

TRABAJO FIN DE MÁSTER

MODELIZACIÓN EMPÍRICA DEL ÍNDICE DE ÁREA FOLIAR EN ECOSISTEMAS DE DEHESA: INTEGRACIÓN DE DATOS DE CAMPO, AEROPORTADOS Y DE SATÉLITE

EMPIRICAL MODELLING OF LEAF AREA INDEX IN TREE-GRASS ECOSYSTEMS: A COMBINATION OF FIELD, AIRBORNE AND SATELLITE DATA

Autor: Christian Mestre Runge

Director: Dra. Raquel Montorio Llovería

Máster Universitario en

Tecnologías de la información geográfica para la ordenación del territorio: sistemas de información geográfica y teledetección

Noviembre de 2018



Universidad
Zaragoza

**Departamento de Geografía
y Ordenación del Territorio**



Resumen

El índice de área foliar es considerado un bioindicador del estado de la salud real de las plantas y de la productividad primaria bruta de la vegetación. Numerosos estudios han demostrado que los modelos basados en regresión simple lineal son herramientas óptimas que tienen la capacidad de relacionar el LAI medido en campo con información derivada de teledetección óptica. El objetivo del presente Trabajo Fin de Máster es desarrollar un modelo predictivo de LAI a partir de información multiespectral de media resolución espacial (Landsat) a partir del análisis y modelización previa de las relaciones entre información hiperespectral a alta resolución espacial y LAI verdad-terreno utilizando la técnica upscaling y, desarrollado para ambientes heterogéneos como son las dehesas. Para ello, se han utilizado datos hiperespectrales derivados del sensor CASI y datos del LAI medida en campo proporcionados por SynerTGE y una gama de índices de Vegetación derivados de los productos Landsat TM y OLI. Un primer análisis se basó en establecer relaciones empíricas entre pseudo-LAI e índices de vegetación. Para seguir evaluando el rendimiento del modelo, se aplicaron análisis de regresión (RLS) para modelizar la relación entre pseudo-LAI e índices de vegetación. Los resultados establecieron que el método propuesto varía en función de los modelos utilizados. Por otra parte, se desarrolló un modelo para i) aplicar y modelizar las funciones predictivas generadas mediante los análisis RLS y, ii) validar los productos mediante estadístico RMSE. Para ello, se utilizaron series multitemporales derivadas de Landast-8 OLI y muestras de LAI total y LAI verde repartidas en 5 jornadas de campo, en cada parcela (11), las muestras fueron tomadas sobre 3 cuadrantes (25x25cm), además, las muestras tomadas se consideran, a priori, representativas a distintos momentos de la dinámica fenológica. Los resultados obtenidos establecen que los modelos predictivos rinden mejor para períodos primaverales-estivales, cuando el pastizal se encuentra en su periodo de máximo crecimiento. Además, el modelo desarrollado sobre pasto y encinares rinde mejor que el modelo A. Si individualizamos los casos, se establece que el modelo predictivo en fecha del 28 de junio de 2015 obtuvo los mejores valores RMSE = 0.196 y RMSE (%) = 6.73 para predecir la variable biofísica LAI verde.

Palabras Clave: LAI, índices de vegetación, Landsat TM y OLI, CASI, upscaling

Abstract

The leaf area index is considered a bioindicator of the state of the real health of the plants and the gross primary productivity of the vegetation. Numerous studies have shown that models based on linear simple regression are optimal tools that have the ability to relate the LAI measured in the field with information derived from optical remote sensing. The objective of the present Master's Thesis is to develop a predictive model of LAI from of multispectral information of medium spatial resolution (Landsat) from the analysis and previous modeling of the relationships between hyperspectral information at high spatial resolution and truth-ground LAI using the upscaling technique and, developed for heterogeneous environments such as dehesas. For this purpose, hyperspectral data derived from the CASI sensor and LAI data measured in the field provided by SynerTGE and a range of Vegetation indices derived from the Landsat TM and OLI products were used. A first analysis was based on establishing empirical relationships between pseudo-LAI and vegetation indices. To further evaluate the performance of the model, regression analysis (RLS) was applied to model the relationship between pseudo-LAI and vegetation indices. The results established that the proposed method varies depending on the models used. On the other hand, a model was developed to i) apply and model the predictive functions generated by the RLS analyzes and, ii) validate the products using the RMSE statistic. For this, multitemporal series derived from Landast-8 OLI and LAI total and LAI green samples distributed over 5 field days were used, in each plot (11), samples were taken over 3 quadrants (25x25cm), in addition, samples taken are considered, a priori, representative of different moments of the phenological dynamics. The obtained results establish that the predictive models yield better for spring-summer periods, when the grassland is in its period of maximum growth. In addition, the model developed on grass and holm oaks yields better than model A. If we individualize the cases, it is established that the predictive model as of June 28, 2015 obtained the best values RMSE = 0.196 and RMSE (%) = 6.73 to predict the bio-physical variable LAI green.

Key Words: LAI, vegetation index, Landsat TM and OLI, CASI, upscaling

Índice

| | |
|---|----|
| 1. INTRODUCCIÓN | 1 |
| 1.1. Relación del Índice del Área Foliar con técnicas teledetección | 2 |
| 1.2 Índices de vegetación y LAI | 4 |
| 1.3 Justificación | 6 |
| 2. HIPÓTESIS Y OBJETIVOS | 7 |
| 3. MÉTODOS Y MATERIALES | 8 |
| 3.1. Área de estudio | 8 |
| 3.2. Esquema metodológico | 9 |
| 3.3. Imágenes de satélite y preprocesamiento aplicados | 11 |
| 3.3.1. Imágenes hiperespectrales | 11 |
| 3.3.2. Imágenes multiespectrales | 12 |
| 3.3.2.1. Normalización topográfica C-correction | 13 |
| 3.3.2.2. Índices de Vegetación para la estimación de LAI | 14 |
| 3.4. Método de ampliación de escala basado en pseudo-LAI | 16 |
| 3.4.1. Cartografía de los valores continuos de pseudo-LAI a partir de CASI | 16 |
| 3.4.2. Fase de ampliación de escala (.upscaling) | 17 |
| 3.5. Análisis de las relaciones empíricas entre pseudo-LAI y los IV | 18 |
| 3.6. Análisis RLS: funciones predictivas y validación de ajustes estadísticos | 19 |
| 3.7. Fase de aplicación y validación | 20 |
| 3.7.1. Muestreo de campo: LAI total y LAI verde | 20 |
| 3.7.2. Imágenes Landsat-8 OLI para la validación del modelo de estimación LAI | 21 |
| 3.7.3. Modelización estadística de LAI total y verde a partir de IV | 22 |
| 4. RESULTADOS | 24 |
| 4.1. Cartografía de los valores continuos de pseudo-LAI a partir de CASI | 24 |
| 4.2. Magnitud y distribución espacial de los valores de pseudo-LAI | 24 |
| 4.3. Análisis de las relaciones empíricas entre pseudo-LAI y los IV | 26 |
| 4.4. Análisis RLS: funciones predictivas | 34 |
| 4.5. Validación de los ajustes estadísticos | 35 |
| 4.6. Aplicación y validación de modelos: datos Landsat-8 y verdad-terreno | 36 |
| 5. DISCUSIÓN | 39 |
| 6. CONCLUSIONES | 42 |
| Bibliografía | 44 |
| Anexo | 1 |

Índices de figuras

| | |
|---|----|
| Figura 1. Las Majadas de Tejar. Cáceres (Extremadura). Fuente: Cartografía base IGN, cobertura dehesa (MAGRAMA), USGS (Landsat) y SynerTGE (CASI). | 8 |
| Figura 2. Esquema metodológico | 10 |
| Figura 3. Proceso metodológico para obtener cartografía Pseudo-LAI | 16 |
| Figura 4. Ilustración de la técnica de ampliación de escala (.upscaling) | 17 |
| Figura 5. Cartografía estadística pseudo-LAI referente a los Coeficientes de Variación derivada de la fase de agregación..... | 18 |
| Figura 6. Proceso metodológico para seleccionar IV | 19 |
| Figura 7. Distribución de las parcelas de muestreo en el área de estudio..... | 20 |
| Figura 8. Cartografía pseudo-LAI | 24 |
| Figura 9. Cartografía pseudo-LAI (estadística) derivada de la ampliación de escala y fase de agregación a resolución Landsat (30m)..... | 25 |
| Figura 10. Análisis de Correlación de Pearson y Coeficientes de determinación para el Modelo A, sensor TM | 27 |
| Figura 11. Análisis de Correlación de Pearson y Coeficientes de determinación para el Modelo A, sensor OLI..... | 28 |
| Figura 12. Análisis de Correlación de Pearson y Coeficientes de determinación para el Modelo B, sensor TM | 30 |
| Figura 13. Análisis de Correlación de Pearson y Coeficientes de determinación para el Modelo B, sensor OLI..... | 31 |
| Figura 14. Relaciones empíricas entre pseudo-LAI mediana y los índices predictores seleccionados a partir TM y OLI | 34 |
| Figura 15. Relaciones empíricas entre LAI observado y pseudo-LAI predicho a partir de MCARI1 (Modelo A) y NDII (Modelo B)..... | 35 |
| Figura 16. LAI observados vs LAI predichos. Validaciones RMSE..... | 37 |
| Figura 17. LAI observado vs LAI predicho. Validaciones RMSE. Utilización de imágenes normalizadas c-correction (Teillet, et al. 1983)..... | 38 |
| Figura 18. Análisis de Correlación de Pearson entre IV vs Pseudo-LAI realizado en base a 5 muestras aleatorias. Modelo A, sensor TM | 1 |
| Figura 19. Análisis de determinación entre IV vs Pseudo-LAI realizado en base a 5 muestras aleatorias. Modelo A, sensor TM..... | 1 |
| Figura 20. Análisis de Correlación de Pearson entre IV vs Pseudo-LAI realizado en base a 5 muestras aleatorias. Modelo A, sensor OLI..... | 2 |
| Figura 21 Análisis de determinación entre IV vs Pseudo-LAI realizado en base a 5 muestras aleatorias. Modelo A, sensor OLI..... | 2 |
| Figura 22. Análisis de Correlación de Pearson entre IV vs Pseudo-LAI realizado en base a 5 muestras aleatorias. Modelo B, sensor TM | 3 |
| Figura 23. Análisis de determinación entre IV vs Pseudo-LAI realizado en base a 5 muestras aleatorias. Modelo B, sensor TM..... | 3 |
| Figura 24. Análisis de Correlación de Pearson entre IV vs Pseudo-LAI realizado en base a 5 muestras aleatorias. Modelo B, sensor OLI..... | 4 |
| Figura 25. Análisis de determinación entre IV vs Pseudo-LAI realizado en base a 5 muestras aleatorias. Modelo B, sensor OLI..... | 4 |
| Figura 26. Análisis de Correlación de Pearson y Coeficientes de determinación realizadas entre las bandas del sensor TM (Landsat-5) y OLI (Landsat-8) y estadísticos LAI. Modelo A | 5 |
| Figura 27. Análisis de Correlación de Pearson y Coeficientes de determinación realizadas entre las bandas del sensor TM (Landsat-5) y OLI (Landsat-8) y estadísticos LAI. Modelo A | 6 |

Índices de tablas

| | |
|---|----|
| Tabla 1. Características técnicas sensores Landsat-5 y 8. Fuente: USGS, 2018.12 | 12 |
| Tabla 2. Índices espectrales utilizados para la estimación del Índice de Área Foliar. Clasificación según Haboudane et al. 2003. | 15 |
| Tabla 3. Factores que implican la selección de imágenes Landsat-8 OLI..... | 22 |
| Tabla 4. Análisis de correlación (r y r^2) entre Pseudo-LAI vs IV en base a muestras aleatorias al 10% sobre las escenas TM y OLI. Modelo A. Representación simplificada de resultados. | 32 |
| Tabla 5. Análisis de correlación (r y r^2) entre pseudo-LAI vs IV en base a muestras aleatorias al 10% sobre las escenas TM y OLI. Modelo B. Representación simplificada de resultados. | 33 |
| Tabla 6. Valores RMSE y RMSE (%) calculado sobre el valor máximo de pseudo-LAI, 3.25). Modelo A | 41 |
| Tabla 7. Valores RMSE y RMSE (%) calculado sobre el valor máximo de pseudo-LAI, 2.91). Modelo B | 41 |

1. INTRODUCCIÓN

Los ecosistemas tipo sabana ocupan aproximadamente un tercio del territorio de la superficie terrestre (Fan *et al.* 2003; Lemaire *et al.* 2005) y, por ello, desempeñan un papel importante en las reservas mundiales de carbono y su productividad (Ahlstrom *et al.* 2015; Grace *et al.* 2006). En el ámbito mediterráneo europeo, estos paisajes se denominan dehesas y constituyen un ecosistema y un sistema productivo único en el mundo. Presentan importantes diferencias con las sabanas subtropicales, siendo exclusivos del suroeste de la Península Ibérica. Se trata del ecosistema agroforestal más extenso de Europa que ofrece los mayores índices de biodiversidad, con una superficie que supera los tres millones de hectáreas (Cáceres *et al.* 2012; Moreno y Pulido, 2009).

Las dehesas son ecosistemas complejos de origen antrópico que proporcionan un importante acervo de valores ambientales, culturales y estéticos, formados principalmente por encinares dispersos, matorral, pasto y cultivos, de larga tradición y gestión sostenible en el ámbito mediterráneo, son un ejemplo de uso múltiple del territorio, que combina el desarrollo socioeconómico de las zonas rurales con la conservación de un ecosistema (González-Dugo *et al.* 2017; Cáceres *et al.* 2012). Desde la óptica ambiental, estos territorios son una pieza angular para el intercambio de flujos de masa y energía entre el sistema atmósfera-biosfera, así como en la productividad de la cubierta y, por tanto, en un entorno de cambio global pueden variar su dinámica y funcionamiento. Por estas razones, su estudio hace que sea necesario para evaluar hasta qué punto las actividades humanas pueden alterar los ciclos bioquímicos naturales e influir en el cambio climático y el ciclo del carbono (Pacheco-Labrador *et al.* 2014; Roig & Rubio, 2009; Lemaire *et al.* 2005).

La estimación de variables biofísicas de la vegetación en zonas heterogéneas, como las dehesas, ha cobrado un gran interés por parte de la comunidad científica tanto para estudios climáticos como para conocer el papel que esta juega en el funcionamiento fisiológico de las plantas, afectando a la productividad de los ecosistemas, la evapotranspiración, el crecimiento celular y la fotosíntesis (Melendo-Vega *et al.* 2017; González-Dugo *et al.* 2017; Cáceres *et al.* 2012; Boyer, 1995).

Una de las variables biofísicas de la vegetación de mayor relevancia por su interés en aplicaciones del ámbito agrícola y forestal es el Índice de Área Foliar (LAI) (Korhonen *et al.* 2017; He *et al.* 2016; Delegido *et al.* 2011; Haboudane *et al.* 2004). Este parámetro biofísico se define como la mitad del área total de la hoja por unidad de superficie de la superficie del terreno (Chen y Black, 1992) y es considerado un bioindicador del estado de la salud real de las plantas y de la productividad primaria bruta de la vegetación (Lichtenthaler *et al.* 1996; Sampson *et al.* 2003).

En este sentido, una gran cantidad de estudios han puesto de manifiesto la eficacia de la teledetección como herramienta para estimar el Índice de Área Foliar debido, precisamente, a su capacidad para ofrecer información a diferentes resoluciones espaciales, radiométricas y frecuencia temporal (Pasqualotto *et al.* 2018; Korhonen *et al.* 2017; Zhen-wang *et al.* 2017; He *et al.* 2016; Fernández-Arango *et al.* 2015; Haboudane *et al.* 2004). Existen varios métodos para estimar LAI

utilizando observaciones de LAI in situ y datos de teledetección, que incluyen métodos de regresión, inversión de ecuación de transferencia de radiación de vegetación y métodos geoestadísticos (He *et al.* 2016; Cohen *et al.* 2003).

Los métodos basados en regresión estadística relacionan parámetros biofísicos, como por ejemplo LAI, con datos espectrales (transformados) mediante técnicas de regresión lineal basados en índices de vegetación (Delegido *et al.* 2014; Haboudane *et al.* 2004). Aunque este sea un método muy utilizado debido a su simplicidad y velocidad de cálculo (Delegido *et al.* 2014), la complejidad de factores que afectan a la generación de productos LAI (He *et al.* 2016; Martín *et al.* 2011; Roberts y Paterson *et al.* 2005), exige nuevos enfoques que permitan proporcionar de manera óptima y precisa insumos para su monitoreo y modelado en pastizales a escalas locales (Korhonen *et al.* 2017).

1.1. Relación del Índice de Área Foliar con técnicas de teledetección

El Índice de Área Foliar es una variable biofísica clave para estimar la cobertura del follaje y para pronosticar el crecimiento y rendimiento de la cubierta vegetal. La variable biofísica LAI verde (*Green LAI*) (utilizada en este trabajo), se corresponde con el LAI sólo de la fracción foliar viva, que puede presentar características estructurales similares pero diversos contenidos de pigmentos (Haboudane *et al.* 2014). El área expuesta de las hojas vivas es clave en los modelos del carbono terrestre, debido a que está estrechamente relacionada con un gran número de procesos biológicos y físicos como la fotosíntesis, la transpiración de las plantas y el intercambio de CO₂ o el ciclo del agua, nutrientes y carbono (Zhen-Wang *et al.* 2017; Delegido *et al.* 2011).

