4. Diagrama de manejo de la densidad para pino Oregón.
- Figura 5. Muestra de tarugo montada.
- Figura 6. Análisis de los tarugos de *Nothofagus obliqua*, identificación de la madera tardía, madera temprana y medición de anillos de crecimiento.
- Figura 7. Diagrama de flujo metodológico. Resumen de la metodología a seguir para el análisis de los predictores de relevancia para el crecimiento anual periódico por hectáreas. En paréntesis se muestra el número de predictores obtenidos en cada paso.
- Figura 8. Modelo lineal generalizado entre el crecimiento anual periódico por hectáreas ( $m^3 ha^{-1} año^{-1}$ ) y el índice de densidad relativa (%).
- Figura 9. RFE-RF. El número de predictores preliminares elegidos por el algoritmo que disminuyen al máximo el RMSE está marcado con un círculo rojo en el primer gráfico ( $n=62$ ) y en el segundo, en el círculo rojo se muestra la selección acotada según el criterio de Hair et al. ( $n=5-6$ ).
- Figura 10. Matriz de correlación entre los predictores finales seleccionados del algoritmo RFE-RF. Los asteriscos rojos representan el nivel de significancia de la correlación (Código Significancia para el p-value del coeficiente de correlación de Pearson: 0 = ‘\*\*\*’;  $0,001 < ‘**’$ ;  $0,01 < ‘*’$ ;  $0,05 < ‘.’$ ).
- Figura 11. Grafico resultante del algoritmo Boruta, los diagramas de caja azules corresponden al mínimo, promedio y máximo “Z-scores” o unidades tipificadas de variables sombra, los diagramas de caja rojos, amarillos y verdes son los “Z-scores” de los atributos rechazados, tentativos y confirmados respectivamente.
- Figura 12. Matriz de correlación entre los predictores finales seleccionados del algoritmo Boruta. Los asteriscos rojos representan el nivel de significancia de la correlación (Código

Significancia para el p-value del coeficiente de correlación de Pearson: 0 = ‘\*\*\*’; 0,001 < ‘\*\*’; 0,01 < ‘\*’; 0,05 < ‘.’).

Figura 13. Mapa de distribución del máximo de GNDVI en el área de estudio.

Figura 14. Mapa de distribución de la Amplitud de Fracción Evaporativa en el área de estudio.

Figura 15. Gráficos de correlación de Pearson para un criterio de densidad relativa, en A) el máximo de GNDVI y los residuos para densidades relativas inferiores a 40%; en B) amplitud de fracción evaporativa y los residuos del modelo para densidades relativas superiores a 60%; en C) el máximo de GNDVI y los residuos para densidades relativas superiores a 80%.

Figura 16. Gráficos descriptivos del comportamiento de los residuos. A) Grafico de predichos vs residuos. B) “Index Plot” que muestra la influencia de los datos residuales en la regresión cuadrática según el orden en el cual los datos fueron ordenados. C) Histograma con distribución normal de los residuos studentizados. D) “Q-Q Plot” de los residuos ordenados vs cuartiles teóricos de comportamiento normal.

Figura 17. Gráficos de correlación para un criterio de densidad relativa menor a 40%, en A) amplitud de fracción evaporativa y los residuos del modelo; en B) el máximo de GNDVI y los residuos.

Figura 18. Gráficos de correlación para un criterio de densidad relativa entre el 40% y el 80%, en A) amplitud de fracción evaporativa y los residuos del modelo; en B) el máximo de GNDVI y los residuos.

Figura 19. Gráficos de correlación para un criterio de densidad relativa mayor a 80%, en A) amplitud de fracción evaporativa y los residuos del modelo; en B) el máximo de GNDVI y los residuos.

Figura 20. Gráficos de correlación para un criterio de densidad relativa mayor a 60%, en A) amplitud de fracción evaporativa y los residuos del modelo; en B) el máximo de GNDVI y los residuos.

## ÍNDICE DE ABREVIATURAS

AIC	: “Akaike Information Criterion”
ASTER	: “Advanced Spaceborne Thermal Emission and Reflection Radiometer”
BIC	: “Bayesian Information Criterion”
CAP	: Crecimiento Anual Periódico
DAP	: Diámetro a la Altura de Pecho
DEM o MDE	: Modelo Digital de Elevación, “Digital Elevation Model” (en inglés)
DMD	: Diagrama de Manejo de Densidad
DR	: Densidad Relativa
EF	: Fracción Evaporativa
ETR	: Evapotranspiración Real
GLCM	: “Grey Level Co-occurrence Matrix”
GLM	: Modelo Lineal Generalizado, “Generalized Linear Model” (en inglés)
GNDVI	: “Green Normalized Difference Vegetation Index”
Hdom	: Altura Dominante
KST inglés)	: Temperatura cinética de superficie, “Kinetic Surface Temperature” (en inglés)
LiDAR	: “Light Detection and Ranging”
MDC	: Modelo Digital de Copas
MDC	: Modelo Digital de Copas
MDS	: Modelo Digital de Suelo
MDT	: Modelo Digital de Terreno
MrRTF	: “Multi-resolution index of Ridge Top Flatness”
MrVBT	: “Multi-resolution index of Valley Bottom Flatness”
NDVI	: “Normalized Difference Vegetation Index”

NHa : Numero de Arboles por Hectárea  
RF : “Random Forest”  
RFE : “Recursive Feature Elimination”  
RMSE : Raíz del Error Cuadrático Medio



## RESUMEN

El roble (*Nothofagus obliqua* (Mirb.) Oerst.) es una de las especies arbóreas más abundantes en los bosques del centro-sur de Chile, y posee un gran potencial de producción forestal, sin embargo, su distribución se ha visto seriamente amenazada debido a la habilitación de tierras agrícolas y plantaciones forestales exóticas. El crecimiento de esta especie se evalúa usualmente mediante modelos dasométricos basados en información *in-situ*, sin embargo, el uso de la teledetección se muestra como una valiosa alternativa a la hora de representar procesos biofísicos vinculados al crecimiento de la vegetación. El propósito de esta investigación es analizar la información del crecimiento volumétrico de rodales de *Nothofagus obliqua* con información derivada de sensores remotos como predictores de las condiciones ambientales en la precordillera de los Andes de la Región del Maule. Se definieron 100 parcelas de al menos 200 m<sup>2</sup> distribuidos en diferentes índices de ocupación donde se tomaron datos dasométricos y dendrocronológicos para el cálculo del crecimiento. Se evaluaron 17 predictores topográficos derivados de datos LiDAR y tres predictores espectrales, GNDVI, NVDI y fracción evaporativa derivadas de seis imágenes del sensor ASTER que abarcaban un periodo de 10 años. De estos se derivaron además estadígrafos básicos además de matrices de ocurrencia y co-ocurrencia generando un total de 74 predictores espacio-temporales. Un modelo de regresión que representa el diagrama de densidad de manejo fue generado con los datos de crecimiento anual periódico y de densidad relativa ( $R^2=0,91$ ). Los residuos de este modelo fueron utilizados como variable dependiente en la predicción ya que representan la incerteza de este modelo presumiblemente asociada a la condición de sitio. A la variable dependiente se le aplicaron técnicas de minería de datos para determinar aquellos predictores que presentaban una correlación significativa. Se determinaron 8 predictores, siendo el máximo de GNDVI y amplitud de fracción evaporativa, en conjunto, los que explicaban de mejor manera el comportamiento de los residuos. El primer predictor se asocia a los procesos de absorción de radiación fotosintéticamente activa mientras que el segundo explica las condiciones de estrés hídrico del sitio, dos factores relacionados directamente con el crecimiento de los árboles. Estas relaciones fueron analizadas bajo distintos rangos de densidad relativa. Sobre 60%, la amplitud de fracción evaporativa muestra un coeficiente de correlación de Pearson (R) de 0,39. Para el predictor máximo de GNDVI la correlación fue de 0,55 y 0,44 para densidades inferiores al 40% y superiores al 80% respectivamente. En otros rangos de densidades relativas, para ambos predictores, no se obtuvieron correlaciones significativas. Los predictores espacio-temporales fueron las que mostraron mayor correlación con los datos de crecimiento mientras que la los predictores estructurales y morfométricos derivados de la información LiDAR fue descartada.

**Palabras Claves:** Roble, Crecimiento, LiDAR, ASTER, índices de vegetación, Fracción evaporativa.

## ABSTRACT

Oak (*Nothofagus obliqua* (Mirb.) Oerst.) is one of the most abundant tree species in the South Central forests of Chile, and has an important forestry and logging potential, nevertheless its distribution has been seriously threatened due to replacement by agricultural and forest exotic plantations. This species growth is usually evaluated by means of dasometric models based in on-site data, however the use of remote sensing is shown as a valuable alternative when representing biophysical processes linked to the growth of vegetation. The purpose of this research is to analyze and compare information of volumetric growth in stands of *Nothofagus obliqua* with information derived from remote sensing which give explanatory predictors of structural and environmental conditions in the Andes foothills of Maule region. Sampling of 100 plots of at least 200m<sup>2</sup> that were distributed at different rates of relative density where dendrochronology and forest mensuration data were taken for the calculation of stand growth. 17 topographic predictors derived from LiDAR and three spectral predictors, GNDVI, NVDI and evaporative fraction derived from six images of ASTER sensor covering a 10-year period were evaluated. Of these predictors were derived basic statistics and also occurrence and co-occurrence matrix, generating 74 spatio-temporal predictors. A regression model representing the density management diagram was generated using periodic annual growth and relative density data ( $R^2 = 0.91$ ). Residuals from this model were used as dependent variable in predicting as they represent the uncertainty of this model presumably associated with the condition of site and data mining techniques were applied to determine which environmental predictors were significantly correlated. Eight predictors had significant correlation with the residuals, being the GNDVI's maximum and the evaporative fraction's range selected together as the best predictors. The first predictor is associated with the processes of absorption of photosynthetically active radiation while the second explains the water stress conditions of the site, two factors directly related to the growth of trees. These relationships were analyzed under different ranges of relative density. For densities higher than 60%, the evaporative fraction's range shows a Pearson correlation coefficient (R) of 0.39, while the GNDVI's maximum shows correlations of 0.55 and 0.44 for densities below 40% and above 80% respectively. The spatio-temporal predictors were those that showed higher correlation with growth data while the structural and morphometric predictors provided by LiDAR were discarded.

**Keywords:** Oak, Growth, LiDAR, ASTER, spectral vegetation indices, Evaporative Fraction.

## INTRODUCCIÓN

El roble (*Nothofagus obliqua* (Mirb.) Oerst.), en conjunto con laurel y lingue, forman la asociación más común y abundante en la región centro-sur de Chile (San Martín et al., 1991). Este tipo de composición vegetacional ha visto reducido una gran parte de la superficie que originalmente ocupaba, debido principalmente a la sustitución por tierras agrícolas, forestales y ganaderas (San Martín et al., 1991; Echeverría et al., 2006). Con respecto a su explotación forestal, su madera se considera según Rodríguez et al. (1983) “de buena calidad, de hermosa veta y con gran contenido de taninos que le confieren una gran durabilidad” y es utilizada generalmente en construcción de estructuras y muebles que requieren solidez y durabilidad, que en consecuencia ha generado una disminución en su potencial como recurso natural del país (Rodríguez et al., 1983).

El crecimiento de las especies forestales está determinado por varios factores: la capacidad genética de la especie, la competencia entre individuos, las características medioambientales específicas del sitio, variables topográficas y la altitud. Según Ginrich (1967) el crecimiento diametral de los árboles es lento cuando la competencia por el espacio es severa, y es rápida cuando la competencia por el espacio es mínima. Ginrich (1967) realiza una observación a los estudios que involucran a más de una especie, ya que, al existir diferentes tasas de crecimiento entre ellas, se requiere de un análisis de información más específico por especie lo que agrega una variabilidad a los modelos de manejo de densidad, y solo los recomienda para casos con extremas condiciones de irregularidad en la composición de especies.

Los Diagramas de Manejo de Densidad (en adelante DMD) representan gráficamente la relación entre densidad, altura dominante, volumen medio y número de árboles por hectárea (Archibald y Bowling, 1995; Newton, 1997; Valbuena et al., 2008; Corvalán, 2015). Estos DMD están basados en la ley de auto-raleo y la construcción de niveles de densidad que permiten definir condiciones de crecimiento de rodal y dan por resultado el crecimiento estimado en cada etapa de desarrollo determinado por el nivel de espaciamiento o densidad de rodal y la competencia que se genera entre individuos (Newton, 1997; Ginrich, 1967; Drew y Flewelling, 1979).

Según Ginrich (1967) y Drew y Flewelling (1979) un DMD está compuesto en su forma más básica por dos líneas que fijan un rango de densidad el cual se encuentra creciendo a su máximo potencial. El límite superior, llamado línea de máxima relación tamaño-densidad o línea de auto-raleo es el nivel al cual la ocupación del sitio está 100% completa y está representado por rodales naturales no perturbados donde el árbol promedio tiene el mínimo espacio que necesita para sobrevivir y su crecimiento es a expensas de la mortalidad de otro individuo (Yoda et al., 1963; Ginrich, 1967; Drew y Flewelling, 1979; White, 1981; Weller, 1987; Zeide, 1987). Reineke (1933) con su modelo de tamaño-densidad, el cual es utilizado, cuestionado y modificado por Navarro et al. (2011), Gezan et al. (2007) y Chauchard et al. (2001) para la construcción de la línea de auto-raleo de diversas especies, es quien estableció el índice de densidad de rodal.

La línea de cierre de copas, es aquella condición donde los árboles crecen de manera libre y desarrollan todo su potencial de crecimiento, ya que disponen de recursos sin limitación, en este punto, el dosel se cierra y comienza la competencia entre copas sin generar mortalidad (Krajicek y Brinkman, 1957; Gezan et al., 2007). Ginrich (1967) establece que la competencia comienza cuando un rodal alcanza el punto en que soporta la máxima cantidad de árboles de crecimiento libre dentro de él, independiente de la edad del rodal y de la calidad del sitio (Krajicek et al., 1961).

Según Corvalán (2015), citando a Newton (1997), los índices de Densidad Relativa (en adelante DR) se expresan como distintos niveles de ocupación en relación con un rodal de igual diámetro medio cuadrático en la línea de auto-raleo, y, en conjunto con la calidad del sitio, explican la dependencia temporal de estos procesos. Consecuentemente los DMD se pueden utilizar para predecir la trayectoria de la densidad de distintas opciones de manejo. Los DMD son ampliamente utilizados para regímenes silvícolas de especies japonesas, norteamericanas y canadienses (Navarro et al., 2010). En Chile, su uso aún no es extensivo. Su uso ha sido documentado por Gezan et al. (2007) quienes utilizaron diagramas de manejo en renovales del tipo forestal roble-raulí-coigüe, por Navarro et al. (2011) quienes lo utilizaron para *Drymis winteri*, y recientemente Müller-Using et al. (2013) y Corvalán (2015) quienes lo utilizaron para *Nothofagus obliqua*.

La información medioambiental del sitio vinculada al crecimiento de árboles puede ser derivada a partir del análisis de imágenes satelitales obtenidas en fechas donde se registren notoriamente procesos del funcionamiento de los ecosistemas, como la productividad primaria (Paruelo, 2008) o la Evapotranspiración real (Olivera-Guerra et al., 2014; Hais y Kucera, 2009). A su vez, el uso de información de alta resolución obtenida mediante sensores LiDAR (“Light Detection and Ranging”), entrega información de la topografía bajo el dosel como también análisis de diversos atributos de las formaciones forestales, como estructura, distribución y altura dominante (Dees et al., 2012). Estas informaciones en su conjunto han permitido modelar diversas propiedades de ecosistemas forestales entre las cuales se destaca la estimación de biomasa (Valencia, 2012; Fassnatch et al., 2014; Laurin et al., 2011; Proisy et al., 2007) y de la biodiversidad (Ewers et al., 2005; Carlson et al., 2007; Kalacska et al., 2007; White et al., 2010; Leutner et al., 2012, Ceballos et al. 2015). Lopatin et al. (2006) indican que la alta frecuencia temporal, la disponibilidad de series de imágenes satelitales por largos periodos de tiempo y que posean diferentes bandas del espectro hacen a esta información útil para monitorear cambios en la vegetación, la cual se basa en la respuesta de la cobertura vegetal a la radiación en el espectro electromagnético visible e infrarrojo cercano.

Para poder comparar la información que determina las condiciones ambientales del sitio extraída mediante teledetección de los rodales en estudio es necesario entonces volver al pasado y poder reconstruir las medidas dasométricas de los rodales en las fechas donde la información fue rescatada por el satélite. Esta información dasométrica se puede rescatar mediante la dendrocronología, técnica que consiste en la comparación de los anillos anuales de crecimiento de distintos individuos mediante la extracción de un tarugo, muestra cilíndrica

de madera y corteza del espécimen (Wolodarsky-Franke y Lara, 2003). La información obtenida en la comparación de anillos puede interpretarse como variaciones climáticas locales, estrés del individuo por falta de agua y cambios notorios en las estaciones del año, el ancho a su vez muestra su crecimiento a través del tiempo, o variaciones en las condiciones del sitio (Wolodarsky-Franke y Lara, 2003). Según Morales et al. (2001) “La dendrocronología es una herramienta de gran utilidad para reconstruir, con resolución anual, el crecimiento de los árboles”. Morales (2001) también añade que “La presencia de anillos de crecimiento demarcados es una característica bien definida en el leño de la mayoría de las especies arbóreas y arbustivas que crecen en las regiones templadas y frías donde existe una fuerte estacionalidad climática que induce un período de reposo invernal en el crecimiento”. Lara et al. (2005) han descrito a la cordillera de Los Andes como una excelente fuente de información paleontológica y medioambiental debido a que sus sistemas físicos y biológicos son altamente sensibles a variaciones climatológicas como también a perturbaciones generadas por el ser humano, a su vez añade que el uso de la dendrocronología provee una oportunidad para estudiar estas señales climáticas alojadas en los anillos de crecimiento a lo largo de variados rangos espaciales y escalas temporales.

Recientemente Corvalán (2015) ha puesto a prueba modelos de altura, volumen y Diámetro a la Altura de Pecho (en adelante DAP) enfocados en la especie *Nothofagus obliqua* que permiten calcular estas variables dasométricas para años anteriores al muestreo usando datos dendrocronológicos, datos necesarios para el cálculo del crecimiento anual periódico por hectáreas y la construcción de los DMD. La presente investigación busca analizar y comparar los resultados de los modelos de crecimiento de *Nothofagus obliqua* generados por Corvalán (2015) en bosques de la zona central de Chile, con predictores ambientales del sitio obtenidos con teledetección activa y pasiva.

## Objetivos

### Objetivo general

El propósito de esta investigación es analizar y relacionar la información del crecimiento volumétrico de renovales de *Nothofagus obliqua* obtenida *in-situ* con información derivada de técnicas de teledetección como predictores de las condiciones ambientales de los rodales en que se desarrollan.

### Objetivos específicos

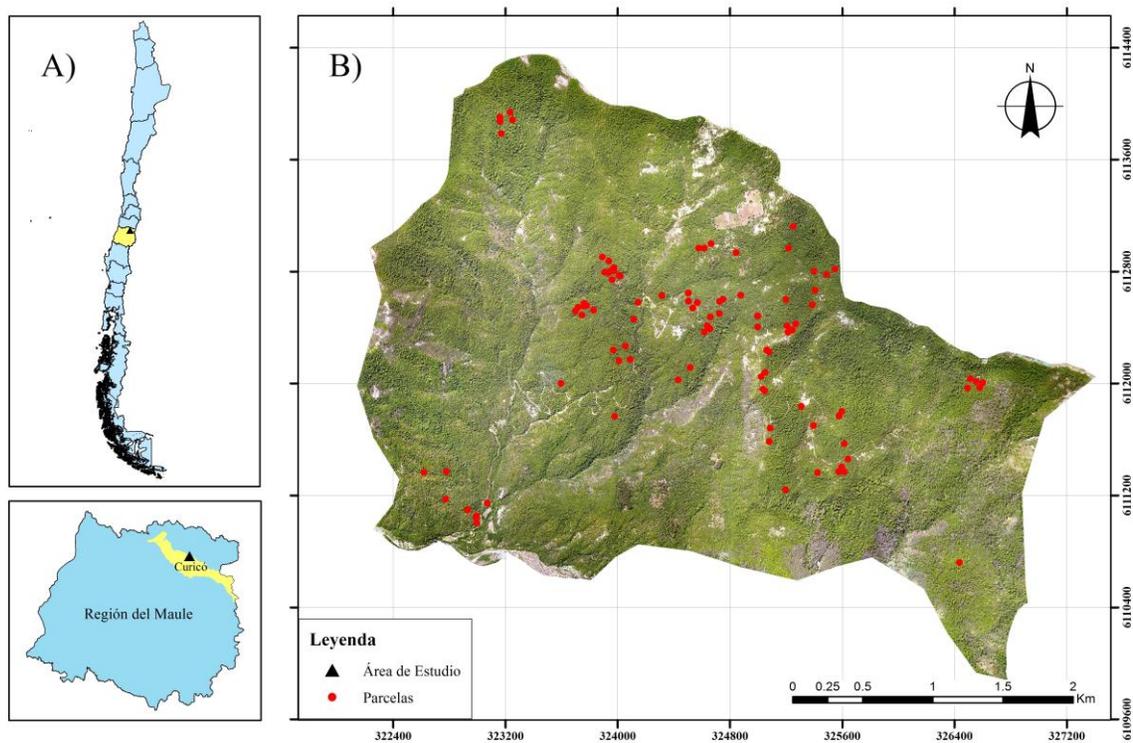
- Determinación del crecimiento anual periódico por hectáreas de renovales de *Nothofagus obliqua* mediante mediciones *in-situ* basadas en técnicas dendrocronológicas y modelos estimadores de variables dasométricas.

