

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

**MEMORIA DE TÍTULO**

**IMPACTO DE LA VEGETACIÓN EN LA ESTIMACIÓN DE LA HUMEDAD DE  
SUPERFICIE UTILIZANDO UN MÉTODO ÓPTICO MICROONDAS PASIVO EN  
CHILE**

**DIEGO ANDRÉS URIBE FIGUEROA**

**Santiago, Chile**

**2016**

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

**MEMORIA DE TÍTULO**

**IMPACTO DE LA VEGETACIÓN EN LA ESTIMACIÓN DE LA HUMEDAD DE  
SUPERFICIE UTILIZANDO UN MÉTODO ÓPTICO MICROONDAS PASIVO EN  
CHILE**

**VEGETATION IMPACT ON THE SURFACE SOIL MOISTURE ESTIMATION  
USING A COMBINED OPTICAL-PASSIVE MICROWAVE METHOD OVER  
CHILE.**

**DIEGO ANDRÉS URIBE FIGUEROA**

**Santiago, Chile**

**2016**

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

**IMPACTO DE LA VEGETACIÓN EN LA ESTIMACIÓN DE LA HUMEDAD DE  
SUPERFICIE UTILIZANDO UN MÉTODO ÓPTICO MICROONDAS PASIVO EN  
CHILE.**

Memoria para optar al Título Profesional de:  
Ingeniero en Recursos Naturales Renovables

**DIEGO ANDRES URIBE FIGUEROA**

<b>Profesor Guía</b>	<b>Calificaciones</b>
Sr. Cristian Mattar B. Ingeniero en Recursos Naturales Renovables, Dr.	7,0
<b>Profesores Evaluadores</b>	
Sr. Luis Morales S. Profesor de Ciencias Naturales y Física, Dr.	7,0
Sra. María Verónica Díaz M. Ingeniero Agrónomo, Mg. Sc.	7,0

**Santiago, Chile**

**2016**

## **AGRADECIMIENTOS**

Comienzo agradeciéndole a mi familia por el cariño, preocupación y apoyo que siempre me brindaron durante todos estos años, especialmente durante la elaboración de esta memoria.

A mi profesor guía Cristian Mattar por su gran apoyo y disposición en todo momento que permitieron lograr esta meta, también a Andrés Santamaría por la ayuda otorgada y al Laboratorio para el Análisis de la Biosfera.

Finalmente, a CONICYT y al proyecto FONDECYT Iniciación 10133359 “Estimating the surface soil moisture at regional scale by using a synergic optical-passive microwave approach and remote sensing data” por hacer posible esta memoria.

## INDICE

RESUMEN .....	1
ABSTRACT .....	2
INTRODUCCIÓN.....	3
Objetivo General.....	5
Objetivos Específicos .....	5
DATOS Y MÉTODOS .....	6
Área de estudio .....	6
Datos .....	7
Metodología.....	9
RESULTADOS Y ANÁLISIS .....	12
Procesamiento Espacial de Datos .....	12
Calibración del Método óptico microondas pasivo de Mattar et al. (2012) .....	14
Validación del Método óptico microondas pasivo de Mattar et al. (2012).....	24
Análisis de Error .....	29
DISCUSIÓN.....	31
CONCLUSIONES.....	33
BIBLIOGRAFÍA.....	34

## ÍNDICE DE FIGURAS

Figura 1. El área de estudio se extiende desde la Región de Coquimbo hasta la Región de los Lagos separándose en zona norte, centro y sur.....	6
Figura 2. Clases de coberturas originales y procesadas extraídas de las bases de datos de CONAF (superior), ESA-CCI (medio) y ECOCLIMAP (inferior).....	13
Figura 3. Mapas de coeficientes “a” (intercepto) de las regresiones realizadas con VEG=LAI (superior), VEG=NDVI (medio) y VEG=0 (inferior), para cada periodo de calibración. ....	15
Figura 4. Mapas de coeficientes “b” (temperatura de brillo horizontal) de las regresiones realizadas con VEG=LAI (superior), VEG=NDVI (medio) y VEG=0 (inferior), para cada periodo de calibración. ....	16
Figura 5. Mapas de coeficientes “c” (temperatura de brillo vertical) de las regresiones realizadas con VEG=LAI (superior), VEG=NDVI (medio) y VEG=0 (inferior), para cada periodo de calibración. ....	17
Figura 6. Mapas del coeficiente “d” (indicador de vegetación) de las regresiones realizadas con VEG=LAI (superior) y VEG=NDVI para cada año y para un periodo general incluyendo todos los años.....	18
Figura 7. Mapas de coeficientes de determinación de las regresiones realizadas con VEG=0 (superior), VEG=LAI (medio) y VEG=NDVI (inferior), para cada año y para un periodo general incluyendo todos los años.....	20
Figura 8. Mapas del incremento del coeficiente de determinación de las regresiones realizadas con VEG=LAI (superior) y VEG=NDVI (inferior), para cada año y para un periodo general incluyendo todos los años.....	21
Figura 9. Diagrama de cajas de humedad del suelo estimada para el año 2015 para cada periodo de calibración agrupados en clases de cobertura de superficie y para cada cartografía. Los “outliers” son representados como círculos. ....	23
Figura 10. Diagramas de caja de RMSE según CONAF (arriba), ECOCLIMAP (medio) y ESA-CCI (abajo) para el año de validación agrupado en clases de cobertura de superficie. Los “outliers” son representados como círculos.....	26
Figura 11. Humedad del suelo y precipitación (in situ) para el año 2015 en la estación LAB-net presente en la localidad de Chimbarongo (a) y Oromo (b) localizadas en 34°43'39,67"S 70°58'46,16"O y 40°52'23,160"S 73°0'41,400"O respectivamente. ....	28
Figura 12. Errores de propagación en la estimación de humedad del suelo para el año 2015 en la estación LAB-net presente en la localidad de Oromo localizada en las coordenadas 40°52'23,160"S 73°0'41,4"O utilizando como indicador de vegetación al LAI (arriba) y NDVI (abajo).....	29

## RESUMEN

La humedad del suelo es una de las variables climáticas esenciales de la biósfera debido a que dirige los flujos de agua y energía entre la superficie de la tierra y la atmósfera. Su estimación es importante para gran cantidad de estudios, entre ellos los relacionados a la demanda hídrica, modelos de predicción climática, estudios sobre la cobertura vegetal y las actividades agrícolas. Entre los métodos para estimar la humedad del suelo se han desarrollado modelos semi-empíricos que utilizan la sinergia generada entre datos ópticos y las microondas pasivas en banda L provenientes de sensores remotos. La ventaja de estos modelos es que consideran los efectos producidos por la cubierta vegetal sobre la señal captada por el sensor, permitiendo estimaciones desde escalas locales a globales. El objetivo de este trabajo fue analizar el impacto de diferentes indicadores de vegetación sobre la estimación de la humedad del suelo utilizando el algoritmo óptico-microondas pasivo (OPM). Esto fue realizado para un periodo entre enero del 2010 hasta diciembre del 2015 considerando los datos de temperatura de brillo bipolarizada en banda L de la misión “Soil Moisture Ocean Salinity” (SMOS); el índice de vegetación de diferencia normalizada (NDVI) y el índice de área foliar (LAI) del sensor “Moderate Resolution Imaging Spectroradiometer” (MODIS) y la humedad y temperatura de los primeros 7 cm de suelo provenientes del “reanalysis” ERA-Interim. Luego se evaluaron y compararon estas estimaciones utilizando las cartografías de uso de suelo de la Corporación Nacional Forestal (CONAF), de la “European Space Agency Climate Change Initiative” (ESA-CCI) y de ECOCLIMAP. Con estos datos se generó una base de 6 años de datos para cada pixel dentro del área de estudio, utilizando desde el 2010 al 2014 para calibrar el método OPM y el año 2015 para validar los valores de humedad del suelo.

Los resultados mostraron que al incluir un indicador de vegetación en el método OPM se generaron en la mayoría de las cartografías disminuciones en la Raíz del Error Cuadrático Medio (RMSE) superiores a un 8%  $m^3m^{-3}$  en las coberturas de “bosque”, “matorral”, “pradera” y “áreas sin vegetación” tanto utilizando NDVI como el LAI. Mientras tanto, el análisis de errores permitió observar que el OPM presenta una mayor sensibilidad para los valores de LAI que para el NDVI, posiblemente atribuible a las diferencias en los métodos de estimación de ambas variables. Las estimaciones de humedad del suelo realizadas a partir de NDVI pueden generar una importante fuente de información para futuras aplicaciones en el estudio de variables ambientales en Chile como por ejemplo índices de sequía a través de datos satelitales o mapas nacionales de monitoreo de sequías.

**Palabras clave:** Humedad de la superficie, índices de vegetación, óptico microondas pasivas, Propagación de errores.

## ABSTRACT

Soil moisture is one of biosphere's essential climate variables because it guides the water and energy flow between the land surface and the atmosphere. Soil moisture estimates is relevant for a great amount of studies, including those related to water demand, climate prediction models, vegetation cover studies and agricultural activities. Among the methods to estimate soil moisture, semi-empirical models have been developed using the synergy between optical data and passive microwaves L-band from remote sensors. The advantage of these models is that they take into account the effects of the vegetation cover captured by the sensor signal, allowing estimate from local to global scales. The objective of this study is to analyze the impact of different vegetation indicators on soil moisture using an Optical Passive Microwave algorithm (OPM). This was done for the period January 2010 - December 2015, considering: the bipolarized brightness temperature data from Soil Moisture Ocean Salinity (SMOS) of the L-band mission; the Normalized Difference Vegetation Index (NDVI) and Leaf Area Index (LAI) from the Moderate Resolution Imaging Spectroradiometer (MODIS) sensor and the humidity and temperature for the first 7 cm. of soil from the reanalysis ERA-Interim. These estimations were evaluated and compared using land use maps from the National Forest Corporation (CONAF), the European Space Agency Climate Change Initiative (ESA-CCI) and ECOCLIMAP. This data is based on six years for each pixel within the study area, where the period 2010 - 2014 was used to calibrate the OPM method, and the year 2015 was used to validate the values of soil moisture.

The results showed that by including a vegetation indicator in the semi-empirical method, the Root Mean Square Error (RMSE) decreases over 8%  $\text{m}^3 \text{m}^{-3}$  in most of the cartographies in the forest, shrub, grasslands and areas without vegetation coverages, both using NDVI and LAI. At the same time, analysis of the errors allowed to observe that the OPM is more sensitive to LAI errors than NDVI error. This is possibly because of the differences in the estimation methods for both variables. Estimates of soil moisture retrieved from NDVI can generate an important source of information for future applications in the study of environmental variables in Chile, such as of drought indexes through satellite data or drought monitoring maps.

**Keywords:** Soil Moisture, Vegetation Index, Optical Passive Microwave, Propagation errors.

## INTRODUCCIÓN

La humedad del suelo es una de las variables climáticas esenciales de la biósfera debido a que dirige los flujos de agua y energía entre la superficie de la tierra y la atmósfera (Kerr, 2007; Mittelbach et al., 2011; Albergel et al., 2012). La humedad del suelo juega un rol fundamental controlando la evaporación y transpiración, desde coberturas de suelos desnudos hasta coberturas con vegetación densa (Albergel et al., 2012), así como también controla el particionado de precipitación en escorrentía e infiltración (Famiglietti et al., 1998; Kerr, 2007). Los estudios de la humedad del suelo a escalas globales o continentales son un importante “input” para diversas áreas, entre ellos, estudios de la variación del tiempo y el clima (Douville y Chauvin, 2000; Drush, 2007), estudios de crecimiento vegetal (Diermeyer et al., 1999; Georgakakos y Carpenter, 2006; de Wit y van Diepen, 2007; Guerif y Duke, 2000) y también en aplicaciones en la agricultura (Berg et al., 2005; Shin et al., 2006; Liu et al., 2008).

A escala global, la humedad del suelo presenta una variabilidad temporal y espacial que está determinada por factores como la topografía, las propiedades del suelo, radiación solar, precipitación y el tipo cobertura de la superficie (Korres et al., 2015). Sobre suelos desnudos, la humedad del suelo está determinada por su constante dieléctrica, la variación de textura, el contenido de materia orgánica, el color, la estructura y la existencia de macroporos (Wang y Schmugge, 1980; Famiglietti et al., 1998). Sin embargo, para las superficies con algún grado de cobertura vegetal, la estimación de la humedad del suelo resulta dependiente de las características propias del dosel como el vigor, fase fenológica, índice de área foliar, estructura del dosel, entre otras (Reynolds, 1970; Famiglietti et al., 1998).

Para la estimación de la humedad del suelo sobre estas coberturas, existen diversos métodos, como la toma de muestras *in situ* o a través de mediciones remotas provenientes de satélites. No obstante, realizar mediciones *in situ* en escalas regionales y de manera regular es difícil debido su complejidad, alto costo financiero, y además de solo ser posible en un limitado número de estaciones (Mallick et al., 2009). Por lo tanto, medidas remotas como el uso de teledetección son utilizadas para obtener productos globales y continuos de humedad del suelo (Shaoning et al., 2014). En este contexto, una de las técnicas de mayor uso es a través de microondas pasivas, específicamente mediante el rango de la banda L (1-1.4 GHz; Jackson y Schmugge, 1995), debido a que no sufren grandes perturbaciones por factores como las cubiertas de nubes, la rugosidad de la superficie del suelo o la cubierta vegetal (Kerr et al., 2001).

Entre las misiones que utiliza la banda L en el rango de las microondas se encuentra la misión “Soil Moisture Ocean Salinity” (SMOS) lanzada en noviembre de 2009. El funcionamiento de SMOS consiste en un radiómetro interferométrico en banda L que permite obtener mediante un algoritmo iterativo la temperatura de brillo (TB) y el espesor óptico de la vegetación ( $\tau$ ), utilizando observaciones multiangulares (0-65°) y bipolarizadas (Horizontal y Vertical) de la radiación emitida por la tierra (Kerr et al., 2001; Kerr et al., 2010). El núcleo

del algoritmo es el modelo “L-band Microwave Emission of the Biosphere” (L-MEB; Wigneron et al., 2007), el cual está fundamentado en el modelo tau-omega ( $\tau - \omega$ ) propuesto por Ulaby et al. (1986). Una aproximación al modelo tau-omega sobre suelos desnudos o cobertura sin vegetación fue presentado por Wigneron et al. (2004) utilizando datos *in situ*. Sin embargo, recientes estudios han logrado generar estimaciones en base al modelo tau-omega a partir de un parámetro de vegetación que relaciona el espesor óptico de la vegetación y los patrones propios de esta, como el vigor y la estructura foliar (Mattar et al., 2012; Parrens et al., 2012; Lawrence et al., 2014; Miernecki et al., 2014). Estos datos de vegetación provienen de sensores ópticos que han presentado una operacionalidad y sinergia con las microondas pasivas (Jones et al., 2011).

Entre los productos de sensores ópticos comúnmente utilizados, están el “Leaf Area Index” (LAI) y el “Normalized Difference Vegetation Index” (NDVI). El primero se define como el área proyectada de hojas por unidad de área del suelo, mientras que su estimación se basa en el análisis multiespectral y multidireccional de las firmas de reflectancia de la vegetación fotosintética, de esta forma los algoritmos para su estimación varían para cada fuente de donde provengan los datos (Wang et al., 2005; Garrigues et al., 2008). El índice NDVI por su lado, es una transformación espectral entre las bandas de infrarrojo cercano y del rojo, y se basa en las diferencias que las hojas generan en la reflectancia que llega al sensor debido a la absorción por pigmentos en la banda del rojo y la dispersión por la estructura de las hojas para la banda del infrarrojo cercano. Este índice está diseñado para mejorar la contribución de las propiedades de la vegetación y permite generar comparaciones inter-temporales y espaciales de la actividad fotosintética y las variaciones estructurales del dosel (Tucker, 1979; Huete et al., 2002), a diferencia del LAI su algoritmo es similar entre distintas fuentes de donde provengan los datos. Por lo tanto, se observa que las medidas espectrales como el NDVI están fuertemente relacionadas al LAI (Tucker, 1979), lo que se ha demostrado de forma teórica (Myneni et al., 1995) y de forma empírica sobre distintos tipos de coberturas (Cohen et al., 2003; Friedl et al., 1994; Law y Waring, 1994; Chen y Cihlar, 1996; Cohen et al., 2003; Fassnacht et al., 1997) concluyendo que los índices espectrales como el NDVI presentan sensibilidades considerables al LAI, pero aún más en valores relativamente bajos de este índice, debido a que con grandes valores de LAI el NDVI tiende a saturarse (Birky, 2001). Es en este contexto en donde los métodos Ópticos Microondas Pasivo (OPM) se caracterizan en utilizar datos tanto de la banda L en las microondas, así como de sensores ópticos como el LAI o NDVI con el fin de mejorar la estimación de la humedad de la superficie.