La medición directa del LAI se realiza mediante campañas de muestreo in situ que suelen proporcionar resultados precisos, pero costosos en términos temporales y económicos y, habitualmente, poco representativos para grandes superficies (Melendo-Vega *et al.* 2017; Delegido *et al.* 2015; Chuvieco *et al.* 2001); en la práctica son utilizadas para calibrar y validar otras metodologías (Yebra *et al.* 2013). Sin embargo, debido a que el LAI está relacionado funcionalmente con la reflectancia del dosel vegetal, se pueden utilizar técnicas no destructivas para analizar su distribución espacial (Melendo-Vega *et al.* 2017; He *et al.* 2016). En este contexto, la teledetección óptica facilita su cuantificación en amplias superficies y en diferentes momentos, en función de la resolución espacio-temporal de los sensores que se utilicen (Chuvieco, 2011).

Generalmente, los índices espectrales de vegetación (IV), al minimizar las perturbaciones debidas al suelo y a la atmósfera (Chuvieco, 2015; Delegido *et al.* 2015; Haboudane *et al.* 2004), permiten la estimación del LAI mediante el análisis de las relaciones entre los datos espectrales y datos de LAI medidos in situ. Sin embargo, los IV presentan ciertas limitaciones intrínsecas debido a la influencia de la geometría de la planta o la arquitectura del dosel (Haboudane *et al.* 2004) y a que el LAI no es la única variable que afecta a los IV. Por ejemplo, el contenido de LAI y clorofila poseen efectos similares en la reflectancia del dosel, particularmente en la porción visible del espectro comprendida entre la región del verde (550 µm) y el borde rojo o *red-edge* (750 µm), donde la mayoría de los pigmentos fotosintéticos absorben, así como también en el infrarrojo cercano (NIR, del inglés *Near-Infrared*) y específicamente en la región *red-edge*, en la que la pendiente de los espectros de reflectancia es máxima (Delegido *et al.* 2015; Yebra *et al.* 2008).

Para maximizar las prestaciones de los IV, durante las últimas décadas, se han ido formulando IV para distintos propósitos: i) *capturar los procesos fotoquímicos asociados a la actividad fotosintética como la eficiencia del uso de luz o para estimar el pigmento de la hoja* (Brouge y Leblanc, 2000); ii) *cuantificar la fracción vegetal* (Gitelson *et al.* 2001); y, por su puesto, iii) *estimar LAI* (Brown *et al.* 2000).

En este último caso, independientemente de si el método de estimación tiene una base física o estadística, la gran mayoría de los índices se centran en la estimación del *green LAI* (Delegido *et al.* 2015), debido a que el *green LAI* es sensible a la región espectral que se encuentra cubierta por los sensores ópticos (Delegido *et al.* 2015). Tales características han conllevado a desarrollar nuevos IV sensibles al LAI utilizándose la combinación de bandas comprendidas entre el verde y el red-edge (Haboudane *et al.* 2004).

Al alejarse del VNIR hacia el infrarrojo de onda corta (SWIR, *Short Wave Infrared*, 1,2 a 2,2 μm), otros componentes de las hojas absorben y dispersan la luz, como el agua, la celulosa, la lignina y otros constituyentes bioquímicos, por lo que la convierte en una región óptima para evaluar el estrés hídrico de la vegetación (Chuvieco, 2015; Brown *et al.* 2000). Sin embargo, tal y como señalan Delegido *et al.* (2015) *se ha demostrado que la región del SWIR es óptima para distinguir la vegetación verde de la vegetación senescente y para estimar LAI de la vegetación senescente*. Aun así, su escasa aplicabilidad se explica por las carencias derivadas de los sensores ópticos tradicionales, los cuales, la gran mayoría de ellos cubren un rango espectral continuo entre 350 y 2400 nm utilizando pocas bandas.

Como indican Haboudane *et al.* (2004), la estimación de LAI se enfrenta a dos dificultades añadidas. Por un lado, los IV se aproximan a un nivel de saturación asintótica, es decir cuando LAI excede de 2 a 5 según el IV aplicado y, por otro lado, no existe una relación única entre LAI y un índice de elección de la vegetación, sino una familia de relaciones, cada una en función del contenido de clorofila y otras características del dosel. Para solucionar estas carencias, varios autores han evaluado y comparado IV en términos de su estabilidad y su poder para estimar el parámetro biofísico LAI (Brouge y Leblanc. 2000; Baret y Guyot, 1991), mientras que otros han tratado de modificar algunos IV para aumentar su sensibilidad al LAI (Brown *et al.* 2000). En consecuencia, algunos IV se han perfilado como mejores predictores de LAI debido, precisamente, a que son menos sensibles a la variación de los parámetros externos que afectan la reflectancia espectral de la cubierta, a las propiedades ópticas del suelo, la geometría de iluminación y las condiciones atmosféricas. Sin embargo, así como afirman Haboudane *et al.* (2004), *el efecto de las variaciones de la clorofila de la hoja en la relación entre el IV y LAI sigue siendo un problema a resolver*.

La utilización de sensores hiperespectrales (CASI, AVIRIS, HyMap, APEX) aplicados a la estimación de LAI ha originado la proliferación de literatura científica al respecto. Su éxito y creciente uso aplicado a pastizales se debe principalmente a que estos sensores poseen un mayor número de bandas espectrales y más estrechas que las disponibles en sensores multiespectrales, por lo que ha contribuido al descubrimiento de nuevas regiones de interés que son clave para analizar de manera más precisa las propiedades fisiológicas y estructurales de la planta (fotosíntesis), factores ambientales y fenológicos que influyen sobre la vegetación (Cogliati *et al.* 2015; Peña, 2007). Por ejemplo, se ha demostrado que el LAI o la clorofila

muestran una respuesta espectral más nítida en regiones espetrales muy específicas (Navarro-Cerrillo, 2013), mientras que otros estudios se han centrado en evaluar el rendimiento de varios tipos de IV derivados de sensores hiperespectrales (determinar bandas estrechas) en la caracterización de LAI en ecosistemas de pastizales (Möckel, 2015; He *et al.* 2006).

Por otro lado, el seguimiento del estado de vegetación mediante sensores multiespectrales, como Landsat o el propio Sentinel-2, presenta la ventaja de ofrecer información a una alta frecuencia temporal, mientras que la información hiperespectral derivada de radiómetros de campo y de sensores aeroportados, en la gran mayoría de la literatura científica, se han limitado a una sola fecha de adquisición por el elevado coste que supone su obtención, sobre todo en el caso de sensores aeroportados (Melendo-Vega *et al.* 2017). Por ejemplo, Fernández-Arango *et al.* (2015) pusieron de manifiesto la necesidad de aumentar la dimensión temporal, especialmente para los ecosistemas de gran variabilidad fenológica. Sin embargo, los datos multiespectrales derivados de plataformas satelitales aún están limitados a resoluciones espaciales bajas en comparación a los sensores hiperespectrales. Ello supone, que los diferentes elementos de una imagen localizada en ambientes heterogéneos como la dehesa, sus distintas coberturas (encinares, pasto, agua y suelo) presenten comportamientos espetrales muy diferenciados, agudizando así, problemas derivados de la mezcla de la respuesta espectral de esas cubiertas dentro del píxel (Melendo-Vega *et al.* 2017; Fernández-Arango *et al.* 2015; Hill *et al.* 2011).

Varios de los autores citados, han demostrado que los enfoques basados en regresión estadística mediante técnicas de regresión lineal, permiten de manera óptima relacionar datos de reflectividad o IV derivados con datos extraídos en campo para la estimación de LAI, puesto que permite crear una ecuación en función de un conjunto de variables de predicción de entrada (Cohen *et al.* 2003; He *et al.* 2016). Aun así, este método solo sirve cuando se dispone de un rango de datos similar a los utilizados para su desarrollo (Li y Wang, 2013).

Sin embargo, debido a la influencia de los algoritmos del modelo, la heterogeneidad de la vegetación, la falta de coincidencia de escala y sus errores asociados a la geolocalización, las condiciones meteorológicas del año (Roberts y Paterson *et al.* 2005) y por la cantidad de datos de referencia exhaustivas y fiables que se requiere para calibrar y validar las fórmulas empíricas en diferentes ecosistemas (Martín *et al.* 2011), los productos LAI inevitablemente tienen incertidumbres inherentes asociadas a la comparación directa entre las mediciones de LAI *in situ* y los productos de LAI a resolución media (Por ejemplo, Landsat o Sentinel-2) (He *et al.* 2016), por lo que su empleo queda limitado en aplicaciones a escalas locales (Yebra *et al.*, 2006).

1.2. Índices de vegetación y LAI

Durante los últimos decenios, se ha suscitado un creciente interés en desarrollar y evaluar índices espetrales para predecir de manera óptima el Índice de Área Foliar, así como también los factores que afectan a la reflectancia del dosel (Haboudane *et al.* 2004; Broge y Leblanc, 2001; Baret y Guyot, 1991). En este contexto, Haboudane *et al.* (2004), realizaron un complejo análisis basado, entre otras cosas, en evaluar el rendimiento de una amplia gama de IV para predecir la variable biofísica LAI. En su estudio, seleccionaron y agruparon los IV en función de sus

características espectrales, definidos por a) *Índices basados en la diferencia normalizada: mejora de la linealidad*; b) *Índices de vegetación suelo-línea: mejora la influencia del suelo y los efectos atmosféricos* y c) *Índices de vegetación mejorados para estimar LAI verde*.

En cuanto a los índices basados en la diferencia normalizada, el NDVI (Rouse *et al.* 1974) es sin duda, el IV más conocido en la bibliografía científica. Pese a su amplio uso, este índice se satura ante el incremento del dosel vegetal y muestra una relación no lineal con LAI verde (Baret y Guyot, 1991, citado en Haboudane *et al.* 2003). Roujean y Breon (1995) desarrollaron el *Renormalized Difference Vegetation Index* para mejorar la linealidad de las variables biofísicas, mientras que Chen (1996) propusieron el *Modify Simple Relation* (MSR) como una mejora del RDVI combinándolo con el índice *Simple Relation* (Jordan, 1969, citado en Haboudane *et al.* 2004). El SRWI, es un índice óptimo para estimar el contenido de humedad vegetativo; la utilización del SWIR-1 y del NIR, este último más insensible al cambio de contenido de agua, hace que sea un índice apropiado para predecir el LAI, aunque satura cuando LAI es superior a 4 (Zarco-Tejada y Ustin 2001). El *Normalized Difference 819/1600 NDII*, ha sido citado como un índice preciso para estimar el contenido de humedad foliar en diversos ecosistemas (Hardisky *et al.* 1983), mientras que, el NDBLeaf fue desarrollado por Le Marie *et al.* (2004) para estimar de forma óptima la clorofila.

Por otra parte, los IV que incorporan la línea de suelo se formularon para minimizar las perturbaciones debidas a la influencia del suelo. Por ejemplo, el *Soil Adjusted Vegetation Index* (SAVI) experimentó mejoras debido a la introducción del factor *L*, conocida como una función que define la densidad vegetal (Huete, 1988). Para mejorar el rendimiento de SAVI, Qi *et al.* (1994) propusieron MSAVI, con *un factor de autoajuste L que no aparecen en la formulación de MSAVI* (Haboudane *et al.* 2004).

En base a MCARI (Daughtry *et al.* 2000) y a TVI (Broge y Leblanc, 2000), Haboudane *et al.* (2003) aplicaron mejoras para estimar el LAI verde. Para ello, introdujeron dos cambios sobre la función MCARI: i) *supresión de la relación (R₇₀₀ y R₆₇₀) para disminuir la sensibilidad a los efectos de la clorofila*; y ii) *la integración de una longitud de onda corta del infrarrojo cercano para aumentar la sensibilidad a los cambios de LAI*. De este modo, la expresión MCARI se simplificó y dio lugar a MCARI1. En cambio, la modificación de TVI se basó en el hecho de que el aumento de la concentración de clorofila provoca cambios en la reflectancia en la región del espectro *red-edge* (750 nm). Para que TVI fuera más preciso para estimar LAI, la longitud de onda 750 μm fue reemplazada por la de 800 μm , cuya reflectancia es afectada por la arquitectura vegetal e insensible a los cambios de nivel de pigmentos. De este modo y aplicando un factor de escala, se formuló MTVI1 (Haboudane *et al.* 2003). MCARI2 y MTVI2 se desarrollaron para preservar la sensibilidad de LAI y la resistencia a la influencia de la clorofila mediante la aplicación del factor de escala desarrollado por Huete (1998), por lo que minimizaron los efectos de la influencia del suelo (Haboudane *et al.* 2003).

Ajenos a la agrupación de IV establecida por Haboudane *et al.* (2003), se incorpora otro grupo definido por IV atmosféricos. El índice *Enhanced Vegetation Index (EVI)* se desarrolló para optimizar la señal de vegetación con una sensibilidad mejorada para regiones de alta biomasa y un mejor monitoreo de la vegetación mediante el desacoplamiento de la señal de fondo del dosel y una reducción

de la influencia de la atmósfera (Huete, 2012). Como novedad introdujo el factor L (ajuste de fondo de cubierta); C_1 , C_2 (Coeficientes de resistencia atmosférica) y el factor de ganancia (2.5). El índice *Global Vegetation Moisture Index* (GVMI) fue desarrollado por Ceccato *et al.* (2002) para mejorar la sensibilidad al contenido de agua de la vegetación y para minimizar la sensibilidad de las perturbaciones atmosféricas y angulares, demostrando que GVMI ofrece mayor rendimiento para predecir el contenido de agua de la vegetación cuando LAI es igual a mayor a 2. El índice no-lineal GEMI (*Global Environment Monitoring Index*) se desarrolló para monitorear la vegetación a partir de mediciones en la parte alta de la atmósfera, por lo que resulta útil para comparar observaciones en distintas situaciones atmosféricas y de iluminación (Pinty y Verstraete, 1992). Por último, el índice *Visible Atmospherically Resistant Index* (VARI; Gitelson *et al.* 2002) se diseñó para introducir una autocorrección atmosférica en base al índice ARVI.

1.3. Justificación

Este trabajo se ha realizado en el contexto del proyecto Plan Nacional de I+D+i del Ministerio de Economía y Competitividad (SynerTGE): “*Landsat 8 + Sentinel-2: exploring sensor synergies for monitoring and modelling key vegetation biophysical variables in tree-grass ecosystems*”. (http://www.lineas.cchhs.csic.es/synerdge/project_overview). La disponibilidad de datos ofrecidos por SynerTGE (espectroscopía de laboratorio y campo e imágenes hiperespectrales aerotransportado CASI) y sensores satelitales multiespectrales, está permitiendo el aumento de trabajos relacionados con la aplicación de innovadoras metodologías centradas en relacionar adecuadamente la información espectral y variables biofísicas de vegetación en el marco del cambio climático, cuya finalidad está siendo validar productos de teledetección a diferentes escalas espaciales adaptadas a los ecosistemas de sabana.

En este sentido, destaca especialmente el trabajo realizado por Melendo-Vega *et al.* (2017), que se utilizará como referencia conceptual y metodológica de este Trabajo Fin de Máster. El objetivo de este artículo se centró en el análisis de las relaciones empíricas entre variables biofísicas, correspondiente al componente herbáceo de una dehesa en distintas fases del ciclo fenológico, y diversos índices espectrales de vegetación. Dichos IV se derivaron, a escala espacial de resolución centimétrica, tanto la información original adquirida mediante espectro-radiometría de campo y del sensor hiperespectral aeroportado CASI, como los datos espectrales remuestreados a la resolución espectral del sensor *Multiespectral Instrument* (MSI) a bordo del Sentinel-2.

Sus resultados demostraron que los IV más idóneos fueron aquellos que utilizan para su cálculo las regiones del SWIR y el *red-edge*, lo que coincide con otros trabajos (Delegido *et al.* 2011; Hermann *et al.* 2011; Lee *et al.* 2004). A partir de ello, generaron para cada una de las variables estimadas modelos de regresión lineal a partir de la serie de imágenes CASI.

Sin embargo, debido a diferente resolución espacial que existe entre los datos de campo y la información espectral proporcionada por las series multitemporales de satélite multiespectrales como Landsat o el propio Sentinel, el grado de ajuste empírico con estos últimos disminuye notablemente, siendo más complejo su uso en el marco de la modelización espacial. En este contexto, en el presente Trabajo

Fin de Máster se propone una metodología para relacionar información multiespectral (Landsat) con variables biofísicas a partir del análisis y modelización previa de las relaciones entre el sensor hiperespectral aeroportado CASI y variables biofísicas. Ello permitirá incorporar la dimensión temporal de los datos multiespectrales en los procesos de modelización empírica aplicados a ecosistemas de gran variabilidad fenológica y heterogeneidad de cubiertas como son las dehesas del sector SW de España.

2. HIPÓTESIS Y OBJETIVOS

El objetivo del presente Trabajo Fin de Máster es desarrollar un modelo predictivo de LAI a partir de información multiespectral de media resolución espacial (Landsat) a partir del análisis y modelización previa de las relaciones entre información hiperespectral a alta resolución espacial y LAI verdad-terreno, desarrollado para ambientes heterogéneos como son las dehesas.

Este objetivo principal se fundamenta en la hipótesis de que las relaciones empíricas entre datos LAI de pasto, obtenidas mediante trabajo de campo y laboratorio en unidades espaciales de 25x25cm e índices de vegetación derivados de imágenes multiespectrales de 30m de resolución espacial (Landsat), no son muy elevadas debido a múltiples factores. Un factor sumamente importante se relaciona con la difusión entre la resolución espacial Landsat y la representatividad de las mediciones en cuadrantes 25x25, por lo que la elección adecuada del método propuesto y los datos elegidos permitirá, a priori, obtener un modelo más robusto que permita, a priori, determinar de manera precisa cual índice sea el más adecuado para predecir el parámetro biofísico LAI.