- Estimación de predictores del sitio donde se ubican rodales de *Nothofagus obliqua* a partir de técnicas de teledetección activa y pasiva.
- Analizar mediante técnicas de minería de datos cuales de los predictores generados tiene una mayor relación estadísticamente significativa con el crecimiento anual periódico por hectáreas de los rodales en 10 años.

## MATERIALES Y MÉTODOS

### Área de estudio

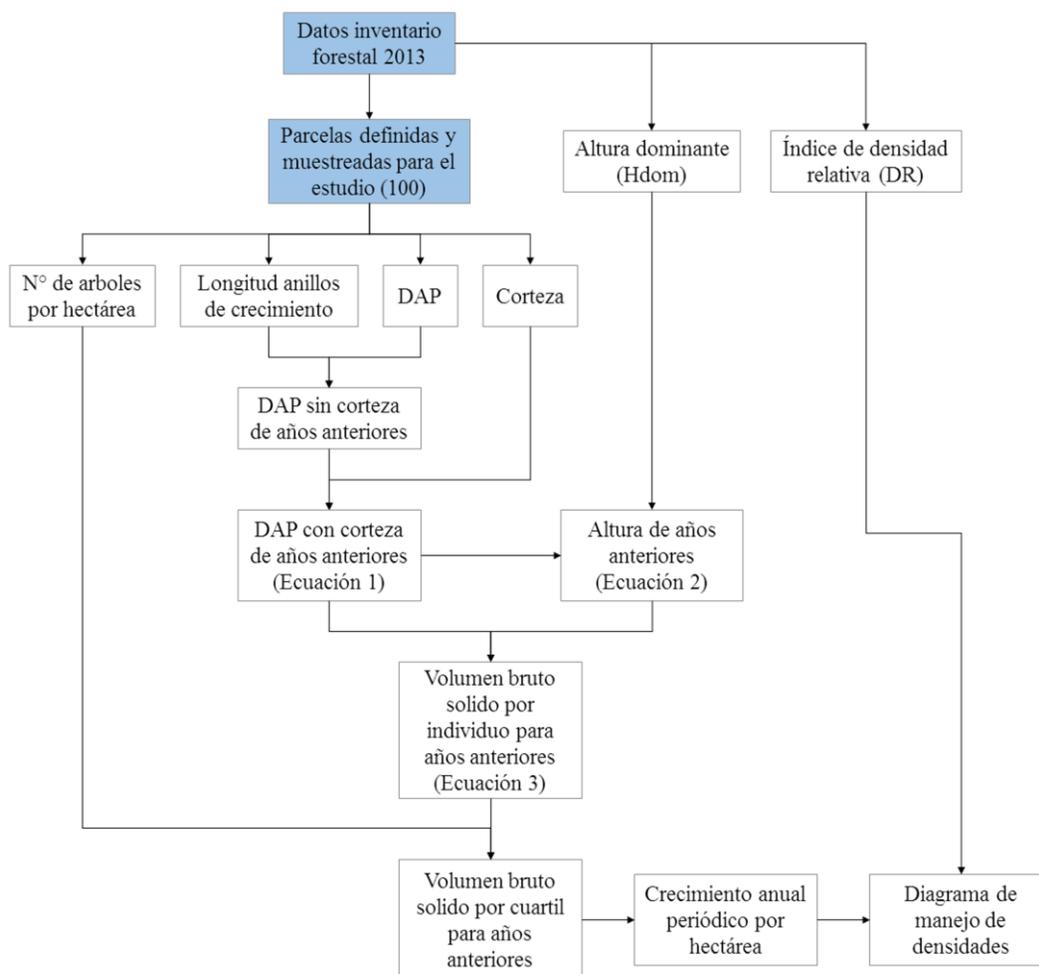
El área de estudio se encuentra en la localidad de Monte Oscuro, Cuenca del Río Mataquito, Subcuenca del Estero Upeo, en la Comuna de Curicó, Región del Maule en las coordenadas 35°07'00" S, 70°55'30" O. Tiene una superficie aproximada de 1.295 hectáreas, muestra una exposición sur predominante y una topografía heterogénea con variaciones de pendiente. Este sector se asocia al piso bioclimático templado submediterráneo con temperaturas promedio que van desde 8°C entre junio y agosto a los 18°C entre diciembre y febrero, un promedio anual de 1.000 mm de precipitación la cual se concentra entre los meses de abril y octubre y una altitud promedio de 1.075 msnm (Luebert y Pliscoff, 2006). Según Luebert y Pliscoff (2006) en el área de estudio existe un bosque secundario caducifolio dominado por roble (*Nothofagus obliqua* (Mirb.) Oerst.), mezclado con especies esclerófilas como quillay (*Quillaja saponaria* Mol.), peumo (*Cryptocarya alba* (Mol.) Looser), naranjillo (*Citronella mucronata* (Ruiz & Pav.) D. Don), y litre (*Lithrea caustica* (Mol.) Hook. et Arn.), asociación que coincide con el piso vegetacional "Bosque caducifolio mediterráneo andino de *Nothofagus obliqua* y *Austrocedrus chilensis*", según Donoso (1995) es común encontrar asociaciones con Ciprés de la Cordillera (*Austrocedrus chilensis* (D. Don) Pic.Serm. & Bizzarri) y tipo forestal esclerófilo. El suelo del área de estudio se compone principalmente de inceptisoles o trumaos, morfogenéticamente, la formación de los suelos de la precordillera es producto de materiales de depósito de morrenas, acarreo fluviales, glaciofluviales, depósitos lacustres y glaciolacustres que han sido cubiertos por capas de ceniza volcánica, a su vez presenta una textura franco-limosa, alto contenido orgánico y baja disponibilidad de fósforo y nitrógeno (CONAF, 1999 citado por Corvalán, 2015). En la Figura 1 se muestra un mapa con el área de estudios y la ubicación de las parcelas de muestreo.



**Figura 1.** Área de estudio y ubicación de parcelas de muestreo. A) Ubicación geográfica del área de estudio. B) Fotografía aérea del área de estudio, límite predial y ubicación de parcelas de muestreo.

## Establecimiento del modelo de crecimiento

Para un mejor entendimiento de los procedimientos que se presentan a continuación, en la Figura 2 se muestra un diagrama de flujo que muestra el orden metodológico utilizado y la fuente de los datos.

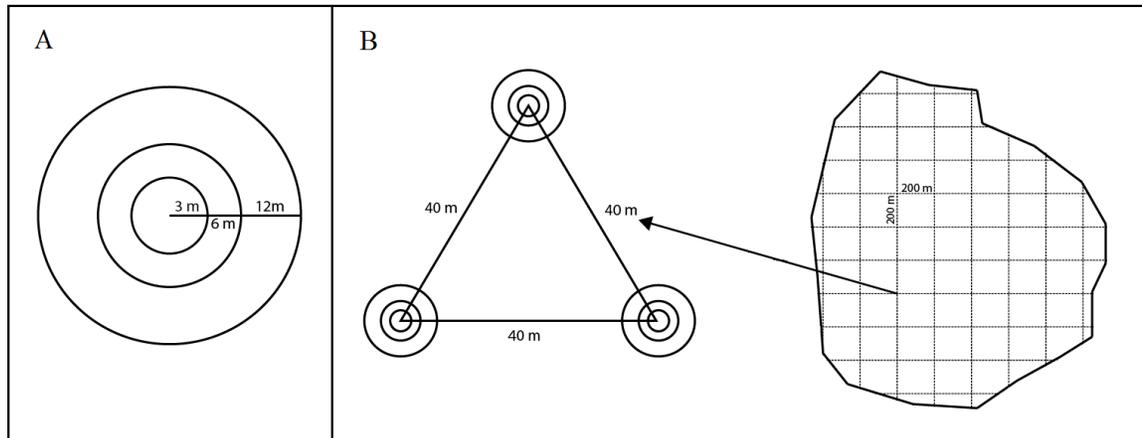


**Figura 2.** Diagrama de flujo metodológico. Resumen de la metodología a seguir para el cálculo del crecimiento anual periódico por hectáreas y la creación del diagrama de manejo de densidades. En paréntesis se muestra la ecuación utilizada para el cálculo de la variable.

### Datos de terreno del inventario forestal

Para la selección de las parcelas de muestreo, se utilizó primeramente el inventario forestal realizado el año 2013 en el área de estudio, en este inventario fueron medidas 151 parcelas

concéntricas agrupadas en “clusters” de tres parcelas ubicadas a 40 metros de distancia de centro a centro formando un triángulo equilátero, los radios de los círculos concéntricos son de 3, 6 y 12 metros, donde se midieron arboles de DAP mayor o igual a 10, 15 y 20 cm respectivamente. Estos “clusters” fueron distribuidos a lo largo del predio en forma de grilla y ubicados en intersecciones de líneas imaginarias horizontales y verticales separadas cada 200 metros en los rodales de interés como se muestra en la Figura 3.



**Figura 3.** Diseño de muestreo del inventario del año 2013. En A se muestra el diseño de las parcelas concéntricas, en B se muestra el “cluster” de parcelas como unidad muestral y la grilla de 200 metros.

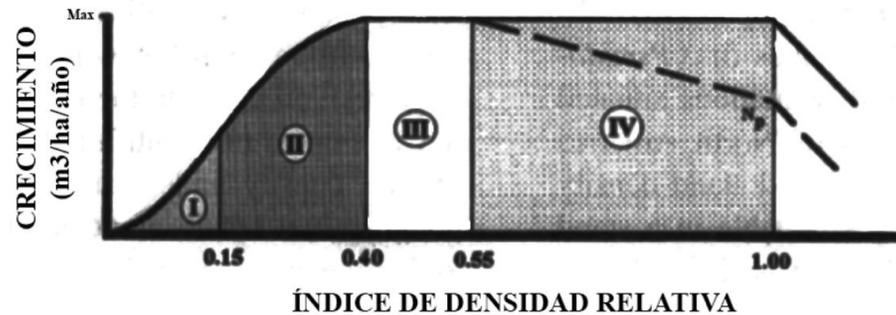
Fuente: Corvalán (2015).

Los datos tomados en cada parcela son los siguientes, DAP sobre 10 cm, dependiendo del radio concéntrico, altura de cada individuo, las especies y observaciones sanitarias (enfermedades o síntomas de mortalidad) (Corvalán, 2015).

Este inventario fue utilizado como fuente de datos complementario a los tomados en terreno, y solo se utilizaron datos que cumplieran con los criterios de selección aplicados a las parcelas de densidad relativa y auto-raleo que se presentarán más adelante (Corvalán, 2015). A su vez de este inventario se tomaron los datos de altura dominante y densidad relativa tal y como indica Corvalán (2015) (Figura 2).

### Diagrama de Manejo de densidad

Para construir el DMD descrito por Langsaeter (1941, citado por Newton, 1997 y Smith et al., 1997) se requiere de un muestreo en los niveles donde la ocupación del sitio este completa, estableciendo curvas de máxima relación tamaño-densidad o de auto-raleo (Gingrich, 1967), y en las líneas inferiores de densidades relativas. Una expresión gráfica del DMD a construir se presenta en la Figura 4.



**Figura 4:** Diagrama de manejo de la densidad para pino Oregón.

Fuente: Traducido de Newton (1997).

La Figura 4, que es una ilustración de la teoría de Langsaeter (1941, citado por Newton, 1997 y Smith et al., 1997), representa en (I) el crecimiento por unidad de área proporcional a la densidad, comportamiento visto en rodales que están en un estado previo a la línea de cierre de copas. En (II) el crecimiento por unidad de área es proporcional a la densidad, pero el crecimiento individual declina, debido al inicio de la competencia, en (III) el crecimiento no es proporcional a la densidad y en (IV) es la zona donde el crecimiento por unidad de área es invariante a la densidad, sin embargo, la producción neta ( $N_p$ ) declina con el aumento de la densidad (Corvalán, 2015).

### Toma de muestras de tarugos

Se utilizaron los datos del inventario forestal (Corvalán 2015), eligiendo parcelas que así definir áreas de densidades de árboles donde realizar la toma de muestras, las cuales cumpliesen con los siguientes criterios de selección: datos de parcelas con más de 100 árboles por hectárea y que tuvieran una abundancia de *Nothofagus obliqua* superior al 60% considerando árboles con DAP superior a 10 cm. Para aumentar las parcelas y tener un espectro de amplia densidad relativa se seleccionaron además, otros sitios de interés utilizando una ortofoto obtenida en el vuelo LiDAR donde se apreció, según criterio experto, evidencia de densidad de bosques formando rodales de interés, información que fue cruzada con datos de altura dominante obtenida del Modelo Digital de Copas (en adelante MDC) creado para el área de estudio por Corvalán (2015) para abarcar la mayor cantidad de condiciones de altura y densidad posible. A su vez se descartaron parcelas en áreas de difícil acceso debido a la dificultad y riesgo que conllevaba la toma de muestras, aquellas con pendientes mayores a 45° y áreas intervenidas por el hombre (zonas incendiadas, áreas pobladas y plantaciones forestales y agrícolas). Se utilizó la información espacial del modelo digital de terreno (en adelante MDT) y la ortofoto del área de estudio para la selección de áreas intervenidas y criterio experto para la accesibilidad.

En terreno se revisaron las condiciones de los rodales seleccionados previamente, así, se definieron 30 parcelas de superficie y forma variable no inferior a los 200 m<sup>2</sup> que no

presentaron efecto borde, distribuidas idealmente en todas las clases de altura que cuenten con cobertura de copa completa, con estructura homogénea, que presenten evidencia de mortalidad y que no presenten signos de poda u otras perturbaciones (Roach, 1977). Estas parcelas corresponden a la línea de auto-raleo, la cual representa el 100% de ocupación del sitio o de máxima densidad del rodal donde la competencia es máxima y existe una alta tasa de mortalidad de individuos (Gingrich, 1967).

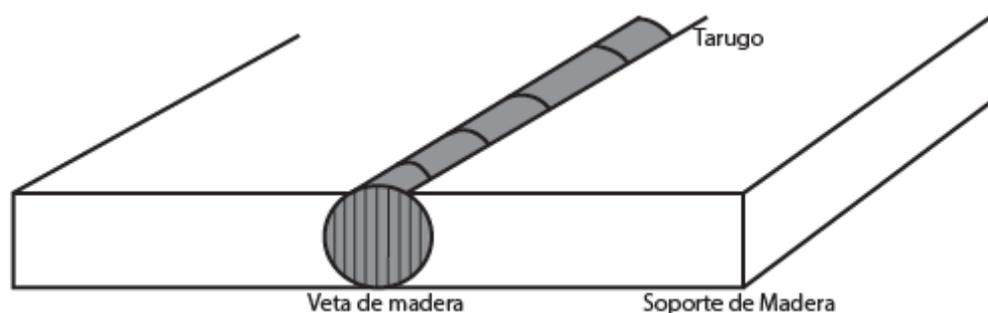
Luego se definieron 70 parcelas de radio fijo, con una superficie de 200 m<sup>2</sup> las cuales fueron seleccionadas utilizando dos criterios: altura dominante y densidad de la parcela, información obtenida del inventario forestal previamente mencionado (Corvalán, 2015). Estos datos se encuentran entre la línea de cierre de copas y la línea de auto-raleo, denominadas parcelas de densidad relativa.

A todos los árboles se les realizaron las siguientes mediciones: el DAP tomado dos veces buscando el eje mayor y el menor, medidos con una forcípula marca Haglöf® modelo Mantax Blue; la altura, con un clinómetro; se identificó la especie, la vitalidad (si el individuo estaba vivo o muerto) y su origen. La ubicación de cada parcela fue registrada con un GPS marca Garmin® modelo GPSmap 62s.

Para cada parcela se determinó el número de árboles por hectárea, los cuales se ordenaron por DAP de mayor a menor y se dividieron los datos en cuartiles, el individuo de roble que se encontró al centro del cuartil fue el elegido para extraer un tarugo o testigo, el cual fue extraído con un taladro de incremento marca JIM-GEM®, a la altura del pecho (1,3m), guardado y sellado dentro de una pajilla, etiquetado y medido su espesor de corteza húmeda (Schweingruber, 1993).

### Procesamiento de los tarugos

Cada tarugo extraído fue montado en soportes de madera y fijados a ellos con cola fría, la veta de madera fue puesta de manera vertical al soporte para que así la superficie que muestra los anillos de crecimiento esté expuesta directamente (Schweingruber, 1993), tal y como se muestra en la Figura 5:

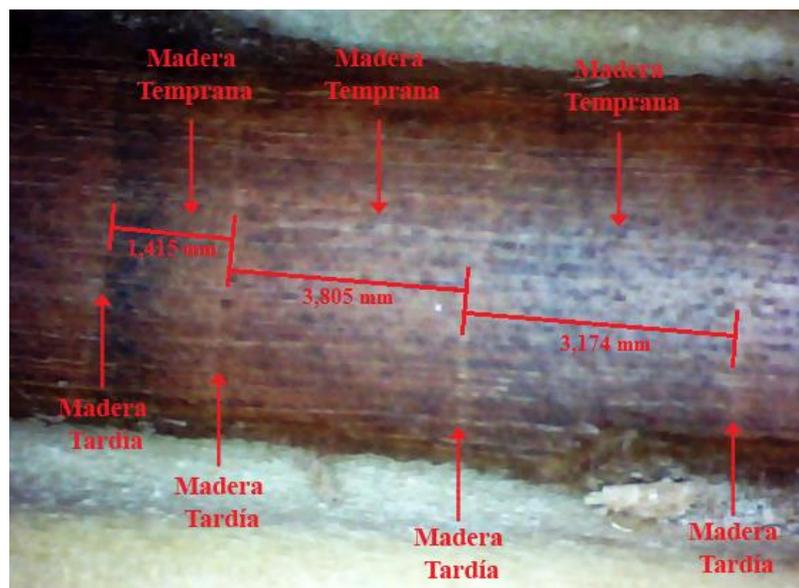


**Figura 5.** Muestra de tarugo montada.

Fuente: Schweingruber (1993).

Luego de montar y dejar secar tanto la madera como el pegamento, se cortó la superficie expuesta del tarugo con un cuchillo cortante para así exponer las células de la madera. Este proceso permite identificar más fácilmente la delimitación de los anillos de crecimiento sobre todo cuando estos son difusos o muy porosos (Schweingruber, 1993). Finalmente, cada tarugo fue sometido a un proceso de pulido, esto vuelve la superficie expuesta más lisa y a su vez empuja polvillo del cepillado dentro del lumen, lo cual vuelve a las paredes celulares oscuras, pudiendo distinguir con mayor facilidad las células de madera temprana y diferenciarla de la madera tardía (Schweingruber, 1993). El pulido fue realizado con papel lija de diferentes grados, inicialmente 100, luego 200, 320 y se finalizó el pulido con 400 grados tal y como recomienda Schweingruber (1993).

Una vez pulidas las muestras se utilizó una lupa USB Digital Microscope 400X marca CoolingTech para tomar las mediciones de ancho de los anillos de crecimiento, estas mediciones fueron hechas con una precisión en decimas de micrón. Los anillos fueron identificados y medidos buscando a través de la veta de madera los tejidos de madera temprana (o de primavera) y madera tardía (o de otoño), tratando de siempre evitar los anillos anuales falsos que Raven et al. (1992) describen como marcas o coloración de la madera entre los anillos que se forma por algún evento ambiental o perturbación que afectó el crecimiento, como es el cambio súbito de agua disponible, cambios en la cantidad de luz, daños estructurales o cambios químicos en el ambiente (Schweingruber, 1993). La madera temprana corresponde al crecimiento del árbol al inicio del periodo primaveral, donde se reinician las actividades vitales post invierno, y se caracteriza por su coloración clara y baja densidad, a su vez, la madera tardía al poseer células más estrechas y con paredes más engrosadas, su densidad es mayor y se visualiza una coloración más oscura. En la zona donde la madera tardía se adosa a la madera temprana el cambio es abrupto y perceptible, en la Figura 6 se muestra la identificación de la madera y la medición de los anillos de crecimiento.



**Figura 6.** Análisis de los tarugos de *Nothofagus obliqua*, identificación de la madera tardía, madera temprana y medición de anillos de crecimiento.

Se definió como periodo de crecimiento del estudio entre los años 2003 (desde el verano-otoño de 2003) y 2012 (hasta el otoño de 2013) ya que todas las muestras fueron tomadas posterior a esas fechas.

### Calculo de variables dasométricas de años anteriores

Todos los datos de anillos medidos fueron ordenados por año de crecimiento, y organizados en conjunto con su parcela correspondiente, cuartil, DAP geométrico, su corteza medida en húmedo, altura, su número de árboles por hectárea y su altura dominante (Hdom).

Se calculó los DAP sin corteza para cada uno de los años entre el periodo 2003 y 2012 restando los correspondientes anillos de crecimiento al DAP tomado en terreno, tomando como premisa que la corteza de los arboles crece de manera proporcional al diámetro sin corteza, la cual se describe en la siguiente ecuación (1).

$$DAP_{c/ci} = DAP_{s/ci} + 2 * (DAP_{s/ci} * \frac{Cr}{DAP - 2 * Cr}) \quad (1)$$

Donde,

$DAP_{c/ci}$  es el DAP con corteza del año i (en metros).

$DAP_{s/ci}$  es el DAP sin corteza del año i (en metros).

$DAP$  es el DAP geométrico del árbol medido en terreno (en metros).