Los métodos semi-empíricos OPM han sido demostrados a nivel *in situ* utilizando el NDVI (Mattar et al., 2012), a nivel de pixel con el uso del LAI (Miernecki et al., 2014) y a escala regional con el uso del LAI (Parrens et al., 2012). En Chile, destaca el estudio de Santamaría-Artigas et al. (2016), en donde se realizó una calibración del OPM entre los años 2010 y 2012, bajo la clasificación temática de cobertura de suelos de la base de datos de ECOCLIMAP y utilizando al índice NDVI como indicador de vegetación. Un estudio similar fue realizado en Mattar et al. (2016a) utilizando una nueva versión de los datos de SMOS y agregando el índice LAI como indicador de vegetación, de esta forma describieron los distintos ajustes de la regresión del método semi-empírico bajo dos índices de vegetación de

uso común. Sin embargo, en ambos estudios no se desarrolló un robusto análisis estadístico sobre el impacto de la vegetación en el OPM, así como el tipo de cartografía utilizada y sensibilidad del método OPM a distintos índices de vegetación. Respecto a las coberturas de vegetación, en el estudio de Santamaría-Artigas et al. (2016) se observó que ciertas discrepancias pueden ocurrir en Chile entre las coberturas de suelo actuales y las presentes en ECOCLIMAP por lo que se hace importante generar un análisis más detallado de la homogenización de estas clasificaciones de cobertura a una escala específica considerando otras cartografías más actualizadas como ESA-CCI o locales como CONAF. Por lo tanto, el objetivo de esta memoria es analizar el impacto de la vegetación sobre el cálculo de la humedad del suelo a través de diferentes indicadores de vegetación utilizando el algoritmo OPM y diferentes cartografías temáticas de cobertura del suelo en Chile entre la Región de Coquimbo y la Región de los Lagos.

### **Objetivo General**

Analizar el impacto de diferentes indicadores de vegetación sobre la estimación de la humedad del suelo utilizando el algoritmo óptico-microondas pasivo (OPM)

### **Objetivos Específicos**

- Analizar los errores en la estimación de la humedad del suelo a partir de los indicadores NDVI y LAI
- Estimar el impacto del uso de una cartografía temática estacionaria sobre la estimación de la humedad del suelo.

## DATOS Y MÉTODOS

### Área de estudio

El área de estudio corresponde a Chile entre la Región de Coquimbo y la Región de los Lagos, lo que se extiende desde los 29° a 43° de latitud sur respectivamente (Figura 1). Según di Castri y Hajek (1976) en esta extensión estaría presente una zona de tendencia mediterránea con precipitaciones concentradas en inviernos fríos y un periodo seco estival y en el sector sur estaría presente una zona de tendencia oceánica, específicamente una región húmeda similar al tipo mediterráneo con máximo de lluvias en invierno, pero con ausencias el periodo seco estival. El área de estudio fue separada en tres zonas, estas son: zona norte entre los 29° y 32° de latitud sur, zona central entre los 32° y 38° de latitud sur; y zona sur entre los 38° y 43° de latitud sur.

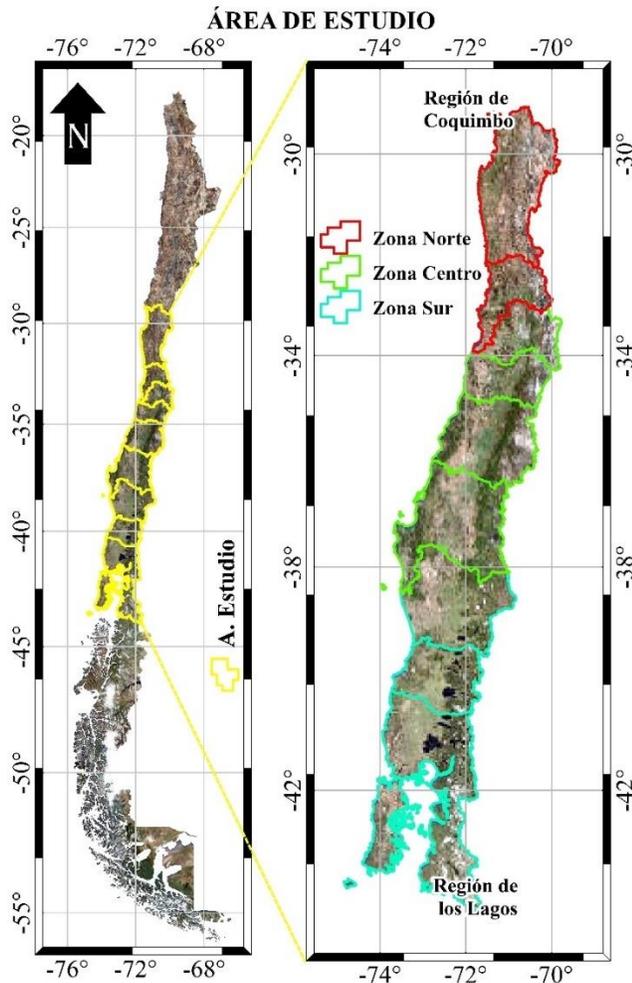


Figura 1. El área de estudio se extiende desde la Región de Coquimbo hasta la Región de los Lagos separándose en zona norte, centro y sur.

## Datos

Para la calibración y validación del método OPM se utilizaron datos de temperatura de brillo (TB) y humedad del suelo de microondas en banda L; datos de humedad y temperatura del suelo entre 0-7 cm; el índice de vegetación de diferencia normalizada (NDVI) y el índice de área foliar (LAI); datos de cobertura de superficie y datos *in situ* de precipitación y humedad del suelo. Todos los datos fueron obtenidos para el periodo comprendido entre el 1 de enero de 2010 y el 31 de diciembre de 2015. Estos datos se detallan a continuación:

### SMOS

Para la calibración del OPM fue utilizado el producto de temperatura de brillo bipolarizada de nivel 3 (L3TB), el cual es un producto diario de temperatura de brillo con ángulos de incidencia ajustados entre 2,5° a 62,5° en intervalos de 5° y está presentado en formato “Equal-Area Scalable Earth Grid” versión 2 (EASE-Grid V2) con una proyección cilíndrica de 25 Km<sup>2</sup> (Kerr et al., 2012; Kerr et al., 2016). En este trabajo se ocupó información de TB a 42,5° y en polarización vertical (TBh) y horizontal (TBv).

### MODIS

Se utilizó información de dos productos proveniente del sensor “Moderate Resolution Imaging Spectroradiometer” (MODIS) a bordo de la plataforma TERRA, estos son:

- MOD13Q1 V5 “Vegetation Index Product”, que corresponde al “Normalized Difference Vegetation Index” (NDVI). Este producto consiste en una composición de imágenes, cada 16 días, con una resolución espacial de 250 m y en una proyección sinusoidal (Huete et al., 2002).
- MOD15A2 “Leaf Area Index” (LAI) y “Fraction of Photosynthetically Active Radiation” (FPAR), compuesto cada 8 días con 1 km de resolución con una proyección sinusoidal (Myneni et al., 2002).

### ERA-INTERIM

Creado por el “European Centre for Medium-Range Weather Forecast” (ECMWF) ERA-INTERIM es una base de datos global de la cobertura de la tierra que cubre el periodo de 1979 – 2010. Entre sus datos se utilizó:

- El producto STL1 de temperatura de suelo en la primera capa de profundidad (0 - 7 cm)
- El producto SWVL1 de la capa volumétrica de agua en el suelo (0 - 7 cm)

Ambos productos tienen una resolución espacial de 0,125 x 0,125 grados y una resolución temporal de 3 horas (Bálsamo et al., 2015).

### **Cartografías Temáticas**

**ECOCLIMAP.** Consiste en una clasificación de 215 ecosistemas a nivel global, a una resolución de 1 km. Estos ecosistemas fueron clasificados utilizando diversas cartografías de cobertura terrestre, mapas climáticos, base de datos de textura del suelo (FAO) y series temporales de NDVI producto del Radiómetro AVHRR (Masson et al., 2003).

**CONAF.** La Corporación Nacional Forestal cuenta con un catastro de recursos vegetaciones dentro de su Sistema de Información Territorial (SIT-CONAF) que se actualiza periódicamente y cuenta con 9 categorías de uso de suelo: “Urbana e Industrial”, “Terreno agrícola”, “Pradera”, “Matorral”, “Bosque”, “Humedal”, “Áreas sin Vegetación”, “Nieves y Glaciares”, y “Cuerpos de Agua”.

**ESA CCI-LC.** Se utilizará el producto “Land Cover” (LC) de la “Climate Change Initiative” (CCI) dependiente de la “European Space Agency” (ESA) para el periodo 2010. Este producto consiste en mapas globales con 300 m de resolución espacial de 37 categorías de uso de suelo (Defourny et al., 2014).

### **Datos *in situ***

Fueron utilizados datos de humedad del suelo y precipitación para el periodo entre el 1 de enero al 31 de diciembre del año 2015, provenientes de la red de estaciones del Laboratorio para el Análisis de la Biosfera (LAB). Esta red de estaciones (LAB-net) cuentan con instrumentación meteorológica y de flujo radiativo que miden variables como humedad y temperatura del suelo, temperatura del aire y humedad relativa, radiación neta, radiación global, temperatura radiométrica, precipitación y flujo de calor del suelo (Mattar et al., 2016b). Para este trabajo fue utilizada la estación de Chimbarongo, localizada en 34°43'39,67"S 70°58'46,16"O y la estación de Oromo, localizada en 40°52'23,160"S 73°0'41,400"O.

## Metodología

### Procesamiento Espacial de Datos

Para procesar los datos fue necesario realizar un filtro de moda a los productos STL1, SWVL1, NDVI, LAI y a las cartografías climáticas con el fin de ajustar su resolución hacia la resolución espacial del producto SMOS L3TB (25 x 25 km). Además, previo a realizar una calibración fue necesario filtrar datos anómalos que el producto SMOS L3TB pueda poseer debido a suelos congelados, agua interceptada en la vegetación y valores de temperatura de brillo horizontal mayores que temperatura de brillo vertical (Santamaría-Artigas et al., 2016). Esto se realizó a través del índice de polarización (Ecuación 1; Mattar et al., 2012).

$$PR = \frac{TB_V - TB_H}{TB_V + TB_H}$$

Ecuación 1.

Donde,

$TB_V$  = Temperatura de brillo vertical

$TB_H$  = Temperatura de brillo horizontal

Conjuntamente se realizó un filtro a los valores de NDVI y LAI de MODIS a través del conjunto de datos “Pixel Reliability” el cual establece cinco clases de confianza de la calidad de los píxeles, las cuales son “Fill/No Data”, “Good Data” (única categoría a utilizar), “Maginal Data”, “Snow/Ice” y “Cloudy”.

### Calibración

Para estimar la humedad del suelo incluyendo los indicadores NDVI y LAI, se utilizó el método Microondas Pasivo de Santamaría-Artigas et al. (2016; Ecuación 2). Este modelo es derivado de Ulaby et al. (1986).

$$\log(w_s) = a + b \left( \log \left( 1 - \frac{TB(\theta, H)}{T_c} \right) \right) + c \left( \log \left( 1 - \frac{TB(\theta, V)}{T_c} \right) \right) + d * VEG$$

Ecuación 2.

Donde,

$w_s$  = humedad del suelo estimada [ $m^3 m^{-3}$ ]

a, b, c y d = coeficientes de regresión

$TB(\theta, V)$  y  $TB(\theta, H)$  = temperatura de brillo vertical y horizontal a  $42,5^\circ$  [K]

$T_c$  = temperatura efectiva del suelo [K]

VEG = indicador de vegetación.

Para calibrar los coeficientes de regresión utilizados en la Ecuación 2 y establecer la mejor

correlación entre las variables SM, TB, T<sub>c</sub> y Veg, se utilizó el método de regresión lineal de mínimos cuadrados y además se generaron tres modelos en los cuales como indicador de vegetación se utilizó:

- 1) NDVI (VEG=MOD13Q1);
- 2) LAI (VEG=MOD15A2)
- 3) Sin indicador de vegetación (VEG=0).

Los modelos con NDVI y con LAI fueron comparados a través del coeficiente de determinación ( $r^2$ ) y los coeficientes de regresión. El análisis se realizó año por año, desde el 2010 hasta el 2014, para todo este periodo y a su vez para cada clasificación dentro de las cartografías temáticas con el fin de estimar el impacto de las cartografías en la estimación de la humedad del suelo.

### Validación

La validación se realizó año a año para cada modelo (NDVI, LAI, VEG=0). Los valores del producto SWVL1 fueron tomados como la variable observada de cada estimación de los modelos en el cálculo del “Root Mean Squared Error” (RMSE; Ecuación 1) el que considera el sesgo de la humedad del suelo y la desviación estándar de los residuos generados entre las estimaciones y los valores observados (Entekhabi et al., 2010)

$$RMSE = \sqrt{bias^2 + \sigma^2}$$

Ecuación 3.

Donde,

$bias$  = sesgo estadístico

$\sigma$  = desviación estándar de los residuos.

### Análisis de Errores

También se efectuó un análisis de sensibilidad para conocer la influencia de los errores asociados al uso de indicadores de vegetación en la estimación de la humedad del suelo, esto se hizo a través del cálculo del error de propagación (Ecuación 4). Por lo tanto, este análisis de errores fue realizado en el caso de utilizar el índice LAI y también en el caso del uso del índice NDVI.

$$\Delta y = \left( \frac{\partial f(x_1, x_2, x_3, x_4)}{\partial x_1} \right) \Delta x_1 + \left( \frac{\partial f(x_1, x_2, x_3, x_4)}{\partial x_2} \right) \Delta x_2 + \left( \frac{\partial f(x_1, x_2, x_3, x_4)}{\partial x_3} \right) \Delta x_3 + \left( \frac{\partial f(x_1, x_2, x_3, x_4)}{\partial x_4} \right) \Delta x_4$$

Ecuación 4

Donde,

$\Delta y$  = error absoluto en la humedad del suelo [ $\text{m}^3 \text{m}^{-3}$ ]

$x_1$  = TB ( $\theta$ , V) [K]

$x_2$  = TB ( $\theta$ , H) [K]

$x_3$  =  $T_c$  [K]

$x_4$  = VEG

## RESULTADOS Y ANÁLISIS

### Procesamiento Espacial de Datos

La Figura 2 muestra el resultado del uso del filtro de moda sobre las cartografías de CONAF, ESA-CCI y ECOCLIMAP en la zona de estudio al generar una resolución de 25 x 25 Km equivalente a la grilla espacial de SMOS (EASE V2). A partir de estos resultados se observa que respectivamente para cada cartografía utilizada se mantienen las superficies con mayor proporción de cobertura tales como “matorral”, en la zona norte, “bosque” y “agrícola” en la zona central y “bosque” ubicados en la zona sur. Sin embargo, se aprecian ciertas diferencias entre las coberturas “agrícola” y “pradera” que existen en la zona central y en la zona sur entre los 32° y 42° de latitud sur, que cambian su proporción espacial al aplicar un filtro de moda, principalmente en la cartografía de ECOCLIMAP. Además, entre la zona norte y la zona centro, la cobertura de suelos desnudos disminuye en su proporción asimilándose como cobertura “matorral”, lo que podría relacionarse con una acentuada fenología debido a la pluviometría del área de estudio. Similares resultados en términos de la variación espacial del tipo de cobertura han sido evidenciados a escala global por Leroux et al. (2013) y para el área de estudio por Santamaría-Artigas et al. (2016) y Mattar et al. (2016a). El tipo de leyenda utilizada en este trabajo corresponde a una reclasificación aplicada a las tres cartografías, con el fin de visualizar el efecto de la distribución espacial de una cobertura en particular y su distribución espacial sobre el área de estudio. Es importante destacar que esta leyenda no implica una homologación o asimilación de las coberturas correspondientes a las tres cartografías utilizadas en este trabajo. De hecho, esto implicaría el desarrollo de una nueva metodología, tal como la descrita en Pérez-Hoyos et al. (2012), dedicada exclusivamente a un análisis de la equivalencia de los tipos de coberturas y no a la propia relación con la humedad del suelo estimada mediante algoritmos ópticos microondas pasivos o derivados de modelos e información satelital.