En este sentido, las imágenes hiperespectrales pueden proporcionar un nivel intermedio al ajustarse mejor, por su resolución espacial y a los datos de LAI medidos en campo. De este modo, espacializar primero el LAI (pseudo-LAI) a partir de los modelos empíricos (Hiperespectral vs LAI campo) y su remuestreo a píxeles Landsat puede maximizar la modelización predictiva con Landsat. Pese a que la idea no sea nueva, con ello además se podría testear la robustez de los modelos con Landsat al trabajar con muchos más datos de LAI.

Para la consecución del objetivo principal planteado, se han establecido una serie de objetivos parciales que se describen a continuación:

- Determinar si el mayor potencial de estimación del LAI está en índices basados en las regiones comprendidas entre el V-NIR o el V-SWIR mediante el uso de técnicas de regresión lineal simple.
- Valorar la influencia de la muestra desde el punto de vista espectral utilizada para generar los modelos y comprobar cómo influye en los resultados mediante el uso de técnicas de regresión lineal simple
- Determinar si la mejor variable a estimar corresponde a la variable biofísica LAI verde o LAI total a partir de las funciones predictivas previas derivadas de los mejores índices espectrales de vegetación, haciendo uso de técnicas de regresión lineal simple y validación RMSE.

- Analizar la influencia/variación del proceso de normalización topográfica sobre el modelo desarrollado a partir de las ecuaciones predictivas previas derivadas de índices espectrales de vegetación, utilizando técnicas de regresión lineal simple y validación RMSE.

3. METODOS Y MATERIALES

3.1. Área de estudio

La zona de estudio se localiza en una dehesa perteneciente a la localidad de Las Majadas de Tiétar, al noroeste de la provincia de Cáceres (Extremadura) ($39^{\circ}56'26''\text{N}$, $5^{\circ}46'29''\text{W}$) (figura 1). Se trata de un área de experimentación caracterizada por un uso extensivo de ganado bovino en la que se sitúa en torno a una torre de medición de flujo *Eddy Covariance*, gestionado por el Centro de Estudios Ambientales Mediterráneos (CEAM) desde el año 2003 y que está incluida en las redes CARBORED (<http://www.ceam.es/carboredes/>) y FLUXNET (<http://fluxnet.ornl.gov/>). Actualmente, este emplazamiento constituye el laboratorio experimental del proyecto SynerTGE.

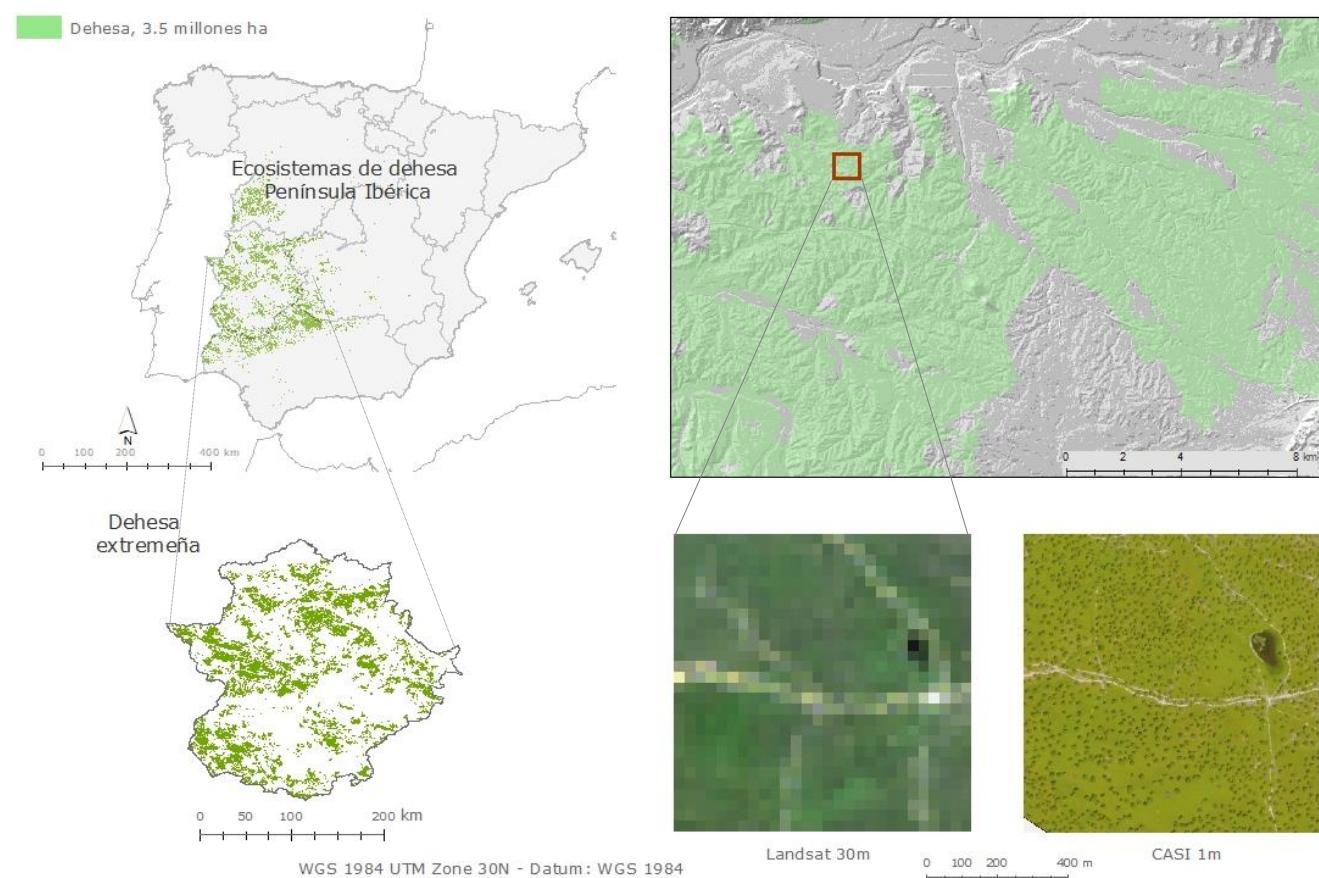


Figura 1. Las Majadas de Tejar. Cáceres (Extremadura). Fuente: Cartografía base IGN, cobertura dehesa (MAGRAMA), USGS (Landsat) y SynerTGE (CASI).

El clima en la zona de estudio es mediterráneo con una temperatura media anual de 16.7°C y una precipitación media de 572 mm, llegando a alcanzarse en

los meses de verano temperaturas máximas de hasta 40°C y precipitaciones medias de tan sólo 67 mm (Fernández-Arango *et al.* 2015). El relieve es poco accidentado, con una altitud media de 256 m.s.n.m.

El tipo de vegetación natural corresponde a las series meso-mediterráneas de *Pyro bourgeanaeae* – *Querceto rotundifoliae querchetum* (Cáceres *et al.* 2012), que ha sido transformada en una vegetación organizada por dos estratos con características biofísicas y fenológicas muy diferenciados. El estrato arbóreo está compuesto principalmente por encinas (*Quercus ilex* ssp. *ballota* (L)), además de algunos alcornoques (*Quercus suber*) y quejigos (*Quercus faginea*). La altura y diámetro medios del dosel arbóreo es de 9 y 6 metros respectivamente y la cobertura arbórea cubre aproximadamente un 16% respecto la región de interés. El estrato herbáceo cubre de manera anual la mayor parte del área seleccionada y está integrada por una gran variedad de especies entre las que se encuentran *Rumex acetosella* L. *Plantago carinata* Shard, *Trifolium subterraneum* (L.), *Cynodon dactylon* (L.) Pers. *Taraxacum dens-leonis* Desf. y *Vulpia myuros* (L.) C. C. Gmel. (Melendo- Vega *et al.* 2017; Fernández-Arango *et al.* 2015). En menor medida superficial, aparecen pequeñas lagunas y caminos rurales con propiedades ópticas completamente diferentes a la de la vegetación.

3.2. Esquema Metodológico

En este apartado se muestra en forma de modelo conceptual el proceso metodológico desarrollado (figura 2). El método propuesto se divide en 1) procesamiento de las imágenes, 2) elaboración cartográfica pseudo-LAI, 3) Análisis de regresión lineal simple (RLS) y correlación (r y r^2), 3) validación de ajustes estadístico, 4) aplicación y validación de los modelos y, 5) resultados RMSE.

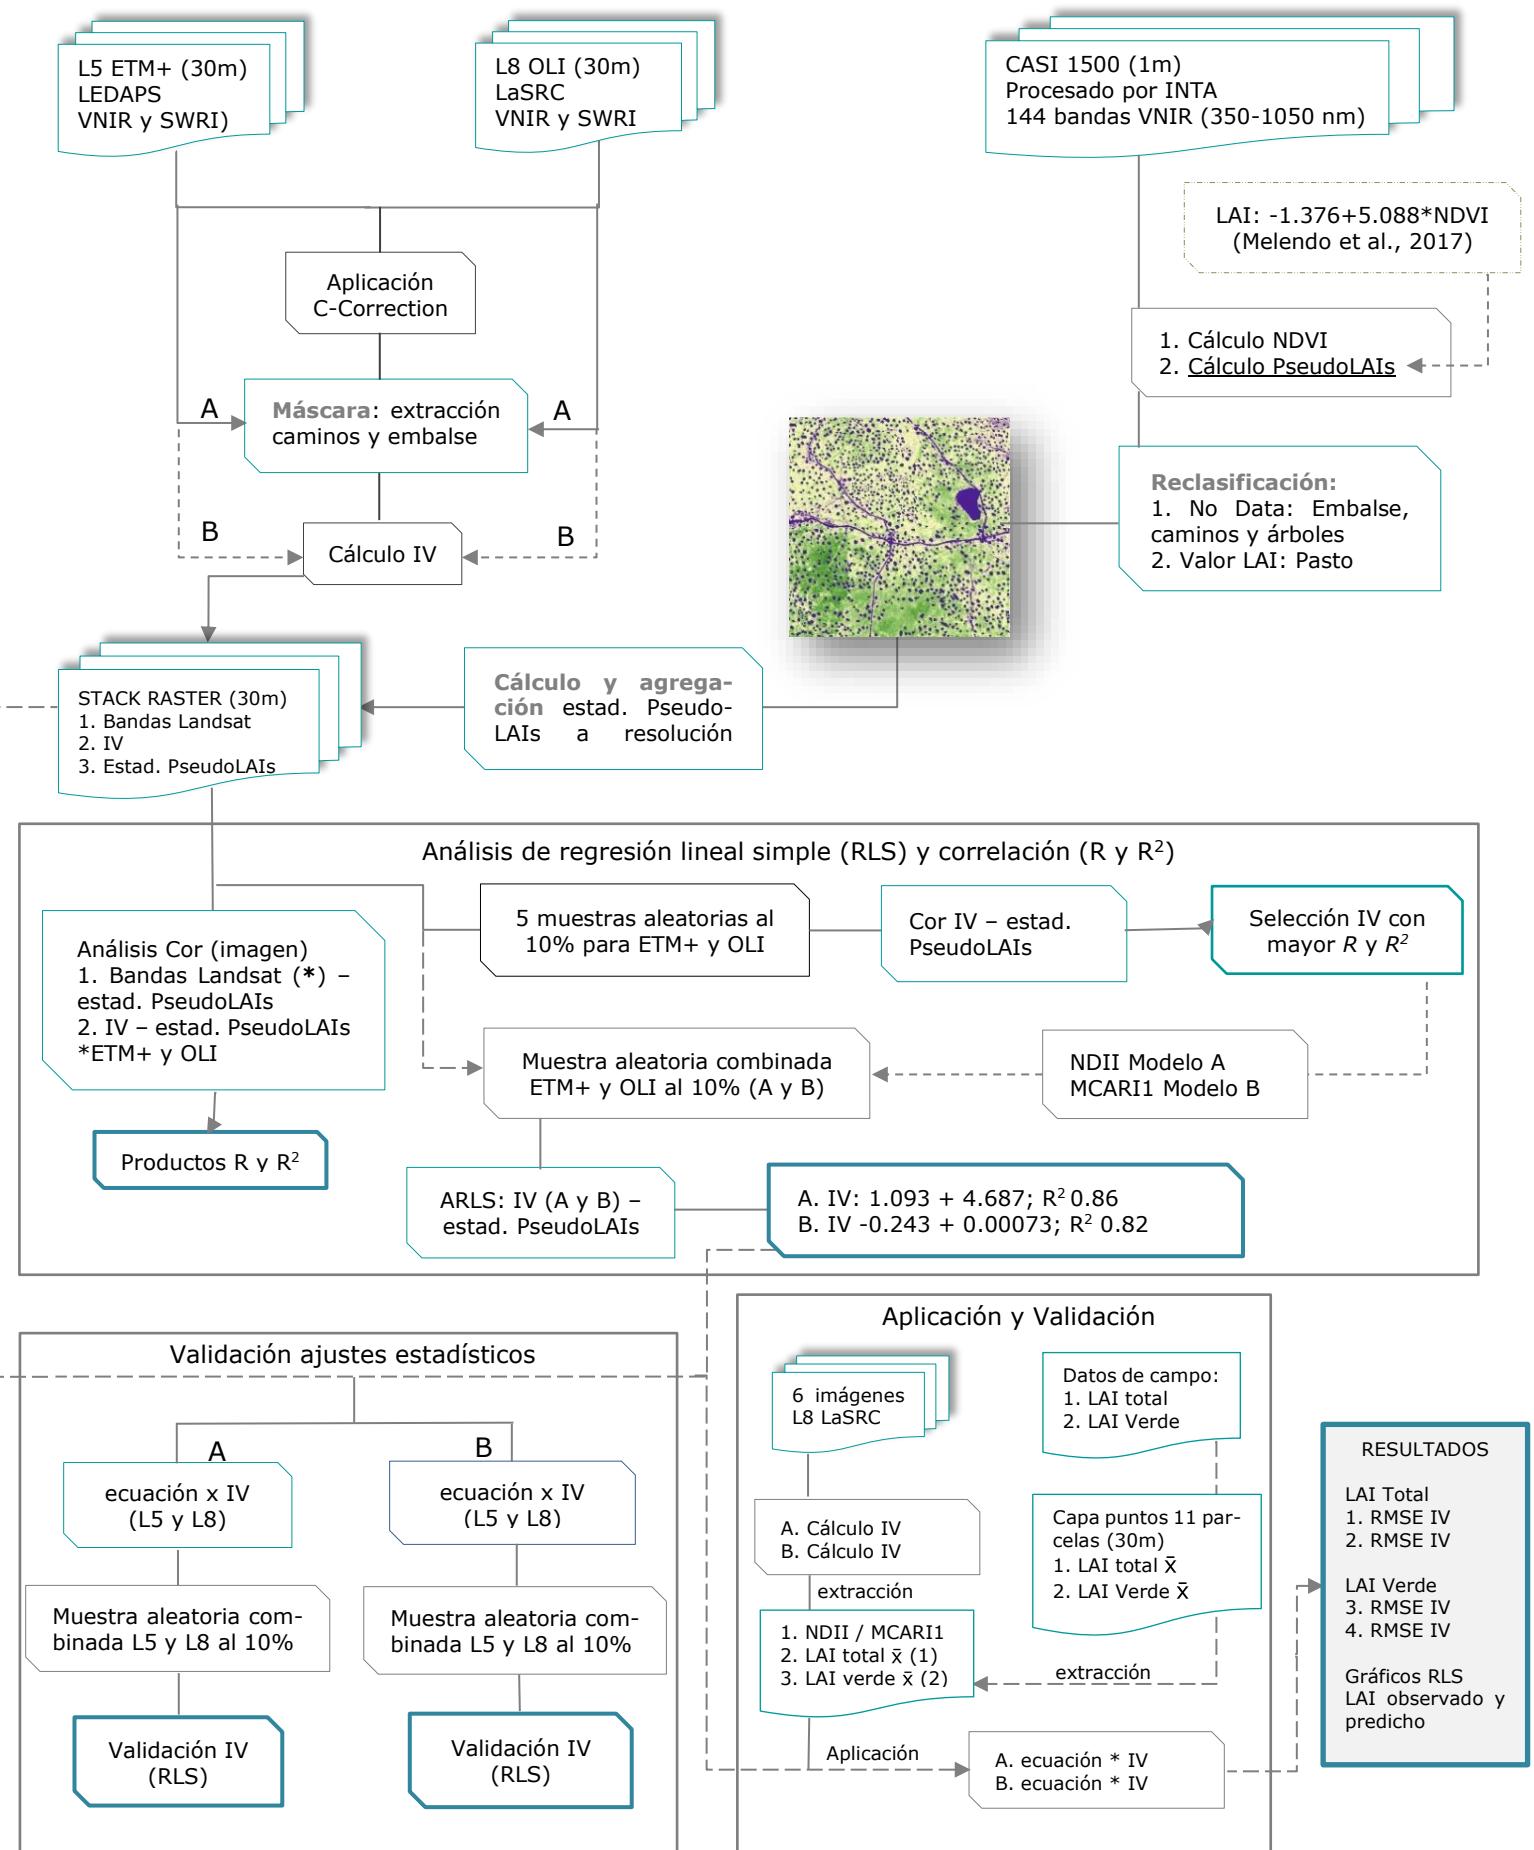


Figura 2. Esquema metodológico

3.3. Imágenes de satélite y preprocesamientos aplicados

Los datos utilizados para este estudio incluyen imágenes del sensor hiperespectral CASI 1500i e imágenes escaneadas por los satélites multiespectrales Landsat. El escaneo de las imágenes CASI que se registraron de forma simultánea a los muestreos de vegetación *in situ* tienen en cuenta el estado fenológico de pasto vigoroso, en desarrollo y desarrollado en primavera. Sin embargo, los datos de reflectividad Landsat no se pudieron tomar de forma simultánea a los datos CASI debido a la presencia de nubes sobre la zona de interés y por el grado de desfase temporal orbital entre la pasada Landsat y las campañas CASI. Por ello, se seleccionaron las imágenes Landsat más próximas a las fechas de las adquiridas por CASI. El programa europeo Copernicus a través de los sensores Sentinel 2A y Sentinel 2B fue descartado para realizar este trabajo puesto que solo existen datos desde junio de 2015.