$Cr$  es la de corteza húmeda medida en terreno (en metros).

Para medir la altura del árbol de años anteriores se utilizó el modelo de Chapman-Richards de 4 parámetros de ajuste descrito por Sharma y Parton (2007) descrita en la siguiente ecuación (2):

$$H = 1,3 + \beta_1 * Hdom^{\beta_2} * (1 - \exp(-\beta_3 * DAP))^{\beta_4} \quad (2)$$

Donde,

$\beta_i$  son parámetros de ajuste,  $H$  es la altura del árbol (en metros) y  $Hdom$  es la altura dominante (en metros).

Para los parámetros de ajuste se utilizaron los descritos por Corvalán (2015) los cuales fueron calculados mediante la rutina SOLVER de Excel, minimizando la suma de cuadrados entre las alturas totales medidas y las estimadas por el modelo, con información tomada en el área de estudio y comparados con otro modelo de Chapman-Richards descritos por Peng et al. (2001, Citado por Corvalán, 2015), los parámetros usados se muestran en el Cuadro 1.

**Cuadro 1.** Parámetros de ajuste para el Modelo de Chapman-Richards

Variables	Parámetros de Ajuste			
	$\beta_1$	$\beta_2$	$\beta_3$	$\beta_4$
DAP Hdom	1,769	0,819	0,183	0,267

Conocida la altura de los árboles y el DAP con corteza de años anteriores, es posible aplicar la ecuación (3) de volumen descrita por Corvalán (2015) presentada a continuación.

$$Vol IU 10 = H(\alpha + \beta * DAP^2) \quad (3)$$

Donde,

*Vol IU 10* es el volumen bruto sólido con corteza hasta un índice de utilización de 10 cm (Corvalán, 2015) (en metros cúbicos).  $\alpha$  y  $\beta$  son parámetros estimados para el modelo. Los parámetros estimados para la ecuación (3) son los determinados por Corvalán (2015) para el área de estudio y se encuentran en el Cuadro 2.

**Cuadro 2.** Parámetros estimados para el modelo de volumen bruto sólido con corteza

Parámetros	
$\alpha$	$\beta$
0,0007387	0,0000352

### Cálculo del Crecimiento Anual Periódico por hectáreas

El crecimiento anual periódico por hectáreas (en adelante CAP) de cada cuartil fue calculado como la diferencia entre el volumen de fuste estimado del cuartil entre fines del 2012 (otoño del 2013) y comienzos del 2003 (invierno de 2003), a su vez el CAP de cada parcela es igual a la suma de los CAP volumétricos de cada cuartil. El volumen estimado del fuste del cuartil es igual al volumen del árbol central del cuartil, de diámetro no inferior 10 centímetros, multiplicado por el número de árboles por hectárea (en adelante NHa) del respectivo cuartil. Para la estimación del número de árboles por hectárea de años anteriores se asume que el número de árboles vivos de cada cuartil no varió en los últimos 10 años, sin embargo, si el DAP del árbol central del cuartil llega a ser inferior a 10 cm se asume que todo el cuartil desaparece ya que la ecuación de volumen (3) está construida para arboles mayores a 10 cm de DAP.

Según Corvalán (2015), ya que no existen registros de mortalidad de individuos en las parcelas utilizadas para el estudio no es posible realizar una estimación del crecimiento bruto, y, ya que en este estudio se asume que no existen grandes cambios en 10 años, se evaluó solo el CAP en volumen neto.

### Construcción del modelo de crecimiento

Para generar el modelo lineal generalizado (en adelante GLM) que emule la curva de los DMD propuesta por Newton (1997) se utilizaron los datos de DR y de CAP como se muestra en la ecuación (4) y se graficaron utilizando el software R mediante un modelo cuadrático como lo sugiere Faraway (2009).

$$lm(CAP \sim DR + I(DR^2) - 1) \quad (4)$$

Donde  $I$  es una función de ajuste polinomial.

El modelo está forzado a iniciar en el origen, y se extrajeron de este los valores de  $R^2$  y sus residuales, producto de la diferencia entre los datos observados y los datos predichos por el modelo.

Los residuos del GLM (en adelante llamados residuos del modelo) representan lo que no es explicado por las variables que lo conforman. Si los residuos son positivos, indica que los datos observados son mayores a los datos predichos, para una densidad relativa en particular, por ende, el modelo subestima el crecimiento anual periódico por hectáreas para ese rodal, en el caso contrario, cuando los residuos son negativos, para una densidad relativa en particular, los datos observados son menores que los datos predichos por el modelo, por ende, el modelo de crecimiento sobreestima el valor del CAP. Estos residuos entonces reflejarían otros factores que están influyendo en esta sobreestimación y subestimación del CAP, estos pueden ser factores de calidad del sitio, determinados por variables del ambiente.

Para verificar los supuestos del GLM, se evaluó la normalidad de los residuos con el test de Shapiro-Wilk utilizando el paquete “stats” del software R (Royston, 1995) en conjunto con varios gráficos descriptivos del comportamiento de los residuos. Se utilizó el paquete “gvlma” para medir la asimetría, curtosis, heterocedasticidad y “link function”, el test de Bonferroni para evaluar los valores “outliers” y el test de Dublin-Watson para determinar si existe autocorrelación, ambos dos utilizando el paquete “car” de R (Fox y Weisberg, 2011), a su vez se verificó la autocorrelación espacial de los residuos usando el test I de Moran o “Moran’s I” (Arthur y Ord, 1992) calculado usando el software ArcGIS 10.1 de ESRI.

## **Obtención de predictores ambientales derivados de teledetección**

### **Información derivada de teledetección pasiva**

Los predictores ambientales se derivaron a partir de 6 escenas corregidas del sensor “The Advanced Spaceborne Thermal Emission and Reflection Radiometer” (ASTER) a bordo del satélite TERRA de la NASA, las cuales poseen tres bandas distribuidas entre el visible y el infrarrojo cercano (VNIR: 0,52 – 0,86  $\mu\text{m}$ ), con un pixel de 15 metros (Fujisada, 1998) y 5 bandas en el espectro del infrarrojo lejano (TIR: 8,125 – 11,65  $\mu\text{m}$ ) las cuales cuentan con una resolución espacial de 90 m (Gillespie et al., 1998). La información satelital utilizada corresponde a los productos nivel 2 de ASTER (California Institute of Technology, 2001), en particular los datos de reflectancia superficial (AST07XT) y de temperatura de superficie (AST08), los cuales vienen con correcciones radiométricas y atmosféricas. En el Cuadro 3 se encuentra la información de las escenas utilizadas en el estudio.

**Cuadro 3.** Especificación de las escenas ASTER utilizadas.

ID del Producto	Nivel del producto	Información de observación		Ángulos solares (°)		
		Fecha	Hora	Azimut	Elevación solar	Angulo de inclinación (°)
AST2B5V121229145 1371306140009	2	29/12/2012	14:51:37	71,37	62,28	-8,711
AST2B5V110219144 5091111090012	2	19/02/2011	14:45:09	59,48	51,81	-9,603
ASTL1B 08-12- 14:52:0010269001	2	2/12/2008	14:52:10	66,30	63,84	-8,711
AST2B5V080330144 5161211290005	2	30/03/2008	14:45:16	42,53	41,61	-9,602
AST2B5V031112144 5571211290014	2	12/11/2003	14:45:57	59,36	61,43	-9,602
AST2B303032414522 51211290007	2	24/03/2003	14:52:25	43,28	44,24	-8,711

Para poder procesar estas escenas se utilizó el ángulo de inclinación otorgado en el metadato para orto-rectificarlas mediante el software ENVI Classic 5.0 y luego fueron cortadas en un cuadrado de 10x10 km con el área de estudio en el centro. Estas fueron georreferenciadas automáticamente al datum WGS84 Huso 19s y transformarlas en archivos utilizables por otros softwares (formato .TXT en código ASCII, y .TIFF).

Para el cálculo de la fracción evaporativa se utilizó la metodología descrita por Roerink et al. (2000) e implementada en Galleguillos et al. (2011) y Olivera-Guerra et al. (2014), utilizando los productos obtenidos para cada escena ASTER siendo los productos de reflectancia superficial, de temperatura cinética de superficie o KST aquellos requeridos para calcular la fracción evaporativa a partir del algoritmo S-SEBI, el cual resuelve el balance de energía superficial. La fracción evaporativa representa la proporción de la energía disponible que es utilizada para generar flujo de calor latente o evapotranspiración real (en adelante ETR) (Ecuación 5).

$$EF = LE/Rn - G0 \quad (5)$$

Donde,

$LE$  es el calor latente de vaporización,  $Rn$  es la radiación neta diaria (obtenida del KST), y  $G0$  es el flujo de calor del suelo (obtenido de la reflectancia superficial) (Galleguillos et al., 2011)

Su valor se asocia al estado hídrico de la vegetación, puesto que permite estimar la energía que utiliza la vegetación en transformar el agua líquida en vapor producto de la respuesta a la demanda atmosférica. En particular si la fracción evaporativa es cercana a 1, implica que la vegetación se encuentra en un estado hídrico adecuado sin limitantes que frenen el proceso de evapotranspiración producto de la demanda representada por la energía disponible. Por el

contrario, una fracción evaporativa cercana a cero implica que la vegetación no estaría generando calor latente o ETR por lo que se asume que está en una condición de estrés hídrico y no responde a la demanda atmosférica.

### **Información derivada de teledetección activa.**

La nube de puntos LiDAR fue adquirida y ortorectificada en febrero del 2011, utilizando un sensor Harrier 54/G4 Dual System, logrando una densidad de puntos de  $4,64 \text{ m}^2$  ( $\text{p}/\text{m}^2$ ). La frecuencia del pulso y escaneo fueron de 100 kHz y 100 Hz respectivamente, con un ángulo de visión de campo aproximado de  $22,5^\circ$  y una longitud de onda de pulso laser igual a 1.550 nm. De la información recogida del vuelo, salieron como resultado ocho archivos en formato texto (.TXT) con datos de retornos promedio de  $1,0 \times 10^7$  haciendo un total de  $8,0 \times 10^7$  retornos en total.

Con el software LASTools que funciona en base a la consola de Microsoft DOS, fueron creados tres modelos digitales de elevación o MDE, un modelo digital de terreno (MDE o DEM en sus siglas en ingles), un modelo digital de superficie (en adelante MDS) y un modelo digital de copas (en adelante MDC) (Isenburg, 2014). Ya que LASTools requiere que los datos estén en un formato de archivo para nubes de puntos LiDAR (.las), los archivos en formato texto fueron transformados utilizando una herramienta otorgada por el mismo software llamada “txt2las.exe”

Para la obtención de los MDT a partir de datos LiDAR es necesario realizar dos pasos importantes: el filtrado de los puntos correspondientes al suelo o “ground filtering” y la aplicación de técnicas de interpolación mediante triángulos irregulares o TIN (Isenburg, 2006). Para el filtrado de puntos se utilizó la herramienta “lasground.exe” que clasifica los puntos mediante una clasificación binaria aquellos retornos que provienen del suelo y los separa de los puntos reflejados del dosel superior de los árboles y de la vegetación existente bajo este. La clasificación de los puntos que conforma el MDT se realizó con la herramienta “las2dem.exe” la cual generó, mediante interpolación de los datos, la elevación del terreno en áreas donde no existe información. Para conformar el MDS se utilizaron los retornos no clasificados como suelo, los cuales fueron interpolados para así crear el dosel de la vegetación. Finalmente, el MDC se calculó mediante la diferencia entre el MDT y el MDS (Maguya et al., 2014). Para este estudio se utilizó el MDC y el MDT como predictores utilizados directamente en el análisis como también mediante cálculos de otros predictores a partir de ellos.

### **Obtención de los predictores derivados de LiDAR y ASTER**

Para los predictores derivados de LiDAR se utilizaron dos softwares, SAGA GIS y ArcGIS 10.1. En total se calcularon 17 predictores derivados de los datos LiDAR, 11 predictores morfométricos, hidrológicos y topográficos en conjunto con el MDT que representa la altitud, cinco predictores obtenidos usando matrices de ocurrencia en el MDC, MDT y pendiente,

los cuales se resumen en el Cuadro 4 (en más detalle en el Apéndice I). Todos los predictores morfométricos, hidrológicos y topográficos seleccionados fueron utilizados previamente por Ceballos et al. (2015) para su modelo predictivo de la riqueza florística realizado en la misma área de estudios.

A partir de las seis imágenes ASTER se calcularon 58 índices ambientales a cada una, algunos de ellos ampliamente estudiados y utilizados en la percepción remota para índices vegetacionales (Clark et al., 2004; Jones and Vaughan, 2010). Se utilizaron los índices NDVI, GNDVI (más detalle de su cálculo en el Apéndice II) y Fracción evaporativa (EF) y de estos predictores se calculó estadísticas básicas y matrices de ocurrencia y co-ocurrencia que permitieron caracterizar la dinámica temporal y espacial de los predictores (Cuadro 4).

**Cuadro 4.** Resumen de predictores ambientales derivados de las imágenes ASTER y LiDAR.

Tipo de predictor	Nombre del predictor generado	Referencia	Sigla
<b>Índices de vegetación</b>	Normalized Difference Vegetation Index	Jones and Vaughan, 2010	NDVI
	Green Normalized Difference Vegetation Index	Jones and Vaughan, 2010	GNDVI
	Evaporative fraction	Roerink et al., 2000	EF
<b>MDT</b>	Altitud	Isenburg, 2006	DEM15
<b>Derivadas topográficas de primer orden en base al MDT</b>	Pendiente	Zevenbergen y Thorne, 1987	SLOPE
	Cos(Aспект) Northness	Roberts, 1986	NORTH
	Sin(Aспект) Eastness	Roberts, 1986	EAST
<b>Predictores hidrológicos en base al MDT</b>	Catchment slope	Seibert y McGlynn, 2007	CATCHSLO
<b>Predictores topo-hidrológicos en base al MDT</b>	Downslope distance gradient	Hjerdt et al., 2004	GRADIENT
<b>Predictores de geoforma topo-morfométricos en base al MDT</b>	Multi-resolution index of Valley bottom flatness (MrVBF)	Gallant y Dowling, 2003	MRVBF
	Multi-resolution index of Ridge Top Flatness (MrRTF)	Gallant y Dowling, 2003	MRRTF
	Terrain Ruggedness Index	Riley et al., 1999	TRI
<b>Predictores de Iluminación en base al MDT</b>	Potential incoming direct insolation	Boehner y Antonic, 2009; Wilson y Gallant 2000; Hofierka y Šúri 2002	DIRECTISO
	Potential incoming diffuse insolation	Boehner y Antonic, 2009; Wilson y Gallant 2000; Hofierka y Šúri 2003	DIFFUSEISO
	Potential incoming total insolation	Boehner y Antonic, 2009; Wilson y Gallant 2000; Hofierka y Šúri 2004	TOTALISO
<b>Predictores estadísticos en base a las seis imágenes de NDVI, GNDVI y EF</b>	Mediana	-	MEDIANA
	Media	-	MEAN
	Desviación estándar	-	SD
	Mínimo	-	MIN
	Máximo	-	MAX
	Amplitud	-	AMPLITUD

**Cuadro 4.** Continuación.

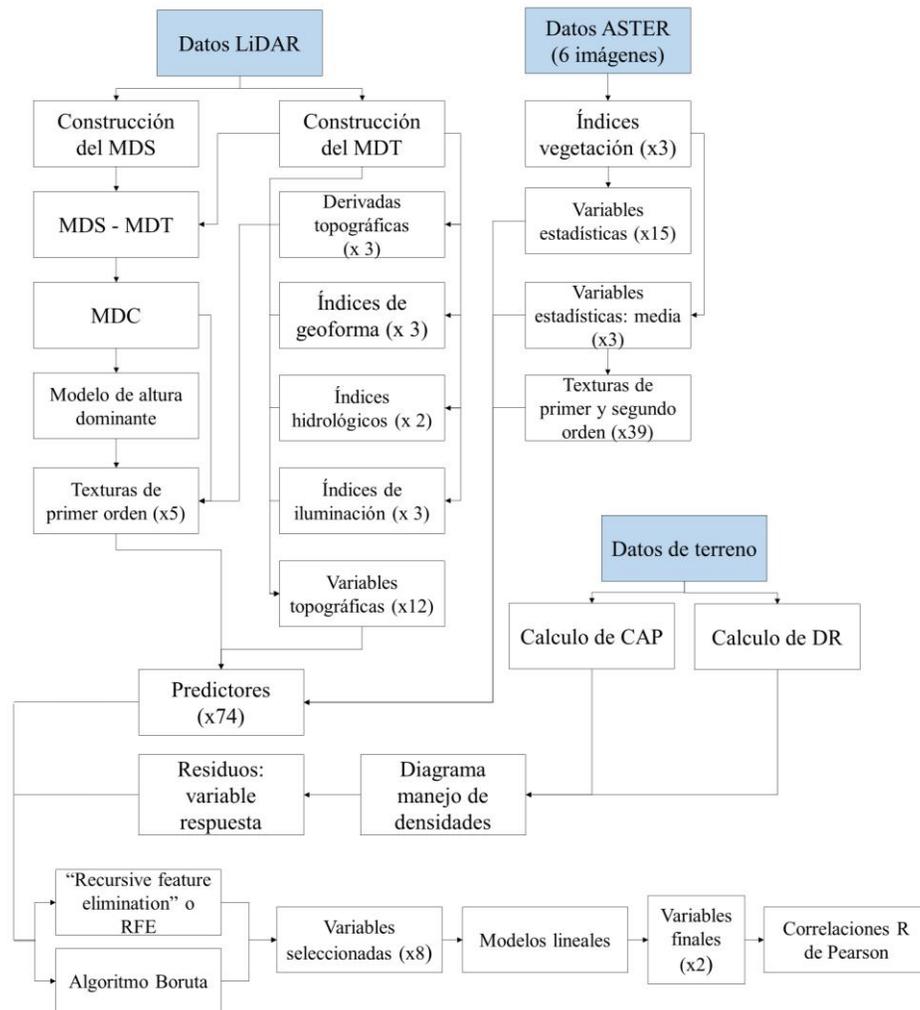
<b>Predictores estadísticos en base a la media de todas las imágenes de NDVI, GNDVI y EF</b>			
<b>Matrices de Ocurrencia o Texturas de primer orden</b>	Desviación estándar	Jones and Vaughan, 2010	SD
	Rango	St. Louis et al., 2006	RANGE
	Mínimo	St. Louis et al., 2006	MIN
	Máximo	St. Louis et al., 2006	MAX
	Media	Jones and Vaughan, 2010	MEAN
<b>Matrices de Co-ocurrencia (GLCM) o Texturas de segundo orden</b>	Varianza	St. Louis et al., 2006	VAR
	Angular second moment	Jones and Vaughan, 2010; Presutti, 2004	SECM
	Media de segundo orden	Presutti, 2004	MEAN2
	Homogeneidad	Gebejes y Huertas, 2013; Presutti, 2004	HOM
	Entropía	Jones and Vaughan, 2010; Presutti, 2004	ENTR
	Disimilaridad	Gebejes y Huertas, 2013	DISS
	Correlación	Nageswara et al., 2013; Presutti, 2004	COR
	Contraste	Jones and Vaughan, 2010; Presutti, 2004	CONT
<b>Predictores estadísticos calculados al MDC</b>			
<b>Textura de primer orden</b>	Media	Jones and Vaughan, 2010	MEAN
	Máximo	St. Louis et al., 2006	MAX
<b>Predictores estadísticos calculados al modelo de altura dominante</b>			
<b>Textura de primer orden</b>	Media	Jones and Vaughan, 2010	MEAN
<b>Predictores estadísticos aplicados al MDT y Slope</b>			
<b>Textura de primer orden</b>	Desviación estándar	St. Louis et al., 2006	SD

Tal y como explican Jones and Vaughan (2010) una forma de mejorar el análisis espacial, es incrementando la información útil que poseen los píxeles vecinos, es así como al tomar en cuenta la relación entre el píxel y las características de sus objetos cercanos, estamos incluyendo a nuestra información espacial el contexto, y al incluir en la medida la homogeneidad de los píxeles vecinos estamos incluyendo la textura. Las medidas de las texturas calculadas en el dominio espacial están divididas en dos categorías: estadísticas de

primer orden o matrices de ocurrencia y estadísticas de segundo orden o matrices de co-ocurrencia (más detalles de su cálculo en el Apéndice III). Las matrices de ocurrencia son derivados de histogramas de intensidad de píxeles en un vecindario dado (el cual para el estudio fue una ventana móvil de 3x3 píxeles) y no toman en consideración la relación espacial (Jones and Vaughan, 2010). Las estadísticas de segundo orden son calculadas con la escala de grises de la matriz de co-ocurrencia (“grey level co-occurrence matrix” o GLCM) que indica la relación entre los niveles de grises de los píxeles en direcciones o distancias específicas, así, cada elemento de la matriz es una medida de la probabilidad de ocurrencia de dos valores de escalas de grises separados por una distancia y una dirección dada (Jones and Vaughan, 2010).

Todos los predictores, para facilitar el desarrollo de la discusión, fueron abreviados en siglas para mayor orden y entendimiento de la nomenclatura usada. En el Cuadro 4 se encuentran las siglas usadas para cada predictor. Al inicio siempre va la sigla que resume el predictor a utilizar seguido del análisis estadístico aplicado a él (ej.: la media de todas las imágenes de NDVI: “NDVI\_MEAN”), ya que todas las texturas de primer y segundo orden, como ya se describió en el Cuadro 4, están basadas en la media de todas las imágenes de los índices, al momento de asignarle sigla. El análisis estadístico media se considera redundante, y se elimina de la nomenclatura (ej.: textura de segundo orden “angular second moment” de la media de todas las imágenes de NDVI: “NDVI\_SECM”), para el caso de las texturas de primer orden y para diferenciarlas de otros análisis, antes de todo el nombre se antepone la sigla TX (ej.: textura de primer orden desviación estándar de la media de todas las imágenes de NDVI: “TXNDVI\_SD”). En el Apéndice IV se encuentra la lista completa de predictores con su determinada sigla.