## Cartografías de Coberturas

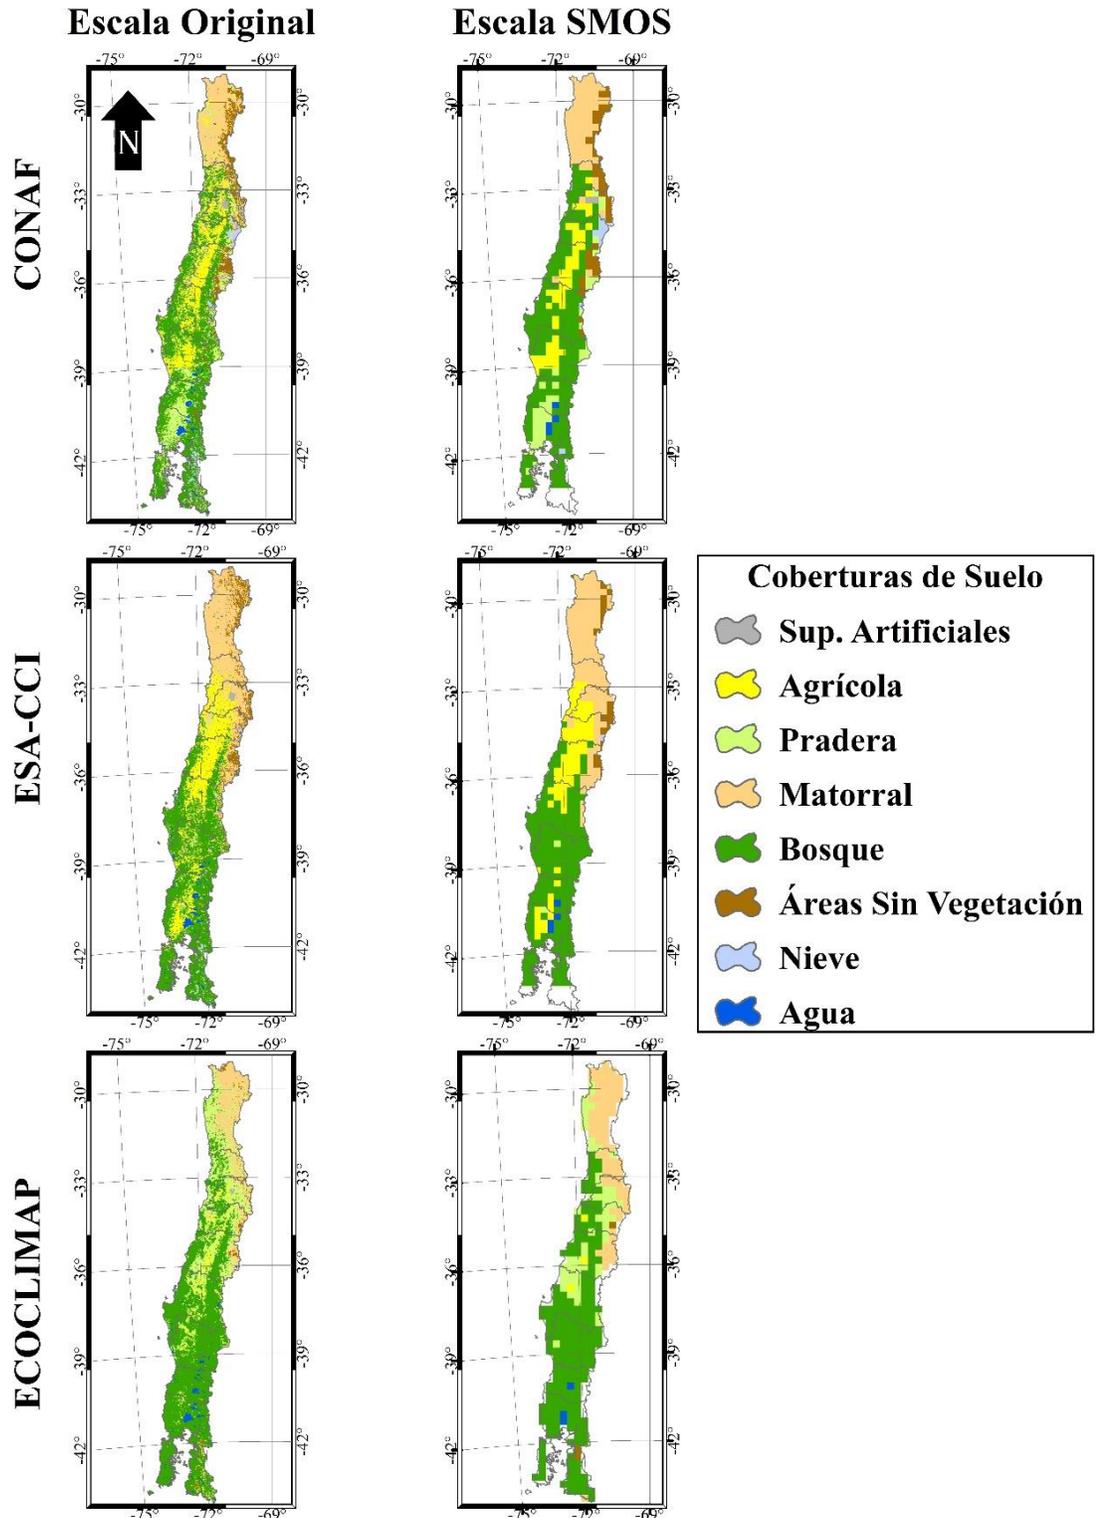


Figura 2. Clases de coberturas originales y procesadas extraídas de las bases de datos de CONAF (superior), ESA-CCI (medio) y ECOCLIMAP (inferior).

## Calibración del Método óptico microondas pasivo de Mattar et al. (2012)

### Coefficientes de Regresión

El patrón espacial del coeficiente "a" (intercepto) se observa en la Figura 3. En la zona norte, predominada por "matorral" se observa que para todos los periodos no existen cambios al momento de utilizar NDVI respecto a no utilizar vegetación, mientras que al utilizar el LAI se generan aumentos de magnitud en "áreas sin vegetación" y "matorral" entre los 71° y 70° de longitud oeste. Por otro lado, en la zona central las magnitudes respecto a VEG=0 aumentan al incluir el LAI, lo cual se destaca en las coberturas de "matorral" y "áreas sin vegetación", mientras que, para estas mismas coberturas disminuyen respecto a VEG=0 con el uso de NDVI. En la zona sur se observa aumentos que son similares entre el LAI y el NDVI respecto a VEG=0. Respecto a los periodos de calibración del método OPM se observan cambios tanto para el LAI, NDVI y VEG=0 en la calibración con los datos del año 2014 los cuales se marcan en mayor forma con el uso del LAI y con VEG=0 entre la zona centro y la zona sur.

Los coeficientes "b" (TBH) y "c" (TBV) se observan en las figuras 4 y 5 respectivamente. En general, el coeficiente "b" tanto para VEG=0 como con el uso de LAI o NDVI presenta diferencias en la calibración con el año 2012 y en menor medida para el año 2013, en donde la zona norte muestra valores bajos en comparación al resto de los periodos. Por el contrario, la calibración del año 2014 demuestra marcados aumentos con respecto al resto de los periodos. Para todas las calibraciones se exhibe que "matorral" y "áreas sin vegetación" poseen magnitudes bajas en comparación a las coberturas "agrícola", "pradera" y "bosque". Por su parte, el coeficiente "c", al igual que el coeficiente "b", presenta un patrón espacial respecto a las clases de cobertura con magnitudes bajas en "matorral" y "áreas sin vegetación" y que van aumentando a medida que cambian a coberturas "agrícola", "pradera" y "bosque".

En la Figura 6 se muestra el coeficiente "d" relacionado con la vegetación en el método OPM. Este coeficiente presenta diferencias entre el uso de NDVI y LAI, ya que el rango de magnitudes y patrones espaciales con el uso del NDVI muestra mayor amplitud respecto al uso del LAI. En general, las coberturas de suelo siguen mostrando un patrón marcado como en el resto de los coeficientes, con valores inferiores en "matorral" y "áreas sin vegetación" y superiores en coberturas "agrícola", "pradera" y "bosque". Se observa que entre los distintos periodos de calibración el uso del LAI se mantiene homogéneo a excepción de la cobertura "matorral" de la zona norte en la calibración con el 2010 y en menor medida con el 2013, donde existen pixeles con valores superiores al del resto de los periodos. Con el uso del NDVI todos los periodos de calibración presentan valores inferiores en la cobertura de "áreas sin vegetación" en la zona norte y centro, y también en "bosque" para la zona sur, con excepción del año 2010 que presenta valores más elevados. Por el contrario, en la zona norte y central se observa que desde la zona costera del área de estudio hasta los 70° de longitud oeste existen elevadas magnitudes a excepción del año 2010 que presenta magnitudes inferiores al resto de los periodos.

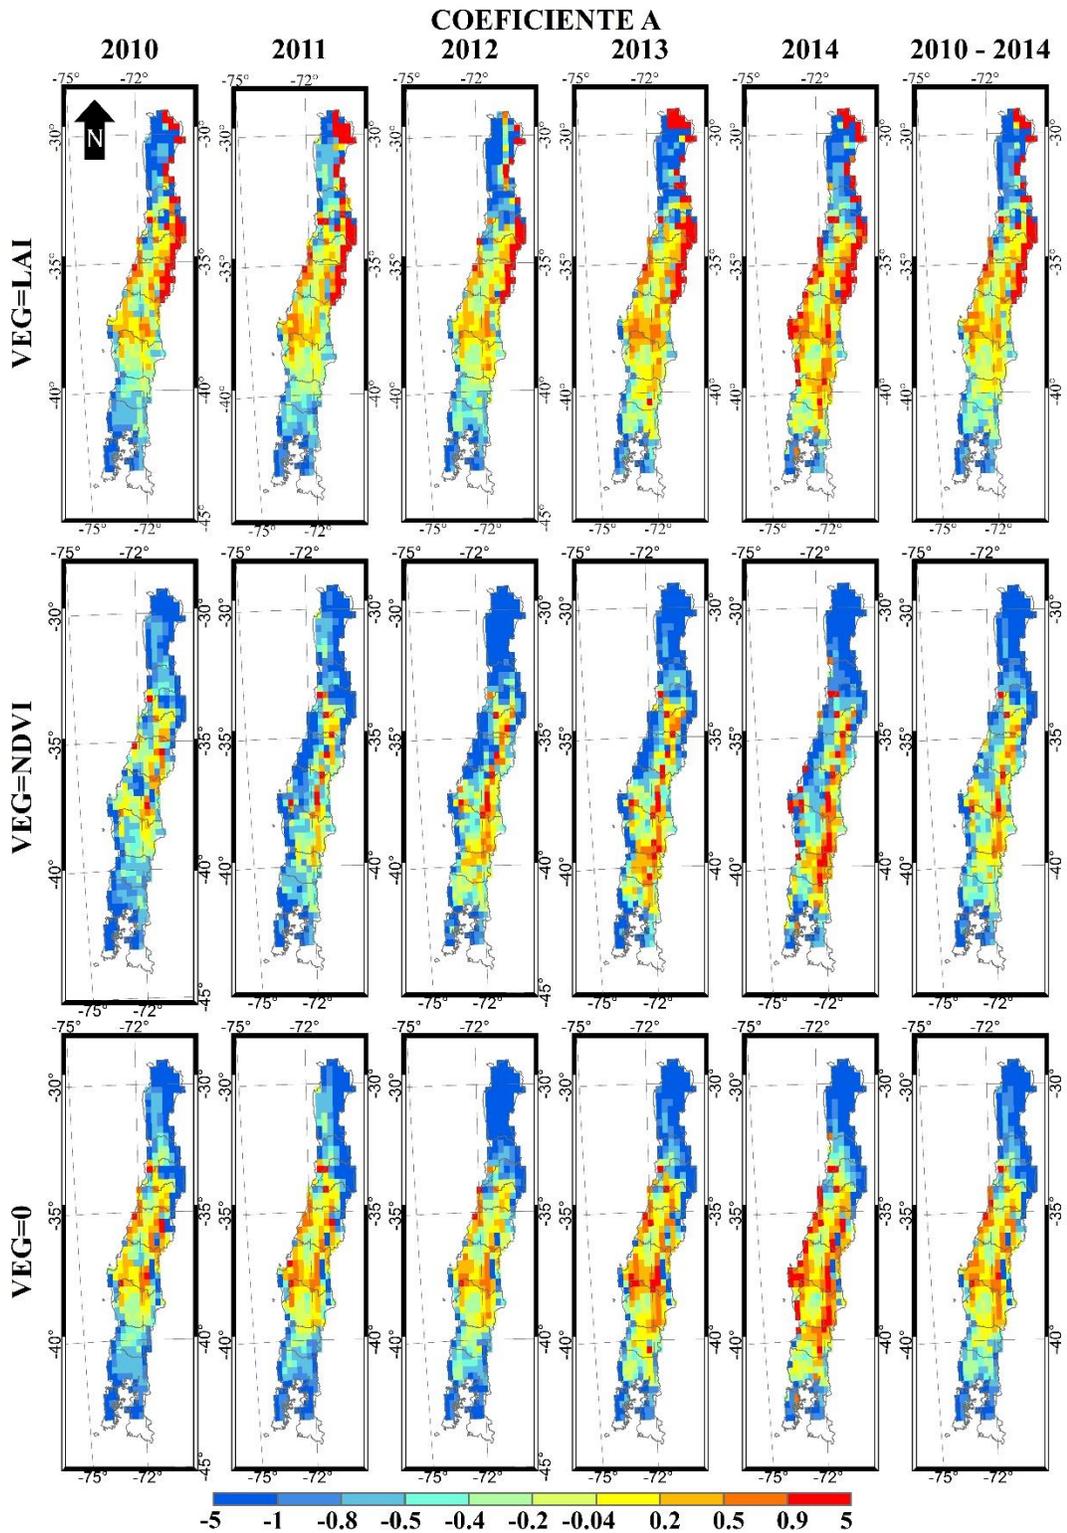


Figura 3. Mapas de coeficientes “a” (intercepto) de las regresiones realizadas con VEG=LAI (superior), VEG=NDVI (medio) y VEG=0 (inferior), para cada periodo de calibración.

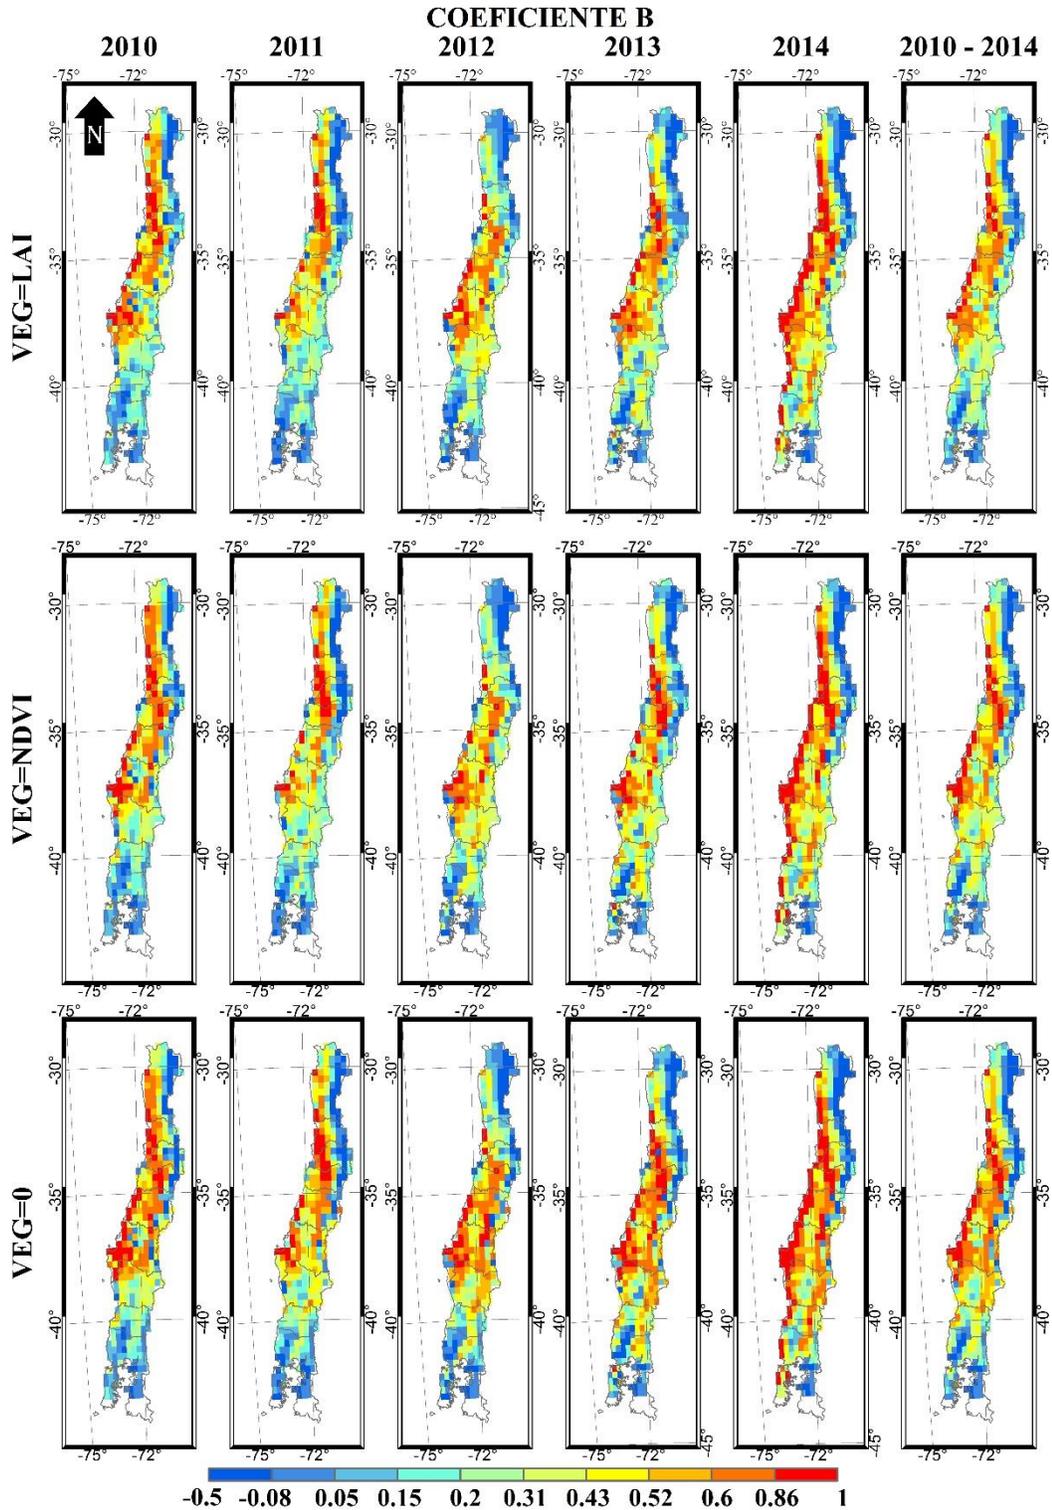


Figura 4. Mapas de coeficientes "b" (temperatura de brillo horizontal) de las regresiones realizadas con VEG=LAI (superior), VEG=NDVI (medio) y VEG=0 (inferior), para cada periodo de calibración.