3.3.1. Imágenes hiperespectrales

La información espectral se extrajo de imágenes obtenidas por el sensor hiperespectral aeroportado CASI 1500i (*Compact Airbone Spectrographic Imager*) en los vuelos realizados por el Instituto de Técnica Aeroespacial (INTA) los días 5 de mayo de 2011 y 8 de abril de 2014 sobre la zona de interés. Se trata de un radiómetro de barrido que genera una imagen mediante una matriz bidimensional de CCD que mide la energía incidente a lo largo de 1440 píxeles “*across-track*” con un tamaño de píxel de 0.90 x 1.58 m. Abarca un total de 288 bandas espectrales comprendidas entre la región del visible y el infrarrojo cercano (VNIR) del espectro electromagnético, 368-1052 μm .

Para este trabajo, las imágenes CASI fueron cedidas a una configuración para adquirir información en 144 bandas (350-1050 nm aprox.), con un ancho de banda (*Full Width at Half Maximum* – FWHM) de 7.5 μm y una resolución espacial que oscila entre 0.5 y 1.5 m. El FOV (*Field of View*) es de 400 y el IFOV (*Instantaneous Field of View*) de 0.49 mrad. En cada campaña se realizaron varias pasadas para cubrir completamente y con distintas geometrías de observación la zona de interés. Sin embargo, solo se dispuso de una imagen por fecha, adquiridas en torno a las 12:00 horas solares en condiciones de cielo descubierto y a una altura de vuelo de 2103 m. Respecto a la campaña de 2011 se dispuso de las pasadas correspondientes al plano solar para minimizar el efecto de sombreado, mientras que para la pasada de 2014 se modificó la configuración del vuelo y no se adquirió pasada en el plano solar. En su lugar, se utilizó la pasada con un rumbo de vuelo de 253°. (Bustamante *et al.* 2016; de Miguel *et al.* 2014).

Todas las imágenes CASI fueron proporcionadas con corrección atmosférica y geométrica mediante protocolos estandarizados del INTA. Concretamente a través del nivel de procesado L2b, tal y como se describe en de Miguel *et al.* (2014). La corrección atmosférica fue realizada con el software ATCOR4 (<http://www.rese.ch/products/atcor/atcor4/>) y fue refinada mediante el método de *Empirical Line Correction* empleando superficies de referencia medidas con el espectro-radiómetro ASD Fieldspec 3 simultáneamente a la adquisición de las imágenes (Melendo-Vega *et al.* 2017).

3.3.2. Imágenes multiespectrales

Con el propósito de generar productos LAI a resolución media (900 m²), se adquirieron gratuitamente imágenes de la misión Landsat a través del portal *U.S. Geological Survey (USGS)* (<http://earthexplorer.usgs.gov/>). Se usaron escenas Landsat libres de nubes correspondientes a los sensores multiespectrales TM (*Thematic Mapper*) de Landsat-5 de día 16 de mayo de 2011 y OLI (*Operational Land Imager*) de Landsat-8 de día 22 de abril de 2014.

Estos sensores describen una órbita heliosíncrona solar de 98. 2° a una altitud aproximada de registro de 705 km con un período de revista cada 16 días, aunque OLI se compensan entre sí cada 8 días. Además, la misión Landsat escanea la superficie terrestre en un campo de visión de 15° y cubre aproximadamente 185 km x 180 km definidos por un sistema de coordenadas de referencia mundial (WRS) de coordenadas de columnas por línea (paralelos) y columnas por filas (latitud paralela) (USGS, 2018; Roy *et al.* 2015).

El sensor *Thematic Mapper* posee un radiómetro de barrido multiespectral de tipo *whisk-broom*, detectan radiación filtrada espectralmente en 7 bandas entre el visible e infrarrojo, centradas entre 0.45 y 12.5 μm. Así mismo, TM y OLI se definen a una resolución de suelo de nadir de 30 metros, pero este último presenta características mejoradas de calibración y señal/ruido, una resolución radiométrica más alta de 12 bits frente los 8 bits de TM y un sistema de escaneo tipo *push-broom* situada a la misma órbita que TM (actualmente fuera de servicio) que le proporciona en comparación a los demás sensores Landsat registrar en 9 bandas más estrechas comprendidas entre el visible e infrarrojo, 0.435 y 2.294 μm (USGS, 2018) (Véase tabla 1).

Tabla 1. Características técnicas sensores Landsat-5 y 8. Fuente: USGS, 2018

| LANDSAT-5 Thematic Mapper | | | LANDSAT-8 OLI y TIRS | | |
|---------------------------|------------------------|----------------|----------------------|------------------------|----------------|
| Número de Bandas | Longitud de ondas (μm) | Resolución (m) | Número de Bandas | Longitud de ondas (μm) | Resolución (m) |
| Banda 1 - Azul | 0.45 - 0.52 | 30 | Banda 1 - Ultra azul | 0.435 - 0.451 | 30 |
| Banda 2 - Verde | 0.52 - 0.60 | 30 | Banda 2 - Azul | 0.452 - 0.512 | 30 |
| Banda 3 - Roja | 0.63 - 0.69 | 30 | Banda 3 - Verde | 0.533 - 0.590 | 30 |
| Banda 4 - NIR | 0.76 - 0.90 | 30 | Banda 4 - Roja | 0.636 - 0.673 | 30 |
| Banda 5 - SWIR-1 | 1.55 - 1.75 | 30 | Banda 5 - NIR | 0.851 - 0.879 | 30 |
| Banda 6 - Térmico | 10.4 - 12.5 | 120* (30) | Banda 6 - SWIR-1 | 1.566 - 1.651 | 30 |
| Banda 7 - SWIR-2 | 2.08 - 2.35 | 30 | Banda 7 - SWIR-2 | 2.107 - 2.294 | 30 |
| | | | Banda 8 - Pan | 0.503 - 0.676 | 15 |
| | | | Banda 9 - Cirrus | 1.363 - 1.384 | 30 |
| | | | Banda 10 - TIRS-1 | 10.6 - 11.19 | 100* (30) |
| | | | Banda 11 - TIRS-2 | 11.50 - 12.51 | 100* (30) |

Las imágenes proporcionadas por el USGS, nivel de procesamiento *Level-2*, incluyen corrección atmosférica y valores de reflectividad superficial en formato *GeoTiff (Geographic Tagged Image-File)*. Para las escenas TM, los valores de reflectancia son corregidos con el algoritmo *Landsat Ecosystem Disturbance Processing System (LEDAPS)*, mientras que para la escena OLI, la corrección atmosférica se basó en el algoritmo *Landsat Surface Reflectance Code (LaSRC)*, aprovechando

el mayor rendimiento radiométrico de las imágenes y la menor exposición de las bandas espectrales a la absorción atmosférica (USGS, 2018; Vermote *et al.* 2016). Se generó un multibanda para cada escena en formato de archivo *.img y se delimitaron acorde a la zona de estudio.

3.3.2.1. Normalización Topográfica C-Correction

En este trabajo se ha realizado la normalización topográfica *C-Correction* sobre las escenas Landsat en base a la metodología propuesta por Teillet *et al.* (1982), utilizando el software ERDAS Imagine® y su extensión de modelado *Spatial Modeler Editor*. Se trata de un modelo con un comportamiento de superficie anisotrópico que mejora el método del Coseno, de tipo lambertiano (Smith *et al.* 1980), ya que añade la constante empírica C para atenuar la sobre-corrección del método del coseno, simulando la contribución de la radiación difusa. Aunque este proceso no sea siempre necesario para zonas poco accidentadas (Chuvieco, 2015), el propósito del mismo, es comparar los resultados de la modelización de parámetros biofísicos de vegetación normalizados topográficamente con aquellos sin corrección, únicamente con corrección atmosférica, a través de las relaciones empíricas que se especifican más adelante.

Para empezar, el modelo incluye en su formulación el cómputo del coseno del ángulo de incidencia local o imagen de iluminación ($\cos \Theta_i$), de cada píxel de la escena a corregir. Para su cálculo, la imagen de iluminación precisa de la pendiente y orientación de la escena, por lo que se utilizó un MDE (Modelo Digital de Elevación) con un paso de malla de 25m proporcionado por el Instituto Geográfico Nacional, IGN. El MDT25 se descargó en formato *.asc y en ETRS89/UTM zona 31, siendo transformado a formato *.tiff y remuestreada a la resolución espacial de Landsat (30m). Así mismo, se consultaron los metadatos de las escenas Landsat para incluir los valores correspondientes al ángulo cenital solar (Θ_{sol}) y el ángulo azimutal solar (\varnothing_{sol}), se añadieron los valores de todos los ángulos expresados en radianes (0.01745 rad) y, posteriormente se aplicó la fórmula de la imagen de iluminación, que se calcula con la siguiente expresión:

$$IL = \cos \Theta_i = \cos \Theta_{sol} \cos \Theta_p + \sin \Theta_{sol} * \sin \Theta_p * \cos (\varnothing_{sol} - \varnothing_{ori})$$

donde $IL = \cos \Theta_i$ es el coseno de incidencia local; Θ_{sol} el ángulo cenital solar; Θ_p es el ángulo de la pendiente del terreno; \varnothing_{sol} es el ángulo acimutal solar y \varnothing_{ori} el ángulo de la orientación del terreno.

Consecutivamente, se aplicó la corrección del coseno (Teillet *et al.* 1982). Para ello, en el modelo se incluyeron las imágenes multibanda de Landsat y se transformó a radianes el coseno del ángulo cenital solar ($\cos \Theta_{sol}$). Se calcula como:

$$pH = pT (\cos \Theta_{sol} / IL)$$

donde pH es la reflectividad normalizada para una superficie horizontal y pT es la reflectividad de una superficie (reflectividad aparente superficial).

Para aminorar la sobre-corrección del método del coseno se añadió la constante empírica C_λ , donde el término b_λ es la constante y m_λ es la pendiente de la recta de regresión entre la reflectividad aparente (variable dependiente) y la imagen de iluminación (variable independiente). Además, la ecuación definida por la C_λ se basó en los píxeles correspondientes a pasto, por lo que se excluyeron del

proceso de corrección las demás cubiertas (lagos, encinares y caminos). Para ello, se rasterizó la capa vectorial, permitiendo seleccionar los píxeles definidos por pasto. Los cocientes de reflectividad calculados para cada banda Landsat se incluyeron en el modelo, cuyos valores comprenden un rango entre -1 y +1.

$$C_\lambda = b_\lambda / m_\lambda$$

Finalmente, se aplicó para el modelo el algoritmo de C-Correction, calculado como:

$$pH = pT (\cos \Theta_{sol} + C_\lambda / IL + C_\lambda)$$

3.3.2.2. Índices de Vegetación para la estimación del LAI

A partir de los valores de reflectividad de las bandas originales de Landsat-5 TM y Landsat-8 OLI se han calculado una serie de Índices de Vegetación. Se han seleccionado los mismos índices espectrales propuestos por Melendo-Vega *et al.* (2017) con el propósito de compararlos con su estudio, basado en índices multi-espectrales calculados con bandas remuestreadas al sensor MSI (Sentinel-2) e índices hiper-espectrales calculados con bandas CASI y ASD originales. Sin embargo, se han omitido aquellos índices que utilizan en su formulación bandas estrechas situadas en la región del *red-edge* (PRI, MCARI y TVI) y otros especializados para sensores hiperespectrales (CAI) que no permiten ser calculados para las bandas Landsat. Los IV han sido calculados en el software estadístico *Rstudio*, utilizándose para ello el paquete “raster”.

Los índices computados para TM y OLI se dividen en cuatro categorías en función de su formalismo y su adhesión a la misma familia (tabla 2) (Haboudane *et al.* 2004).

Tabla 2. Índices espectrales utilizados para la estimación del Índice de Área Foliar. Clasificación según Haboudane et al. 2003.

| Formulación para Landsat-5 (TM) y Landsat-8 (OLI) | | | |
|---|--|--|----------------------------|
| Índices | Landsat-5 TM | Landsat-8 OLI | Referencias |
| a) Índices basados en la diferencia normalizada: mejora de la linealidad | | | |
| NDVI | $\frac{B4-B3}{B4+B3}$ | $\frac{B5-B4}{B5+B4}$ | Rouse et al. 1974 |
| RDVI | $\frac{B4-B3}{\sqrt{B4+B3}}$ | $\frac{B5-B4}{\sqrt{B5+B4}}$ | Roujean y Breon, 1995 |
| MSR | $\frac{\left(\frac{B4}{B3}\right)-1}{\sqrt{\left(\frac{B4}{B3}+1\right)}}$ | $\frac{\left(\frac{B5}{B4}\right)-1}{\sqrt{\left(\frac{B5}{B4}+1\right)}}$ | Chen, 1996 |
| SRWI | $\frac{B4}{B5}$ | $\frac{B5}{B6}$ | Zarco-Tejada y Ustin, 2001 |
| NDII | $\frac{B4-B5}{B4+B5}$ | $\frac{B5-B6}{B5+B6}$ | Hardisky et al. 1983 |
| NDBLeaf | $\frac{B6-B5}{B6+B5}$ | $\frac{B7-B6}{B7+B6}$ | Le Maire et al. 2004 |
| b) Índices de vegetación suelo-línea: mejora la influencia del suelo y efectos atmosféricos | | | |
| SAVI | $\frac{(1+L)*(B4-B3)}{(B4+B3+L)}$ $L = 0.5$ | $\frac{(1+L)*(B5-B4)}{(B5+B4+L)}$ $L = 0.5$ | Huete, 1988 |
| MSAVI | $0.5 * [2 * B4 + 1 - \sqrt{(2 * B4 + 1)^2 - 8 * (B4 - B3)}]$ | $0.5 * [2 * B5 + 1 - \sqrt{(2 * B5 + 1)^2 - 8 * (B5 - B4)}]$ | Qi et al. 1994 |
| SARVI | $\frac{B4-B3-L*(B3-B1)}{B4-B3+L*(B3-B1)}$ $L = 0.5$ | $\frac{B5-B4-L*(B4-B2)}{B5-B4+L*(B4-B2)}$ $L = 0.5$ | Haboudane et al. 2004 |
| CVI | $\frac{B4*B3}{(B2)^2}$ | $\frac{B5*B4}{(B3)^2}$ | Datt et al. 2003 |
| CLGreen | $\frac{B4}{B2} - 1$ | $\frac{B5}{B3} - 1$ | Gitelson et al. 2005 |
| c) Índices de vegetación mejorados para estimar LAI verde | | | |
| MCARI1 | $1.2 * [2.5 * (B4 - B3) - 1.3 * (B4 - B1)]$ | $1.2 * [2.5 * (B5 - B4) - 1.3 * (B5 - B3)]$ | Haboudane et al. 2004 |
| MCARI2 | $\frac{1.5*[(B4-B3)-2.5(B3-B1)]}{\sqrt{(2*B4+1)^2-(6*B4-5\sqrt{B3})-0.5}}$ | $\frac{1.5*[(B5-B3)-2.5(B4-B3)]}{\sqrt{(2*B5+1)^2-(6*B5-5\sqrt{B4})-0.5}}$ | Haboudane et al. 2004 |
| MTVI1 | $1.2 * [1.2 * (B4 - B1) - 2.5 * (B3 - B1)]$ | $1.2 * [1.2 * (B5 - B3) - 2.5 * (B4 - B3)]$ | Haboudane et al. 2004 |
| MTVI2 | $\frac{1.5*[2.5*(B4-B1)-2.5(B3-B1)]}{\sqrt{(2*B4+1)^2-(6*B4-5\sqrt{B3})-0.5}}$ | $\frac{1.5*[2.5*(B5-B3)-2.5(B4-B3)]}{\sqrt{(2*B5+1)^2-(6*B5-5\sqrt{B4})-0.5}}$ | Haboudane et al. 2004 |
| d) Índices de vegetación atmosféricos | | | |
| EVI | $2.5 * \left(\frac{B4-B3}{B4+6*B3-7.5*B1} + 1 \right)$ | $2.5 * \left(\frac{B5-B4}{B5+6*B4-7.5*B2} + 1 \right)$ | Huete et al. 2002 |
| GVMI | $\frac{(B4+0.1)-(B5-0.002)}{(B4+0.1)+(B5-0.002)}$ | $\frac{(B5+0.1)-(B6-0.002)}{(B5+0.1)+(B6-0.002)}$ | Ceccato et al. 2002 |
| GEMI | $[\pi * (1 - 0.25 * \pi)] - \frac{B3-0.125}{1-B3}$ | $[\pi * (1 - 0.25 * \pi)] - \frac{B4-0.125}{1-B4}$ | Pinty y Versraete, 1992 |
| VARI | $\frac{B2 - B3}{B2 + B3 - B1}$ | $\frac{B3 - B4}{B3 + B4 - B2}$ | Gitelson et al. 2002 |

3.4. Método de ampliación de escala basado en pseudo-LAI

Debido a las numerosas incertidumbres asociadas, entre otras, a la comparación entre las mediciones de LAI in situ y la información proporcionada por sensores multiespectrales, el grado de ajuste empírico para predecir LAI disminuye considerablemente (Korhonen *et al.* 2017; Hufkens *et al.* 2008). Por este motivo, se propone un método basado en la ampliación de escala (upscaling) para evaluar la información proporcionada por Landsat con la variable biofísica LAI, a partir de remuestrear la cartografía del LAI (resolución 1m), obtenida mediante los procesos de modelización empírica previa entre el sensor hiper-espectral CASI y la toma de dato LAI medida en campo (Melendo-Vega *et al.* 2017). Se ha convenido en este trabajo que, el resultado de la modelización del LAI mediante imágenes hiperespectrales y su posterior ajuste a la resolución Landsat, se denomine pseudo-LAI, toda vez que no representa mediciones reales de LAI.