El proceso de construcción de todos los predictores y los análisis estadísticos posteriores están condensados en el diagrama de flujo explicativo disponible en la Figura 7.



**Figura 7.** Diagrama de flujo metodológico. Resumen de la metodología a seguir para el análisis de los predictores de relevancia para el crecimiento anual periódico por hectáreas. En paréntesis se muestra el número de predictores obtenidos en cada paso.

## Selección de predictores

### Algoritmos de minería de datos

Con los valores residuales del modelo de crecimiento se realizó el procedimiento de selección de predictores más relevantes. Se optó por realizar un análisis exploratorio a través de dos métodos de minería de datos, los cuales están basados en Random Forest (RF), que es un método que usa un algoritmo de aprendizaje automático basado en árboles de clasificación y regresión que utiliza el proceso de ‘bootstrap aggregation’ o empaquetado (Dietterich, 2000,

citado por Ceballos et al., 2015), los dos métodos de minería de datos se presentan a continuación:

1. “Recursive feature elimination” o RFE-RF es un método recursivo que primeramente ajusta el modelo a todos los predictores y calcula su rendimiento. Luego, cada predictor es ordenado según su medida de importancia con el modelo, y va eliminando los predictores menos importantes, para finalmente calcular una medida de precisión, en este caso la raíz del error cuadrático medio (RMSE) (Cabezas et al., 2016; Granitto et al., 2006), utilizando una validación cruzada para estabilizar la selección (“10-fold cross validation”) (Breiman, 1996; Grossmann et al., 2010). Se obtiene así la relación entre el RMSE y el número de predictores, obteniendo los predictores más importantes en cada paso (Cabezas et al., 2016), para luego iterar eliminando los predictores menos importantes y calculando nuevamente todas las medidas de precisión para cada predictor. Luego de iterar, calcula el perfil de rendimiento de los predictores y elige un número apropiado de ellos que entreguen el menor RMSE, y grafica como resultado del algoritmo el comportamiento de este error, según como se van eliminando uno a uno los predictores, el resultado entregado por el algoritmo es un listado de los predictores que mostraron mejores resultados en sus medidas de precisión (Granitto et al., 2006).
2. El algoritmo Boruta de primera, agrega aleatoriedad a los datos creando variables sombra, que son copias de los predictores seleccionados, pero sus datos han sido mezclados y desordenados. Luego entrena un clasificador con Random Forest en el conjunto de datos y aplica una medida de importancia para evaluar el peso de cada uno de los predictores, donde más alto implica más importante, y en cada iteración analiza si el predictor real tiene más importancia que la mejor variable sombra creada, calculando un índice de unidades tipificadas o “z-score” y, constantemente elimina predictores que son considerados de no importancia (Kursa y Rudnicki, 2010).

Para el RFE-RF se utilizó el paquete “caret” del software R, y se seleccionaron los cinco predictores más significativos, para el algoritmo Boruta se utilizó el paquete “Boruta” del software R y se seleccionaron 6 predictores que tenían un grado de importancia más alto. De entre los predictores seleccionados por los dos algoritmos, tres de ellos fueron seleccionados por ambos algoritmos, dejando un total de 8 predictores relevantes.

Una vez obtenidos el conjunto de predictores, se extrajeron sus respectivos valores del pixel correspondiente a la parcela de muestreo, utilizando un archivo georreferenciado con todas las ubicaciones de las parcelas tomadas en terreno.

Los 8 predictores de mayor relevancia en la explicación de la variable respuesta (residuos del modelo) fueron seleccionadas, probando diversos modelos de regresión lineal lo que permitió eliminar uno a uno los predictores de menor importancia utilizando como criterio el “Akaike information criterion” (AIC) y el “Bayesian information criterion” (BIC), donde los resultados más bajos de AIC o BIC es el modelo que mejor se ajusta (Posada y Buckley, 2004). Cabe destacar que todos los predictores utilizados para la creación de los modelos

lineales fueron centrados para minimizar el efecto del intercepto tal y como propone Marquardt (1980).

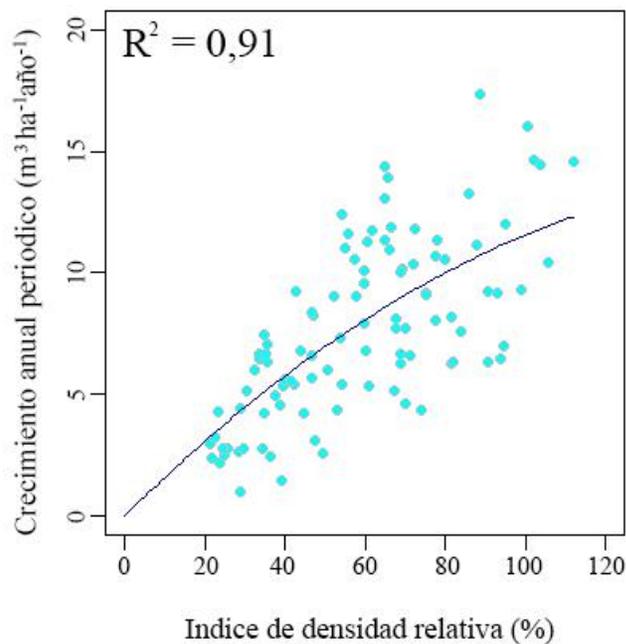
### **Comparación entre residuos y predictores ambientales**

Luego de que las variables finales fueron seleccionadas, se realizó un análisis de significancia al 0,05 utilizando un análisis de correlación mediante el coeficiente de correlación de Pearson (Caballero, 1975) evaluando las variables una a una en distintos intervalos de densidad relativa propuestos por Corvalán (2015): inferiores a 40%, entre 40% y 80%, y sobre 80% como también el criterio de densidad relativa sobre 60% propuesto por Gezan et al. (2007) que define en este nivel de ocupación de sitio la línea de inminente mortalidad por competencia, todos utilizados para formaciones vegetacionales de *Nothofagus obliqua*. Este análisis fue realizado en el software R con la librería básica incluida en el software.

## RESULTADOS Y DISCUSIÓN

### Diagrama de Manejo de Densidad

Se graficó el GLM utilizando los datos de CAP y DR obtenidos para cada una de las parcelas, luego de eso se ajustó un modelo cuadrático con un intercepto en el origen, este modelo se muestra graficado en la Figura 8, en el Apéndice V se encuentra la evaluación de los supuestos del GLM y en el Apéndice VI se encuentran los gráficos que explican el comportamiento de los residuos del modelo.



**Figura 8.** Modelo lineal generalizado entre el crecimiento anual periódico por hectáreas ( $\text{m}^3 \text{ha}^{-1} \text{año}^{-1}$ ) y el índice de densidad relativa (%).

De este ajuste cuadrático, el modelo posee un error estándar medio residual (RSME) de 2,59  $\text{m}^3 \text{ha}^{-1} \text{año}^{-1}$ , con 98 grados de libertad y un coeficiente de determinación ajustado  $R^2$  de 0,91 ( $p$ -value  $< 0,05$ ), en el Apéndice VII se encuentra el sumario de salida del GLM.

La ecuación del modelo obtenido es la siguiente (6):

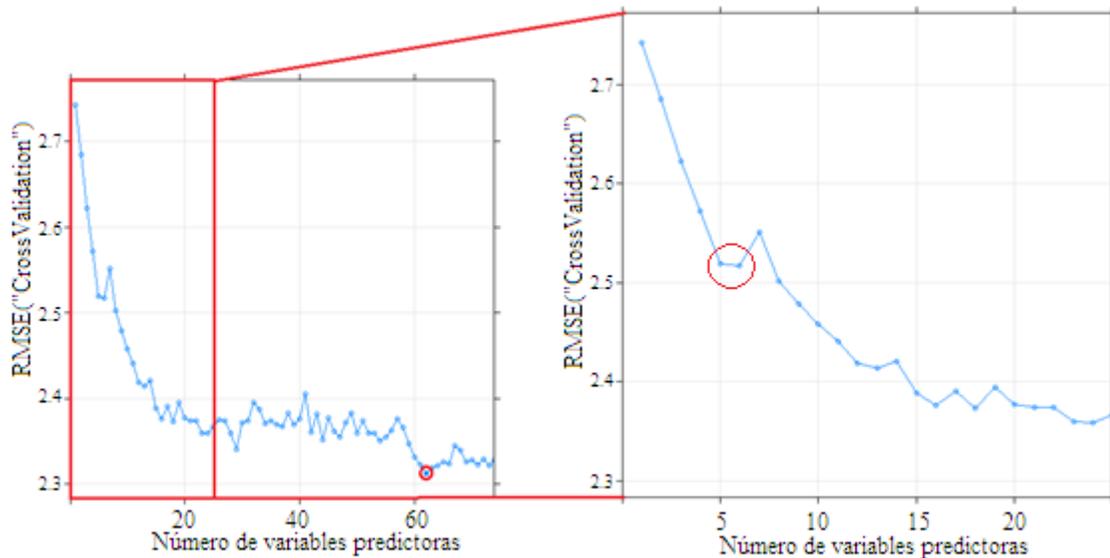
$$CAP = 0,1627904 * DR - 0,0004728 * DR^2 + \varepsilon$$

Donde  $\varepsilon \sim \mathcal{N}(0, 2,593)$  (6)

Los valores de  $R^2$  indican la fracción de la variación observada de la variable dependiente es explicada por el modelo. Así, si  $R^2$  es igual a 0,91; el 91% de la variación observada puede ser descrita por el modelo y solo 9% de ella queda como varianza residual (Ahern et al., 1991). Esto implica que la variación en el CAP es 91% explicada por la densidad relativa.

### Selección de Predictores

Utilizando la recomendación de Hair et al. (2009) y la cantidad de observaciones (en nuestro estudio  $n=74$ ), el número de predictores no debería ser mayor a 8. En la Figura 9 se muestran los gráficos obtenidos del RFE con una validación cruzada “10-fold” y como el RMSE disminuye mientras más predictores se eligen para responder la variabilidad de los residuos del modelo.



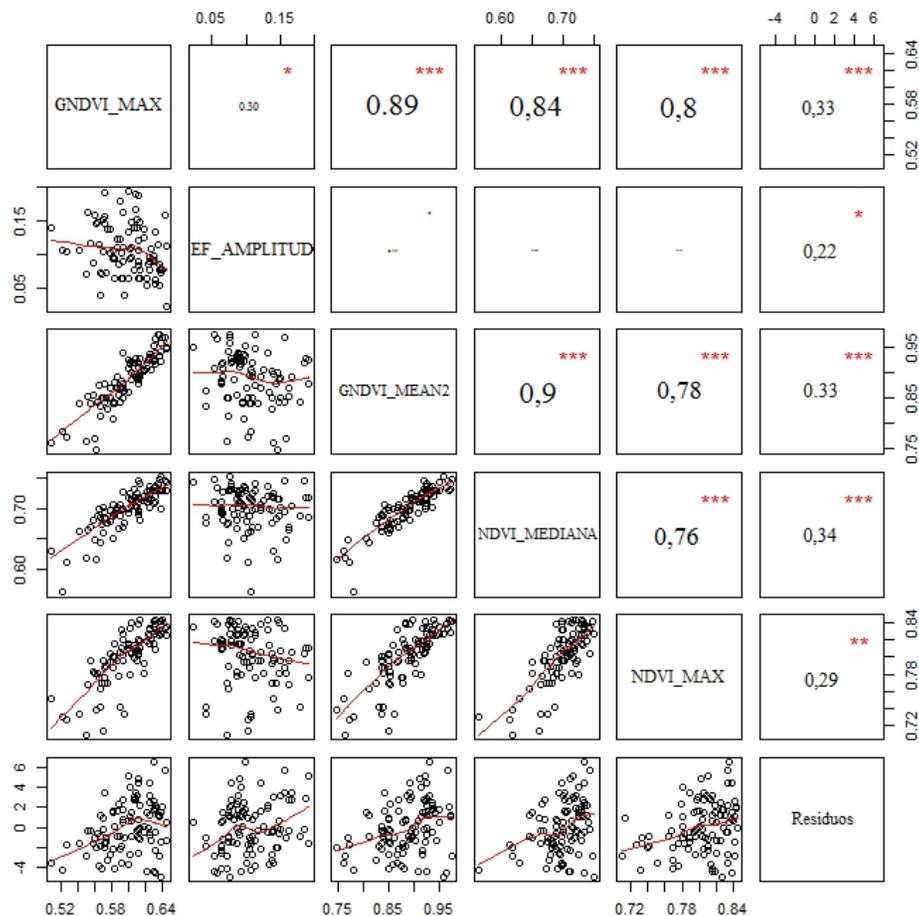
**Figura 9.** RFE-RF. El número de predictores preliminares elegidos por el algoritmo que disminuyen al máximo el RMSE está marcado con un círculo rojo en el primer gráfico ( $n=62$ ) y en el segundo, en el círculo rojo se muestra la selección acotada según el criterio de Hair et al. ( $n=5-6$ ).

Al ser analizado el gráfico resultante del RFE-RF (Figura 9), este arroja preliminarmente que 62 predictores fueron escogidos porque, en este paso del algoritmo, el RMSE llegó a su punto más bajo. Sin embargo, utilizando el criterio de Hair et al. (2009) descrito anteriormente, se eligen solo cinco predictores (Cuadro 5) ya que en ese punto del gráfico existe un quiebre y, a su vez, al agregar un predictor más, aunque disminuye el RMSE, este no aporta una gran diferencia en la minimización del error, y el rendimiento del análisis puede disminuir debido a la gran cantidad de predictores que generen ruido (Hastie et al., 2009, citado por Cabezas et al., 2016).

**Cuadro 5.** Listado de los 5 predictores seleccionados por el algoritmo RFE y su sigla asociada.

Tipo de predictor	Sigla
El máximo valor entre todas las imágenes de GNDVI	GNDVI_MAX
La diferencia entre el mayor y el menor valor o amplitud entre todas las imágenes de fracción evaporativa	EF_AMPLITUD
Textura de segundo orden, media, de los GNDVI	GNDVI_MEAN2
La mediana entre todas las imágenes de NDVI	NDVI_MEDIANA
El máximo valor entre todas las imágenes de NDVI	NDVI_MAX

La matriz de correlación entre los 5 predictores seleccionados por el algoritmo RFE en conjunto con los residuos permitió identificar las correlaciones estadísticamente significativas (Figura 10).

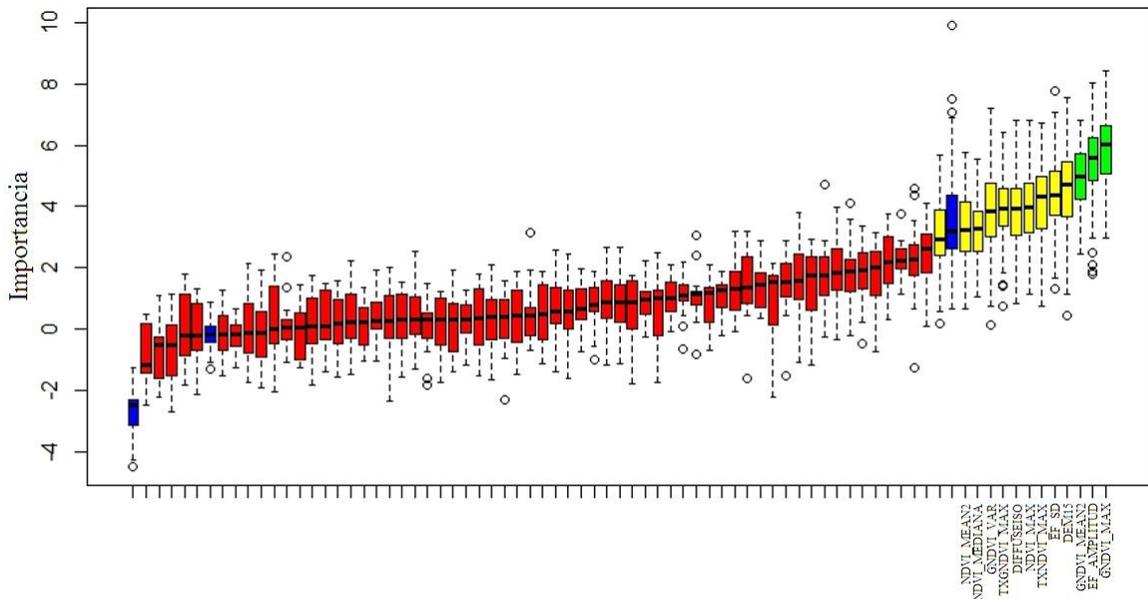


**Figura 10.** Matriz de correlación entre los predictores finales seleccionados del algoritmo RFE-RF. Los asteriscos rojos representan el nivel de significancia de la correlación (Código Significancia para el p-value del coeficiente de correlación de Pearson: 0 = '\*\*\*'; 0,001 < '\*\*'; 0,01 < '\*'; 0,05 < '.').

Todos los predictores seleccionados son derivados de análisis texturales de segundo orden y predictores de estadísticos temporales (máximo en dos de ellas, amplitud y mediana, como predictores estadísticos; y media como textura de segundo orden, todas descritas en el Cuadro 4). El análisis mostró que, de los cinco pares de predictores seleccionados, cuatro de estos muestran una alta correlación entre sí ( $R > 0,8$ ), lo cual indica su colinealidad, o en otras palabras representan en mayor medida la misma información para explicar el comportamiento de los residuos.

Al comparar los predictores seleccionados por el RFE-RF con los residuos del modelo todas tienen significancia (indicadas como asteriscos rojos en la Figura 10) siendo las más significativas, NDVI\_MEDIANA, GNDVI\_MEAN2 y GNDVI\_MAX con un  $R \geq 0,33$ .

Utilizando el algoritmo Boruta (Kursa y Rudnicki, 2010) se obtuvo un resultado similar en la discriminación de los predictores, como se muestra en la Figura 11, donde GNDVI\_MAX y EF\_AMPLITUD son aquellos predictores de mayor importancia

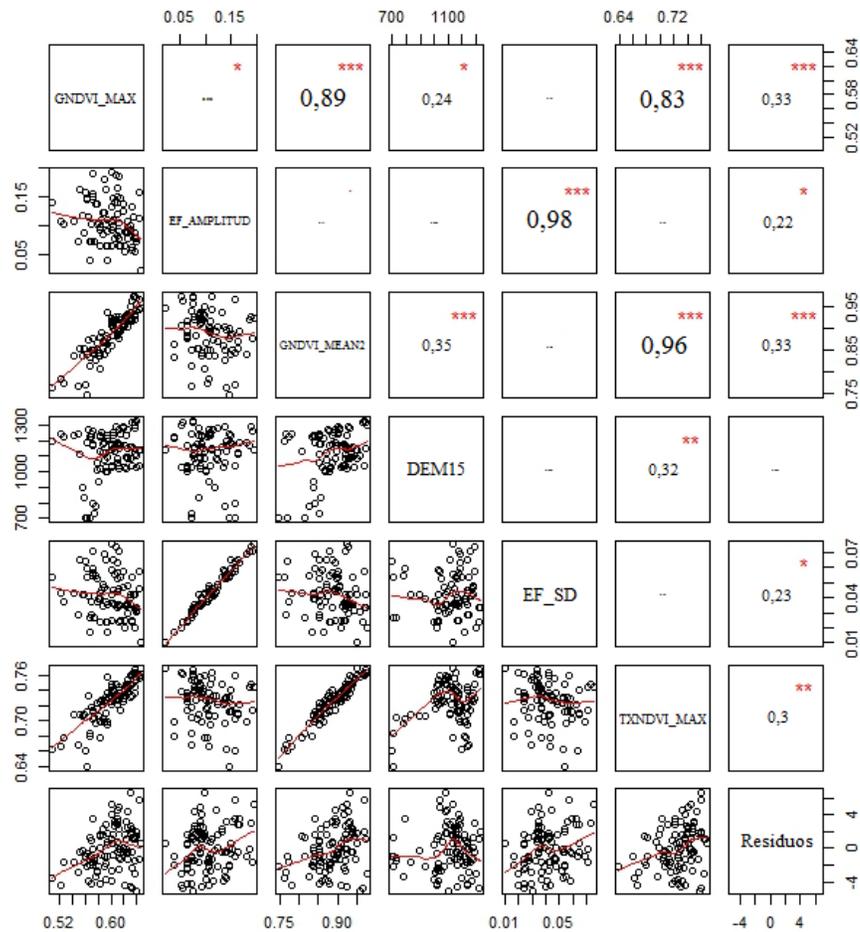


**Figura 11.** Grafico resultante del algoritmo Boruta, los diagramas de caja azules corresponden al mínimo, promedio y máximo “Z-scores” o unidades tipificadas de variables sombra, los diagramas de caja rojos, amarillos y verdes son los “Z-scores” de los atributos rechazados, tentativos y confirmados respectivamente.

Del algoritmo Boruta se seleccionaron los tres primeros predictores con valores de importancia más altos, los cuales, según el algoritmo, fueron confirmados, se tomaron a su vez los tres siguientes en orden de importancia, listados y descritos en el Cuadro 6. Se compararon los predictores entre ellos en conjunto con los residuos en una matriz de correlación la cual se muestra en la Figura 12.