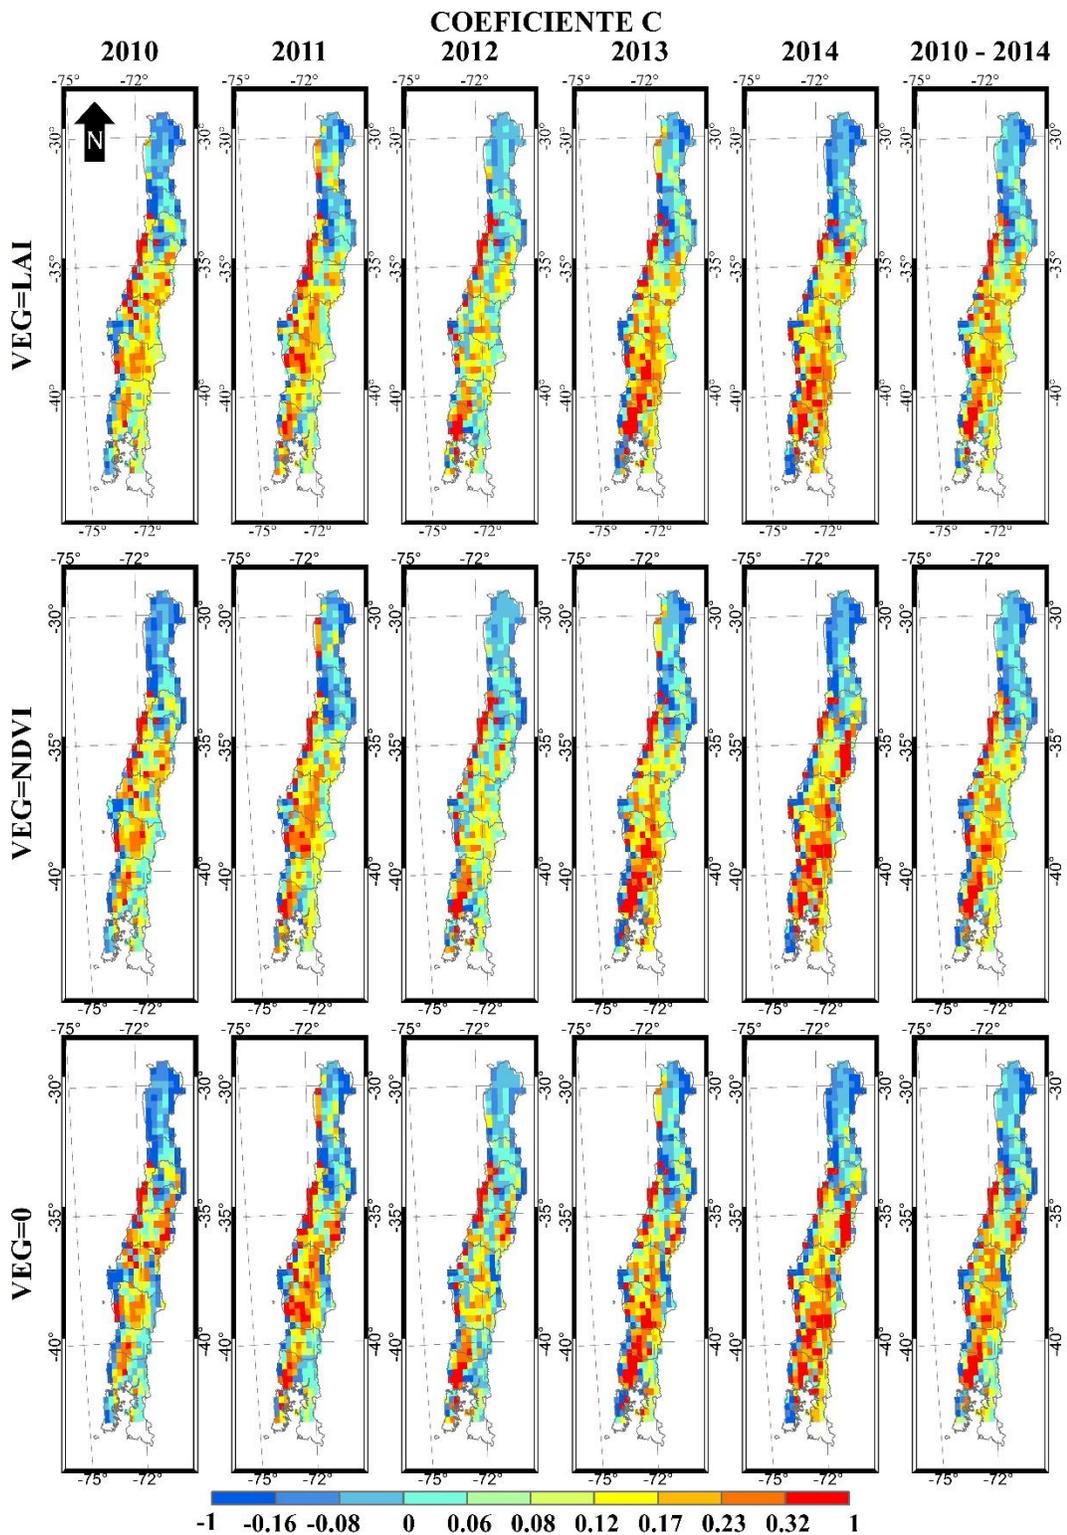


Figura 5. Mapas de coeficientes “c” (temperatura de brillo vertical) de las regresiones realizadas con VEG=LAI (superior), VEG=NDVI (medio) y VEG=0 (inferior), para cada periodo de calibración.

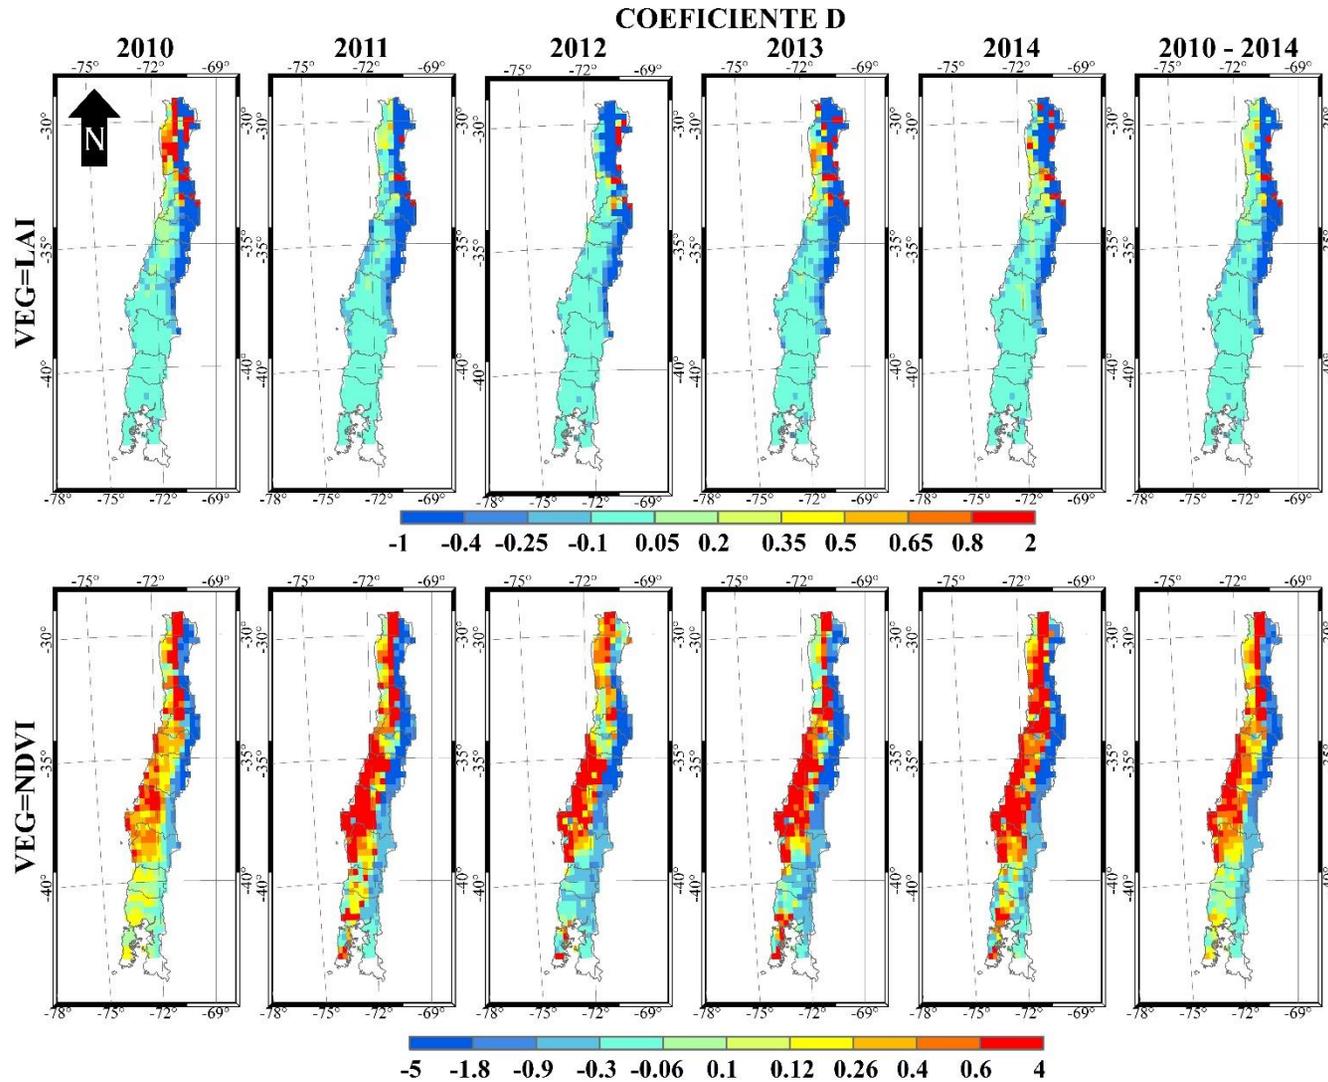


Figura 6. Mapas del coeficiente “d” (indicador de vegetación) de las regresiones realizadas con VEG=LAI (superior) y VEG=NDVI para cada año y para un periodo general incluyendo todos los años.

### **Coefficiente de determinación**

La distribución espacial de los coeficientes de determinación generados a partir de la calibración del método OPM utilizando NDVI, LAI o VEG=0 se presentan en la Figura 7 y en la Figura 8 se presentan los incrementos generados tanto al utilizar NDVI y LAI. Los resultados muestran que para todos los periodos de calibración, al utilizar un índice de vegetación se generan aumentos en el  $r^2$ , estos aumentos se observan en toda el área de estudio en coberturas como “matorral” y “áreas sin vegetación” de la zona norte, y en “bosque” en la zona sur, generando incrementos entre un 30% a un 80% los cuales elevan el  $r^2$  a mas de 0,8. Esto se explicaría debido a que cuando no se utiliza un indicador de vegetación en el modelo OPM la zona central presenta valores de  $r^2$  con un ajuste superior a un 0,8, similar a los valores estimados al utilizar un indicador de vegetación, mientras que en el resto del área de estudio existen valores inferiores a 0,5. Respecto al uso de vegetación en el método OPM, en toda el área de estudio se observa mejores ajustes en la regresión con el uso de NDVI en la cobertura “agrícola”, “bosque” y “pradera” en comparación al uso del LAI, a excepción de ciertos pixeles de “bosque” en la zona sur en donde el LAI presenta  $r^2$  superiores. Por otro lado, el impacto del periodo de calibración se hace notorio en la zona norte los años 2010 y 2011 y en la zona sur el año 2014 tanto con el uso de LAI, NDVI y VEG=0. Esto se debe a la existencia de pixeles con valores superiores respecto al resto de los periodos y, de  $r^2$  mayores a 0,8, mientras que con VEG=0 en la zona norte para el año 2012 existen pixeles con valores inferiores a 0,2 de  $r^2$ , lo que puede observarse en los incrementos del año 2012 con el uso del LAI presentando mejoras superiores al 30%. Estudios similares han demostrado mejoras similares al utilizar indicadores de vegetación mediante un método OPM como, en el estudio de Parrens et al. (2012) sobre Fracia. A nivel *in situ*, en el estudio de Mattar et al. (2012) fue demostrado el impacto de la vegetación sobre el sitio de estudio “Surface monitoring of soul reservoir experiment” (SMOSREX) el uso del NDVI generaba aumentos de  $r^2$  respecto a no considerar un indicador de vegetación dentro del método OPM. A su vez, Miernieki et al. (2014) comparó el desempeño de distintos métodos para estimar la humedad del suelo entre ellos método OPM sobre viñas en una zona mediterranea de España, resultando el uso del NDVI en una significativa mejora de la estimaciones de humedad. No obstante, sobre la misma área presente en este trabajo los resultados del estudio de Santamaría-Artigas et al. (2016) muestran que con el uso del NDVI y otra versión de SMOS se genera aumentos en el ajuste lineal de la calibración del OPM sobre coberturas como “matorral”, “bosque” y “áreas sin vegetación”. Además, los resultados de este trabajo también son complementarios con los de Mattar et al. (2016a), donde se compara el uso de NDVI y LAI como indicador de espesor óptico en el método OPM dando como resultado coeficientes de determinación similares al de este estudio, pero en un periodo de tiempo de calibración menor (2010-2012).