3.4.1. Cartografía de los valores continuos de pseudo-LAI a partir de CASI

Para el tratamiento de las imágenes CASI se ha utilizado el software ENVI versión 4.7 SP1®. A partir de las imágenes originales cedidas por el INTA, en formato *.hdr, se delimitó el área de estudio a través de un ROI (*Region of interest*). Consecutivamente, se calculó el NDVI utilizando la banda 65 (672.5 µm; roja) y la banda 92 (801.6 µm; NIR), para a continuación, aplicar la ecuación de regresión descrita en Melendo-Vega *et al.* (2017), siendo $x = 1.376$ e $y = 5.088$; el IV fue NDVI con un RMSE = 22.6 y $r^2 = 0.84$. Ello permitió obtener la cartografía de los pseudoLAI a resolución de 1m. Se transformaron las escenas pseudoLAI de *.adf a formato*.tiff para realizar una reclasificación en ArcGIS® versión 10.5, con la finalidad última de enmascarar aquellos píxeles que no fueran pasto (figura 3).

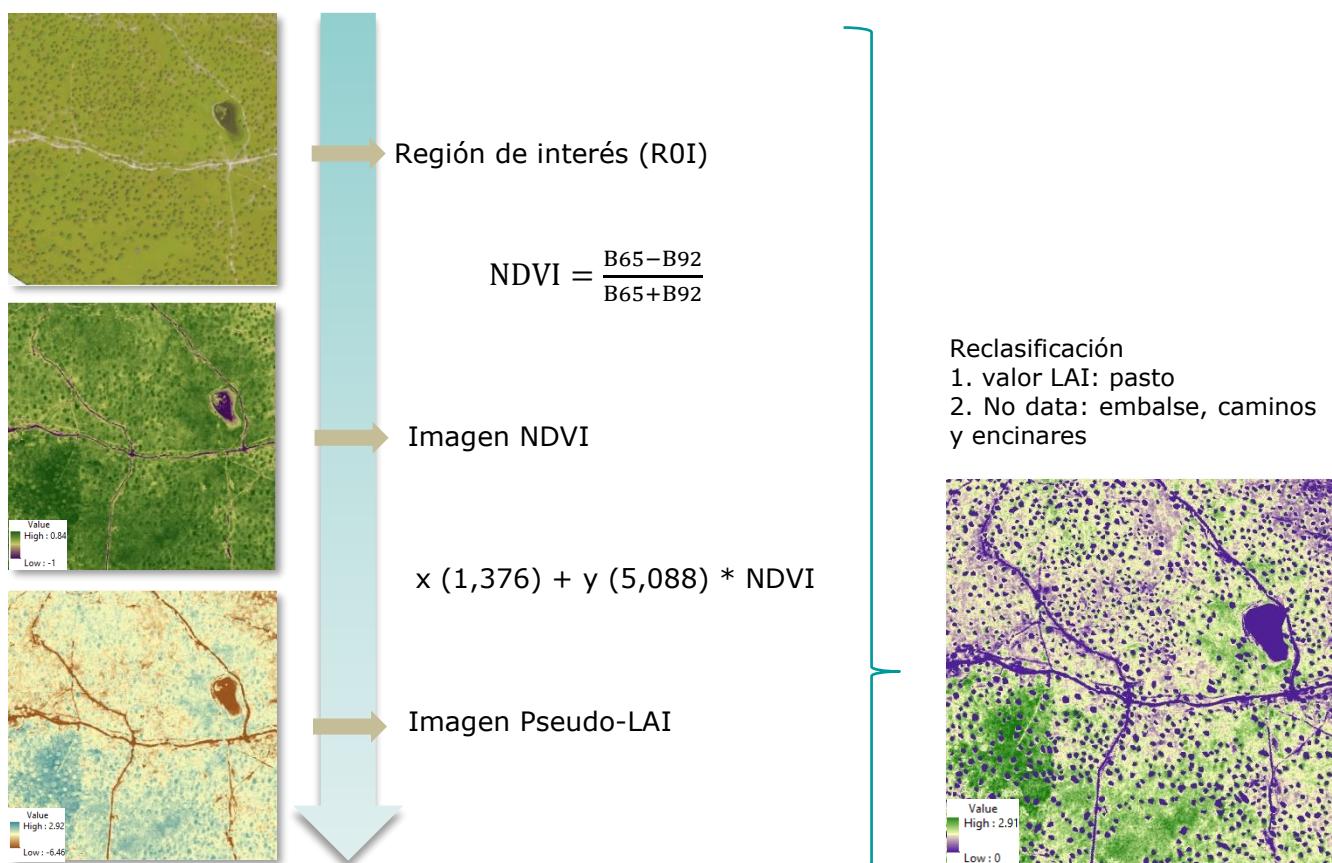


Figura 3. Proceso metodológico para obtener cartografía Pseudo-LAI

3.4.2. Fase de ampliación de escala (upscaling)

Se utilizó un método de ampliación de escala (upscaling) a través de *Rstudio* (paquete *raster*) para remuestrear la cartografía de pseudo-LAI obtenida mediante las imágenes hiperespectrales, a la resolución espacial de las imágenes Landsat-5 TM y Landsat-8 OLI (30m) (Véase figura 4). Para ello, los píxeles de pseudo-LAI (1m) se agregaron considerando diferentes estadísticos de centralidad y dispersión (media, mediana, valores mínimos y máximos y coeficiente de variación) (Figura 5). Entre otras cosas, su análisis permite identificar valores anómalos para que estos puedan ser omitidos (Chuvieco, 2015)

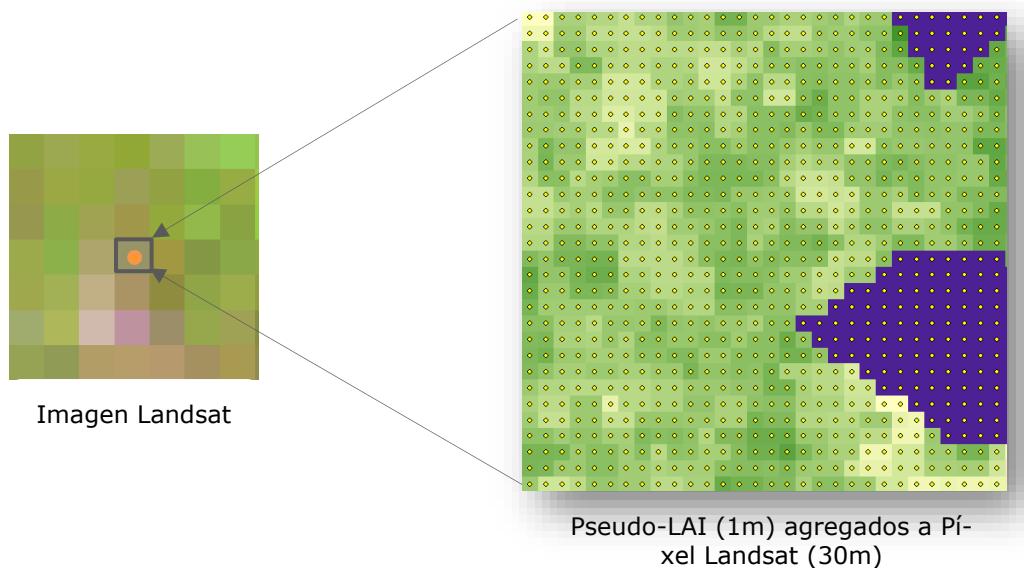


Figura 4. Ilustración de la técnica de ampliación de escala (upscaling)

Por otra parte, se evaluó la relación entre la dimensión del valor pseudo-LAI y la variabilidad de dicho parámetro biofísico de los píxeles de la imagen a través del coeficiente de variación de Pearson (CV). Para ello, primero se calculó la desviación estándar de ambas escenas, que se define como la variación de los valores pseudo-LAI con respecto a la media de dicha variable. El CV se calculó para cada escena a través de la siguiente expresión:

$$CV = \frac{\sigma}{[\bar{X} \text{ pseudoLAI}]}$$

donde σ es la desviación estándar, y la \bar{X} pseudo-LAI es la media de los valores LAI de la imagen.

Tal y como se muestra en la figura 5, los mayores valores del coeficiente de variación indican mayor heterogeneidad en los valores de pseudo-LAI debido a la presencia de coberturas que no representan pasto, tales como caminos y el embalse. En cambio, donde abunda el pasto, el coeficiente de variación presenta valores menores, determinando así una mayor homogeneidad en los valores pseudo-LAI. En este sentido, se establece que la presencia de coberturas que no representan pasto altera de forma significativa, sobre todo el embalse, los valores pseudo-LAI.

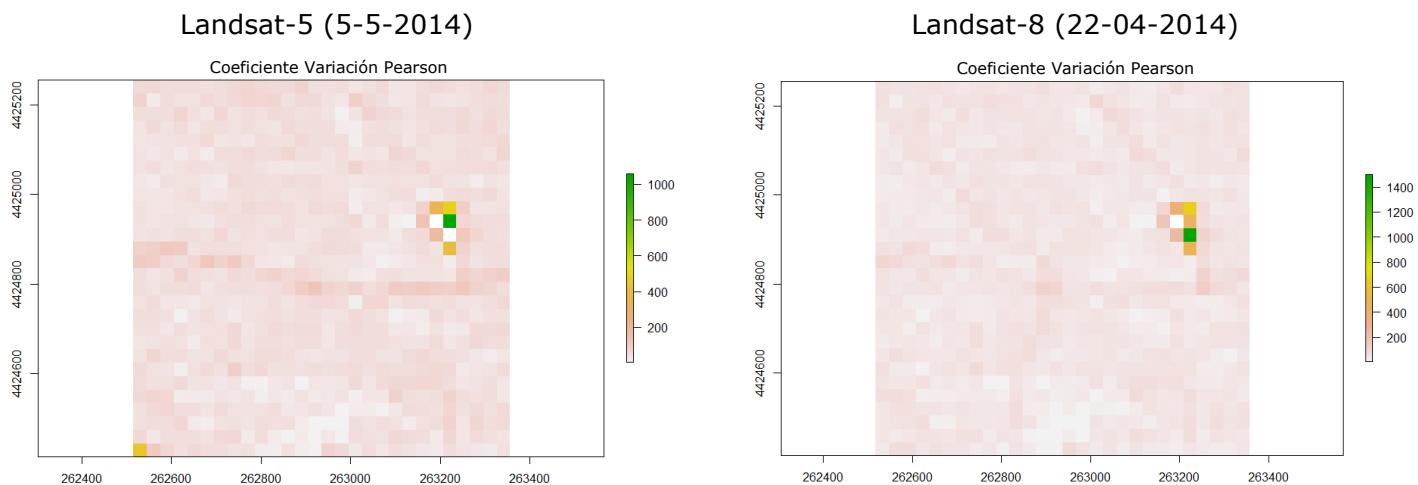


Figura 5. Cartografía estadística pseudo-LAI referente a los Coeficientes de Variación derivada de la fase de agregación.

En base a este análisis estadístico, se decidió realizar una máscara sobre las imágenes Landsat para eliminar del análisis todas aquellas cubiertas que no correspondieran a pasto, exceptuando los encinares. La no exclusión de encinares se debe principalmente a su alta densidad de ejemplares, por lo que su aplicación hubiera supuesto eliminar gran parte de los píxeles de las imágenes. Por tanto, para este trabajo, se ha considerado generar dos modelos para cada escena, uno que contempla todas las cubiertas y, por tanto, incluye todos los píxeles de la imagen (modelo A) y otro que excluye del análisis aquellos píxeles que representan láminas de agua y caminos (modelo B), incluyendo los píxeles cercanos a ellos.

3.5. Análisis de las relaciones empíricas entre pseudo-LAI y los índices espectrales de vegetación

En este apartado se evaluó el grado de variación conjunta existente entre los IV extraídos de la literatura científica (variables independientes) y estadísticos pseudo-LAI (variable dependiente) mediante un análisis de correlación simple (Pearson). El análisis se realizó para cada escena (TM y OLI). De forma paralela, se realizó un mismo análisis entre los valores de reflectividad de cada banda y estadísticos pseudo-LAI para ambos sensores (TM y OLI).

Este análisis de correlaciones permitió obtener para cada variable estimada los primeros resultados relacionados a los coeficientes de correlación de Pearson (valor r) y, coeficientes de determinación (valor r^2). En cada modelo, se evaluaron los resultados para poder obtener una primera aproximación de aquellos IV o bandas espectrales que más se ajustan linealmente a los estadísticos de pseudo-LAI. Los valores de los coeficientes varían des de -1 (correlación total negativa) a 1 (correlación total positiva). Los valores cercanos a cero implican escasa o nula correlación entre ambas variables. Dichos análisis se realizaron en *Rstudio*, utilizando el paquete “*corplot*”.

$$r_{xy} = \frac{\sum x_i y_i}{n S_x S_y}$$

donde x_i e y_i refiere a las diferencias de cada variable (IV y estadísticos LAI); n el número de la muestra; y S_x y S_y corresponde a las desviaciones típicas del IV y estadístico pseudo-LAI respectivamente.

A continuación, todos los IV fueron sometidos a una muestra aleatoria simple mediante la función *sample*, con un tamaño de la muestra establecida al 10% sobre el total de la escena (Modelo A 76 píxeles; Modelo B 46 píxeles). Pese a que esta técnica sacrifique píxeles de la muestra, cada uno de los píxeles que representan los valores de los IV tienen la misma posibilidad de ser elegidos, por lo que su ventaja principal radica en su poder de generalización.

Como resultado, se obtuvo para cada variable estimada los coeficientes de correlación r y r^2 y, en consecuencia, se seleccionaron aquellos IV que alcanzaron mayores coeficientes. (Figura 6).

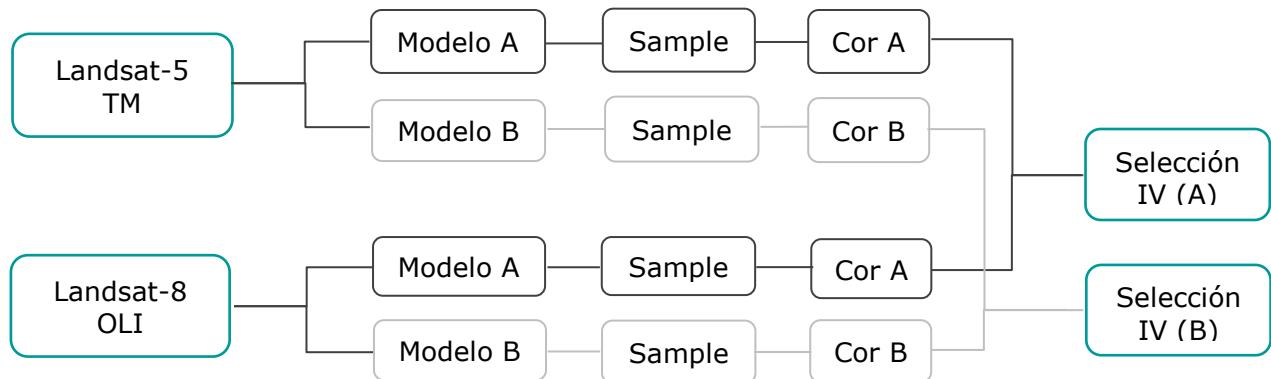


Figura 6. Proceso metodológico para seleccionar IV

3.6. Análisis RLS: funciones predictivas, validación de ajustes estadísticos

Una vez elegidos los IV para cada modelo, tanto los índices seleccionados como LAI fueron sometidos a otra muestra aleatoria establecida al 10% de manera combinada, es decir, utilizando ambos sensores. Para obtener un solo valor representativo de la variable dependiente pseudo-LAI y la independiente (IV), se aplicó sobre cada variable la media aritmética entre ambos sensores.

Tal y como apunta Cohen *et al.* (2003), en el caso lineal, el análisis de regresión simple (RLS) por mínimos cuadrados es un enfoque empírico que modela la relación entre dos variables observadas, siendo Y la variable dependiente pseudo-LAI mediana y, X , la variable independiente (IV). La expresión de regresión simple se describe como:

$$Y = \beta_0 + \beta_1 X + \varepsilon$$

donde Y es la variable a predecir, X es la variable de la que Y se predice, β_0 es la intersección, β_1 es la pendiente de la relación entre X e Y , y ε es el error.

En consecuencia, a través de la modelización estadística realizada sobre ambas variables se obtuvieron los coeficientes de determinación r^2 y las funciones predictivas para ambos modelos.

Con el análisis de regresión realizado, se aplicaron para cada modelo las ecuaciones predictivas realizadas en función de los IV seleccionados y pseudo-LAI. Estas funciones predictivas fueron aplicadas a las imágenes de los satélites TM y OLI en fechas del 16 de mayo de 2011 y 22 de abril de 2014, respectivamente. Tras la obtención del pseudo-LAI estimado se procedió a su validación realizando una

selección aleatoria del 10% de las escenas. A través de análisis de regresión simple y sus coeficientes de determinación se validó la forma y la fuerza de la relación entre valores observados y los predichos.