**Cuadro 6.** Listado de los 6 predictores seleccionados por el algoritmo Boruta y su sigla asociada.

Tipo de predictor	Sigla
El máximo valor entre todas las imágenes de GNDVI	GNDVI_MAX
La diferencia entre el mayor y el menor valor o amplitud entre todas las imágenes de fracción evaporativa	EF_AMPLITUD
Textura de segundo orden, media, de los GNDVI	GNDVI_MEAN2
Altitud	DEM15
Desviación estándar de todas las imágenes de fracción evaporativa	EF_SD
Textura de primer orden, máximo, de los NDVI	TXNDVI_MAX



**Figura 12.** Matriz de correlación entre los predictores finales seleccionados del algoritmo Boruta. Los asteriscos rojos representan el nivel de significancia de la correlación (Código Significancia para el p-value del coeficiente de correlación de Pearson: 0 = ‘\*\*\*’; 0,001 < ‘\*\*’; 0,01 < ‘\*’; 0,05 < ‘.’)

En la matriz de correlación se muestra que tanto EF\_AMPLITUD como EF\_SD tienen una alta correlación (R=0,98) al igual que GNDVI\_MEAN2 y TXNDVI\_MAX (R=0,96)

determinando la colinealidad entre estas variables, como también se muestra que DEM15 no posee correlación con los residuos del modelo.

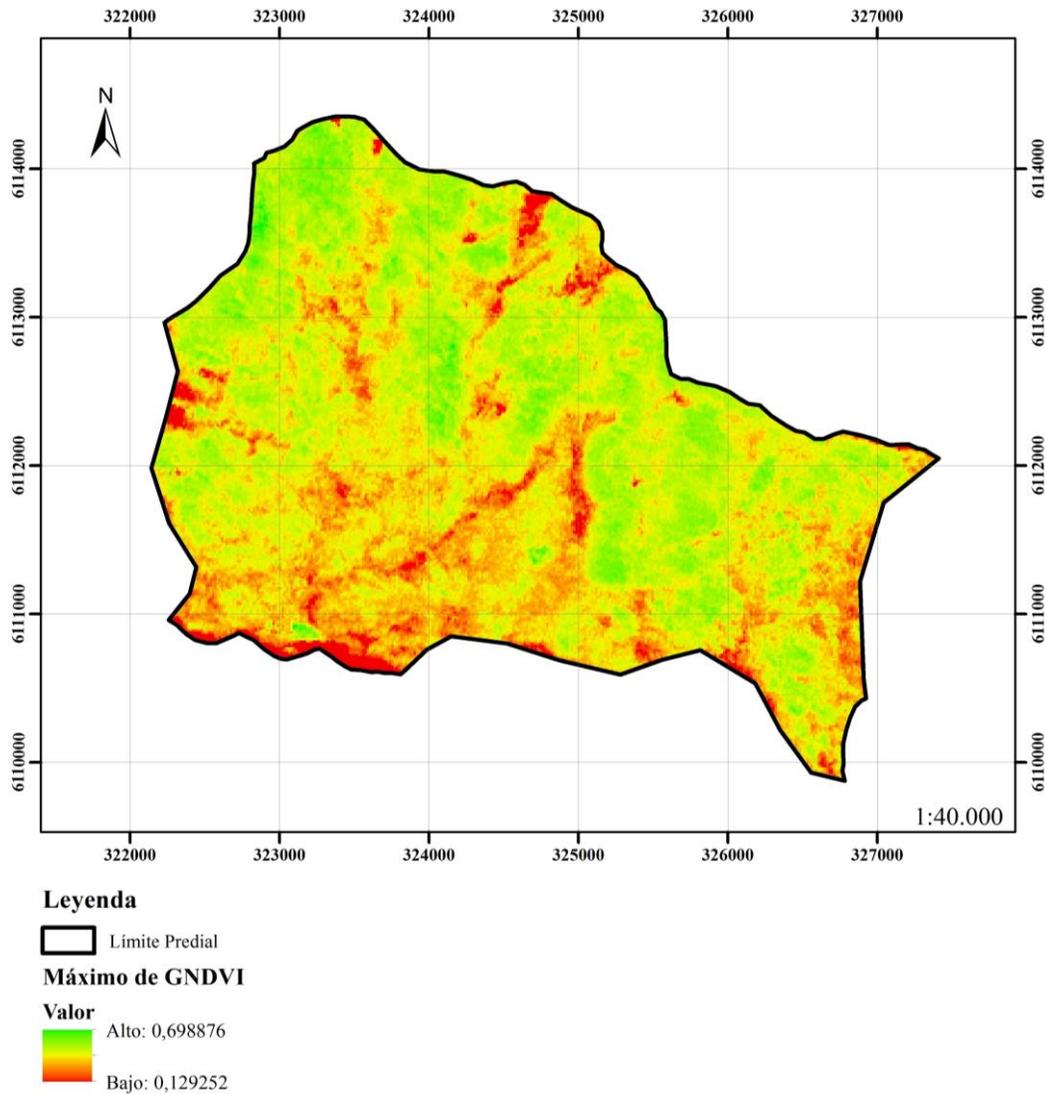
Una vez obtenidos los mejores predictores con significativa relación con los residuos del modelo y que a su vez no estuviesen correlacionados entre sí, se usaron modelos lineales (LM) para determinar los predictores con el mayor poder predictivo (Cuadro 7).

**Cuadro 7.** Modelos lineales para la predicción de residuos del modelo en base a los predictores seleccionados por los algoritmos RFE-RF y Boruta.

Modelo Lineal	Predictores agregados al modelo lineal	RSE	R <sup>2</sup> Multiple	R <sup>2</sup> Adjusted	p-value	AIC	BIC
(1)	EF_AMPLITUD, GNDVI_MAX	2,342	0,193	0,1763	3,05 x10 <sup>-5</sup>	458,9	469,32
(2)	GNDVI_MAX	2,445	0,1108	0,1017	0,0007158	466,6	474,42
(3)	EF_AMPLITUD	2,532	0,0465	0,03677	0,03118	473,58	481,4

El Cuadro 7 nos muestra que un modelo lineal como el (1), con dos predictores, EF\_AMPLITUD y GNDVI\_MAX, tiene el más alto R<sup>2</sup> ajustado (0,1763) el menor “p-value” (3,05x10<sup>-5</sup>) y los menores AIC y BIC (458,9 y 469,32 respectivamente) siendo estos los predictores más relevantes para explicar los residuos del modelo, a su vez los modelos (2) y (3) demuestran que estos predictores por si solos no son capaces de explicar los residuos del modelo, mostrando los “p-value”, AIC y BIC más altos de entre todos los modelos. Todos los modelos lineales generados y comparados se encuentran en el Apéndice VIII.

En las figuras 13 y 14 se muestran los dos predictores seleccionados distribuidos espacialmente a través del área de estudios.

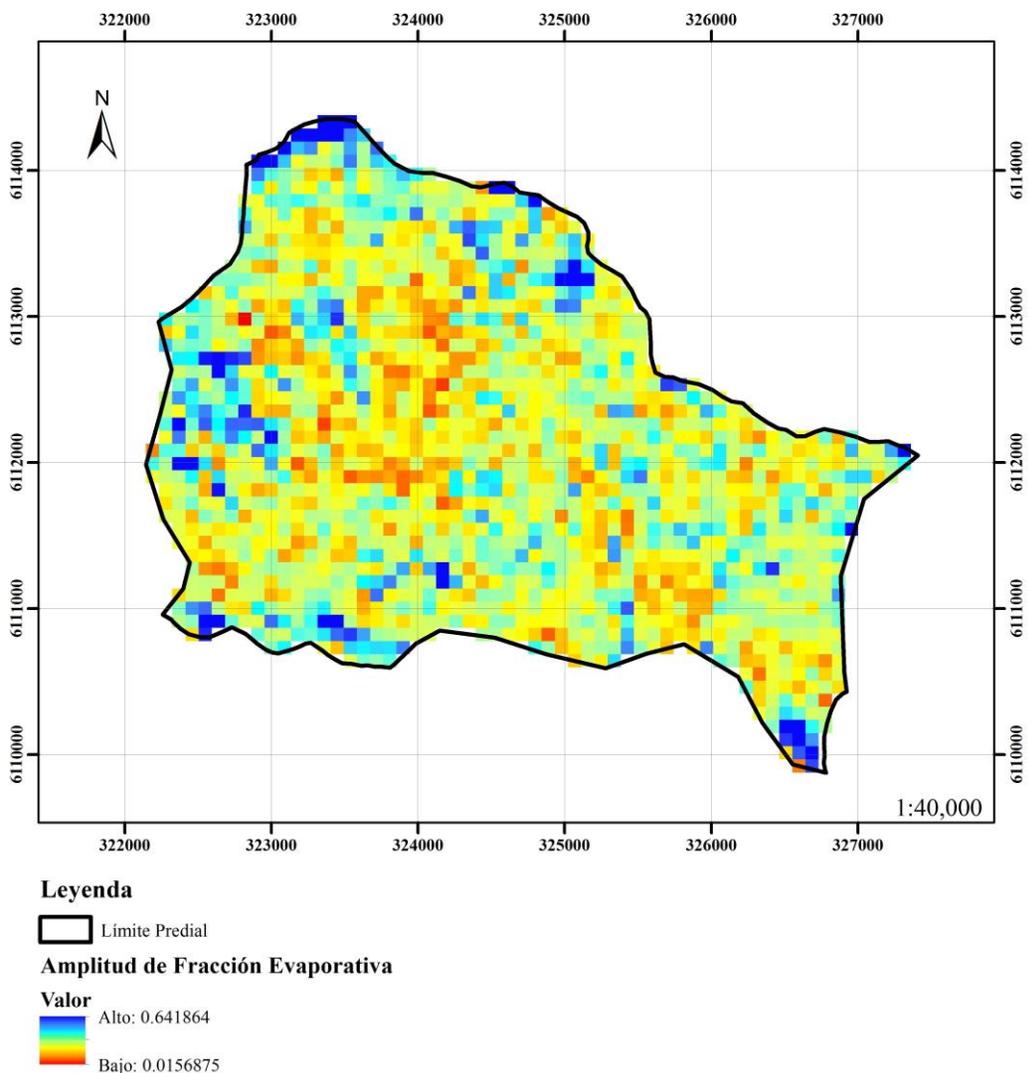


**Figura 13.** Mapa de distribución del máximo de GNDVI en el área de estudio.

El máximo de GNDVI es un indicador que muestra los máximos “peaks” de verdor, que se asocia, en menor o mayor medida, a la radiación fotosintéticamente activa, proceso directamente asociado con el crecimiento (Monteith, 1972; Goward et al., 1985; Wang, 2004). Este predictor indica, en el periodo de tiempo estudiado, los máximos niveles de verdor que fueron percibidos por el sensor. Un alto valor de este predictor (píxeles verdes en la Figura 13) son rodales que mostraron un alto “peak” de verdor, por el contrario, valores rojos representan zonas cuyo máximo valor de GNDVI fue bajo.

Ahern et al. (2014) realizaron un estudio entre la tasa de crecimiento de los árboles en bosques de coníferas de Canadá, relacionándola con distintos índices vegetacionales, principalmente NDVI y GNDVI (llamado verdor o “greenness” en el estudio) en conjunto con las bandas del rojo, infrarrojo cercano, y el infrarrojo de onda corta (en total 7 bandas),

obtenidas del “Thematic Mapper” (TM) de LANDSAT. En ese estudio, Ahern et al. (2014) encuentran una relación significativa entre los índices vegetacionales y el crecimiento de los árboles, pero principalmente una significativa relación con la banda 7 del infrarrojo de onda corta, banda no utilizada en este estudio ya que las imágenes ASTER utilizadas no la posee pero que da pie a futuras investigaciones las cuales pueden a su vez agregar más bandas del espectro como también información de sensores hiperespectrales (Vaglio Laurin et al., 2014). El estudio realizado por Ahern et al. (2014) utilizan una metodología distinta a la de este estudio, ya que ellos utilizaron información de crecimiento del fuste recopilada de parcelas monitoreadas durante 10 años, la cual fue relacionada con modelos de regresión con un máximo de tres predictores espectrales, los resultados muestran relaciones correlacionadas entre NDVI y GNDVI con el crecimiento de los árboles ( $R^2$  sobre 0,7).



**Figura 14.** Mapa de distribución de la Amplitud de Fracción Evaporativa en el área de estudio.

Un estudio realizado por Wang (2004) habla de la relación que existe entre el crecimiento diametral (el cual uso técnicas dendrocronológicas y datos dasométricos para el cálculo) y la media, mínimo y máximo del NDVI, obtenidas al igual que en el presente estudio, calculando estas estadísticas con un conjunto de imágenes en un periodo de tiempo de siete años. Wang (2004) llegó a la conclusión de que la media del NDVI estaba altamente correlacionada con el crecimiento diametral ( $R^2=0,86$ ). Aunque existen estudios que dejen en evidencia que el NDVI tiene relación con el crecimiento, ninguno de los predictores calculados por el presente estudio que derivan de él fueron seleccionados por los algoritmos de minería de datos. Hunt (1994) que realizó un estudio de la relación entre la producción primaria y el NDVI llega a la conclusión de que este indicador por sí solo no es suficiente para determinar el crecimiento de los árboles, ya que la efectividad de este indicador vegetal se ve altamente reducida por efectos del clima y otros factores no mencionados por el autor.

La amplitud de fracción evaporativa indica la variabilidad de la energía utilizada para evapotranspirar con respecto a la energía disponible en el rodal para el periodo de tiempo del estudio. Un bajo valor en este predictor (píxeles rojos y naranjos en la Figura 14) representa a rodales que mostraron una baja variación en la amplitud de sus valores de fracción evaporativa, siendo zonas estables en términos evapotranspirativos, mientras que zonas de color azul fueron altamente variables en su rango de EF lo que implica que presentaron variaciones importantes de su tasa evapotranspirativa.

Luna et al. (2013) explican que el monitoreo de la fracción evaporativa aporta al conocimiento del funcionamiento del ciclo hidrológico y la estimación de ésta muestra el estrés hídrico que afecta al ecosistema y los patrones de uso de agua de los rodales, se define entonces a la amplitud de EF como un indicador de la variabilidad de la disposición hídrica en el rodal.

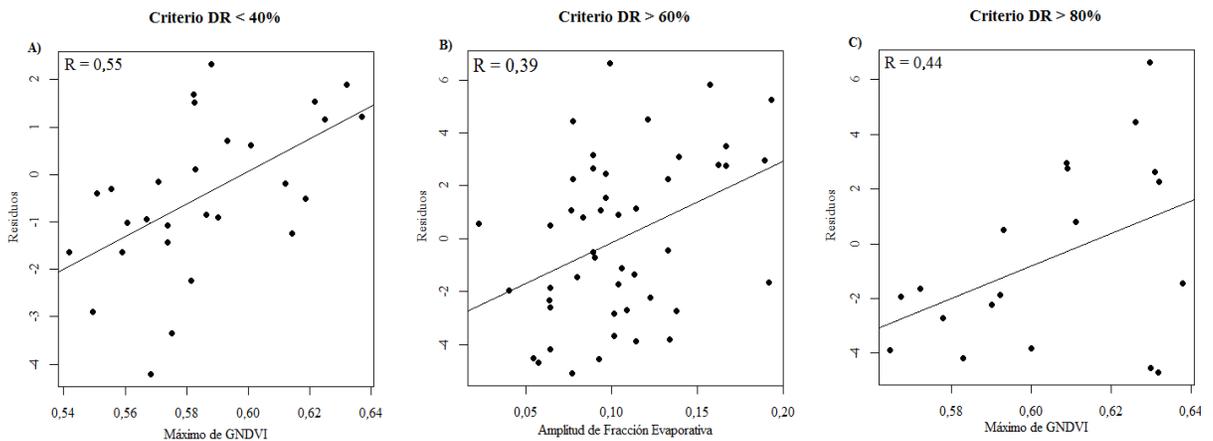
En los resultados obtenidos por el RFE, ninguno de los predictores topográficos fueron seleccionados, aunque cabe destacar que en la 6ta posición de selección se encontraba DEM15 (predictor topográfico que representa la altitud). Sin embargo éste, según el mismo algoritmo, no aporta una reducción significativa del RMSE (lo cual se muestra en la Figura 9). A su vez el algoritmo Boruta considero a DEM15 como un predictor tentativo, pero como se muestra en la Figura 12, este no posee correlación con los residuos del modelo. Un estudio realizado por Song y Woodcock (2003), utilizando imágenes LANDSAT 5 y 7 observó los cambios sucesionales de un bosque de coníferas altamente intervenido y de ambiente montañoso en Oregon, Estados Unidos, concluyendo que la topografía tiene una incidencia en los índices de verdor (“greenness”) pero tiene un mínimo efecto en el NDVI y que a su vez la topografía afecta mayoritariamente a los bosques más maduros y que los efectos topográficos son mínimos en pendientes menores a 30°. Esto puede explicar la falta de predictores topográficos en los resultados obtenidos, ya que en la selección de las parcelas, se descartaron zonas con pendiente muy inclinada (pendientes no mayores a 45°), y a su vez este estudio se enfocó en analizar todos los estados de desarrollo del bosque.

De la misma forma que los predictores topográficos, las variables texturales derivadas de las matrices de ocurrencia y co-ocurrencia tampoco fueron seleccionadas ampliamente por los

algoritmos de minería de datos. Las únicas que se mostraron significativas fueron GNDVI\_MEAN2 y TXNDVI\_MAX, las cuales como indican las matrices de las figuras 10 y 12, entre ellas poseen un  $R$  de 0,98, entendiendo este estadístico como que estos dos predictores describen lo mismo. A su vez ambos poseen una correlación de  $R = 0,89$  y  $R = 0,83$  respectivamente con GNDVI\_MAX, indicando que estos tres predictores son colineales entre sí. Sin embargo, GNDVI\_MAX demostró en los modelos lineales posteriores estar más correlacionado con los residuos del modelo. Otra explicación para que los predictores derivados de las matrices de ocurrencia y co-ocurrencia no fueran seleccionados por los algoritmos de minería de datos es que el área de estudios recibe una cantidad de radiación relativamente homogénea (Ceballos et al., 2015), por lo que la información de los vecinos no es significativa.

### Comportamiento de los predictores bajo diferentes niveles de Densidad de Rodal

Utilizando el criterio de división de la densidad relativa utilizado por Corvalán (2015) se analizaron los predictores seleccionados, EF\_AMPLITUD y GNDVI\_MAX, y cómo se comportan estos en intervalos de DR. En el Cuadro 8 y en la Figura 15 se muestran las correlaciones más significativas que estos predictores tienen con los residuos del modelo a diferentes índices de densidad relativa. En el Apéndice IX se muestran todos los gráficos creados para los distintos intervalos de densidad relativa.



**Figura 15.** Gráficos de correlación de Pearson para un criterio de densidad relativa, en **A)** el máximo de GNDVI y los residuos para densidades relativas inferiores a 40%; en **B)** amplitud de fracción evaporativa y los residuos del modelo para densidades relativas superiores a 60%; en **C)** el máximo de GNDVI y los residuos para densidades relativas superiores a 80%.

**Cuadro 8.** Estadísticos de los análisis de correlación de Pearson.

<b>Criterio de Densidad</b>	<b>Predictor</b>	<b>t</b>	<b>R</b>	<b>p-value</b>
DR < 40%	Máximo de GNDVI	3,3685	0,55	0,0023
DR > 60%	Amplitud de EF	2,8473	0,39	0,00662
DR > 80%	Máximo de GNDVI	1,993	0,44	0,0625

Los resultados muestran que el máximo de GNDVI tiene una alta correlación ( $R=0,55$ ) para densidades relativas bajas (Figura 15, gráfico A), y, como se muestra en la Figura 15, gráfico C, también tiene una correlación significativa para densidad relativas muy altas ( $R=0,44$ ) pero su significancia es mayor al 0,05. La amplitud de la fracción evaporativa no muestra correlaciones muy significativas ( $R=0,22$  en el criterio de densidad relativa entre 40% y 80% el más alto), sin embargo, al analizar con el criterio de densidad relativa que determina la línea de inminente mortalidad por competencia o auto-raleo propuesta por Gezan et al. (2007), esta muestra una correlación de  $R=0,39$ , la más alta para este predictor (Figura 15, gráfico B).

En densidades relativas inferiores al 40% de ocupación, bajo la línea de cierre de copas, el crecimiento es proporcional a la densidad de rodal, pero al llegar a esta línea, el crecimiento individual declina (Newton, 1997). Con índices bajos de competencia a estos niveles de densidad, los individuos tienen la capacidad de alcanzar máximos niveles de verdor ya que estos tienen un ambiente libre de competencia entre copas, y por consiguiente un ambiente con mayor disponibilidad de radiación fotosintéticamente activa. En ambientes donde la densidad es mayor al 80% el crecimiento es invariante de la densidad (Newton, 1997). Esto quiere decir que el crecimiento, en donde existe una inminente mortalidad por competencia, mayores tasas de crecimiento, implica mejores condiciones del sitio, y, por consiguiente, mayores índices de verdor. En densidades relativas intermedias, el crecimiento se estanca (Newton, 1997), y deja de ser proporcional a la densidad. Es aquí donde la competencia comienza a afectar a los individuos, el sitio deja de ser el factor que determina el crecimiento, sino la competencia, por consiguiente, se espera que los índices de verdor no estén correlacionados con los residuos del modelo.