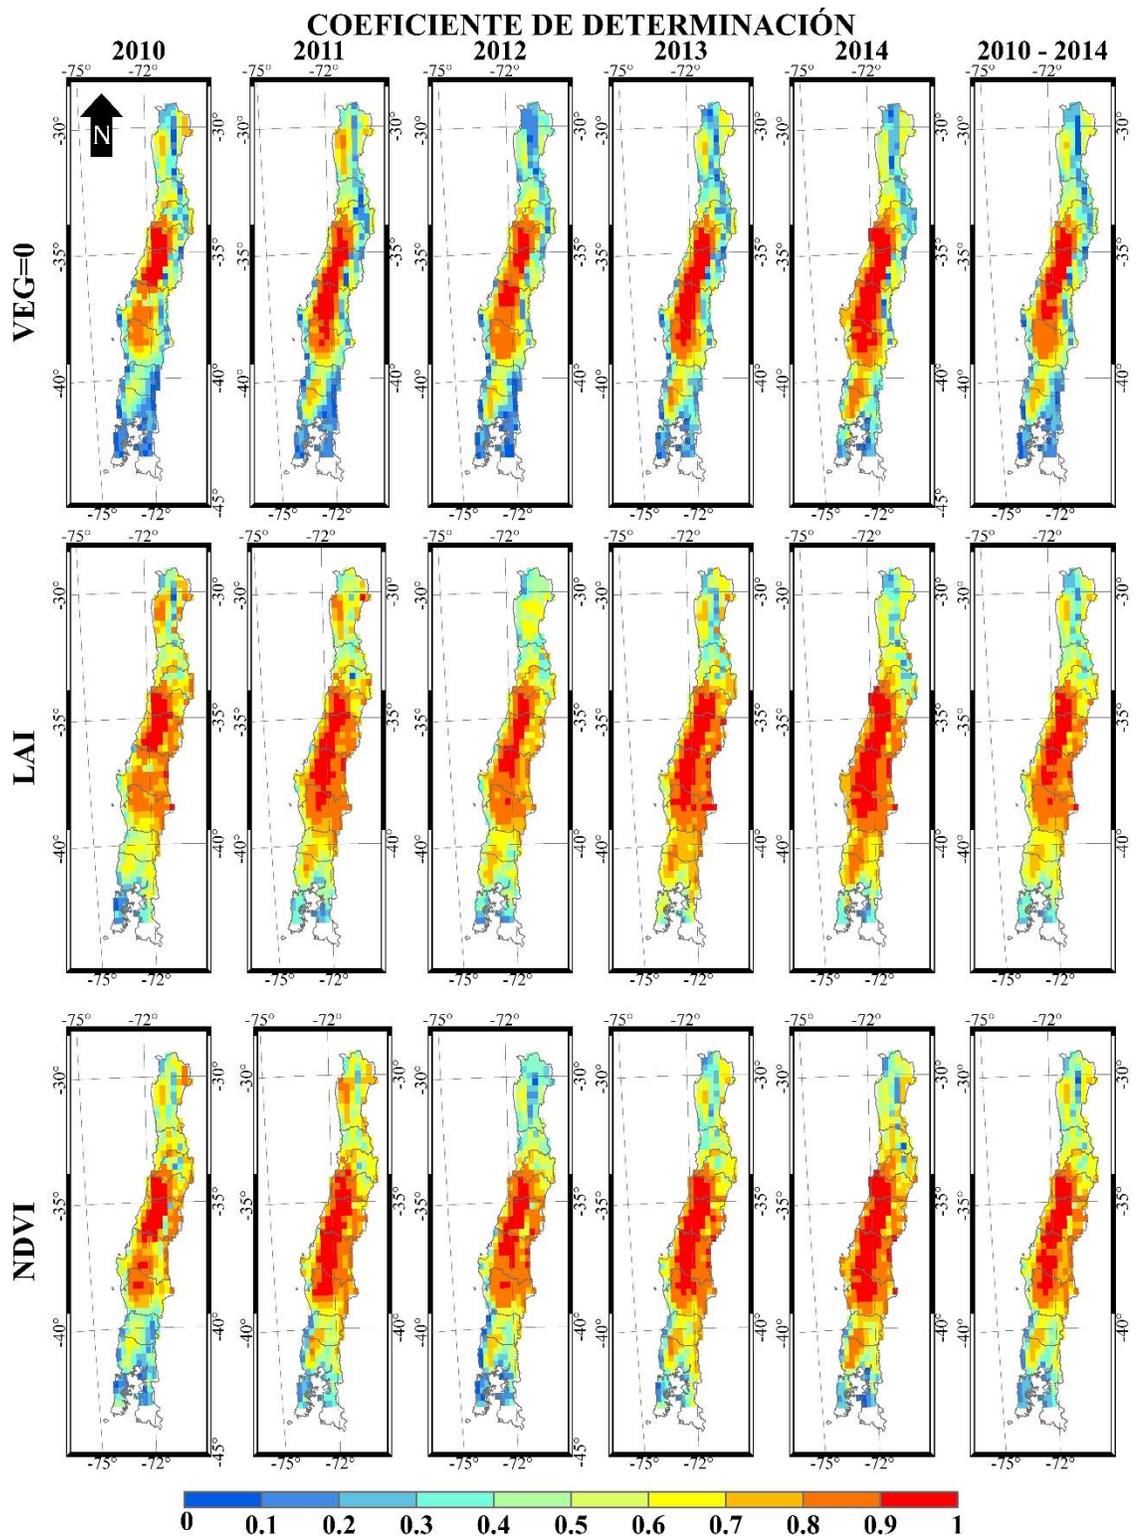


Figura 7. Mapas de coeficientes de determinación de las regresiones realizadas con VEG=0 (superior), VEG=LAI (medio) y VEG=NDVI (inferior), para cada año y para un periodo general incluyendo todos los años.

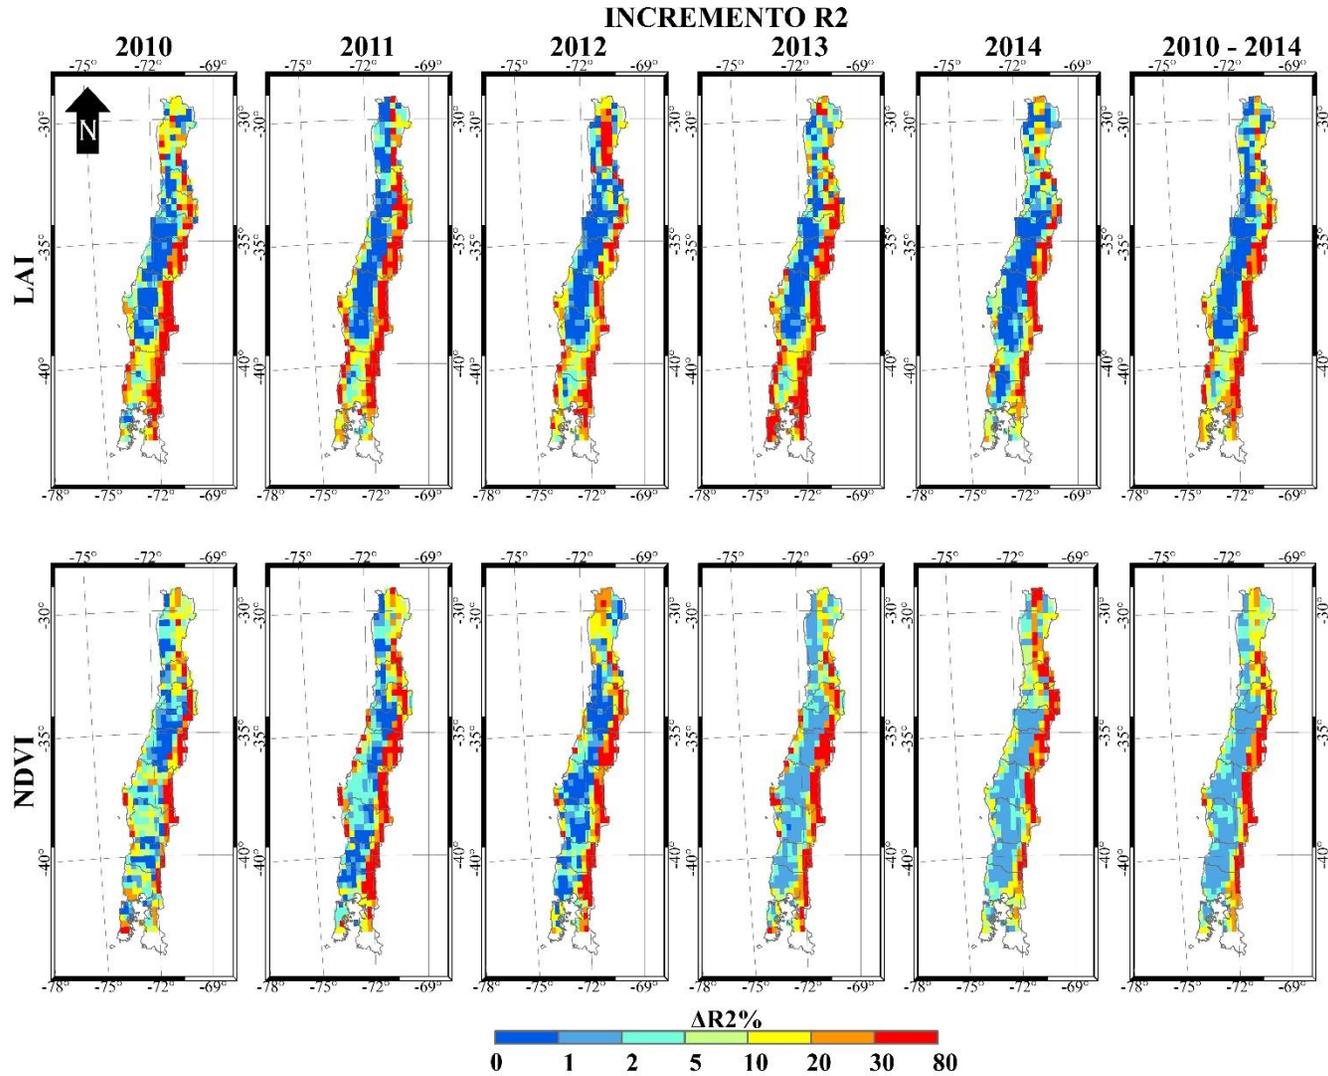


Figura 8. Mapas del incremento del coeficiente de determinación de las regresiones realizadas con VEG=LAI (superior) y VEG=NDVI (inferior), para cada año y para un periodo general incluyendo todos los años.

### Variabilidad temporal de los Coeficientes

La Figura 9 muestra la dispersión de los valores de humedad de superficie estimados por el OPM en distintos periodos de calibración sobre distintas coberturas de suelo. Los diagramas de caja de la estimación de humedad del suelo utilizando la cartografía de CONAF muestran que las coberturas de suelo tienen en promedio una estimación superior a  $0,2 \text{ m}^3 \text{ m}^{-3}$ , con excepción de “matorral” con una media inferior a  $0,2 \text{ m}^3 \text{ m}^{-3}$  para todos sus periodos. El uso de distintos índices de vegetación muestra estimaciones de humedad similares en la cobertura “agrícola” a diferencia del resto de las coberturas, en donde el NDVI en la mayoría de los periodos tiende a estimar valores más bajos respecto al uso de LAI y  $\text{VEG}=0$ , por su parte el uso del LAI tiende a estimar valores mayores que  $\text{VEG}=0$ . Respecto a los periodos de calibración, se observan estimaciones de humedad del suelo similares a excepción de la calibración del año 2012 y para algunas coberturas de suelo, como es el caso de la variabilidad en la humedad del suelo en “bosque” con el uso del NDVI y las bajas estimaciones de humedad que se observan para “matorral” y “suelos desnudos”. Destaca también la gran cantidad de “outliers” en las coberturas “pradera”, “matorral”, “suelos desnudos” y en menor medida en “bosque”.

Las coberturas de la cartografía de ESA-CCI muestran gran similitud a CONAF en todas las estimaciones de humedad del suelo por periodo y por índice de vegetación. Solo se observan diferencias en la cobertura de “pradera”, ya que esta es la cobertura que presenta mayor discrepancia espacial en sus cartografías y que se hizo notoria al momento de utilizar el filtro de moda. Debido a la baja dispersión entre sus píxeles se presentan estimaciones de humedad sin “outliers” pero con mayor variabilidad que en CONAF. También, se repiten las diferencias entre las calibraciones del 2012 y el resto de los periodos, con estimaciones de humedad del suelo inferiores en las coberturas de “bosque”, “matorral” y “áreas sin vegetación”.

La cartografía de ECOCLIMAP tiende a ser más alejada a las estimaciones observadas en CONAF y ESA-CCI, pero manteniendo semejanzas en la cobertura “agrícola”, “bosque” y “matorral”. La cobertura de “pradera” presenta estimaciones de humedad del suelo similares entre cada periodo y respecto al uso de índices de vegetación, con valores medios entre 0,2 y  $0,25 \text{ m}^3 \text{ m}^{-3}$ . Por el contrario, en “áreas sin vegetación” si existen diferencias entre periodos de calibración y el uso de índices de vegetación, ya que mientras en el año 2010 y 2012 presenta estimaciones medias superiores a  $0,2 \text{ m}^3 / \text{m}^3$  con el uso de LAI y  $\text{VEG}=0$ , con el uso del NDVI las estimaciones son menores a  $0,2 \text{ m}^3 / \text{m}^3$ . Asimismo, en esta cobertura, la calibración del periodo 2010-2014 presenta las estimaciones medias de humedad del suelo más altas, las que son superiores a  $0,3 \text{ m}^3 / \text{m}^3$  tanto para el uso del LAI, NDVI y  $\text{VEG}=0$ .

La baja variabilidad en la estimación de la humedad del suelo de cada periodo de calibración respecto al periodo que utilizó datos desde el 2010 al 2014 muestra que es posible consolidar una calibración del método OPM incluyendo la influencia de factores temporales sobre la estimación de humedad en la mayoría de coberturas de suelo. Esta calibración general permitiría su uso futuro en Chile sin la necesidad de volver a recalibrar los coeficientes.

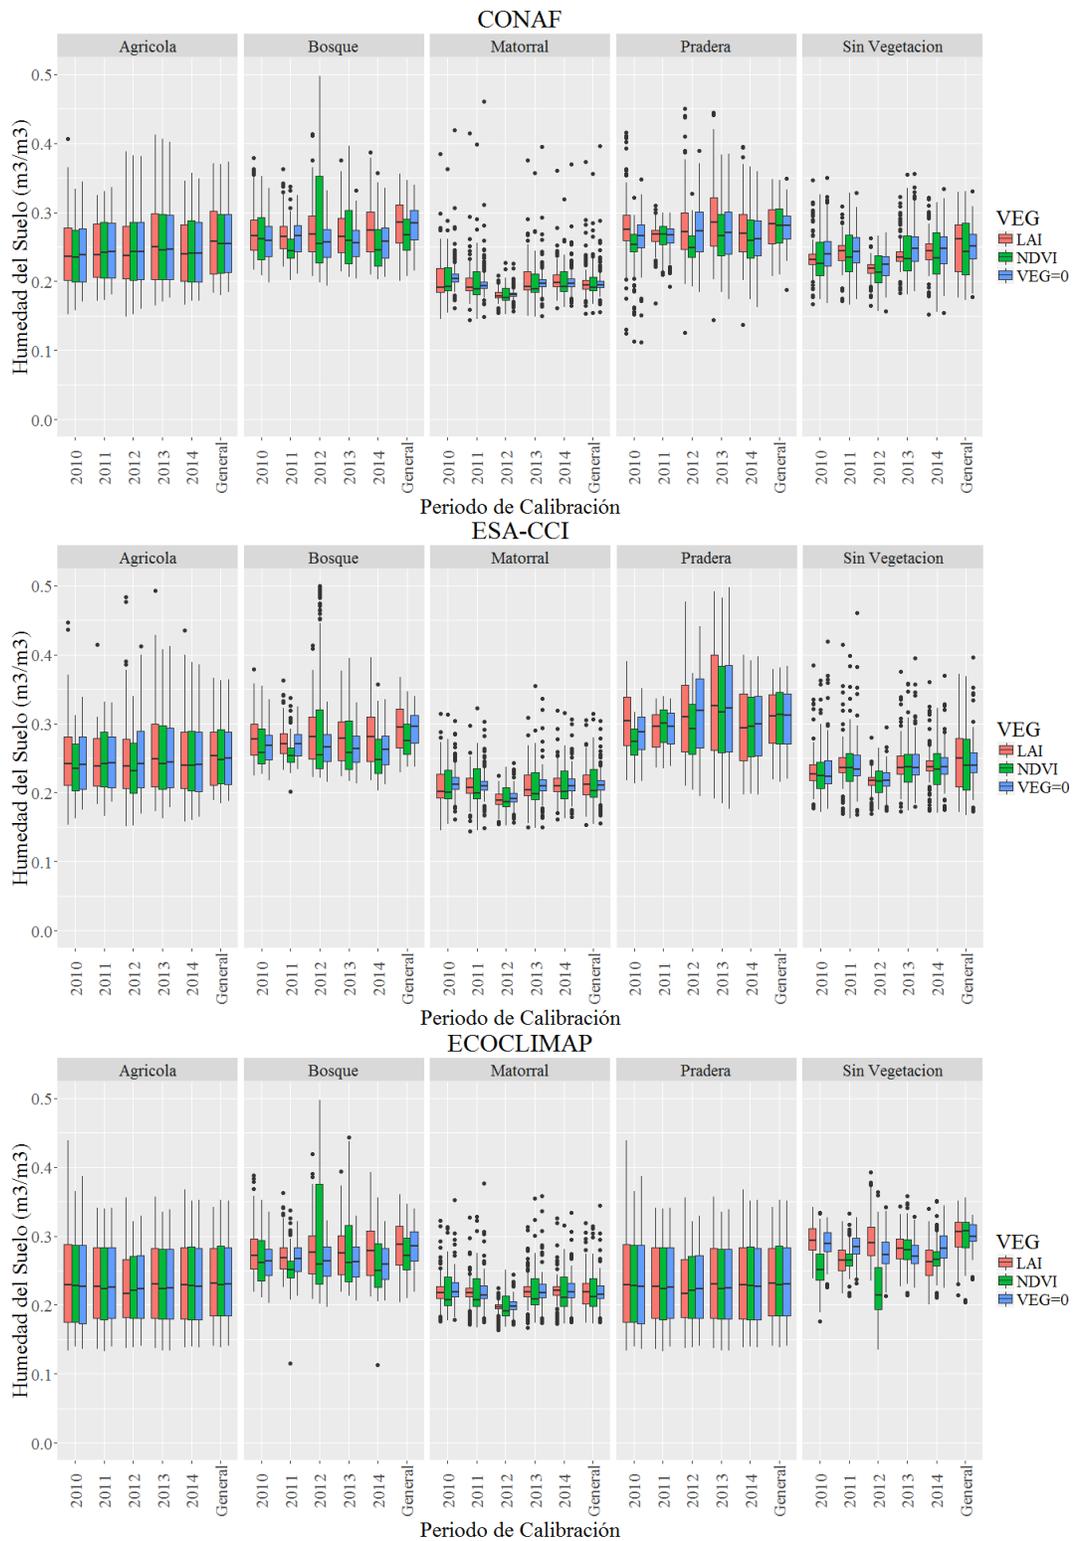


Figura 9. Diagrama de cajas de humedad del suelo estimada para el año 2015 para cada periodo de calibración agrupados en clases de cobertura de superficie y para cada cartografía. Los “outliers” son representados como círculos.