3.7. Fase de aplicación y validación

La validación de productos biofísicos derivados de sensores remotos es un requisito fundamental para garantizar la calidad y precisión de los productos empíricamente determinados. El método más eficaz para validar productos biofísicos derivados de sensores remotos es compararlos con mediciones tomadas en campo para las cuales existen protocolos de medición establecidos (Privette *et al.* 1998). Ante esta afirmación, en este trabajo se desarrolló un modelo para establecer de manera óptima relaciones empíricas entre datos correspondientes a las variables biofísicas LAI total y LAI verde (Green LAI) medidas en una dehesa con información óptica derivada de Landsat-8 OLI.

3.7.1. Muestreo en campo: LAI total y LAI verde

Según indican Melendo-Vega *et al.* (2017), los muestreos en campo se realizaron sobre un total de 11 parcelas de 25x25m localizadas en una dehesa extremeña. (figura 7).



Figura 7. Distribución de las parcelas de muestreo en el área de estudio.

Estas parcelas se distribuyeron de forma aleatoria de acuerdo al protocolo propuesto en el proyecto Biospec (<http://www.lineas.cchs.csic.es/biospec/>). En cada una de las once parcelas se realizaron muestras destructivas del pasto entre el 30 de octubre de 2013 y el 15 de junio de 2016 repartidas en 17 jornadas de muestreos en campo. En cada parcela se tomaron muestras de pasto sobre 3 cuadrantes de 25x25 cm localizados de forma semi-aleatoria. En los casos de que dentro de la parcela hubiera uno o más encinares, al menos uno de los cuadrantes de muestreo se localizó bajo el área de dominio de la copa del encinar, espacio donde suele

tener propiedades distintas debido al efecto del sombreado y el aporte de la materia seca muerta (Melendo-Vega *et al.* 2017).

El procesado de las muestras de pasto fue realizado por el equipo científico SynerTGE en un laboratorio adaptado para ello. El proceso empezó con la separación manual de una submuestra representativa de la muestra total. La cantidad de submuestra seleccionada varió en función del peso de la muestra total siendo en cualquier caso superior al 18% de la misma. Cada una de las submuestras fue escaneada (Epson Perfection V30 color scanner) con el objetivo de realizar el cálculo del área foliar del vegetal. Para ello, obtuvieron clasificaciones no supervisadas de las imágenes escaneadas utilizando el algoritmo ISOCLUS con 16 iteraciones utilizándose los softwares PCI y Matlab®. A continuación, las muestras de pasto pasaron por un proceso de secado a través de una estufa a 60°C durante un período de 48 horas, obteniéndose así su peso seco (Melendo-Vega *et al.* 2017). A continuación, calcularon las variables LAI total y LAI verde mediante las siguientes expresiones:

$$LAI \text{ verde} = \frac{W d * W d s v}{W d s * A s v}$$
$$W d s v * A_{plot}$$

donde W es el peso en cm; d refiere al peso seco; s significa la submuestra; v corresponde a la fracción verde; A es el área y A_{plot} es la superficie del suelo muestrada.

Para calcular el LAI total, anteriormente tuvieron que calcular LAI no verde (nv) a través de la siguiente expresión:

$$LAI \text{ no verde (nv)} = \frac{W d * W d s nv}{W d s * A s nv}$$
$$W d s nv * A_{plot}$$

Donde nv corresponde a la fracción no verde.

Por tanto, LAI total se define como:

$$LAI \text{ total} = LAI \text{ verde} + LAI \text{ no verde}$$

En este trabajo, las variables LAI tomadas en campo se les aplicó la media aritmética en hoja Excel sobre LAI total y LAI verde en relación a cada una de las once parcelas de muestreo y para sus distintos días de toma de datos en campo. De esta forma, se obtuvo el valor de LAI total y LAI verde como valores observados. A continuación, se vectorizaron ambas variables en distintos archivos *.shp mediante el software ArcGIS 10.5.

3.7.2. Imágenes Landsat-8 OLI para la validación del modelo de estimación de LAI

Se descargaron a través del portal USGS 5 imágenes escaneadas por el sensor OLI, a bordo de Landsat-8. La serie multitemporal y, libre de nubes, correspondieron a las fechas del 7 de marzo de 2014, 08 de mayo de 2014, 31 de octubre de 2014, 28 de junio de 2015 y 17 de junio de 2016. Las escenas se adquirieron con

el nivel de procesamiento *Level-2*, por lo que se adquirieron con corrección atmosférica a través del algoritmo *LEDAPS*. Para todas las escenas, se generó un multi-banda acorde a la región de interés, mientras que para ajustarse al modelo B se realizó una máscara para eliminar los píxeles situados sobre el embalse y caminos, así como sus píxeles vecinos.

Se excluyeron del análisis todas aquellas escenas con presencia de nubes sobre el área de estudio. Además, se tomó el criterio de no utilizar aquellas escenas con un desfase temporal mayor a 7 días entre el escaneo realizado por sensor OLI y las muestras realizadas en campo debido a las incertidumbres inherentes asociadas a condiciones meteorológicas o fenológicas sobre el pasto (Tabla 3). Así mismo, la escena solicitada el 16 de febrero de 2016 fue cancelada por parte del USGS. Aun así, las escenas utilizadas tienen en cuenta el estado fenológico del pasto, caracterizado por un significativo contraste entre un pasto vigoroso en desarrollo y desarrollado en primavera, y seco y carente de actividad fotosintética a final de verano (Melendo- Vega *et al.* 2017)

| | | | | | | | | | | | | | | | | | |
|-----------------------------------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|
| Aduisición escena | X | ✓ | X | X | ✓ | X | ✓ | X | X | X | ✓ | X | X | X | X | ✓ | |
| Solicitud cancelada | | | | | | | | | | | | ✓ | | | | | |
| Presencia de nubes | ✓ | | ✓ | | | ✓ | | ✓ | | | | | | | | | |
| Desfase días escaneo sensor-campo | >2 | | >5 | >7 | >0 | >0 | >0 | >1 | >7 | >7 | >7 | >4 | >7 | >7 | >7 | >7 | |
| Fechas muestras en campo | 30-oct-13 | 06-mar-14 | 26-mar-14 | 08-abr-14 | 08-may-14 | 09-jun-14 | 31-oct-14 | 19-feb-15 | 16-mar-15 | 23-abr-15 | 21-may-15 | 02-jul-15 | 10-nov-15 | 16-feb-16 | 01-abr-16 | 03-may-16 | 15-jun-16 |
| Estación climática | Oto | Inv | Pri | Pri | Pri | Pri | Oto | Inv | Inv | Pri | Pri | Ver | Oto | Inv | Pri | Pri | Pri |

Tabla 3. Factores que implican la selección de imágenes Landsat-8 OLI

3.7.3. Modelización estadística de LAI total y LAI verde a partir de Índices de Vegetación

Se testean las funciones predictivas realizadas utilizando las distintas escenas Landsat-8 OLI y las medidas de LAI en campo, para a continuación, evaluar las predicciones de LAI dadas por los índices con mayores coeficientes de r y r^2 .

Validación de modelos

Una vez obtenidos los valores predichos y observados para cada uno de los escenarios generados, se realizó un análisis de regresión simple para cada variable estimada y sujetas a sus distintos modelos, con el propósito de evaluar la relación lineal entre los valores predichos y observados. Los resultados se graficaron y se trataron mediante *Rstudio* a través del paquete “*ggplot2*”.

Para la validación se utilizó el error cuadrático medio (*Root-mean-square deviation*, RMSE). Éste es un estadístico destinado a medir el promedio de los errores

al cuadrado entre los valores predichos y observados y, es una expresión equivalente a la desviación típica en ausencia de sesgo, es decir, si el valor del error medio fuera cero. RMSE presenta errores en la misma unidad de medida que la muestra, donde cuánto más próximo sea su valor a 0 mejor será el producto obtenido. La expresión del error cuadrático medio de define como:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{Y}_i)^2}{n}}$$

donde y es el valor observado, \hat{Y} es el valor predicho, y n es el número total de observaciones.

4. RESULTADOS

4.1. Cartografía de los valores continuos de pseudo-LAI a partir de CASI

En base a la función de regresión utilizada por Melendo-Vega *et al.* (2017) y calculada a través del NDVI, se elaboró cartografía de pseudo-LAI a resolución de 1m para cada escena CASI centrada en la región de interés. Además, tal y como se ilustra en la figura 8, la reclasificación realizada permitió representar aquellos píxeles exclusivos a pasto y, al mismo tiempo, excluir aquellos píxeles representativos a láminas de agua, caminos y encinares. A simple vista, la escena CASI (5-5-2011) presenta valores de pseudo-LAI ligeramente superiores a la imagen CASI (8-4-2014). Entre esta diferencia, la cantidad de lluvia recibida por el dosel vegetal en las semanas previas al escaneo de las escenas CASI, podría haber marcado el vigor vegetal del pasto y, con ello, la dinámica fenológica (Chuvieco, 2015).

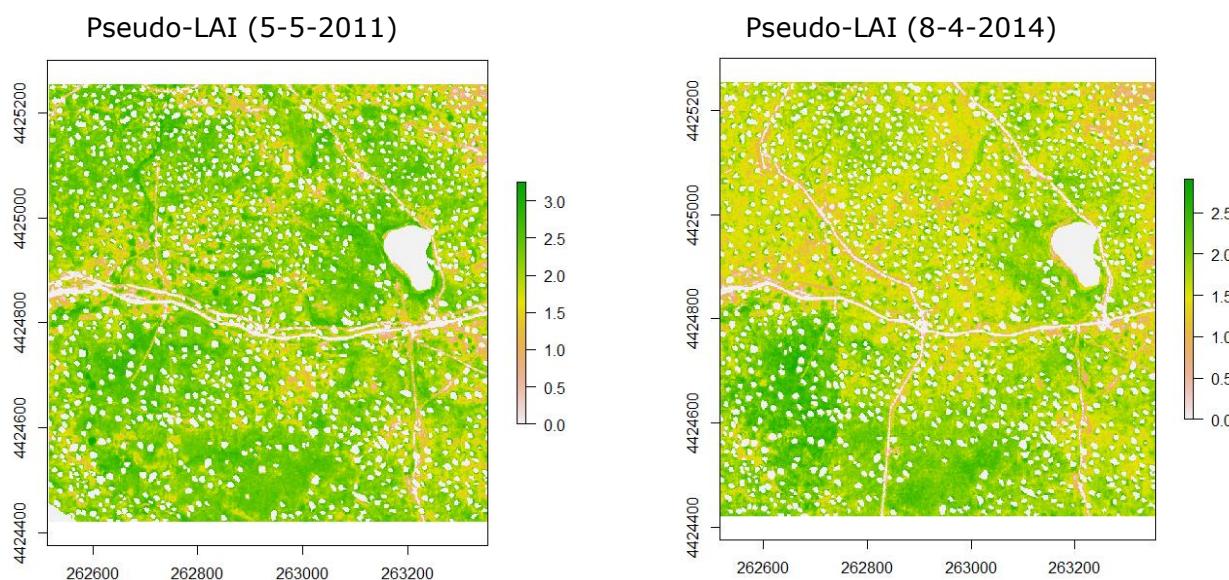


Figura 8. Cartografía pseudo-LAI

4.2. Magnitud y distribución espacial de los valores pseudo-LAI

Se aplicó la técnica de ampliación de escala en base a la cartografía pseudo-LAI y, con ello, se aplicaron estadísticos, para a continuación, ser agregados a resolución Landsat 30m. En la figura 9, se muestra la magnitud y distribución espacial de los valores pseudo-LAI representados por estadísticos de centralidad (media y mediana) y de dispersión (valores mínimos y máximos) a resolución Landsat 30m, en fechas del 5-5-2011 (Landsat-5) y 22-4-2014 (Landsat-8)

En cuanto a la media, en tales escenas se define por la suma de todos los valores pseudo-LAI por el número total de píxeles de la imagen. En este sentido, la magnitud de pseudo-LAI media establecida para la escena Landsat-5 es de 1.80, mientras que para la imagen Landsat-8 es ligeramente inferior, siendo de 1.42. La diferencia en relación a la magnitud de los valores pseudo-LAI media entre una y otra escena, está relacionada por la dinámica fenológica, es decir, el estado de vigor vegetal del pasto.

Por otro lado, se calculó la mediana como otro estadístico de centralidad que define el número de píxeles de pseudo-LAI cuando se clasifican en orden, siendo

de 2.13 para Landsat-5 y 1.65 para la Landsat-8. pseudo-LAI mediana se formuló para ambas escenas como:

$$Landsat5 = Me = L_i + \frac{\frac{784}{2} - F_{I-1}}{F_i} * a_I \quad (3.25) \quad Landsat8 = Me = L_i + \frac{\frac{784}{2} - F_{I-1}}{F_i} * a_I \quad (2.91)$$

Donde L_i es el límite inferior del valor pseudo-LAI donde se encuentra la mediana; $\frac{784}{2}$ es la semisuma de las frecuencias absolutas; F_{I-1} es la frecuencia acumulada anterior a LAI mediana y a_I es la amplitud de los valores pseudo-LAI.

Pese a que pseudo-LAI media y pseudo-LAI mediana desempeñen una función similar para analizar la tendencia central del conjunto de píxeles representativos a pseudo-LAI, pseudo-LAI media es más sensible a los valores extremos de los píxeles de la escena, es decir, se ve afectada por valores de píxeles separados que son mucho más altos o bajos que el resto de píxeles, como por ejemplo las láminas de agua, caminos, etc. En cambio, pseudo-LAI mediana representa un tanto mejor la realidad de la variable biofísica LAI, debido a que se afecta menos por la presencia de sesgos de los píxeles con valores extremos.

Los estadísticos de dispersión utilizados describen el grado de dispersión de los valores de los píxeles pseudo-LAI respecto a la medida de la tendencia central. En relación a la escena Landsat-5, los valores de pseudo-LAI presentan un rango de 3.25, mientras que, para Landsat-8 el rango es ligeramente inferior. Tal y como se ilustra en la figura 8, se aprecia como la heterogeneidad de cubiertas origina que existan muy pocos píxeles a resolución Landsat que representen exclusivamente pasto, en cambio, en relación a los valores máximos, se aprecia que el pasto está representado en la totalidad de los píxeles, a excepción de la laguna. En ambos casos, se da una distribución espacial de pseudo-LAI opuestamente homogéneos.

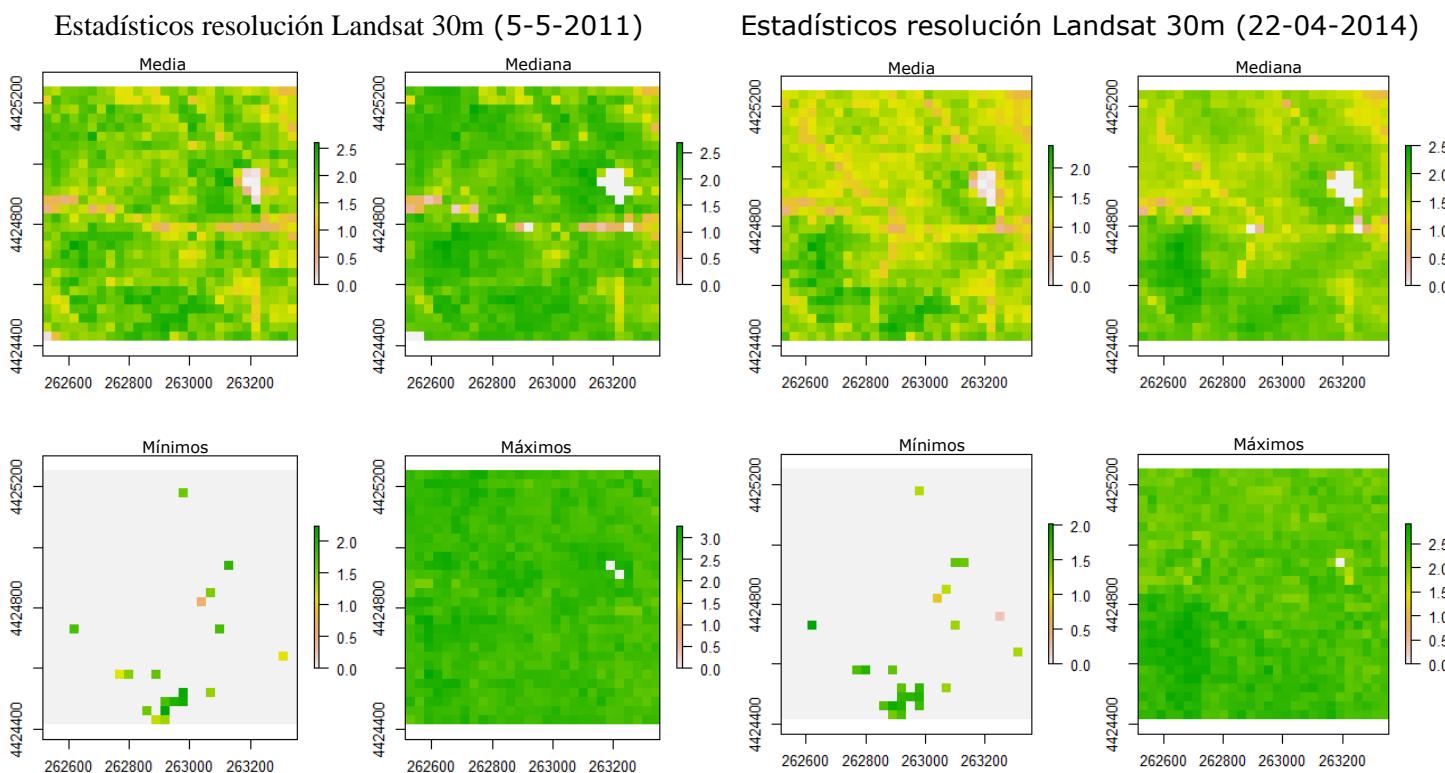


Figura 9. Cartografía pseudo-LAI (estadística) derivada de la ampliación de escala y fase de agregación a resolución Landsat (30m)

4.3. Análisis de las relaciones empíricas entre pseudo-LAI e índices espectrales de vegetación

El grado de ajuste lineal (r y r^2) entre los IV computados y los pseudo-LAI se presentan divididas en cuatro categorías en función de su formalismo y su adhesión a la misma familia (Haboudane *et al.* 2004), sea para sensor TM como para OLI y, sus modelos asociados. Además, se presentan los resultados procedentes de las muestras (*sample*) aleatorias para cada escena y modelo de manera simplificada y en formato tablas. Estos procesos permitieron seleccionar aquellos IV que obtuvieron un mayor grado de correlación.