Cuando los residuos del modelo son negativos y se sobreestima el crecimiento para densidades relativas sobre el 60%, el rango entre los máximos y los mínimos (amplitud) de fracción evaporativa es estrecho, implicando un régimen hídrico más homogéneo en el rodal, esto puede explicar que, en condiciones de máxima competencia dadas en la línea de inminente mortalidad por competencia (Gezan et al., 2007), es probable que los individuos que necesiten mayores cantidades de agua, no estén obteniéndola, y por ende, su crecimiento se estanca (Bréda et al., 1994). En casos donde los residuos son positivos y se subestima el crecimiento, los máximos y los mínimos “peaks” de EF son más distantes entre sí, lo que demuestra una alta variabilidad en la condición hídrica del rodal, con condiciones de

variabilidad en los regímenes de agua, individuos más viejos están más propensos a morir por competencia en épocas de escasez, dando espacio a individuos más jóvenes para que tomen su lugar y crezcan a una mayor celeridad. Cornish y Vertessy (2000) hablan de la relación entre la evapotranspiración y el crecimiento, el cual también relacionan con el área foliar y la edad. Según Ryan et al. (1997, Citado por Cornish y Vertessy, 2000) los componentes claves de la productividad de los bosques (productividad primaria neta, producción de madera, fotosíntesis y área foliar) cambian con la edad, al inicio incrementan, seguido de un “peak” a cierta edad donde luego comienza a decaer, la evapotranspiración a su vez imita este comportamiento si se observa el bosque en periodos extensos de tiempo (Langford, 1976; citado por Cornish y Vertessy, 2000). Las fluctuaciones que tiene la fracción evaporativa cambian según la edad del rodal, si la edad es heterogénea, la fluctuación es mayor y en caso contrario, cuando la edad es más homogénea dentro del rodal, la fluctuación de la evapotranspiración es menor.

Muñoz et al. (2014) investigaron la relación entre el crecimiento y la humedad del suelo obtenida por observaciones satelitales en *Araucaria araucana*, siendo esta asociación la más significativa en su estudio ( $R^2=0,65$ ), donde se plantea que las cambiantes sequías de las décadas pasadas, mostradas por datos de bajas precipitaciones y altas temperaturas, ha resultado en el declive regional del crecimiento en los bosques de los Andes. Corvalán et al. (2014) también reportan que para el área de estudios la precipitación promedio anual entre los años 2006-2012 presenta una disminución del 34,8%, y en consecuencia una disminución del crecimiento anual corriente de un 22,2% para árboles en competencia. Relacionando estos datos con los resultados de amplitud de fracción evaporativa, al haber un escaso pero homogéneo régimen hídrico en los rodales, el crecimiento es bajo pero constante. En casos donde hay regímenes hídricos más variables, existen épocas donde la disponibilidad del recurso es mayor, y los individuos aprovechan estos periodos para crecer.

## CONCLUSIONES

El propósito de esta investigación fue analizar y comparar la información del crecimiento volumétrico de renovales de *Nothofagus obliqua* con información derivada de técnicas de teledetección como predictores de las condiciones estructurales y ambientales en que los rodales se desarrollan. Los predictores temporales derivados de teledetección pasiva presentaron correlaciones significativas con los residuos del modelo de crecimiento, por sobre aquellos predictores topográficos-estructurales y aquellos texturales. Se destaca principalmente el máximo de verdor alcanzado en 10 años (GNDVI\_MAX), y la amplitud de fracción evaporativa, esto es la diferencia entre los máximos y los mínimos de EF obtenidos en el periodo estudiado.

Se registraron correlaciones entre los residuos del DMD y el máximo de vigor (GNDVI\_MAX) en densidades relativas muy altas, esto se puede explicar con los diagramas de manejo de densidad, donde en esos índices de densidad, el sitio es el que más determina el crecimiento de los rodales, y no así la competencia. En caso de densidades bajas, también se encontró una correlación entre el máximo vigor y el CAP, al no poseer competencia entre las copas de los individuos, los rodales tienen la capacidad de absorber toda la radiación fotosintéticamente activa, lo que se traduce en altos índices de verdor.

Para rodales donde existe una inminente mortalidad por competencia, los rangos de fracción evaporativa son los más correlacionados con el crecimiento en los rodales, en casos donde el crecimiento es sobrestimado por el modelo de crecimiento, el consumo hídrico de los rodales es más homogéneo, a su vez, cuando el modelo subestima el crecimiento, se muestran mayores variaciones en la evapotranspiración lo que se traduce en rodales de respuestas variadas al estrés hídrico, existen periodos donde el recurso hídrico es más abundante, dando posibilidad a los individuos de crecer. Esto también puede ser explicado por las fluctuaciones que tiene la fracción evaporativa según la edad del rodal, si la edad es heterogénea, la fluctuación es mayor y en caso contrario, cuando la edad es más homogénea dentro del rodal, la fluctuación de la evapotranspiración es menor.

Este estudio comprueba la relación entre el crecimiento de los árboles, con predictores ambientales derivadas de la teledetección pasiva, en un periodo de diez años. Estos resultados, se consideran un aporte para el conocimiento del comportamiento de los rodales de *Nothofagus obliqua*, y pueden ser utilizados para intereses económicos y de explotación de estos recursos.

## BIBLIOGRAFÍA

- Ahern, F. J.; T. Erdle; D. A. Maclean e I. D. Knepeck. 2014. A quantitative relationship between forest growth rates and Thematic Mapper reflectance measurement. *International Journal of Remote Sensing*, 12(3): 387-400.
- Archibald, D. y C. Bowling. 1995. Jack pine density management diagram for boreal Ontario. (Technical Note N°31), Ministry of Natural Resources. Northeast and Northwest Science and Technology Unit. Ontario, Canada. 21p.
- Arthur, G. y J. K. Ord. 1992. The Analysis of Spatial Association by Use of Distance Statistics. *Geogr. Anal.*, 20(3): 189-206.
- Asrar, G.; M. Fuchs; E. T. Kanemasu; y J. L. Hatfield. 1984. Estimating Absorbed Photosynthetic Radiation and Leaf Area Index from Spectral Reflectance in Wheat. *Agron. J.*, 76(2): 300-306.
- Boehner, J. y O. Antonic. 2009. Land surface parameters specific to topo-climatology. *Developments in Soil Science*, 33: 195-226.
- Bréda, N.; A. Granier y G. Ausenac. 1994. Effects of thinning on soil and tree water relations, transpiration and growth in an oak forest (*Quercus petraea* (Matt.) Liebl.). *Tree Physiology*, 15: 295-306.
- Breiman, L. 1996. Heuristic of instability and stabilization in model selection. *Ann. Statist.*, 24(6): 2350-2383.
- Breiman, L. 2001. Random forests. *Machine Learning*, 45(1): 5-32.
- Burrough, P. A. y R. A. McDonell. 1998. Principles of Geographical Information Systems. USA, New York: Oxford University Press, 190p.
- Caballero, W. 1975. Introducción a la estadística. San José, Costa Rica: Instituto Interamericano de Ciencias Agrícolas. 291p.
- Cabezas, J.; M. Galleguillos y J. F. Perez-Quezada. 2016. Predicting Vascular Plant Richness in a Heterogeneous Wetland Using Spectral and Textural Features and a Random Forest Algorithm. *IEEE Geoscience and Remote Sensing Letters*, 13(5): 646-650.
- California Institute of Technology. 2001. ASTER Higher-Level Product User Guide. (JPL D-20062), Jet Propulsion Laboratory, California Institute of Technology. [en línea]. California, USA: Caltech. 80 p. Recuperado en:

<[https://asterweb.jpl.nasa.gov/content/03\\_data/04\\_Documents/ASTERHigherLevelUserGuideVer2May01.pdf](https://asterweb.jpl.nasa.gov/content/03_data/04_Documents/ASTERHigherLevelUserGuideVer2May01.pdf)> Consultado el: 24 de abril de 2016.

Carlson, K.; G. Asner; R. Hughes; R. Ostertag y R. Martin. 2007. Hyperspectral Remote Sensing of Canopy Biodiversity in Hawaiian Lowland Rainforests. *Ecosystems*, 10(4): 536-549.

Ceballos A.; J. Hernández; P. Corvalán y M. Galleguillos. 2015. Comparison of airborne LiDAR and satellite hyperspectral remote sensing to estimate vascular plant richness in deciduous Mediterranean forest of central Chile. *Remote Sens.*, 7(3): 2692-2714.

Chauchard, L; R. Sbrancia; M. González; L. Maresca; A. Rabino y M. Mazzuchelli. 2001. Aplicación de leyes fundamentales de la densidad a bosques de *Nothofagus*: II. Línea de inicio de competencia y diagramas de manejo de la densidad. *Bosque*, 22(1): 3-10.

Clark, M. L.; D. B. Clark y D. A. Roberts. 2004. Small-footprint lidar estimation of subcanopy elevation and tree height in a tropical rain forest landscape. *Remote Sens. Environ.*, 91(1): 68-89.

Cornish, P. M. y R. A. Vertessy. 2000. Forest age-induced Changes in evapotranspiration and water yield in a eucalypt forest. *Journal of Hydrology*, 242: 43-63.

Corvalán, P.; M. Galleguillos y J. Hernandez. 2014. Impacto de la declinación de la precipitación en el crecimiento diametral del roble (*Nothofagus obliqua* (Mirb.) Oerst. ) en el límite norte de su distribución. En: International Expert Symposium "Coping with Droughts"(1ra, noviembre de 2014, Santiago, Chile). Santiago, Chile: UNESCO. 1p.

Corvalán, P. 2015. Diagrama de manejo de la densidad de rodal para el control del tamaño de ramas basales en bosques septentrionales altoandinos dominados por roble en la Región del Maule. Santiago, Chile: Facultad de Ciencias Forestales y de la Conservación de la Naturaleza. 121p.

Dees, M.; C. Straub y B. Koch. 2012. Can Biodiversity Study Benefit from Information on the Vertical Structure of Forest? Utility of LiDAR Remote Sensing. *Forest Remote Sensing, Biodiversity and Climate*, 102(8): 1181-1187.

Dietterich, T. G. 2000. An experimental comparison of three methods for constructing ensembles of decision trees: Bagging, boosting, and randomization. *Mach. Learn.*, 40(2): 139-157.

Donoso, C. 1995. Bosques templados de Chile y Argentina: Variación, estructura y dinámica. 3a ed. Santiago: Editorial Universitaria. 477p.

Drew, T. J. y J. W. Flewelling. 1979. Stand density management: an alternative approach and its application to Douglas-fir plantations. *Forest Science*, 25(3): 518-532.

- Echeverría, C.; D. Coomes; J. Salas; J.M. Rey-Benayas; A. Lara y A. Newton. 2006. Rapid deforestation and fragmentation of Chilean temperate forests. *Biol. Con-serv.*, 130(4): 481-494.
- Ewers, R. M.; R. K. Didham; S. D. Wratten y J. M. Tylianakis. 2005. Remotely sensed landscape heterogeneity as a rapid tool for assessing local biodiversity value in a highly modified New Zealand landscape. *Biodivers. Conserv.*, 14(6): 1469-1485.
- Faraway, J. J. 2009. Linear Models with R. Florida, USA: Taylor & Francis Group. 242p.
- Fox, J. y S. Weisberg. 2011. An R Companion to Applied Regression. 2da ed. Minneapolis, USA: SAGE Publications. 472p.
- Fassnacht, F. E.; F. Hartig; H. Latifi; C. Berger; J. Hernández; P. Corvalán et al. 2014. Importance of sample size, data type and prediction method for remote sensing-based estimations of aboveground forest biomass. *Remote Sens Environ.* 154: 102-114.
- Fujisada, H. 1998. ASTER Level-1 Data Processing Algorithm. *IEEE Transactions on Geoscience and Remote Sensing*, 36(4): 1101-1111.
- Gallant, J. C. and T. I. Dowling. 2003. A multiresolution index of valley bottom flatness for mapping depositional areas. *Water Resour. Res.*, 39(12): 1347.
- Galleguillos, M.; F. Jacob; L. Prévot; A. French y P. Lagacherie. 2011. Comparison of two temperature differencing methods to estimate daily evapotranspiration over a Mediterranean vineyard watershed from ASTER data. *Remote Sensing of Environment*, 115(6): 1326-1340.
- Gebejes, A. y R. Huertas. 2013. Texture Characterization based on Grey-Level Co-occurrence Matrix (pp. 375-378). En: Information and Communication Technologies - International Conference (2a, Marzo de 2013, Žilina, Slovakia). ICTIC - Proceedings in conference of informatics and management sciences. Žilina, Slovakia: EDIS – Publishing. 512p.
- Gezan, S.; A. Ortega y E. Andenmatten. 2007. Diagramas de manejo de densidad para renovales de Roble, Raulí y Coigüe en Chile. *Bosque*, 28(2): 97–105.
- Gillespie, A. R.; T. Matsunaga; S. Rokugawa y S. J. Hook. 1998. Temperature and Emissivity Separation from Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER) Images. *IEEE Transactions on Geoscience and Remote Sensing*, 36: 1113-1126.
- Ginrich, S. 1967. Measuring and evaluating stocking and stand density in upland hardwood forests in the central states. *Forest Science*, 13(4): 38-53.
- Goward, S. N.; C. J. Tucker y D. G. Dye. 1985. North American vegetation patterns observed with the NOAA-7 advanced very high resolution radiometer. *Vegetatio*, 64(1): 3-14.

Granitto P. M.; C. Furlanello; F. Biasioli y F. Gasperi. 2006. Recursive feature elimination with random forest for PTR-MS analysis of agroindustrial products. *Chemom. Intell. Lab. Syst.*, 83(2): 83-90.

Grossmann, E.; J. Ohmann; J. Kagan; H. May y M. Gregory. 2010. Mapping ecological systems with a random forest model: tradeoffs between errors and bias. *Gap Analysis Bulletin*, 17(1): 16-22.

Hair, J. F.; W. C. Black; B. J. Babin y R. E. Anderson. 2009. *Multivariate Data Analysis*. 7th ed. Upper Saddle River, USA: Prentice-Hall. 816p.

Hais, M. y T. Kucera. 2009. The influence of topography on the forest surface temperature retrieved from Landsat TM, ETM+ and ASTER thermal channels. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(6): 585-591.

Hastie, T.; R. Tibshirani y J. Friedman. 2009. *The Elements of Statistical Learning: Data mining, Inference and Prediction*. 2nd ed. New York, USA: Springer-Verlag. 745p.

Hjerdt, K. N.; J. J. McDonnell; J. Seibert y A. Rodhe. 2004. A new topographic index to quantify downslope controls on local drainage. *Water Resources Research*, 40: 1-6.

Hofierka, J. y M. Šúri. 2002. The solar radiation model for Open source GIS: implementation and applications. En: GRASS users conference 2002 (1ra, Septiembre de 2002, Trento, Italia). Proceedings of the Open source GIS. Trento, Italia. 19p.

Hunt, R. 1994. Relationship between woody biomass and PAR conversion efficiency for estimating net primary production from NDVI. *International Journal of Remote Sensing*, 15(8): 1725-1729.

Isenburg, M., 2014. LAStools-Efficient Tools for LiDAR Processing, Software for rapid converting, filtering, viewing, gridding, and compressing of LIDAR. Versión: 140221. [en línea] Germany. Recuperado en: <<http://lastools.org>>. Consultado el: 26 marzo de 2016.

Isenburg, M.; Y. Liu; J. Shewchuk; J. Snoeyink y T. Thirion. 2006. Generating Raster DEM from Mass Points via TIN Streaming. *Lecture Notes in Computer Science*, 4197 LNCS: 186-198.

Jones, H.G. y R.A. Vaughan. 2010. *Remote Sensing of Vegetation: Principles, Techniques, and Applications*. New York, USA: Oxford University Press. 353p.

Kalacska, M.; G. Sanchez-Azofeifa; B. Rivard; T. Caelli; H. White y J.C. Calvo-Alvarado. 2007. Ecological Fingerprinting of Ecosystem Succession: Estimating Secondary Tropical Dry Forest Structure and Diversity Using Imaging Spectroscopy. *Remote Sensing of Environment*, 108(1): 82-96.

- Krajicek, J. y K. Brinkman. 1957. Crown competition-a measure of density. *Forest Science*, 7: 35-42.
- Krajicek, J.; K. Brinkman y S. Ginrich. 1961. Crown competition – a measure of density. *Forest Science*, 7(1): 35–42.
- Kursa, M. B. y W. R. Rudnicki. 2010. Feature Selection with the Boruta Package. *Journal of Statistical Software*, 36(11): 1-13.
- Langford, K. J. 1976. Change in yield of water following a bushfire in a forest of Eucalyptus regnans. *J. Hydrol.*, 29: 87-114.
- Lara, A.; A. Wolodarsky-Franke; J. C. Aravena; R. Villalba; M. E. Solari; L. Pezoa et al. 2005. Climate fluctuations derived from tree-rings and other proxy-records in the Chilean Andes: state of the art and future prospects. *Advances in Global Change Research*, 23: 145-156.
- Laurin, G. V.; Q. Chen; J. A. Lindsell; D. A. Coomes; F. Del Frate; L. Guerriero et al. 2014. Above ground biomass estimation in an African tropical forest with lidar and hyperspectral data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 89: 49-58.
- Leutner, B.; B. Reineking; J. Müller; M. Bachmann; C. Beierkuhnlein; S. Dech et al. 2012. Modelling Forest  $\alpha$ -Diversity and Floristic Composition - On the Added Value of LiDAR plus Hyperspectral Remote Sensing. *Remote Sensing*, 4(9): 2818-2845.
- Long, J. N. 1985. A practical approach to density management. *For. Chron.*, 61: 88–89.
- Lopatin, E.; T. Kolström y H. Spiecker. 2006. Determination of forest growth trends in Komi Republic (northwestern Russia): combination of tree-ring analysis and remote sensing data. *Boreal Environment Research*, 11: 341-353.
- Luebert, F. y P. Plischoff. 2006. Sinopsis bioclimática y vegetacional de Chile. Santiago, Chile: Editorial Universitaria. 316p.
- Luna, E.S.; P. I. Figuerola; E. G. Abril y A. C. Ravelo. 2013. La fracción evaporativa en diferentes regiones agrícolas y naturales del centro-noroeste de la Argentina. *Agriscientia*, 30(1): 13-24.
- Maguya, A. S.; V. Junttila y T. Kauranne. 2014. Algorithm for extracting Digital Terrain Models under forest canopy from airborne LiDAR data. *Remote Sens.*, 6(7): 6524-6548.
- Marquardt, D. 1980. You Should Standardize the Predictor Variables in Your Regression Models. *Journal of the American Statistical Association*, 369(75): 87-91.

- Monteith, J. L. 1972. Solar radiation and productivity in tropical ecosystems. *Journal of Applied Ecology*, 9: 747-766.
- Morales, M.; R. Villalba; H. Grau; P. Villagra; J. Boninsegna; A. Ripalta et al. 2001. Potencialidad de *Prosopisferox* Griseb (Leguminosae, subfamilia: Mimosoideae) para estudios dendrocronológicos en desiertos subtropicales de alta montaña. *Revista Chilena de Historia Natural*, 74(4): 865-872.
- Müller-Using, B.; R. Rodríguez y P. Gajardo. 2013. Desarrollo de una guía de manejo de la densidad en bosques de segundo crecimiento de roble (*Nothofagus obliqua*) en la región del Biobío. *Bosque*, 34(2): 201-209.
- Muñoz, A. A.; J. Barichivich; D. A. Christie; W. Dorigo; D. Sauchyn; Á. González-Reyes et al. 2014. Patterns and drivers of *Araucaria araucana* forest growth along a biophysical gradient in the northern Patagonian Andes: Linking tree rings with satellite observations of soil moisture. *Austral Ecology*, 39: 158–169.
- Nageswara, C.R.; S.S. Sreehari; K. Mallika; H.S. Tiong y K.B. Mahalakshmi. 2013. Co-Occurrence Matrix and Its Statistical Features as an Approach for Identification of Phase Transitions of Mesogens. *International Journal of Innovative Research in Science, Engineering and Technology*, 2(9): 4531-4538.
- Navarro, C.; M. Herrera; F. Drake y P. Donoso. 2011. Diagrama de manejo de densidad y su aplicación a raleo en bosques de segundo crecimiento de *Drimys winteri* en el sur de Chile. *Bosque*, 32(2): 175–186.
- Navarro, C; J. Pinares; C. Pinilla y M. Sanhueza. 2010. Diagramas de manejo de la densidad: una herramienta de gestión silvícola. *Gestión Ambiental*, 20: 63–73.
- Newton, P. 1997. Stand density management diagrams: review of their development and utility in stand-level management planning. *Forest Ecology and Management*, 98: 251– 265.
- Olivera-Guerra, L.; C. Mattar y M. Galleguillos. 2014. Estimation of real evapotranspiration and its variation in Mediterranean landscapes of central-southern Chile. *International Journal of Applied Earth Observation and Geoinformation*, 28: 160-169.
- Paruelo, J. 2008. La caracterización funcional de ecosistemas mediante sensores remotos. *Ecosistemas*, 17(3): 4-22.
- Peng, C.; L. Zhang y J. Liu. 2001. Developing and validating nonlinear height-diameter models for major tree species of Ontario's boreal forests. *North. J. Appl. For.*, 18:87-94.
- Posada, D., and T. R. Buckley. 2004. Model selection and model averaging in phylogenetics: advantages of akaike information criterion and bayesian approaches over likelihood ratio tests. *Systematic biology*, 53:793–808.