### Validación del Método óptico microondas pasivo de Mattar et al. (2012)

El RMSE obtenido entre la humedad de la superficie de referencia (ERA-INTERIM) y las tres estimaciones generadas por el OPM (VEG=LAI, VEG=NDVI, VEG=0) utilizando la calibración del periodo del 2010-2014 se muestran en la Figura 10. Los valores de RMSE fueron agrupados por clases de cobertura de las tres cartografías utilizadas. Para todas las cartografías los resultados obtenidos muestran que el uso de vegetación en el modelo OPM genera disminuciones de RMSE respecto a VEG=0 en la mayoría de coberturas de uso de suelo. En general tanto con el uso de índices de vegetación como sin su uso, las categorías de “matorral” y “áreas sin vegetación” presentan los valores de RMSE más altos con valores absolutos superiores a  $0,052 \text{ m}^3 \text{ m}^{-3}$  mientras que los valores más bajos se observan en la cobertura “agrícola” con un RMSE absoluto inferior a  $0,035 \text{ m}^3 \text{ m}^{-3}$ .

Para la cartografía de CONAF, los resultados muestran que al incorporar el NDVI o el LAI en el OPM se generan disminuciones en la magnitud del RMSE en promedio superiores a 9% de  $\text{m}^3 \text{ m}^{-3}$  para las coberturas de “bosque”, “pradera” y “áreas sin vegetación” en comparación a los RMSE con VEG=0. Por el contrario, “matorral” y “agrícola” presentan disminuciones en promedio de RMSE inferiores a 3% de  $\text{m}^3 \text{ m}^{-3}$  con el uso de estos índices. Para esta cartografía puede verse que las disminuciones de RMSE al utilizar el LAI respecto al uso de NDVI en el OPM son mayores, pero con diferencias que van entre un 5% de  $\text{m}^3 \text{ m}^{-3}$  para “bosque” y menores a un 1,5% de  $\text{m}^3 \text{ m}^{-3}$  en “pradera” y “áreas sin vegetación”.

En la cartografía de ESA-CCI se observa que los valores de RMSE muestran similitudes con la mayoría de las coberturas de la cartografía de CONAF, excepto en la cobertura de “matorral” donde las magnitudes de RMSE generados al incluir un indicador de vegetación son mayores a las vistas en la cartografía de CONAF, con disminuciones en promedio de 16,2% de  $\text{m}^3 \text{ m}^{-3}$  y 10% de  $\text{m}^3 \text{ m}^{-3}$  para el LAI y NDVI respectivamente. Asimismo, en “pradera” se ve una disminución de las magnitudes de RMSE inferior a un 1% de  $\text{m}^3 \text{ m}^{-3}$  con el uso del NDVI mientras que con el uso del LAI se generan aumentos de RMSE de un 2,5% de  $\text{m}^3 \text{ m}^{-3}$ . En esta cartografía se observa que el uso de un indicador de vegetación genera en promedio valores de RMSE más bajos en las coberturas “agrícola”, “matorral” y “pradera” con el uso de NDVI, mientras que con el uso del LAI esto ocurren en “bosque” y “áreas sin vegetación”.

En el caso de la cartografía de ECOCLIMAP solo las coberturas de “bosque” y “matorral” presentan similitudes con las cartografías de CONAF y ESA-CCI respecto a los valores de RMSE. Puesto que, en la cobertura “agrícola” se generan incrementos en promedio de las magnitudes de RMSE de un 1,5% de  $\text{m}^3 \text{ m}^{-3}$  con el uso del LAI, mientras que la cobertura de “áreas sin vegetación”, “matorral” y “pradera” presentan disminuciones en promedio de un 10% de  $\text{m}^3 \text{ m}^{-3}$  de RMSE tanto con el uso del NDVI como el LAI.

Respecto al uso de un indicador de vegetación dentro de la calibración del método OPM, el uso del NDVI y LAI mejoran los resultados significativamente en gran parte de las coberturas analizadas, con disminuciones de RMSE para todas las coberturas en comparación a VEG=0,

con excepción de la cobertura “agrícola” en donde se observa menor impacto en las disminuciones de RMSE. Esto se explicaría debido a que en el caso de VEG=0 la calibración del método OPM sobre la zona centro, en donde se ubica gran parte de la cobertura “agrícola”, muestran valores de  $r^2$  muy similares a los vistos con el uso de NDVI y LAI. Estos resultados están de acuerdo a los obtenidos por Santamaría-Artigas et al. (2016) con el uso del indicador NDVI y en Mattar et al. (2016a), tanto con NDVI como con LAI, ya que esta cobertura también fue la que presentó menores aumentos de  $r^2$  y menores disminuciones de RMSE utilizando el NDVI o LAI.

Respecto a las cartografías, si bien los resultados de  $r^2$  y RMSE varían según el origen, existe una gran similitud en estos valores entre las cartografías de CONAF y ESA-CCI, difiriendo marcadamente en ciertas coberturas con la cartografía de ECOCLIMAP. Al igual que en el estudio de Santamaría-Artigas et al. (2016), ECOCLIMAP genera discrepancias originadas por la diferencia entre la cobertura de suelo actual y las que existen en su base de datos. Por lo tanto, se recalca la importancia de utilizar distintas fuentes de coberturas para analizar las estimaciones de humedad del suelo.

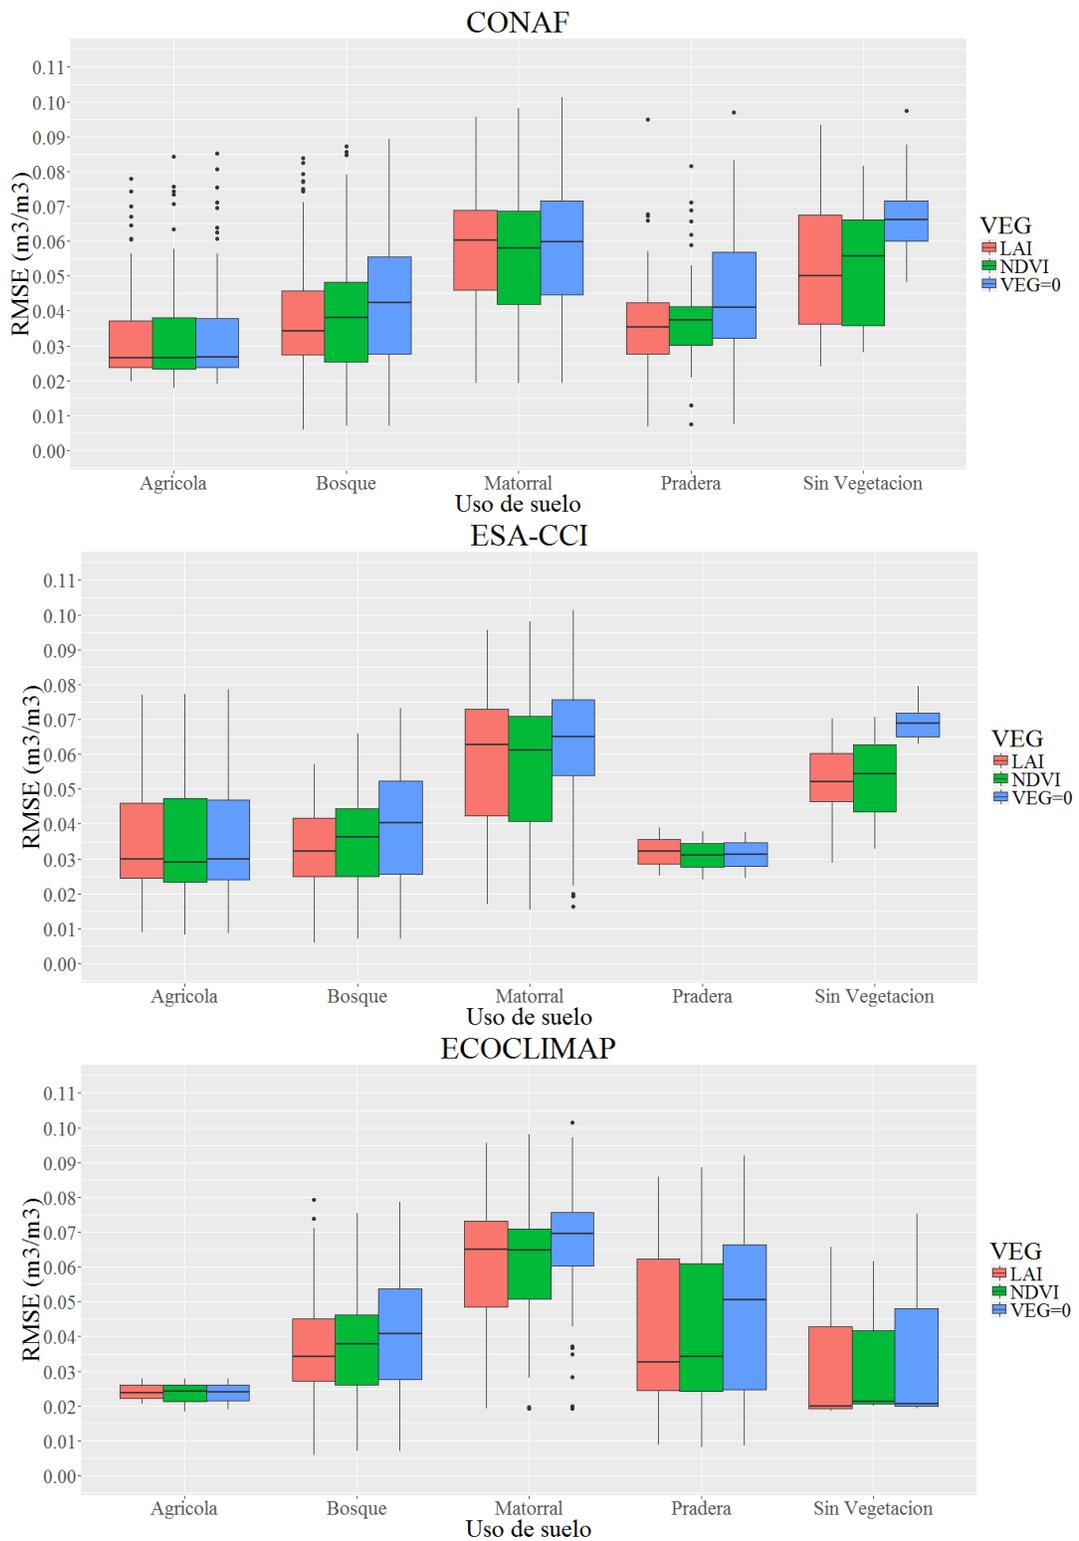


Figura 10. Diagramas de caja de RMSE según CONAF (arriba), ECOCLIMAP (medio) y ESA-CCI (abajo) para el año de validación agrupado en clases de cobertura de superficie. Los “outliers” son representados como círculos.

## Series de tiempo

Con el fin de validar las estimaciones de humedad a partir del método OPM, las figuras 11a y 11b muestran una comparación con datos de humedad del suelo derivados de estaciones *in situ*, SMOS y ERA-INTERIM. Esta comparación se realizó para el año 2015 con la estimación de la humedad de superficie generada con el método OPM utilizando los coeficientes derivados del periodo de calibración 2010-2014 y utilizando los pixeles donde están localizadas las estaciones LAB-net de Chimbarongo y Oromo (Mattar et al., 2016b).

En la Figura 11a se observan los valores asociados al pixel en el cual se localiza la estación LAB-net de Chimbarongo. Se observa la influencia de la estacionalidad en la estimación de humedad del suelo del método OPM y de ERA-INTERIM mostrando valores alrededor de  $0,19 \text{ m}^3 \text{ m}^{-3}$  para el OPM y ERA-INTERIM desde enero hasta mayo, aumentos hasta más de  $0,35 \text{ m}^3 \text{ m}^{-3}$  en el mes de agosto y disminuciones en el mes de octubre a valores alrededor de  $0,19 \text{ m}^3 \text{ m}^{-3}$ . También, se observa que entre noviembre hasta abril las estimaciones de humedad del OPM tienden a sobreestimar las estimaciones de ERA-INTERIM, mientras que entre abril y noviembre son subestimadas. Respecto a las mediciones *in situ* de humedad del suelo se puede evidenciar la influencia tanto de los eventos pluviométricos en la zona, estimando valores de humedad que varían entre  $0,25$  y  $0,35 \text{ m}^3 \text{ m}^{-3}$  y también del periodo de riego entre los meses de diciembre hasta abril con valores de humedad entre  $0,25$  y  $0,3 \text{ m}^3 \text{ m}^{-3}$ .

En la Figura 11b se observan los valores asociados al pixel donde se localiza la estación LAB-net de Oromo. En este pixel las estimaciones de humedad del suelo del OPM muestran similitudes con las estimaciones de ERA-INTERIM, con valores que rodean los  $0,32 \text{ m}^3 \text{ m}^{-3}$  entre abril a diciembre. En cambio, entre el periodo desde enero a marzo, el OPM sobreestima los valores de humedad de ERA-INTERIM. Por su parte, entre abril y octubre las estimaciones *in situ* de humedad del suelo presentan valores superiores al OPM y ERA-INTERIM que sobrepasan los  $0,4 \text{ m}^3 \text{ m}^{-3}$  y que luego disminuyen bajo los  $0,18 \text{ m}^3 \text{ m}^{-3}$  en los meses de enero hasta abril. Sin embargo, se observa que las estimaciones de humedad de estas tres fuentes siguen un mismo patrón relacionado a máximos y a mínimos a lo largo del año, lo cual se relaciona con la presencia de eventos pluviométricos. Respecto a SMOS, la influencia de los eventos pluviométricos produce que las estimaciones de humedad del suelo varíen entre  $0,3$  a  $1 \text{ m}^3 \text{ m}^{-3}$  en los meses de abril hasta octubre en donde existe mayor precipitación, pero disminuyendo una vez alcanzado el mes de noviembre.

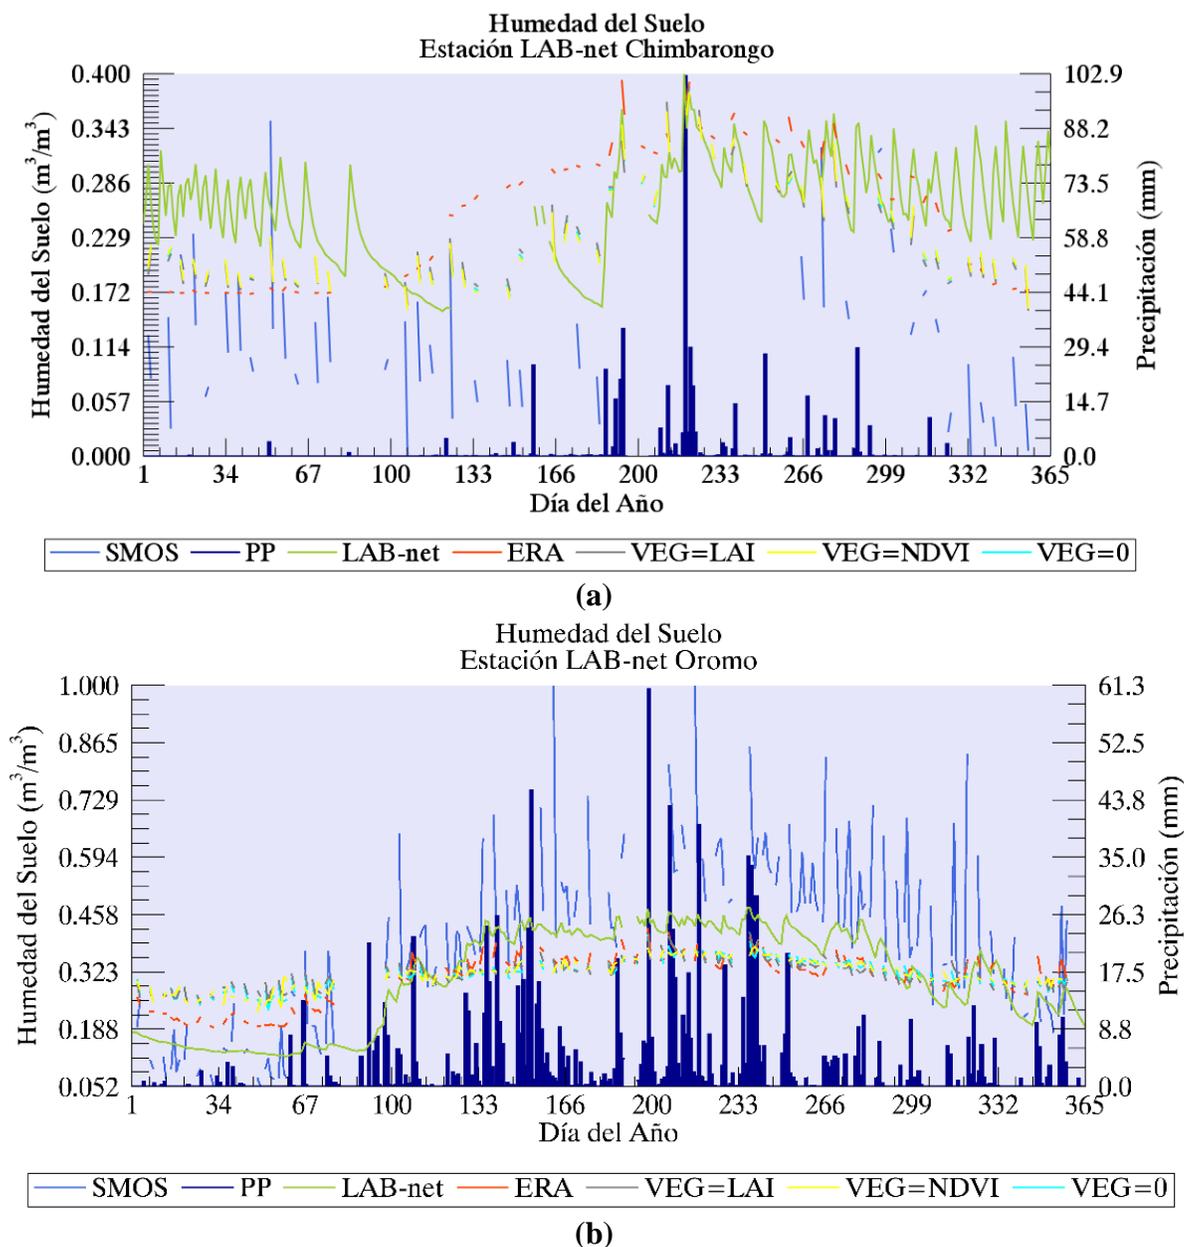


Figura 11. Humedad del suelo y precipitación (in situ) para el año 2015 en la estación LAB-net presente en la localidad de Chimbarongo (a) y Oromo (b) localizadas en  $34^{\circ}43'39,67''S$   $70^{\circ}58'46,16''O$  y  $40^{\circ}52'23,160''S$   $73^{\circ}0'41,400''O$  respectivamente.