Modelo A, Landsat-5 TM y Landsat-8 OLI

En cuanto a la imagen Landsat-5 TM, tal y como se muestra en la figura 10, se han obtenido mayores correlaciones (r y r^2) con aquellos IV especializados a estimar LAI verde. Por el contrario, Los IV atmosféricos muestran bajos grados de correlación. Además, los IV computados se relacionan linealmente mejor con el estadístico pseudo-LAI mediana en lugar de pseudo-LAI media para todos los casos, debido a que pseudo-LAI mediana se aproxima más a la realidad de pseudo-LAI medida en campo.

De manera individual y asociados al grado de ajuste con pseudo-LAI mediana, los IV con mayor grado de correlación son MCARI1 y MTVI1 con $r = 0.77$ y $r^2 = 0.59$ y, los IV MSAVI y MTVI2 con $r = 0.74$ y $r^2 = 0.54$. Por otro lado, GEMI y CVI obtuvieron bajos grados de correlación, mientras que, el IV NOBLeaf obtuvo un coeficiente de correlación negativa y de carácter moderada.

En relación a la escena Landsat-8 OLI, así como se observa en la figura 11, los resultados son semejantes a los obtenidos para la escena TM, afirmando que los mayores coeficientes responden a los IV especializados a estimar LAI verde. Sin embargo, los valores de los coeficientes de r y r^2 son un tanto mayor, encabezados por MCARI y MTVI1 con $r = 0.84$ y $r^2 = 0.71$ y CLGreen con $r = 0.82$ y $r^2 = 0.68$. Los índices espectrales que peores ajustes lineales presentaron fueron GEMI con $r = 0.29$ y $r^2 = 0.08$ y, CVI con $r = 0.47$ y $r^2 = 0.22$.

En cuanto a los ajustes lineales entre las bandas espectrales y los pseudo-LAI, como se ilustra en la figura anexada 26 la única banda espectral que muestra un grado de variación conjunta moderada con la variable dependiente pseudo-LAI corresponde a la banda NIR, con coeficientes (r y r^2) similares tanto para la escena TM como para OLI. Así mismo, a diferencia de los IV utilizados, las bandas espectrales se relacionan mejor con pseudo-LAI media en lugar de pseudo-LAI mediana, aunque de manera muy tímida.

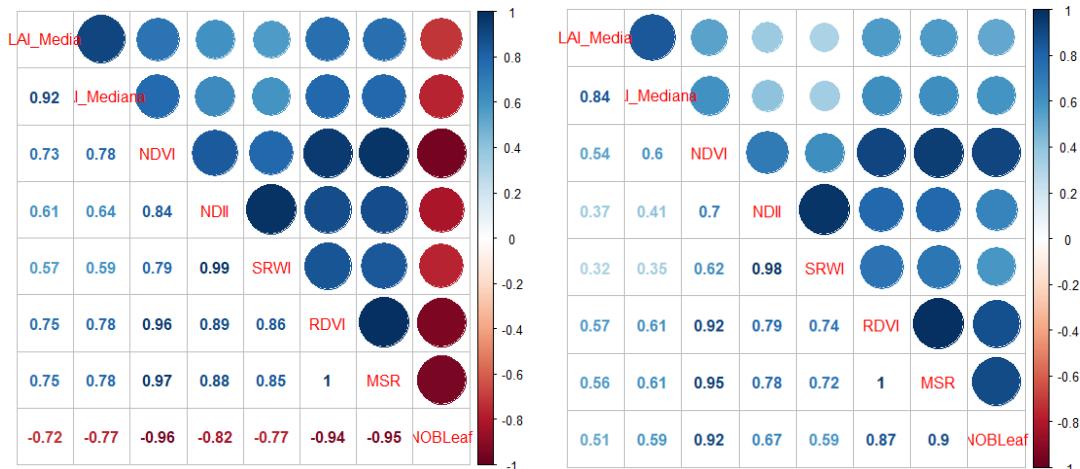
Por tanto, la banda NIR derivada del sensor OLI obtuvo coeficientes con respecto a pseudo-LAI media de $r = 0.69$ y $r^2 = 0.48$, mientras que la imagen TM obtuvo valores ligeramente inferiores, con $r = 0.53$ y $r^2 = 0.28$. En este sentido, es destacable remarcar que los coeficientes obtenidos para el NIR a través de OLI son equiparables a IV tales como SARVI, MCARI2, EVI y, mejores a NDII.



Figura 10. Análisis de Correlación de Pearson y Coeficientes de determinación para el Modelo A, sensor TM

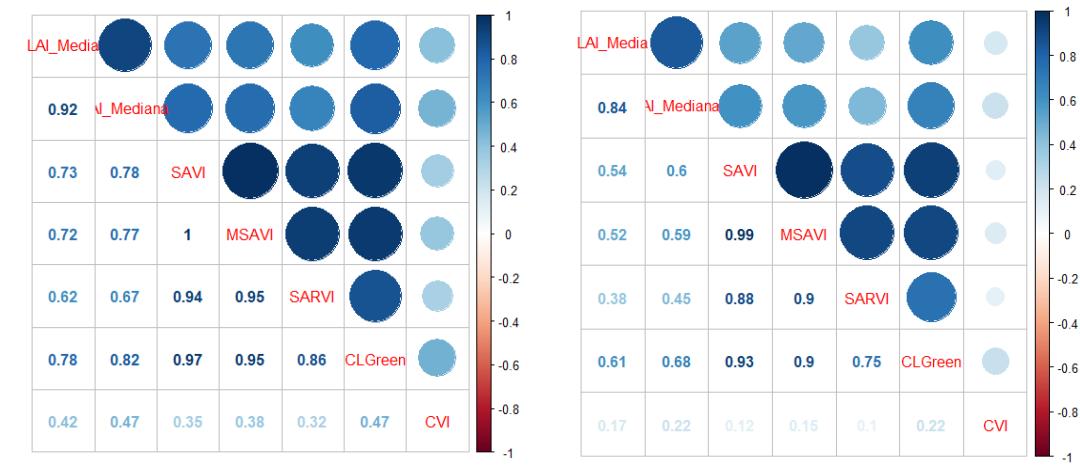
Coeficientes Correlación Pearson r

Índices basados en la diferencia normalizada: mejora de la linealidad

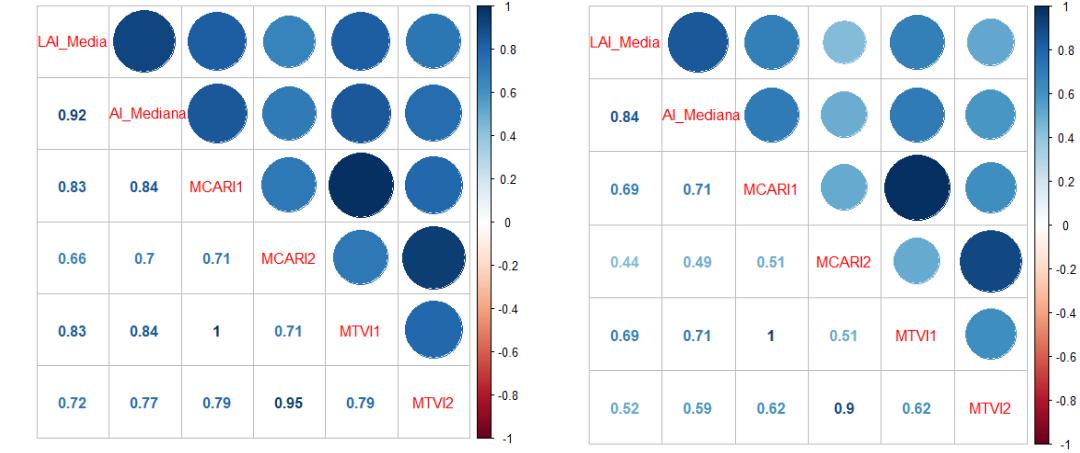


Coeficientes de determinación r^2

Índices de vegetación suelo-línea: mejor la influencia del suelo y los efectos atmosféricos.



Índices de vegetación mejorados para estimar LAI verde



Índices de vegetación atmosféricos

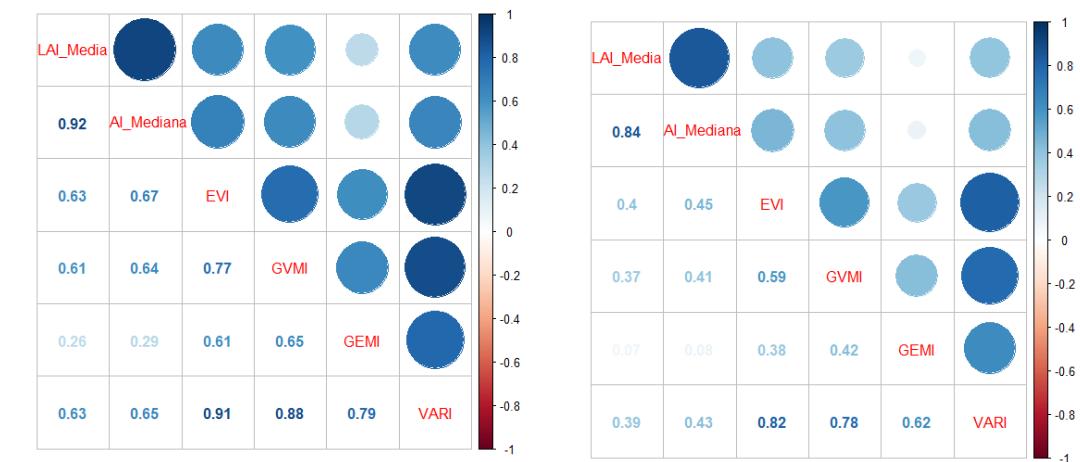


Figura 11. Análisis de Correlación de Pearson y Coeficientes de determinación para el Modelo A, sensor OLI

Modelo B, Landsat-5 TM y Landsat-8 OLI

En cuanto a la escena Landsat-8 TM, tal y como se muestra en la figura 12 se han obtenido mayores correlaciones (r y r^2) con aquellos IV basados en la diferencia normalizada y mejora de la linealidad, exceptuando el IV NDBLeaf, cuya correlación con los estadísticos pseudo-LAI sigue siendo al igual que ocurre en el modelo A, negativa y moderada. No obstante, el grupo de IV especializados a estimar LAI verde siguen teniendo altos grados de ajuste lineal con los estadísticos pseudo-LAI. En cambio, los IV que mejoran la influencia del suelo y los efectos atmosférico y, los IV atmosférico ofrecen las peores relaciones lineales con las variables dependientes pseudo-LAI, a excepción de GVMI, el cual obtuvo un alto grado de correlación.

Por tanto, los IV con mayores correlaciones con LAI mediana corresponden a NDII y GVMI con $r = 0.81$ y $r^2 = 0.69$ y, SRWI y MSAVI con $r = 0.8$ y $r^2 = 0.65$ y 0.64, respectivamente. Cerca de esos valores, se dispone de una batería de IV con altas correlaciones (NDVI; MSR; SAVI; MCARI1; MTVI1 y RDVI). En contrapartida, destacar el bajo rendimiento que ofrece el IV CVI, cuya asociación lineal con LAI es más bien baja.

Sin duda alguna, tal y como se ilustra en la figura 13, en general, todos los IV presentan altos grados de correlación con relación a los estadísticos pseudo-LAI, a excepción de EVI, GEMI y CVI. Así mismo, el IV NDBLeaf presenta, al igual que ocurre con la escena TM, un valor de asociación con pseudo-LAI de forma moderada y negativa.

Por grupos de IV, tanto los basados en la diferencia normalizada y mejora de la linealidad, como los especializados a estimar pseudo-LAI y los IV que mejoran la influencia del suelo, en general, ostentan correlaciones de valor r y r^2 muy altos, entre 0.88 y 0.91 y, 0.77 y 0.81, respectivamente. Sin embargo, destaca sobre los demás y al igual que ocurre con la escena TM, los IV NDII y GVMI, ambos con $r = 0.91$ y $r^2 = 0.83$ en relación con LAI mediana. Vuelve a destacar por su nula correlación con los estadísticos LAI, la variable independiente CVI.

En relación a la variación conjunta entre las bandas espectrales y los pseudo-LAI, se aprecia en la figura anexada 27, que la banda NIR es la única que presenta grados de correlación óptimos. Pese a ello, existen diferencias en cuanto a los valores de los coeficientes entre la escena TM y OLI, siendo para esta mayor a TM. Sin embargo, se observa que la banda NIR, como caso único en relación a las demás bandas TM Y OLI, se relaciona mejor con pseudo-LAI media en lugar de pseudo-LAI mediana.

Por tanto, la banda NIR derivada de TM ostenta un $r = 0.68$ y $r^2 = 0.46$ en relación a pseudo-LAI media y, mucho mayor para OLI, con $r = 0.85$ y $r^2 = 0.73$ en relación a pseudo-LAI mediana. Es destacable como la banda NIR derivada del sensor OLI, presenta coeficientes en relación a LAI mediana casi equiparables con aquellos IV que obtuvieron valores altos de correlación.