- Presutti, M. 2004. La matriz de Co-ocurrencia en la clasificación multispectral: tutorial para la enseñanza de medidas texturales en cursos de grado universitario. En: 4ª Jornada de Educação em Sensoriamento Remoto no Âmbito do Mercosul (4ta, agosto de 2004, São Leopoldo, Brasil). Recursos Didáticos para o Ensino de Sensoriamento Remoto. 9p.
- Proisy, C.; P. Couteron y F. Fromard. 2007. Predicting and mapping mangrove biomass from canopy grain analysis using Fourier-based textural ordination of IKONOS images. *Remote Sensing of Environment*, 109: 379-392.
- Raven, P. H.; R. F. Evert y S. E. Eichhorn. 1992. Biología de las Plantas. 4ta ed. Barcelona, España: Editorial Reverté S. A. 777p.
- Reineke, L. 1933. Perfecting a stand density index for even-age forest. *Journal of Agricultural Research*, 46: 627-638.
- Riley, S.J.; S.D. De Gloria y R. Elliot. 1999. A terrain ruggedness that quantifies topographic heterogeneity. *Intermount. J. Sci.*, 5(1): 23-27.
- Roach, B. 1977. A stocking guide for allegheny hardwood and its use in controlling intermediate cuttings. Forest Service research paper, United States Department of Agriculture, 34p.
- Roberts, D.W. 1986. Ordination on the basis of fuzzy set theory. *Vegetatio*, 66(3): 123-131.
- Rodriguez, R.; O. Mathei y M. Quezada. 1983. Flora arbórea de Chile. Ed. Universitaria de Concepción. 408p.
- Roerink, G. J.; Z. Su y M. Menenti. 2000. S-SEBI: a simple remote sensing algorithm to estimate the surface energy balance. *Physics and Chemistry of the Earth. Part B: Hydrology, Oceans and Atmosphere*, 25(2), 147-157.
- Royston, P. 1995. Remark AS R94: A remark on algorithm AS 181: The W-test for normality. *Appl. Stat.*, 44(4): 547-551.
- Rueda, C.V.; G. Baldi; S.R. Verón y E.G. Jobbáry. 2013. Apropiación Humana de la producción primaria en el chaco Seco. *Ecología Austral*, 23: 44-54.
- Ryan, M.G.; D. Binkley y J.H. Fownes. 1997. Age-related decline in forest productivity: pattern and process. *Adv. Ecol.*, 27: 213-262.
- San Martin C.; C. Ramirez; H. Figueroa y N. Ojeda. 1991. Estudio sinicológico del bosque roble-laurel-lingue del centro-sur de Chile. *Bosque*, 12(2): 11-27.

Schweingruber, F.H. 1988. *Tree Rings: Basic and Applications of Dendrochronology*. Dordrecht, Paises Bajos: Kluwer Academic Publisher. 276p.

Seibert, J. y B. McGlynn. 2007. A new triangular multiple flow direction algorithm for computing upslope areas from gridded digital elevation models. *Water Resour. Res.*, 43(4): W04501.

Shapiro, S. S., y M. B. Wilk. 1965. An Analysis of Variance Test for Normality (Complete Samples). *Biometrika*, 52: 591–611.

Sharma, M. & Parton, J. 2007. Height-diameter equations for boreal tree species in Ontario using a mixed-effects modeling approach. *Forest Ecology and Management*, 249:187-19.

Shaw, J. y J. Long. 2005. A density management diagram for even-aged ponderosa pine stands. *Western Journal of Applied Forestry*, 20(4): 205–215.

Shaw, J. y J. Long. 2007. A density management diagram for longleaf pine stands with application to red-cockaded woodpecker habitat. *Southern Journal of Applied Forestry*, 31(1): 28–38.

Smith, D.; B. Larson; M. Kelty y P. Ashton. 1997. *The Practice of silviculture: Applied forest ecology*. 9th ed. New York, USA: John Wiley & Sons. 537p.

Song, C. y C.E. Woodcock. 2003. Monitoring Forest Succession With Multitemporal Landsat Images: Factors of Uncertainty. *IEEE Transaction on Geoscience and Remote Sensing*, 41(11): 2557-2567.

St-Louis, V.; A.M. Pidgeon; V.C. Radeloff; T.J. Hawbajer y M.K. Clayton. 2006. High-resolution image texture as a predictor of bird species richness. *Remote Sensing of Environment*, 105: 299-312.

Vacchiano, G.; R. Motta; J. Long y J. Shaw. 2008. A density management diagram for Scots pine (*Pinus sylvestris* L.): a tool for assessing the forest's protective effect. *Forest Ecology and Management*, 255(7): 2542-2554.

Vaglio Laurin, G.; Q. Chen; J. A. Lindsell; D. A. Coomes; F. Del Frate; L. Guerriero et al. 2014. Above ground biomass estimation in an African tropical forest with lidar and hyperspectral data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 89: 49-58.

Valbuena, P.; C. Del Peso y F. Bravo. 2008. Stand Density Management Diagrams for two Mediterranean pin species in Eastern Spain. *Investigación Agraria: Sistemas y Recursos Forestales*, 17(2): 97-104

Valencia, D. 2012. Estimación de biomasa aérea en plantaciones de *Pinus radiata* (D. Don) utilizando datos LiDAR en combinación con diferentes índices vegetacionales. Memoria

Ingeniero Forestal, Mención Gestión Forestal. Santiago, Chile: Facultad de Ciencias Forestales y de la Conservación de la Naturaleza, Universidad de Chile. 28h.

Valenzuela, T. 2014. Diagramas de manejo de densidad de rodal en el tipo forestal Roble-Hualo. Memoria Título Profesional de Ingeniero Forestal. Facultad de Ciencias Forestales y de la Conservación de la Naturaleza. 35p.

Wang, J.; P.M. Rich; K.P. Price y W.D. Kettle. 2004. Relations between NDVI and tree productivity in the central Great Plains. *International Journal of Remote Sensing*, 25: 3127-3138.

Weller, D. 1987. A reevaluation of the  $-3/2$  power rule of plant self-thinning. *Ecological Monographs*, 57(1): 23-43.

White, J.; C. Gómez; M. Wulder y N. Coops. 2010. Characterizing Temperate Forest Structural and Spectral Diversity with Hyperion EO-1 Data. *Remote Sensing of Environment*, 114(7): 1576-1589.

Wilson, J.P.; J.C. Gallant. 2000. Terrain Analysis - Principles and Applications. 1ra ed. New York, USA: John Wiley & Sons. 520p.

Wolodarsky-Franke, A. y A. Lara. 2003. La dendrocronología como herramienta en la conservación de especies arbóreas en peligro en Chile. *Gestión Ambiental*, 9: 15-23.

Yoda, K.; T. Kira; H. Ogawa y K. Hozumi. 1963. Intraspecific competition among higher plants. XI: self-thinning in overcrowd pure stand under cultivated and natural conditions. *Journal of Osaka City University Institute of Polytechnics*, 14: 107-129.

Zeide, B. 1987. Analysis of the  $3/2$  power law of self-thinning. *Forest Science*, 33: 517-537.

Zevenbergen, L. W. and C. R. Thorne. 1987. Quantitative analysis of land surface topography. *Earth Surf. Proc. Land.*, 12(1): 47-56.

## APÉNDICES

### Apéndice I: Cálculo de predictores LiDAR

#### Predictores topográficos:

1. **Altitud:** Este predictor es equivalente al MDT el cual fue calculado a partir de la nube de puntos LiDAR, utilizando el Software LASTools, el cual se ejecuta desde la consola de comandos de Windows ya que está basado en el sistema operativo DOS (“Disk Operating System”). La metodología para la obtención de este MDT es la utilizada por Ceballos et al. (2015).
2. **Pendiente:** Este predictor fue calculado en base al MDT utilizando el software ArcGIS 10.1 de ESRI, en el directorio: “ArcToolBox/Spatial Analyst Tools/Surface/Slope”. el cálculo de la herramienta “Slope” utiliza el valor de cada pixel en una celda de 3x3 alrededor del pixel central a procesar, convirtiendo estos valores en coordenadas del eje z. el valor de la pendiente de este plano es calculada usando la técnica del promedio máximo (Burrough y McDonell, 1998).

La pendiente derivada del algoritmo puede ser calculada en dos tipos de unidad, grados y porcentaje de elevación, en el caso de este estudio se utilizó la unidad de grados que es el ángulo que se provoca entre la distancia entre los pixeles (primer cateto) y la elevación o valor del eje z del pixel central (segundo cateto).

3. **Aspect:** Esta variable fue utilizada para el cálculo de otros predictores, pero no fue utilizada como un predictor topográfico para el desarrollo de los resultados. Para el cálculo de esta variable se utilizó en software ArcGIS 10.1 y el MDT, la herramienta se encuentra en el directorio: “ArcToolBox/Spatial Analyst Tools/Surface/Aspect” del mismo software.

El algoritmo utiliza el mismo concepto que en el cálculo de pendiente, usa una celda 3x3 alrededor del pixel a procesar y utiliza el valor de los pixeles como valores del eje z. luego analiza la dirección a la que apunta el plano generado y la considera como la orientación de la celda central, esta dirección se mide en el sentido de las agujas del reloj en grados, desde 0 (dirección norte) a 360 (dirección norte, nuevamente), formando un círculo completo. Para áreas sin pendiente o planas, se les otorga un valor de -1 y son consideradas sin orientación.

4. **Northness y Eastness:** estos predictores fueron generados utilizando las herramientas de ArcGIS 10.1 que se encuentran en el directorio: “ArcToolBox/Spatial Analyst Tools/Math /Trigonometric/” usando para “Northness” la herramienta “Cos” y para “Eastness” la herramienta “Sin”. Se utilizó como objeto de entrada el “Aspect” calculado

anteriormente.

La orientación o “Aspect” no puede ser utilizada directamente ya que tanto el dato de grado 0 como el de grado 360 representan la misma orientación (en este caso norte), por lo tanto, es necesario transformarlo utilizando cálculos trigonométricos. Calculando el coseno de la orientación, los pixeles con orientación cercana al norte tendrán un valor próximo al uno y los pixeles con orientación cercana a la sur, tendrán datos de “Northness” próximos al cero. Usando el seno de la orientación el comportamiento es similar al explicado con anterioridad, solo que para “Eastness” los datos que se acerquen más hacia el este tendrán valores cercanos al 1.

La transformación de la orientación como la explicada con anterioridad fue seleccionada ya que, aunque es posible transformar los datos de orientación en simples variables cualitativas (N, NE, E, SE, S, SW, W, NW), estas no pueden ser ingresadas a algoritmos que utilizan como motor a “Random Forest” y ser comparada con datos cuantitativos continuos como los utilizados en esta investigación.

### **Predictores hidrológicos:**

5. **Catchment Slope:** Para el cálculo de este predictor se utilizó el algoritmo disponible en el software SAGA GIS en el directorio: “Terrain Analysis – Hydrology/Catchment Area (Parallel) de la librería de módulos del software. Este algoritmo utiliza como variable de entrada el MDT y es el resultado derivado del cálculo principal del algoritmo que es la acumulación de flujo o “Catchment Area” y la opción del cálculo se encuentra en la misma herramienta como opción adicional. Este predictor representa la medida relativa de la pendiente media de todas las celdas que son consideradas “upslope” o aguas arriba de la celda objetivo y representa el indicador de energía potencial de todo el flujo que puede eventualmente pasar sobre esa celda, pero se relaciona directamente con la velocidad y el poder de estos. Los parámetros de entrada utilizados para el cálculo de esta variable son: “Step” o la definición del paso a considerar para la acumulación del flujo; “Method” que otorga cinco posibles métodos a utilizar; y tres parámetros asociados, “Linear Flow” y “Linear Flow Threshold” asociados al “Method” “Deterministic 8” y “Convergence” asociado al método “Multiple Flow Direction”. A continuación, se entregan los parámetros utilizados para el cálculo de este predictor:

- Step: 1, de celda en celda, opción “Default”
- Method: Multiple Flow Direction, opción “Default”
- Linear Flow: Sin Marcar o 0, opción “Default”
- Linear Flow Threshold: 500, opción “Default”
- Convergence: 1.1, opción “Default”

Este predictor fue utilizado por Ceballos et al. (2015) y fue uno de los predictores más relevantes en sus resultados, motivo por el cual fue seleccionado para esta investigación

y la metodología para el cálculo de este predictor también fue obtenida de la misma fuente.

- 6. Downslope Distant Gradient:** Para el cálculo de este predictor se utilizó el algoritmo disponible en el software SAGA GIS en el directorio: “Terrain Analysis – Morphometry/Downslope Distant Gradient” el cual utiliza como variable de entrada el MDT.

Este predictor calcula que tan lejos, en una ladera cuesta abajo, una parcela de agua debe moverse para perder cierta cantidad de energía potencial. Este efecto podría ser de gran importancia en ciertos tipos de terreno para el control de gradientes hidráulicas (Hjerdt et al. 2004).

Los parámetros de entrada necesarios para el cálculo del algoritmo son: “Vertical Distance”; y “Output” que es la selección de la unidad de medida del resultado, el cual puede ser en distancia, o en gradiente (ya sea en grados o como la tangente del ángulo). Los parámetros seleccionados se encuentran a continuación:

- Vertical Distance: 10, opción “Default”
- Output: gradient (degree), opción “Default”

#### **Predictores de geoforma:**

- 7. MrVBF y MrRTF:** Para el cálculo de estos dos predictores se utilizó el algoritmo disponible en el software SAGA GIS en el directorio: “Terrain Analysis – Morphometry/Multiresolution Index of Valley Bottom Flatness” y utiliza como variable de entrada el MDT. Ambos predictores son resultado de una misma herramienta y utilizan los mismos parámetros de entrada.

EL MrVBF o “Multi-resolution Index of Valley Bottom Flatness” identifica zonas que tengan comportamiento de valles, analizando el comportamiento de la pendiente y la elevación de los píxeles vecinos en consecutivas operaciones aumentando y disminuyendo la escala, permitiendo identificar valles a pequeña y gran escala.

El MrRTF o “Multi-resolution index of Ridge Top Flatness” identifica áreas que posean características de cumbre, analizando el comportamiento de la pendiente y la elevación de los píxeles vecinos en consecutivas operaciones con mayores y menores escalas, lo cual permite identificar cumbres a pequeña y a gran escala.

Los parámetros de entrada para el cálculo de ambos predictores son:

- Initial Threshold for Slope: 15, correspondiente al tamaño del pixel utilizado.
- Threshold for Elevation Percentile (Lowness): 0.4, opción “Default”
- Threshold for Elevation Percentile (Upness): 0.35, opción “Default”

- Shape Parameter for Slope: 4, opción “Default”
- Shape Parameter for Elevation Percentile: 3, opción “Default”
- Update Views: 1, opción “Default”
- Classify: 0, opción “Default”
- Vertical Distance: 10, opción “Default”
- Maximum Resolution (Percentage): 100, opción “Default”

**8. Terrain Ruggedness Index:** Para el cálculo de este predictor se utilizó el algoritmo disponible en el software SAGA GIS en el directorio: “Terrain Analysis – Morphometry/Terrain Ruggedness Index (TRI)” y utiliza como variable de entrada el MDT.

Este predictor calcula la heterogeneidad del terreno, realizando una suma de los cambios de elevación obtenidos del MDT, sus parámetros de entrada son:

- Radius (Cells): 1, opción “Default” que es el radio considerado desde el pixel objetivo.
- Weighting: 4, opción “Default” que es el peso asociado a los vecinos analizados.

#### **Predictores de iluminación:**

**9. Potential Incoming Insolation:** Para el cálculo de estos tres predictores se utilizó el algoritmo disponible en el software SAGA GIS en el directorio: “Terrain Analysis – Lighting, Visibility/Potential Incoming Solar Radiation” y utiliza como variable de entrada el MDT.

De este algoritmo se derivan tres predictores utilizados en este estudio, “Potential Incoming Direct Insolation”, “Potential Incoming Diffuse Insolation” y “Potential Incoming Total Insolation”, todos derivan de un mismo algoritmo y requieren de los mismos parámetros de entrada. Estos predictores miden la cantidad de radiación solar potencial en el área, tanto la radiación directa, la radiación difusa, y la suma de ambas dos. Este cálculo fue realizado para todas las fechas que fueron tomadas las imágenes ASTER y luego se realizó un promedio de todas ellas para los tres predictores.

Los parámetros de entrada para el cálculo de los tres predictores son:

- Solar Constant [ $W / m^2$ ]: 1367, opción “Default”
- Local Sky View Factor: 0, que se basa en la pendiente local.
- Units:  $kWh / m^2$ , opción “Default”
- Latitude: latitude otorgada por el MDT
- Planetary Bending: 0, opción “Default”
- Time Period: range of days
- Moment: 12, opción “Default”
- Time Span: 24, horas del día consideradas.

- Time Resolution: los días que fueron tomadas las imágenes ASTER, luego se realizó un promedio de ellas.
- Update: 0, opción "Default"
- Atmospheric Effects: Height of Atmospheric and Vapour Pressure, opción "Default"
- Height of Atmosphere [m]: 12000, opción "Default"
- Water Vapour Pressure [mbar]: 10, opción "Default"

## Apéndice II: Cálculo de Predictores con Imágenes ASTER

Las imágenes ASTER poseen tres bandas que son utilizables para realizar el cálculo de índices vegetacionales, la banda 1 (B1) tiene una longitud de onda entre 0,52 y el 0,60  $\mu\text{m}$  que representa al verde dentro del espectro visible, la banda 2 (B2) tiene una longitud de onda entre el 0,63 y el 0,69  $\mu\text{m}$  que es el espectro rojo, finalmente la banda 3 (B3) representa el espectro entre el 0,76 y el 0,86  $\mu\text{m}$ , considerado el infrarrojo cercano. Las fórmulas utilizadas a continuación tienen la nomenclatura de las bandas utilizadas para su cálculo.

1. **NDVI:** este índice representa la cantidad, calidad y desarrollo de la vegetación en base a la medición de la intensidad de la radiación de ciertas bandas del espectro electromagnético que la vegetación refleja, y capturada mediante sensores remotos. El cálculo de este índice se encuentra en la Ecuación (7).

$$NDVI = \frac{B3-B2}{B3+B2} \quad (7)$$

2. **GNDVI:** Este índice representa la actividad fotosintética de la vegetación o verdor, y es el índice más usado para determinar el consumo de agua y nitrógeno en el dosel de los cultivos. El cálculo de este índice se encuentra en la Ecuación (8)

$$GNDVI = \frac{B3-B1}{B3+B1} \quad (8)$$

### Apéndice III: Cálculo de Texturas de Primer y Segundo Orden

1. **Texturas de Primer Orden:** para el cálculo de las texturas de primer orden fue utilizado el software ArcGIS 10.1, específicamente la herramienta “Focal Statistics” ubicada en el directorio: “ArcToolBox/Spatial Analyst Tools/Neighborhood” y la variable de entrada fue el MDT. Las texturas de primer orden también llamadas Matrices de Ocurrencia calculan estadísticas utilizando el valor del pixel seleccionado y el de los vecinos que lo rodean, agregando información espacial del contexto (relación de un pixel con los objetos y características que tiene a su alrededor) a la que ya se posee (Jones y Vaughan, 2010). Las matrices de ocurrencia calculadas con la herramienta son las siguientes: “Mean” que determina la media de los pixeles vecinos; “Maximum” que deja el valor máximo de entre todos los vecinos; “Minimum” que selecciona y para el pixel central el mínimo valor de entre los vecinos; “Range” que calcula la diferencia entre el valor mayor y el menor de entre todos los vecinos y “STD” que calcula la desviación estándar entre los vecinos. Los parámetros utilizados para todas las texturas de primer orden son las siguientes:
  - Height: 3
  - Width: 3
  - Units: Cell
  - Ignore NoData in calculation: si
  
2. **Texturas de Segundo Orden:** Para el cálculo de las texturas de segundo orden se utilizó el software R y el paquete “gldm”. La variable de entrada fue el MDT transformado a formato ASCII para su introducción como matriz de datos a R.

Las texturas de segundo orden o también conocidas como matrices de co-ocurrencia o GLCM (“Grey Level Co-occurrence Matrix”) busca la relación entre los niveles de grises entre los pixeles vecinos en específicas direcciones o distancias (Jones y Vaughan, 2010). Homogeneidad es una medida de contraste, en este caso determina la suavidad de la variación de las escalas de grises, el opuesto a Contraste, que determina la variación local entre los grises; Disimilaridad es otra forma de medir variación entre las escalas de grises, similar a Contraste pero se calcula de manera distinta; GLCM media o media de segundo orden calcula la media de la frecuencia de la co-ocurrencia del pixel en combinación con un determinado valor del pixel vecino, no es la ponderación por sí mismo; Entropía tiene valores altos cuando los elementos de la matriz de co-ocurrencia tiene valores relativamente iguales; Correlación determina que tan relacionados los niveles de grises entre los pixeles vecinos, un pixel tiene alta correlación dentro de él que entre objetos adyacentes, a su vez, pixeles cercanos tienen más correlación entre sí que pixeles más distantes (Jones y Vaughan, 2010); la varianza de segundo orden, determina al igual que la media, no solo la ponderación de la varianza por sí misma, sino la frecuencia de la co-ocurrencia del pixel en combinación con un determinado valor del pixel vecino (St. Louis et al., 2006).

Los parámetros utilizados para el cálculo de las texturas de segundo orden son:

- n\_grey: 32, el número de escalas de grises se utilizará en el cálculo.
- window: c(3, 3), el tamaño de la ventana a considerar para la textura.
- shift: c(1, 1), se especifica el cambio de la matriz a utilizar
- statistics: dependiendo de la GLCM a utilizar; "mean", "variance", "homogeneity", "contrast", "dissimilarity", "entropy", "second\_moment", "correlation".
- na\_opt: "ignore", como maneja los datos No-Data, en este caso, se ignorarán.
- na\_val: NA, como estarán escritos los valores No-Data en la matriz de salida.
- scale\_factor: 1, factor multiplicativo de los datos, útil para resultados con números enteros.
- asinteger: FALSE, en este caso se pide no redondear los datos a enteros.