Si bien la diferencia entre utilizar o no utilizar un indicador de vegetación no es significativa para los dos pixeles seleccionados en la validación, si lo es la diferencia existente entre las estimaciones de humedad del suelo de OPM y la humedad del suelo estimada por SMOS. Por otra parte, las mediciones de humedad del suelo a nivel *in situ* y las estimaciones de humedad del suelo de OPM están sujetas a diferencias propias de cada pixel, debido a que las estaciones LAB-net miden humedad del suelo a distintas profundidades. En el caso de Chimbarongo la humedad es medida en los primeros 5 cm de suelo, mientras que en la

estación de Oromo se mide la humedad de los primeros 7 cm de suelo.

### Análisis de Error

Los errores absolutos debido a la variación de los valores de NDVI y LAI utilizados en el OPM sobre la humedad de la superficie sobre el pixel de Oromo se muestran en la Figura 12.

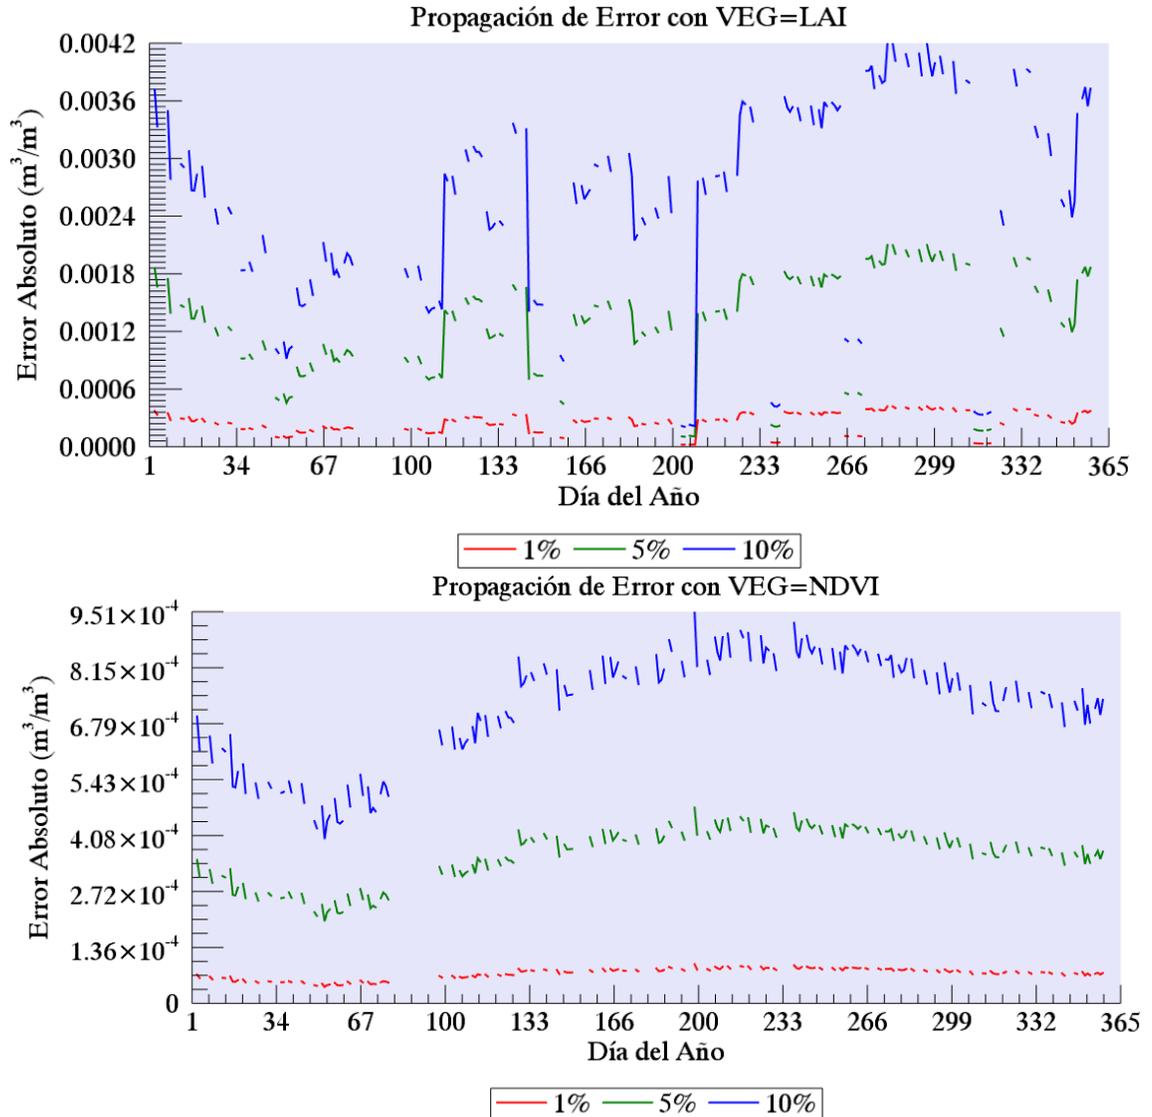


Figura 12. Errores de propagación en la estimación de humedad del suelo para el año 2015 en la estación LAB-net presente en la localidad de Oromo localizada en las coordenadas  $40^{\circ}52'23,160''S$   $73^{\circ}0'41,4''O$  utilizando como indicador de vegetación al LAI (arriba) y NDVI (abajo).

Se observa que los errores absolutos en la humedad de superficie con el uso del LAI siguen un patrón temporal variable respecto sus máximos y mínimos a través del año. Los máximos valores de error de la estimación de humedad varían de un 0,1%, 0,7% y 1,3%, mientras que los mínimos varían entre 0,005%, 0,03% y 0,06%, en ambos casos respectivamente para un 1%, 5% y 10% de error en la estimación del LAI. Con el uso del NDVI los máximos errores en la estimación de humedad del suelo varían entre un 0,03%, 0,13% y 0,25%, mientras que los mínimos varían entre 0,02%, 0,08% y 0,16%, en ambos casos respectivamente para un 1%, 5% y 10% en los errores de estimación del NDVI. Estos resultados muestran una gran sensibilidad del método OPM a los errores asociados al LAI, al contrario de los observados con el uso del NDVI.

## DISCUSIÓN

De acuerdo a Santamaría-Artigas (2016), existen factores que afectan el número de datos disponibles en la calibración y validación ligados al periodo en que estos se generen, como la influencia de eventos climáticos extremos (e.g. ENSO) (Hill et al., 2011; Hoyos et al., 2013; Krishnamurthy y Misra, 2010) ocurridos en el 2010, así como la actualización de la versión de datos SMOS (Daganzo-Eusebio et al., 2013; Oliva et al., 2012). Sin embargo, en este trabajo, la estimación de humedad de la superficie a través de la calibración del método OPM fue generada para seis periodos de tiempo, de estos, cinco fueron por cada año desde el 2010 al 2014 y un sexto fue utilizando todos los datos de desde el 2010 al 2014. Este sexto periodo engloba la variabilidad anual en la calibración de los coeficientes que podrían afectar las estimaciones de humedad.

En relación a los índices de vegetación utilizados en las estimaciones de humedad del suelo en el OPM, es necesario contrastar los métodos de estimación entre el LAI y el NDVI. El NDVI se calcula la diferencia normalizada entre las bandas del infrarrojo cercano y rojo, en el cálculo de LAI de MODIS se utiliza un algoritmo que compara la reflectancia observada con una modelada en una variedad de estructuras de dosel y patrones del suelo (Garrigues et al., 2008; Zhen y Moskal, 2009). Si bien, el uso de LAI en el OPM genera RMSE más bajos respecto al uso del NDVI para la mayoría de coberturas, hay que considerar que el método OPM presenta una alta sensibilidad a las variaciones correspondientes a los valores de LAI, generando grandes impactos en las estimaciones de humedad del suelo. Esto implicaría que el potencial uso de LAI en las estimaciones de humedad del suelo podría presentar ciertos sesgos al método de cálculo del indicador de vegetación y su uso en un método semi-empírico. De hecho, algunos estudios han mostrado buenos resultados en la estimación de humedad utilizando métodos semi-empíricos sin incluir un indicador de vegetación, como en el caso del estudio de Al-Yaari et al. (2016) a escala global y regional utilizando el sensor AMRSE-E, y también en el estudio de Albergel et al. (2011) sobre Francia utilizando datos de SMOS. A pesar de que en estos estudios no fue considerado Chile, el uso de métodos que no utilizan un indicador de vegetación podría ser considerado sobre coberturas donde no hay un impacto significativo de estos indicadores. Tal es el caso de la cobertura “agrícola”, no obstante, en la mayoría de las cartografías tanto el NDVI como el LAI generan mejoras en la estimación de humedad.

La comparación entre estimaciones de humedad del suelo permitió observar que el OPM presenta similitudes en la estimación de humedad con ERA-INTERIM. En cambio, respecto a la estimación de humedad del suelo de las estaciones LAB-net, solo presenta un comportamiento similar en cuanto a aumentos y disminuciones relacionados a eventos pluviométricos, no necesariamente coincidiendo en la magnitud de las mediciones de humedad del suelo. Esto se podría explicar debido a las diferencias en las profundidades de medición de humedad del suelo entre el OPM y las estaciones LAB-net. Además, el comparar humedad del suelo sobre un área de 25 km<sup>2</sup> con mediciones *in situ* no siempre es posible obtener resultados equivalentes, sobre todo con la presencia de eventos pluviométricos o

periodos de riego. Se observa también que los valores de humedad *in situ* son similares a las estimaciones de humedad del suelo del OPM respecto a las de SMOS. Esto implicaría que las estimaciones del OPM podrían mejorar el desempeño de índices de sequía a base de datos satelitales como es el caso del SWDI (Martínez et al., 2016) el cual utiliza datos de humedad del suelo de SMOS demostrando buen desempeño a escala local en sectores agrícolas. A su vez, el método OPM podría ser un aporte complementando mapas de monitoreo de sequías en Chile, como los elaborados por la Unidad Nacional de Emergencias Agrícolas y Gestión del Riesgo Agroclimático (UNEA) dependiente del Ministerio de Agricultura. Actualmente estos mapas utilizan indicadores de sequías relevantes con el fin de exponer índices de sequía meteorológico (déficit pluviométrico), sequía hidrológica (déficit hídrico), sequía agrícola (déficit de vegetación) y su efecto combinado. Si bien para la sequía agrológica son utilizados datos de humedad del suelo, estos son de carácter mensual, con un desfase aproximado de tres meses y se exponen de forma relativa (0-100%) como balance hídrico respecto a la capacidad de campo. Además, se calcula de manera indirecta a través variables como la evapotranspiración, precipitación y almacenamiento de agua en el suelo del periodo anterior (UNEA, 2016). El OPM permitiría proveer estimaciones de carácter diaria, con valores absolutos ( $\text{m}^3 \text{ m}^{-3}$ ) y utilizando datos satelitales de fácil acceso que permitirían realizar estimaciones de forma directa.

La sinergia presentada en este trabajo entre las microondas pasivas y los datos ópticos también puede ser complementada con datos derivados de las bandas del infrarrojo térmico (TIR), como lo son la emisividad de la superficie (LSE) y la temperatura de la superficie (LST; Mattar et al., 2016a). Hasta la fecha varios estudios han demostrado de forma parcial la relación que existe entre la humedad del suelo, el LST y el LSE. Por ejemplo, la existencia de una relación entre el LST con la estimación de la temperatura efectiva de la superficie (Wigneron et al., 2008 y Hasan et al., 2014). Por otra parte, existen estudios que demuestran la relación entre el LSE y las propiedades del suelo mostrando su superioridad respecto al NDVI como un indicador de cambio en la cobertura del suelo (French et al., 2008; French y Inamdar, 2010; Sobrino et al., 2012). Actualmente, debido a los estudios que se han realizado para estimar LSE a partir de metodologías que utilizan sensores como ASTER, MODIS y SEVIRI (Gilliespie et al., 1998; Hulley y Hook, 2011; Jiménez-Muñoz et al., 2014) y también estudios comparativos entre estas metodologías (Sobrino et al., 2008) es posible generar estimaciones de LSE permitiendo explorar la relación entre la humedad del suelo y el TIR. Por lo tanto, se abren nuevas posibilidades para generar enfoques que produzcan estimaciones de humedad del suelo más precisas del OPM incluyendo una nueva sinergia con el TIR. Sin embargo, aún es necesario más análisis para comprender mejor la relación entre la humedad del suelo y el TIR.

## CONCLUSIONES

En este trabajo se analizó el impacto que se genera en la estimación de la humedad del suelo mediante el método óptico microondas pasivo al considerar distintos indicadores de vegetación sobre distintos tipos de cobertura del suelo. Para ello, se realizaron calibraciones sobre un periodo de datos entre el 2010 y 2014 utilizando los índices LAI y NDVI, y comparándolos con el no uso de un índice de vegetación. Para esto, se utilizaron datos de temperatura de brillo bipolarizadas de la misión SMOS, los índices de vegetación de LAI y NDVI derivados de sensores ópticos de MODIS, la estimación de temperatura superficial del “reanalysis” de ERA-INTERIM. Luego, para evaluar y comparar estos resultados, fueron utilizadas las coberturas de suelo de ECOCLIMAP, ESA-CCI y CONAF.

Tanto el uso del NDVI como el LAI mejoran más de un 8% de  $\text{m}^3 \text{m}^{-3}$  el RMSE en las estimaciones de humedad del suelo en la mayoría de las coberturas a excepción de la cobertura “agrícola”. Estos resultados están de acuerdo a los obtenidos en la calibración con aumentos significativos de  $r^2$  para todas las coberturas menos la “agrícola”. Por otro lado, se observa gran sensibilidad del OPM a los errores relacionados al LAI en comparación a los errores del NDVI.

El método OPM demuestra ser una herramienta útil para la estimación de humedad sobre la cobertura existente en la mayor parte de Chile. Debido a las características en la estimación de NDVI es posible el uso del OPM con datos de este índice provenientes de distintas fuentes, sin la necesidad de tener que recalibrar el modelo. Este método, también puede ser aplicable a otras escalas espaciales además de ser útil con datos provenientes de otros sensores remotos que utilizan las microondas pasivas. Las mejoras que el OPM presenta sobre el área de estudio podrían ser un importante aporte en áreas de investigación y gestión que utilicen la humedad del suelo, como base para cálculo de índices de sequía. No obstante, son necesarios estudios previos que relacionen el desempeño de este índice utilizando el método OPM y otros índices *in situ* de sequías. El impacto que podría tener el OPM en la estimación de índices de sequía a nivel nacional estaría ligado a la nueva generación de fuentes de información y monitoreo satelital para enfrentar futuros periodos de escasez hídrica debido a la actual disminución de precipitaciones relacionadas con el actual calentamiento global.