### Apéndice IV: Lista de predictores

**Cuadro 9.** Listado de predictores utilizados en los algoritmos de minería para determinar la relación con los residuos del modelo.

Tipo de predictor	Nombre del predictor generado	Sigla
<b>MDT</b>	Altitud	DEM15
<b>Derivadas topográficas de primer orden en base al MDT</b>	Pendiente	SLOPE
	Cos(Aspect) Northness	NORTH
	Sin(Aspect) Eastness	EAST
<b>Predictores hidrológicos en base al MDT</b>	Catchment slope	CATCHSLO
<b>Predictores topo-hidrológicos en base al MDT</b>	Downslope distance Gradient	GRADIENT
<b>Predictores de geoforma topomorfométricos en base al MDT</b>	Multi-resolution index of Valley bottom flatness (MrVBF)	MRVBF
	Multi-resolution index of Ridge Top Flatness (MrRTF)	MRRTF
	Terrain Ruggedness Index	TRI
<b>Predictores de Iluminación en base al MDT</b>	Potential incoming direct insolation	DIRECTISO
	Potential incoming diffuse insolation	DIFFUSEISO
	Potential incoming total insolation	TOTALISO
<b>Predictores estadísticos</b>	Mediana de GNDVI	GNDVI_MEDIANA
	Mediana de NDVI	NDVI_MEDIANA
	Mediana de Fracción Evaporativa	EF_MEDIANA
	Media de GNDVI	GNDVI_MEAN
	Media de NDVI	NDVI_MEAN
	Media de Fracción Evaporativa	EF_MEAN
	Desviación estándar de GNDVI	GNDVI_SD
	Desviación estándar de NDVI	NDVI_SD
	Desviación estándar de Fracción Evaporativa	EF_SD
	Mínimo de GNDVI	GNDVI_MIN
	Mínimo de NDVI	NDVI_MIN
	Mínimo de Fracción Evaporativa	EF_MIN
	Máximo de GNDVI	GNDVI_MAX
	Máximo de NDVI	NDVI_MAX
	Máximo de Fracción Evaporativa	EF_MAX
Amplitud de GNDVI	GNDVI_AMPLITUD	
Amplitud de NDVI	NDVI_AMPLITUD	
Amplitud de Fracción Evaporativa	EF_AMPLITUD	

**Cuadro 9:** Continuación.

<b>Matrices de Ocurrencia o Texturas de primer orden</b>	Desviación estándar de los vecinos de GNDVI	TXGNDVI_SD
	Desviación estándar de los vecinos de NDVI	TXNDVI_SD
	Desviación estándar de los vecinos de Fracción Evaporativa	TXEF_SD
	Rango de los vecinos de GNDVI	TXGNDVI_RANGE
	Rango de los vecinos de NDVI	TXNDVI_RANGE
	Rango de los vecinos de Fracción Evaporativa	TXEF_RANGE
	Mínimo de los vecinos de GNDVI	TXGNDVI_MIN
	Mínimo de los vecinos de NDVI	TXNDVI_MIN
	Mínimo de los vecinos de Fracción Evaporativa	TXEF_MIN
	Máximo de los vecinos de GNDVI	TXGNDVI_MAX
	Máximo de los vecinos de NDVI	TXNDVI_MAX
	Máximo de los vecinos de Fracción Evaporativa	TXEF_MAX
	Media de los vecinos de GNDVI	TXGNDVI_MEAN
	Media de los vecinos de NDVI	TXNDVI_MEAN
	Media de los vecinos de Fracción Evaporativa	TXEF_MEAN
	Media de los vecinos de MDC	TXMDC_MEAN
	Máximo de los vecinos de MDC	TXMDC_MAX
	Media del modelo de altura dominante	TXHDOM_MEAN
	Desviación estándar de los píxeles vecinos de altura	TXDEM_SD
	Desviación estándar de los píxeles vecinos la pendiente	TXSLOPE_SD

**Cuadro 9:** Continuación.

<b>Matrices de Co-ocurrencia (GLCM) o Texturas de segundo orden</b>	Varianza de GNDVI	GNDVI_VAR
	Varianza de NDVI	NDVI_VAR
	Varianza de Fracción Evaporativa	EF_VAR
	Angular second moment de GNDVI	GNDVI_SECM
	Angular second moment de NDVI	NDVI_SECM
	Angular second moment de Fracción Evaporativa	EF_SECM
	Media de segundo orden de GNDVI	GNDVI_MEAN2
	Media de segundo orden de NDVI	NDVI_MEAN2
	Media de segundo orden de Fracción Evaporativa	EF_MEAN2
	Homogeneidad de GNDVI	GNDVI_HOM
	Homogeneidad de NDVI	NDVI_HOM
	Homogeneidad de Fracción Evaporativa	EF_HOM
	Entropía de GNDVI	GNDVI_ENT
	Entropía de NDVI	NDVI_ENT
	Entropía de Fracción Evaporativa	EF_ENT
	Disimilaridad de GNDVI	GNDVI_DISS
	Disimilaridad de NDVI	NDVI_DISS
	Disimilaridad de Fracción Evaporativa	EF_DISS
	Correlación de GNDVI	GNDVI_COR
	Correlación de NDVI	NDVI_COR
Correlación de Fracción Evaporativa	EF_COR	
Contraste de GNDVI	GNDVI_CONT	
Contraste de NDVI	NDVI_CONT	
Contraste de Fracción Evaporativa	EF_CONT	

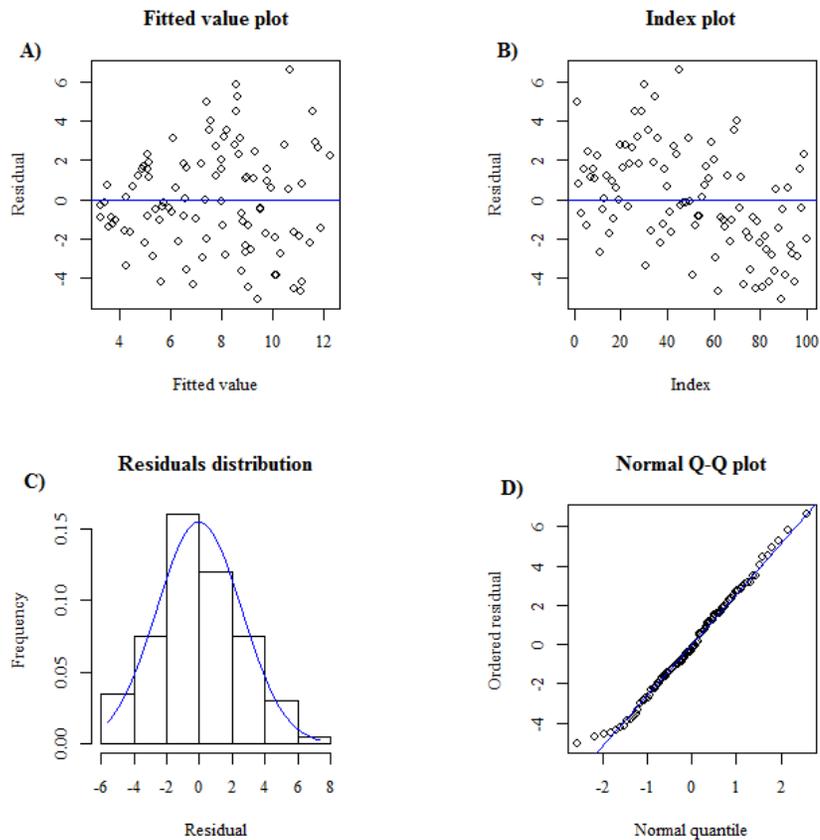
### Apéndice V: Evaluación de Supuestos del GLM

En el Cuadro 10 se muestran los análisis de los supuestos del GLM que corroboran la robustez del modelo propuesto.

**Cuadro 10.** Evaluación de supuestos del GLM y validación del análisis de regresión.

<b>Supuestos del Modelo Lineal Generalizado</b>	<b>Valor</b>	<b>p-value</b>	<b>p-value aceptable</b>			
Estadística Global	2,664	0,6155	> 0,05			
Asimetría	0,4	0,527	> 0,06			
Curtosis	0,856	0,355	> 0,07			
“Link Function”	0,0737	0,391	> 0,08			
Heterocedasticidad	0,672	0,413	> 0,09			
<b>Evaluación de "Outliers"</b>	<b>Bonfer. p</b>	<b>p-value</b>	<b>Parcela</b>	<b>p-value aceptable</b>		
Prueba de Bonferroni	0,887	0,0089	45	< 0,05		
<b>Normalidad de los residuos</b>	<b>W</b>	<b>p-value</b>	<b>p-value aceptable</b>			
Test de Shapiro-Wilk	9,9887	0,557	> 0,05			
<b>Prueba de Autocorrelación</b>	<b>D-W</b>	<b>Autocorr.</b>	<b>p-value</b>	<b>p-value aceptable</b>		
Test de Dublin-Watson	1,293	0,332	0	< 0,05		
<b>Prueba de autocorrelación espacial</b>	<b>Índice</b>	<b>Índice Esperado</b>	<b>z-score</b>	<b>p-value</b>	<b>p-value aceptable</b>	<b>Patrón</b>
Prueba I de Moran	0,299	-0,0101	1,6412	0,1007	> 0,05	Aleatorio

## Apéndice VI: Gráficos descriptivos del comportamiento de los residuos del GLM



**Figura 16.** Gráficos descriptivos del comportamiento de los residuos. **A)** Grafico de predichos vs residuos. **B)** “Index Plot” que muestra la influencia de los datos residuales en la regresión cuadrática según el orden en el cual los datos fueron ordenados. **C)** Histograma con distribución normal de los residuos studentizados. **D)** “Q-Q Plot” de los residuos ordenados vs cuartiles teóricos de comportamiento normal.

Analizando los gráficos **C)** y **D)** de la Figura 16 se corrobora de manera gráfica lo ya indicado por el test de Shapiro-Wilk mostrando el comportamiento normal de los datos, según Hair et al. (2009) en datos que se comportan normalmente, el “Q-Q Plot” de probabilidad normal debe estar en la extensión de los cuartiles sobre la línea de distribución normal acumulativa (representada por la línea azul en la Figura 16, D). En el gráfico **A)** se muestra una correlación nula, aunque por su forma se puede también interpretarse como una relación heterocedástica (Hair et al., 2009), entre los residuos y los predichos, en **B)** se muestra una correlación nula entre los residuos y su orden de muestreo (Hair et al., 2009).

### Apéndice VII: Sumario de salida del GLM

**Cuadro 11.** Sumario de salida del ajuste cuadrático realizado al GLM.

Residuales:				
Mínimo	1Q	Mediana	3Q	Máximo
-5,079	-1,764	-0,244	1.718	6.623
Coeficientes:				
	Estimado	Error	t	Pr(> t )
DR	0,1627904	0,0154456	10,54	<2e-16***
I(DR^2)	-0,0004728	0,0001985	-2,382	0,0192*
Código Significancia: 0 '***' 0,001 '**' 0,01 '*' 0,05 '.' 0,1 ' ' 1				

Error estándar Residual: 2,593 en 98 grados de libertad.

R-cuadrado Múltiple: 0,9078, R-cuadrado Ajustado: 0,9059

Estadístico F: 482,2 en 2 y 98 grados de libertad,

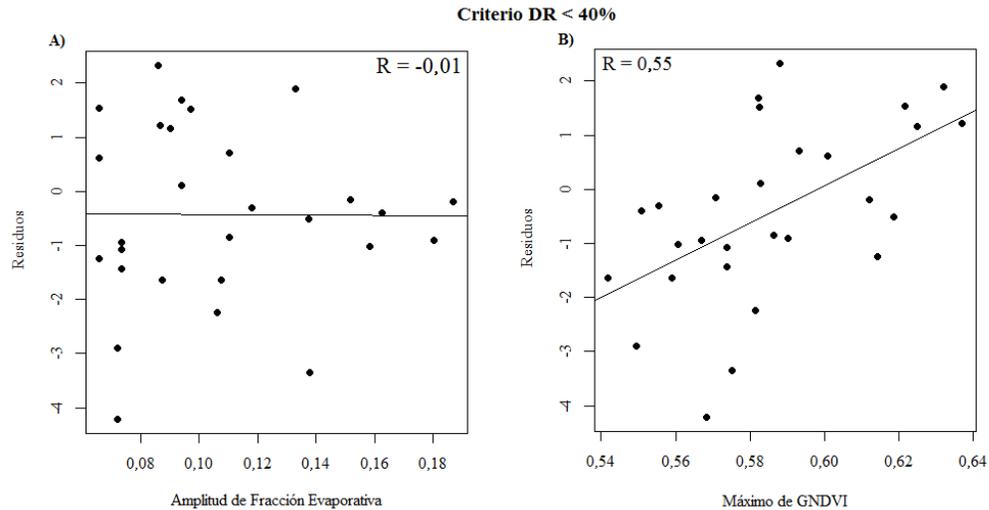
p-value: < 2,2e-16

### Apéndice VIII: Modelos Lineales analizados

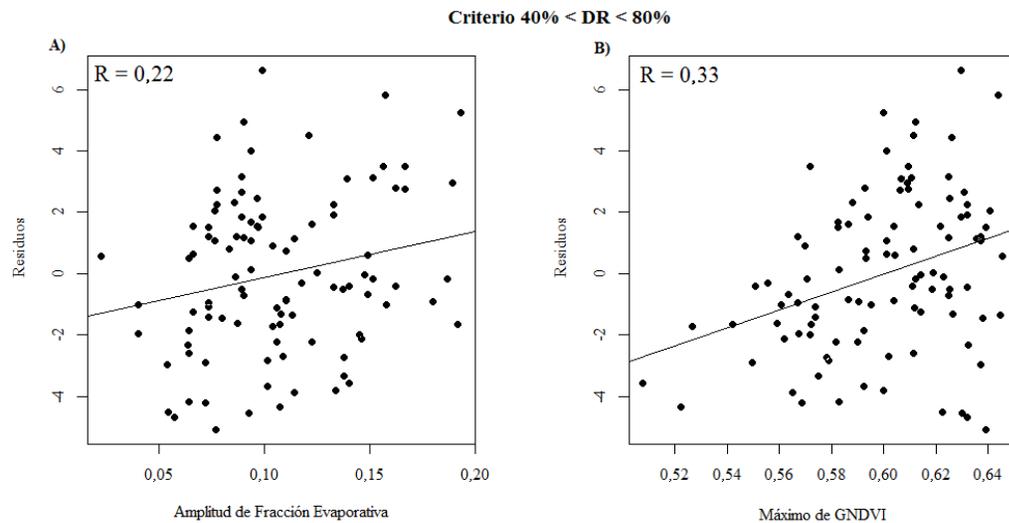
**Cuadro 12.** Modelos lineales para los residuos del modelo en base a los predictores seleccionados por los algoritmos RFE y Boruta.

Modelo Lineal	Predictores agregados al modelo lineal	RSE	R <sup>2</sup> Multiple	R <sup>2</sup> Adjusted	p-value	AIC	BIC
(1)	EF_AMPLITUD, NDVI_MAX, GNDVI_MAX, gndvimean2, NDVI_MEDIANA, DEM15, EF_SD, TXNDVI_MAX	2,393	0,2095	0,14	0,004769	468,83	494,88
(2)	EF_AMPLITUD, NDVI_MAX, GNDVI_MAX, gndvimean2, NDVI_MEDIANA, DEM15, EF_SD	2,382	0,2077	0,1474	0,002553	467,06	490,51
(3)	EF_AMPLITUD, NDVI_MAX, GNDVI_MAX, gndvimean2, DEM15, EF_SD	2,369	0,2077	0,1566	0,00116	465,06	485,91
(4)	EF_AMPLITUD, GNDVI_MAX, gndvimean2, DEM15, EF_SD	2,36	0,2055	0,1633	0,0005317	463,33	481,57
(5)	EF_AMPLITUD, GNDVI_MAX, gndvimean2, DEM15	2,348	0,205	0,1715	0,0001986	461,4	477,03
(6)	EF_AMPLITUD, GNDVI_MAX, gndvimean2	2,347	0,1977	0,1726	9,32 x10 <sup>-5</sup>	460,31	473,34
(7)	EF_AMPLITUD, GNDVI_MAX	2,342	0,193	0,1763	3,05 x10 <sup>-5</sup>	458,9	469,32
(8)	gndvimean2, EF_SD	2,353	0,1847	0,1679	4,99 x10 <sup>-5</sup>	459,92	470,34
(9)	GNDVI_MAX	2,445	0,1108	0,1017	0,0007158	466,6	474,42
(10)	EF_AMPLITUD	2,532	0,0465	0,03677	0,03118	473,58	481,4

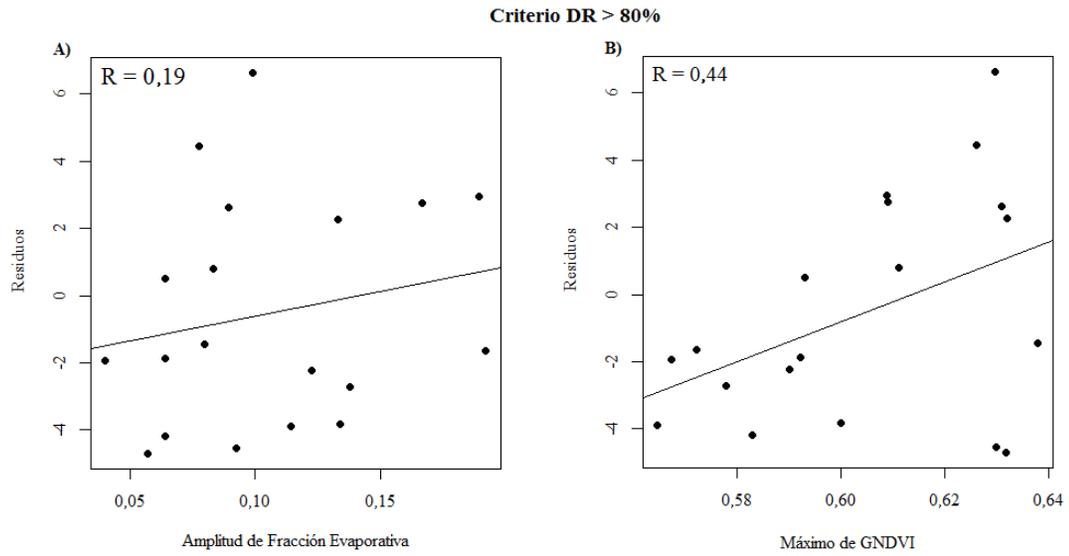
### Apéndice IX: Gráficos de correlación de Pearson para diferentes criterios de densidad relativa



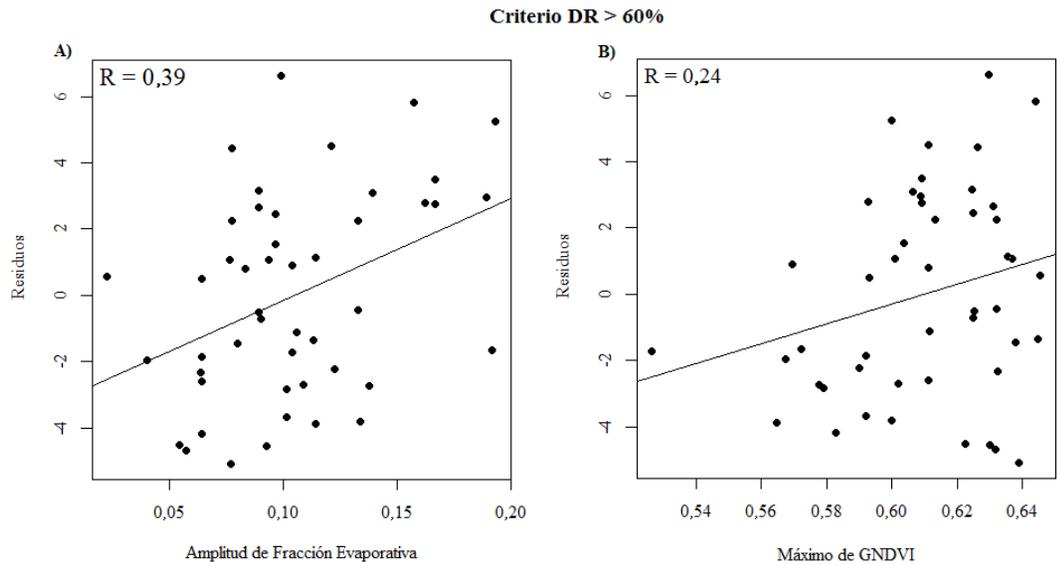
**Figura 17.** Gráficos de correlación para un criterio de densidad relativa menor a 40%, en **A)** amplitud de fracción evaporativa y los residuos del modelo; en **B)** el máximo de GNDVI y los residuos.



**Figura 18.** Gráficos de correlación para un criterio de densidad relativa entre el 40% y el 80%, en **A)** amplitud de fracción evaporativa y los residuos del modelo; en **B)** el máximo de GNDVI y los residuos.



**Figura 19.** Gráficos de correlación para un criterio de densidad relativa mayor a 80%, en A) amplitud de fracción evaporativa y los residuos del modelo; en B) el máximo de GNDVI y los residuos.



**Figura 20.** Gráficos de correlación para un criterio de densidad relativa mayor a 60%, en A) amplitud de fracción evaporativa y los residuos del modelo; en B) el máximo de GNDVI y los residuos.