## BIBLIOGRAFÍA

- Albergel, C.; E. Zakharova; J. C. Calvet; M. Zribi; M. Pardé; J. P. Wigneron. et al. 2011. A first assessment of the SMOS data in southwestern France using in situ and airborne soil moisture estimates: The CAROLS airborne campaign. *Remote sensing of environment*, 115(10): 2718-2728.
- Albergel, C.; P. De Rosnay; C. Gruhier; J. Muñoz-Sabater; S. Hasenauer; L. Isaksen. et al. 2012. Evaluation of remotely sensed and modelled soil moisture products using global ground-based in situ observations. *Remote Sensing of Environment*, 118: 215-226.
- Al-Yaari, A.; J. P. Wigneron; Y. H. Kerr; R. De Jeu; N. Rodriguez-Fernandez; R. Van Der Schalie. et al. 2016. Testing regression equations to derive long-term global soil moisture datasets from passive microwave observations. *Remote Sensing of Environment*, 180: 453-464.
- Bálsamo, G.; C. Albergel; A. Beljaars; S. Boussetta; E. Brun; H. Cloke. et al. 2015. ERA-Interim/Land: a global land surface reanalysis data set. *Hydrol. Earth Syst. Sci.*, 19: 389-407.
- Berg, A. A.; J. S. Famiglietti; M. Rodell; R. H. Reichle; U. Jambor; S. L. Holl and P.R. Houser. 2005. Development of a hydrometeorological forcing data set for global soil moisture estimation. *International Journal of Climatology*, 25(13): 1697-1714.
- Birky, A. K. 2001. NDVI and a simple model of deciduous forest seasonal dynamics. *Ecological Modelling*, 143: 43– 58.
- Chen, J. M. and J. Cihlar. 1996. Retrieving leaf area index of boreal conifer forests using Landsat TM images. *Remote Sensing of Environment*, 55: 153– 162.
- Cohen, W. B.; T. K. Maier-sperger; S. T. Gower y D. P. Turner. 2003. An improved strategy for regression of biophysical variables and Landsat ETM+data. *Remote Sensing of Environment*, 84: 561–571.
- Daganzo-Eusebio, E.; R. Oliva; Y. H. Kerr; S. Nieto; P. Richaume and S. M. Mecklenburg. 2013. SMOS radiometer in the 1400–1427-MHz passive band: Impact of the RFI environment and approach to its mitigation and cancellation. *IEEE Transactions on Geoscience and Remote Sensing*, 51(10): 4999-5007.
- Defourny, P.; G. Kirches; C. Brockmann; M. Boettcher; M. Peters; S. Bontemps. et al. 2014. Land Cover CCI: Product User Guide Version 2. Université catholique de Louvain: Louvain-la-Neuve, Belgium. 91p.
- De Wit, A. J. and A.J. van Diepen. 2007. Crop model data assimilation with the ensemble

- Kalman filter for improving regional crop yield forecasts. *Agr. Forest Meteorol*, 146: 38–56.
- Dirmeyer, P. A.; A. J. Dolman and N. Sato. 1999. The pilot phase of the global soil wetness project. *Bulletin of the American Meteorological Society*, 80(5): 851.
- Di Castri, F y E. Hajek. 1976. Bioclimatología de Chile. Editorial de la Universidad Católica de Chile, Santiago. 163p.
- Douville, H. and F. Chauvin. 2000. Relevance of soil moisture for seasonal climate predictions: A preliminary study. *Climate Dynamics*, 16(10): 719-736.
- Drusch, M. 2007. Initializing numerical weather prediction models with satellite-derived surface soil moisture: Data assimilation experiments with ECMWF's integrated forecast system and the TMI soil moisture data set. *Journal of Geophysical Research*, 112(3): 1-14.
- Entekhabi, D.; R. Reichle; R. Koster and W. Crow. 2010. Performance metrics for soil moisture retrievals and application requirements. *Journal of Hydrometeorology*, 11(3): 832-840.
- Famiglietti, J.; J. Rudnicki and M. Rodell. 1998. Variability in surface moisture content along a hillslope transect: Rattlesnake Hill, Texas. *Journal of Hydrology*, 120: 259-281.
- Fassnacht, K. S.; S. T. Gower; M. D. MacKenzie; E. V. Nordheim and T. M. Lillesand. 1997. Estimating the leaf area index of north central Wisconsin forests using the Landsat Thematic Mapper. *Remote Sensing of Environment*, 61: 229– 245.
- French, A.N. and A. Inamdar. 2010. Land cover characterization for hydrological modelling using thermal infrared emissivities. *Int. J. Remote Sens.* 31 (14): 3867-3883.
- French, A.N.; T. J. Schmugge; J. C. Ritchie; A. Hsu; F. Jacob; K. Ogawa. 2008. Detecting land cover change at the Jornada Experimental Range, New Mexico with ASTER emissivities. *Remote Sens. Environ.* 112 (4): 1730–1748.
- Friedl, M. A.; J. Michaelsen; F. W. Davis; H. Walker and D. S. Schimel. 1994. Estimating grassland biomass and leaf area index using ground and satellite data. *International Journal of Remote Sensing*, 15: 1401– 1420.
- Garrigues, S.; R. Lacaze; F. Baret; J. T. Morisette; M. Weiss; J. E. Nickeson. et al. 2008. Validation and intercomparison of global Leaf Area Index products derived from remote sensing data. *Journal of Geophysical Research*, 133: 1-20.
- Georgakakos, K. P. and M. Carpenter. 2006. Potential value of operationally available and spatially distributed ensemble soil water estimates for agriculture, *J. Hydrol.* 328: 177–191.
- Gillespie, A.; S. Rokugawa; T. Matsunaga; J. S. Cothorn; S. Hook and A. B. Kahle. 1998. A

temperature and emissivity separation algorithm for Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER) images. *IEEE transactions on geoscience and remote sensing*, 36(4): 1113-1126.

Guerif, M. and C. I. Duke. 2000. Adjustment procedures of a crop model to the site-specific characteristics of soil and crop using remote sensing data assimilation. *Agr. Ecosyst. Environ.* 85: 57–69.

Hasan, S.; C. Montzka; C. Rüdiger; M. Ali; H. R. Boga and H. Vereecken. 2014. Soil moisture retrieval from airborne L-band passive microwave using high resolution multispectral data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 91: 59-71.

Hill, K. J.; A. S. Taschetto and M. H. England. 2011. Sensitivity of South American summer rainfall to tropical Pacific Ocean SST anomalies. *Geophysical Research Letters*, 38(1): 1-6.

Hoyos, N.; J. Escobar; J. C. Restrepo; A. M. Arango and J. C. Ortiz. 2013. Impact of the 2010–2011 La Niña phenomenon in Colombia, South America: the human toll of an extreme weather event. *Applied Geography*, 39: 16-25.

Huete; A. R.; K. Didan; T. Miura; E. P. Rodríguez; X. D. Gao and L. G. Ferreira. 2002. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83: 195–213.

Hulley, G. C. and S. J. Hook. 2011. Generating consistent land surface temperature and emissivity products between ASTER and MODIS data for earth science research. *IEEE Transactions on Geoscience and Remote Sensing*, 49(4): 1304-1315.

Jackson, T. J. and T. J. Schmugge. 1995. Surface soil moisture measurement with microwave radiometry. *Acta Astronautica*, 35(7): 477-482.

Jiménez-Muñoz, J. C.; J. A. Sobrino; C. Mattar; G. Hulley and F. M. Göttsche. 2014. Temperature and emissivity separation from MSG/SEVIRI data. *IEEE Transactions on Geoscience and Remote Sensing*, 52(9): 5937-5951.

Jones, M. O.; L. A. Jones; J. S. Kimball and K. C. McDonald. 2011. Satellite passive microwave remote sensing for monitoring global land surface phenology. *Remote Sensing of Environment*, 115(4): 1102-1114.

Kerr, Y. H.; P. Waldteufel; J. P. Wigneron; J. M. Martinuzzi; J. Font and M. Berger. 2001. Soil moisture retrieval from space: The Soil Moisture and Ocean Salinity (SMOS) mission. *Geoscience and Remote Sensing*, 39(8): 1729-1735.

Kerr, Y. H. 2007. Soil moisture from space: Where are we? *Hydrogeology Journal*, 15(1): 117-120.

- Kerr, Y. H.; P. Waldteufel; P. Richie; J. P. Wigneron; P. Frazzle; A. Mahmood. et al. 2012. The SMOS Soil Moisture Retrieval Algorithm. *Proc. IEEE*, 50(5):1384-1403.
- Kerr, Y.H.; P. Waldteufel; J. P. Wigneron; S. Delsarte; F. Cabot; J. M. Bouton. et al. 2010. The SMOS Mission: New Tool for Monitoring Key Elements of the Global Water Cycle. *Proc. IEEE*, 98(5): 666–687.
- Kerr, Y. H.; A. Al-Yaari; N. Rodriguez-Fernandez; M. Parrens; B. Molero; D. Leroux. et al. 2016. Overview of SMOS performance in terms of global soil moisture monitoring after six years in operation. *Remote Sensing of Environment*, 180: 40-63.
- Korres, W.; T. G. Reichenau; P. Fiener; C. N. Koyama; H. R. Bogen; T. Cornelissen. et al. 2015. Spatio-temporal soil moisture patterns—A meta-analysis using plot to catchment scale data. *Journal of hydrology*, 520: 326-341.
- Krishnamurthy, V. and V. Misra. 2010. Observed ENSO teleconnections with the South American monsoon system. *Atmospheric Science Letters*, 11(1): 7-12.
- Law, B. E. and R. H. Waring. 1994. Remote sensing of leaf area index and radiation intercepted by understory vegetation. *Ecological Applications*, 4: 272– 279.
- Lawrence, H.; J. P. Wigneron; P. Richaume; N. Novello; J. Grant; A. Mialon. et al. 2014. Comparison between SMOS Vegetation Optical Depth products and MODIS vegetation indices over crop zones of the USA. *Remote Sens. Environ.* 140: 396–406.
- Leroux, D. J.; Y. H. Kerr; P. Richaume and R. Fieuzal. 2013. Spatial distribution and possible sources of SMOS errors at the global scale. *Remote Sensing of Environment*, 133: 240-250.
- Liu, Z.; X. Shi; E. Warner; Y. Ge; D. Yu; S. Ni and H. Wang. 2008. Relationship between oriental migratory locust plague and soil moisture extracted from MODIS data. *International Journal of Applied Earth Observation and Geoinformation*, 10(1): 84-91.
- Mallick, K.; B. K. Bhattacharya and N. K. Patel. 2009. Estimating volumetric surface moisture content for cropped soils using a soil wetness index based on surface temperature and NDVI. *Agricultural and Forest Meteorology*, 149(8): 1327-1342.
- Martínez-Fernández, J.; A. González-Zamora; N. Sánchez; A. Gumuzzio and C. M. Herrero-Jiménez. 2016. Satellite soil moisture for agricultural drought monitoring: Assessment of the SMOS derived Soil Water Deficit Index. *Remote Sensing of Environment*, 177: 277-286.
- Masson, V.; J. L. Champeaux; F. Chauvin; C. Marignat. and R. Lacaze. 2003. A Global Database of Land Surface Parameters at 1-km Resolution in Meteorological and Climate Models. *Journal of Climate*, 16(9): 1261-1282.
- Mattar, C.; J. P. Wigneron; J. A. Sobrino; N. Novello; J. C. Calvet; C. Albergel. et al. 2012.

A Combined Optical-Microwave Method to Retrieve Soil Moisture Over Vegetated Areas. *IEEE Trans. Geoscience and Remote Sensing*, 50(5): 1404-1413.

Mattar, C.; A. Santamaría-Artigas and J. A. Sobrino. 2016a. Soil Moisture Retrieved from a Combined Optical and Passive Microwave Approach: Theory and Applications. (cap 7, pp.135-158). En: Srivastava, P. K.; Petropoulos, G. y Kerr, Y. H. *Satellite Soil Moisture Retrieval*. Elsevier. 411p.

Mattar, C.; A. Santamaría-Artigas; C. Durán-Alarcón; L. Olivera-Guerra; R. Fuster and D. Borvarán. 2016b. The LAB-Net Soil Moisture Network: Application to Thermal Remote Sensing and Surface Energy Balance. *Data*, 1(1): 6.

Miernecki, M.; J. P. Wigneron; E. López-Baeza; Y. H. Kerr; R. De Jeu; G. De Lannoy. et al. 2014. Comparison of SMOS and SMAP soil moisture retrieval approaches using tower-based radiometer data over a vineyard field. *Remote Sensing of Environment*, 154: 89-101.

Mittelbach, H.; F. Casini; I. Lehner; A. J. Teuling and S. I. Seneviratne. 2011. Soil moisture monitoring for climate research: Evaluation of a low-cost sensor in the framework of the Swiss Soil Moisture Experiment (SwissSMEX) campaign. *Journal of Geophysical Research*, 116 (D5): 111.

Myneni, R. B.; F. G. Hall; P. J. Sellers and A. L. Marshak. 1995. The interpretation of spectral vegetation indexes. *IEEE Transactions on Geoscience and Remote Sensing*, 33: 481– 486.

Myneni, R. B.; S. Hoffman; Y. Knyazikhin; J. L. Privette; J. Glassy; Y. Tian. et al. 2002. Global products of vegetation leaf area and fraction absorbed PAR from year one of MODIS data. *Remote sensing of environment*, 83(1): 214-231.

Oliva, R.; E. Daganzo; Y. H. Kerr; S. Mecklenburg; S. Nieto; P. Richaume and C. Gruhier. 2012. SMOS radio frequency interference scenario: Status and actions taken to improve the RFI environment in the 1400–1427-MHz passive band. *IEEE Transactions on Geoscience and Remote Sensing*, 50(5): 1427-1439.

Parrens, M.; E. Zakharova; S. Lafont; J. C. Calvet; Y. H. Kerr; W. Wagner and J. P. Wigneron. 2012. Comparing Soil moisture retrievals from SMOS and ASCAT over France. *Hydrol. Earth Syst. Sci. Discuss*, 8: 8565-8607.

Pérez-Hoyos, A.; F. J. García-Haro and J. San-Miguel-Ayanz. 2012. Conventional and fuzzy comparisons of large scale land cover products: Application to CORINE, GLC2000, MODIS and GlobCover in Europe. *ISPRS journal of photogrammetry and remote sensing*, 74: 185-201.

Reynolds, S. G. 1970. The gravimetric method of soil moisture determination Part III An examination of factors influencing soil moisture variability. *J. Hydrol*, 11(3): 288-300.

Santamaría-Artigas, A.; C. Mattar and J. P. Wigneron. 2016. Application of a Combined Optical–Passive Microwave Method to Retrieve Soil Moisture at Regional Scale Over Chile. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(4): 1493-1504.

Shaoning, L. V.; J. Wen; Y. Zeng; H. Tian and Z. Su. 2014. An improved two-layer algorithm for estimating effective soil temperature in microwave radiometry using in situ temperature and soil moisture measurements. *Remote Sensing of Environment*, 152: 356-363.

Shin, D.; J. Bellow; T. LaRow; S. Cocke and J. O'Brien. 2006. The role of an advanced land model in seasonal dynamical downscaling for crop model application. *J. Appl. Meteorol. Climatol*, 45(5): 686-701.

Sobrino, J. A.; J. C. Jiménez-Muñoz; G. Soria; M. Romaguera; L. Guanter; J. Moreno. et al. 2008. Land surface emissivity retrieval from different VNIR and TIR sensors. *IEEE Transactions on Geoscience and Remote Sensing*, 46(2): 316-327.

Sobrino, J. A.; B. Franch; C. Mattar; J. C. Jiménez-Muñoz and C. Corbari. 2012. A method to estimate soil moisture from Airborne Hyperspectral Scanner (AHS) and ASTER data: Application to SEN2FLEX and SEN3EXP campaigns. *Remote Sensing of Environment*, 117: 415-428.

Tucker, C. J. 1979. Red and photographic infrared linear combinations for monitoring vegetation. *Remote sensing of Environment*, 8(2): 127-150.

Ulaby, F. T.; R. K. Moore and A. K. Fung. 1986. Microwave remote sensing: Active, passive Vol III: From theory to applications. Dedham, MA: Artech House. 1100p.

Wang, J. R. and T. J. Schmugge. 1980. An empirical model for the complex dielectric permittivity of soils as a function of water content. *IEEE Trans. Geosci. Remote Sensing*, 18: 288-295.

Wang, Q.; S. Adiku; J. Tenhunen and A. Granier. 2005. On the relationship of NDVI with leaf area index in a deciduous forest site. *Remote Sensing of Environment*, 94: 244-255.

Wigneron, J. P.; Y. H. Kerr; P. Waldteufel; K. Saleh; M. Escorihuela and P. Richaume. 2007. L-Band Microwave Emission of the Biosphere Model (L-MEB) model: Description and calibration against experimental data sets over crop fields. *Remote Sensing of Environment*, 107:639-655.

Wigneron, J. P.; J. C. Calvet; P. De Rosnay; Y. H. Kerr; P. Waldteufel; K. Saleh. et al. 2004. Soil Moisture Retrievals from Biangular L-Band Passive Microwave Observations. *IEEE Trans. Geoscience and Remote Sensing*, 1(4): 277-281.

Wigneron, J. P.; A. Chanzy; P. De Rosnay; C. Rudiger and J. C. Calvet. 2008. Estimating the

effective soil temperature at L-band as a function of soil properties. *IEEE Transactions on Geoscience and Remote Sensing*, 46(3): 797-807.

UNEA (Unidad Nacional de Emergencias Agrícolas y Gestión del Riesgo Agroclimático). Monitoreo de sequías [en línea]. Santiago, Chile: Universidad de Chile. Recuperado en: <<http://www.climatedatalibrary.cl/UNEA/maproom/Monitoring/index.html>>. Consultado el: 22 de agosto de 2016.

Zheng, G. and L. M. Moskal. 2009. Retrieving leaf area index (LAI) using remote sensing: Theories, methods and sensors. *Sensors*, 9(4): 2719-2745.