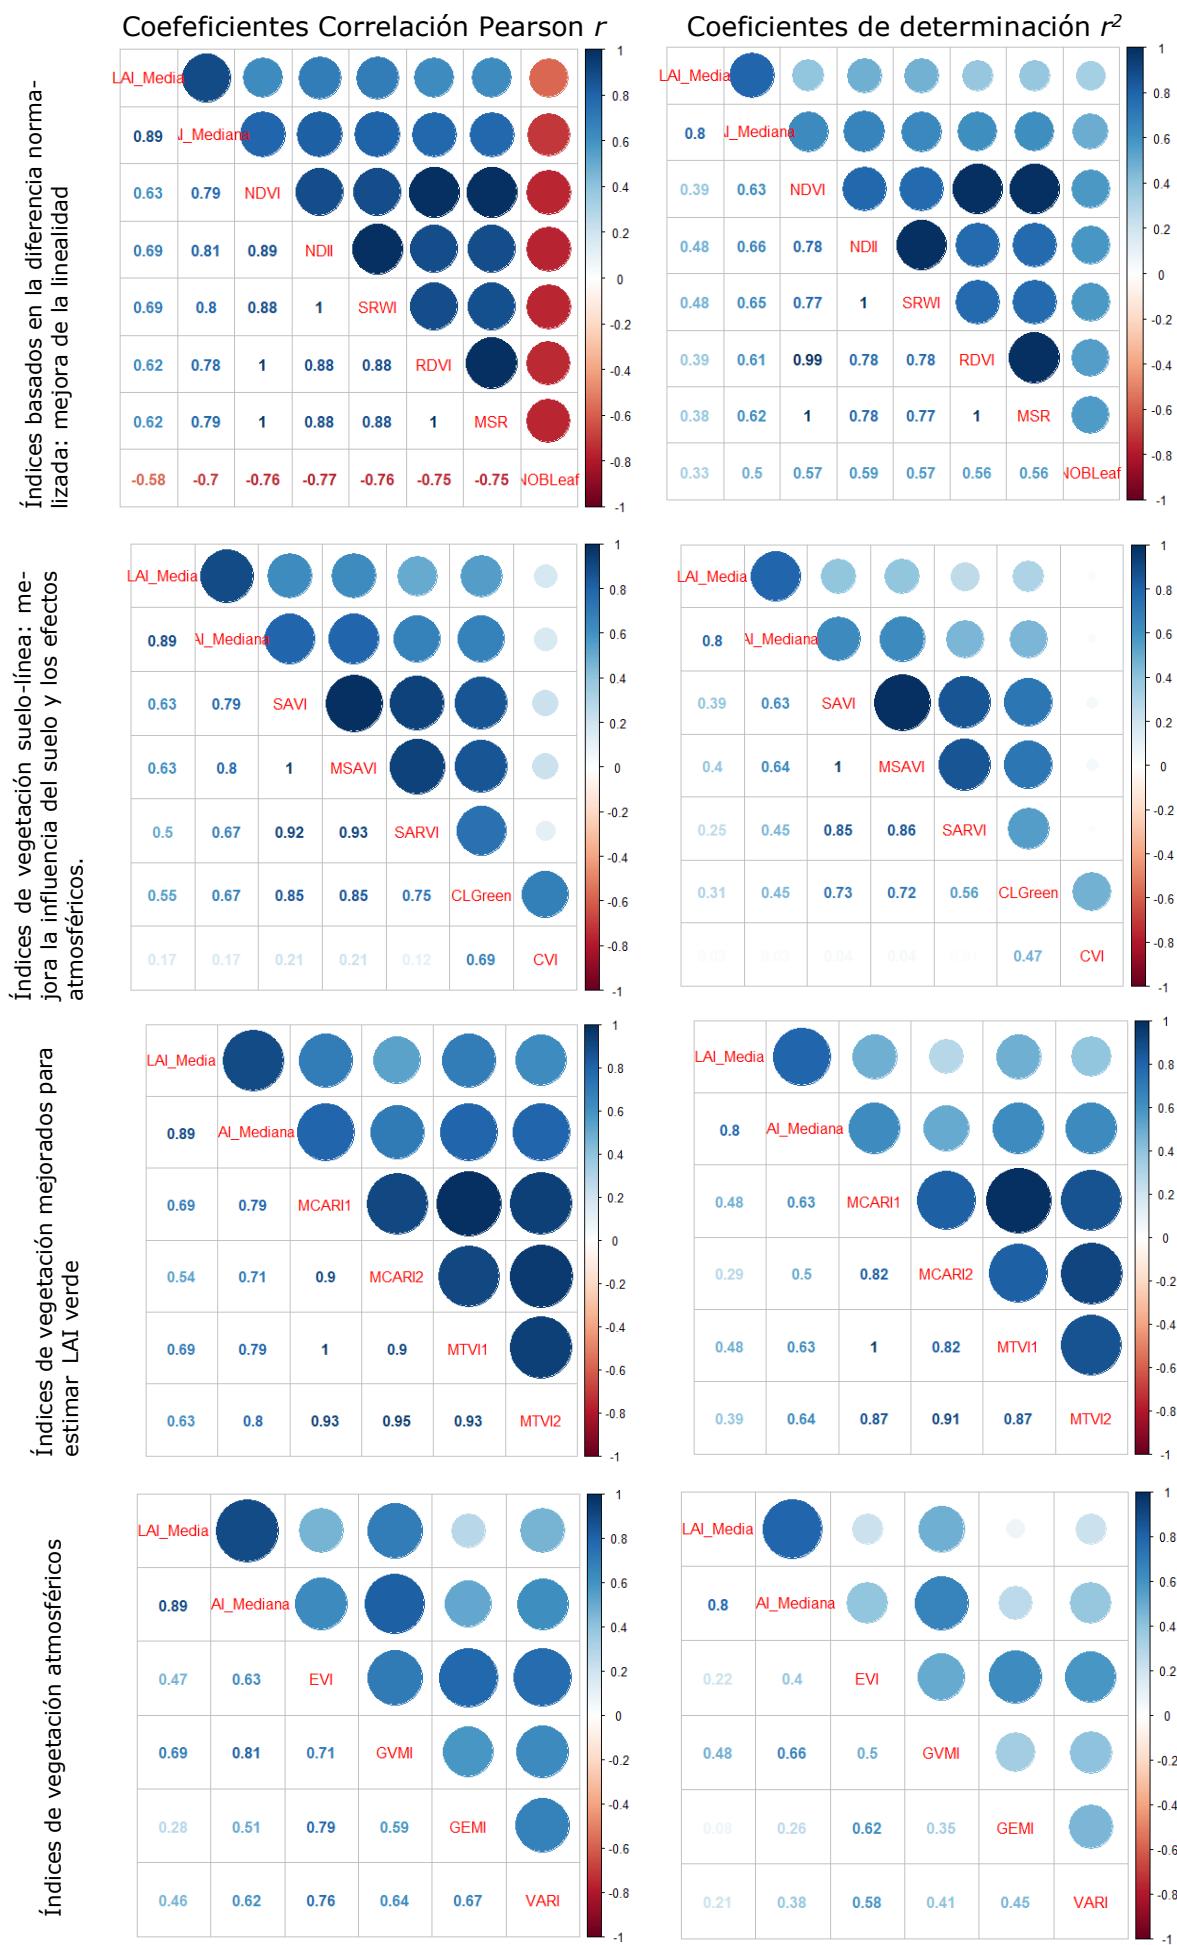


Figura 12. Análisis de Correlación de Pearson y Coeficientes de determinación para el Modelo B, sensor TM

Coeficientes Correlación Pearson r

Coeficientes de determinación r^2

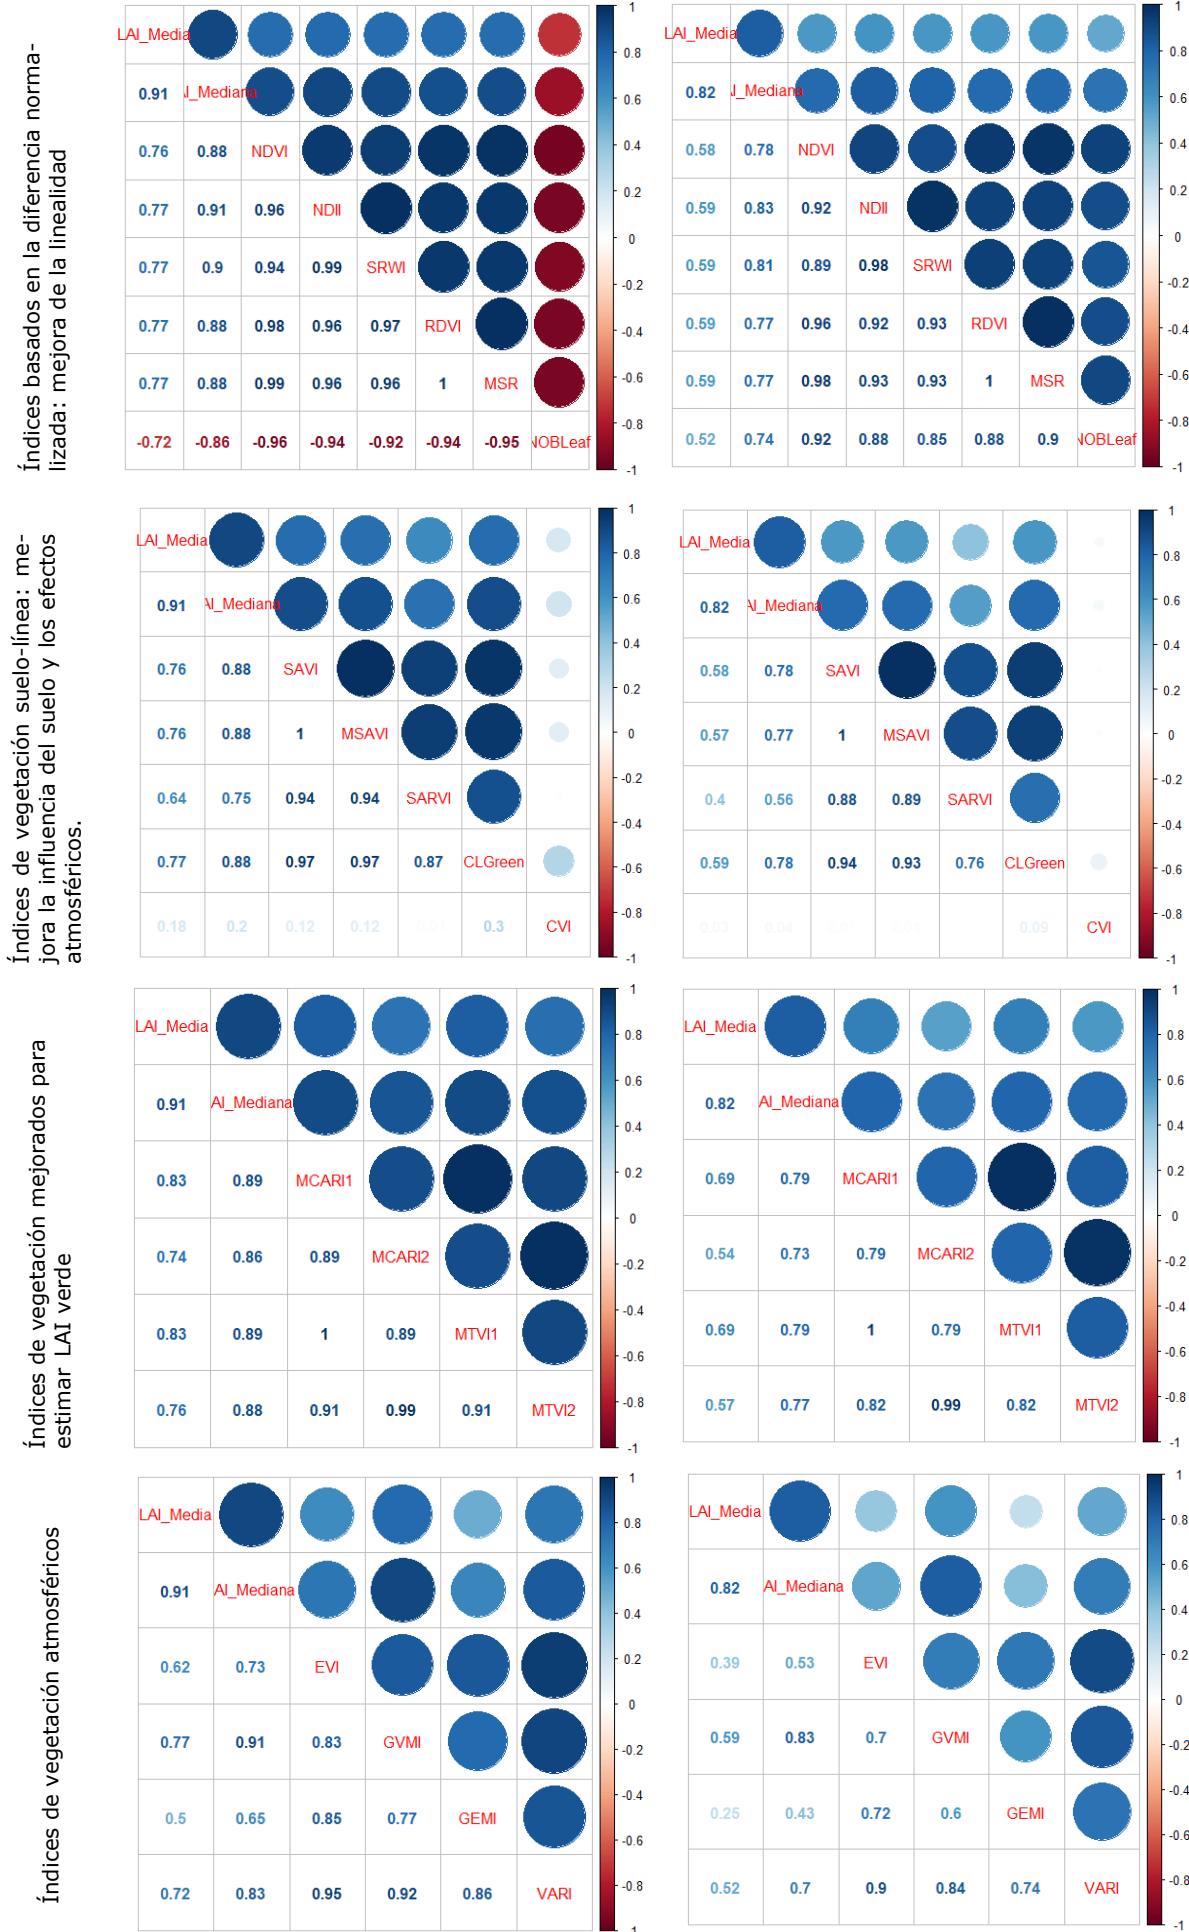


Figura 13. Análisis de Correlación de Pearson y Coeficientes de determinación para el Modelo B, sensor OLI

Muestras aleatorias y selección del IV, MODELO A

Una vez aplicadas las correlaciones para ambos modelos, se realizaron muestras aleatorias sobre cada escena asociada a cada modelo. En base a ello, los resultados fueron simplificados y plasmado en tablas con la finalidad de eliminar del análisis los índices con valores bajos de correlación y, a la vez, facilitar la interpretación sobre aquellos IV que obtuvieron las mayores correlaciones.

En relación al modelo A, la tabla 4 muestra los resultados derivados de las muestras aleatorias establecidas al 10% sobre las escenas TM y OLI. Para ambas escenas, los índices espectrales de vegetación con mayor grado de correlación con pseudo-LAI mediana corresponden a MCARI1 y MTVI1, ambos con $r = 0.81$ y $r^2 = 0.65$ para Landsat-5 y, del mismo modo, con $r = 0.88$ y $r^2 = 0.77$ para Landsat-8.

Sin embargo, resulta interesante como todos los IV seleccionados mejoran su rendimiento para predecir pseudo-LAI cuando utilizan información espectral derivada de Landsat-8 en lugar de Landsat-5. Por ejemplo, sobre esta idea destaca en relación a los demás, el IV CLGreen, donde este índice mejora substancialmente su rendimiento para predecir LAI cuando utiliza el sensor OLI, es decir, pasa de un $r = 0.73$ (Landsat-5) a un $r = 0.86$ (Landsat-8).

Tabla 4. Análisis de correlación (r y r^2) entre Pseudo-LAI vs IV en base a muestras aleatorias al 10% sobre las escenas TM y OLI. Modelo A. Representación simplificada de resultados.

| Índices de vegetación | Modelo A, Sensor TM (Landsat-5) | | Modelo A, Sensor OLI (Landsat-8) | |
|-----------------------|---------------------------------|-------------|----------------------------------|-------------|
| | LAI mediana | LAI mediana | LAI mediana | LAI mediana |
| | r | r^2 | r | r^2 |
| MCARI1 | 0,81 | 0,65 | 0,88 | 0,77 |
| MTVI1 | 0,81 | 0,65 | 0,88 | 0,77 |
| MTVI2 | 0,75 | 0,56 | 0,8 | 0,65 |
| MSAVI | 0,75 | 0,56 | 0,8 | 0,66 |
| NDVI | 0,74 | 0,56 | 0,81 | 0,66 |
| SAVI | 0,74 | 0,56 | 0,81 | 0,66 |
| RDVI | 0,73 | 0,54 | 0,81 | 0,66 |
| MSR | 0,73 | 0,54 | 0,81 | 0,66 |
| CLGreen | 0,73 | 0,53 | 0,86 | 0,74 |
| NDII | 0,41 | 0,22 | 0,5 | 0,36 |

En consecuencia, en función a los mayores grados de correlación obtenidos, se selecciona el IV MCARI1 para el posterior análisis de regresión lineal simple. Así mismo, se afirma que para este modelo en la que participan todos los píxeles de la escena y, por tanto, todas las cubiertas (embalse, caminos, encinares y pasto), los IV con mayor correlación con pseudo-LAI mediana corresponden a los destinados a estimar LAI verde.

Muestras aleatorias y selección del IV, MODELO B

En cuanto al modelo B, las mayores correlaciones derivadas de las muestras aleatorias sobre cubiertas exclusivas de pasto y encinares corresponden a los índices de vegetación NDII y GVMI (tabla 5). En concreto, para la escena TM, ambos IV obtuvieron un $r = 0.81$ y $r^2 = 0.65$, mientras que para Landsat-8, todos los IV de vegetación mejoraron substancialmente su grado de variación conjunta con la variable dependiente pseudo-LAI. De manera análoga a TM, los índices espectrales con mayor grado de asociación con LAI corresponden a las variables independientes NDII y GVMI, ambos con un $r = 0.92$ y $r^2 = 0.85$.

No obstante, es destacable como los IV MCARI1, MTVI1, MTVI2 y MSAVI ofrecen muy buenas prestaciones para predecir pseudo-LAI en ambo modelos. En cambio, NDII y GVMI ostentan los mayores valores de reflectividad, aunque reducen su fiabilidad cuando se trata de estimar pseudo-LAI a través de Landsat-5.

Tabla 5. Análisis de correlación (r y r^2) entre pseudo-LAI vs IV en base a muestras aleatorias al 10% sobre las escenas TM y OLI. Modelo B. Representación simplificada de resultados.

| Índices de vegetación | Modelo B, Sensor TM (Landsat-5) | | Modelo B, Sensor OLI (Landsat-8) | |
|-----------------------|---------------------------------|-------------|----------------------------------|-------------|
| | LAI mediana | LAI mediana | LAI mediana | LAI mediana |
| | r | r^2 | r | r^2 |
| NDII | 0,81 | 0,65 | 0,92 | 0,85 |
| GVMI | 0,81 | 0,65 | 0,92 | 0,85 |
| SRWI | 0,8 | 0,64 | 0,91 | 0,83 |
| MCARI1 | 0,78 | 0,61 | 0,89 | 0,79 |
| MTVI1 | 0,78 | 0,61 | 0,89 | 0,79 |
| MTVI2 | 0,78 | 0,61 | 0,88 | 0,78 |
| NDVI | 0,77 | 0,59 | 0,89 | 0,79 |
| SAVI | 0,77 | 0,59 | 0,89 | 0,79 |
| MSAVI | 0,77 | 0,59 | 0,88 | 0,78 |
| MSR | 0,76 | 0,58 | 0,88 | 0,78 |
| RDVI | 0,76 | 0,58 | 0,88 | 0,78 |

En base a los resultados obtenidos, se selecciona el NDII como aquel IV que ha obtenido el mayor grado de correlación en relación a los demás con pseudo-LAI mediana, por lo que será el IV utilizado para realizar el posterior análisis RLS. Estos análisis demuestran que los IV formulados sobre píxeles situados sobre pasto y relacionados empíricamente con pseudo-LAI mediana, ha originado que estos IV ostenten mayores grados de variación conjunta con la variable dependiente pseudo-LAI en relación a los demás modelos.

4.4. Análisis RLS: funciones predictivas

En base a los análisis de correlación realizados anteriormente se han seleccionado aquellos IV con mayor grado de variación conjunta con pseudo-LAI mediana, siendo MCARI1 (modelo A) y NDII (modelo B). Para cada modelo, la relación empírica entre pseudo-LAI mediana y los IV seleccionados se determinaron a partir de datos obtenidos en base a un muestreo aleatorio simple de forma combinada establecida al 10% sobre ambos sensores (TM y OLI).

A partir de los análisis de regresión lineal simple se obtuvieron las ecuaciones predictivas para cada modelo, responden a las siguientes expresiones y, con ellas se mide la bondad del ajuste de la recta a los datos a partir del coeficiente de determinación:

Modelo A

MCARI1: pseudo-LAI mediana = $-0.2432 + 0.0007304$, con un r^2 0.842

Modelo B

NDII: pseudo-LAI mediana = $1.093 + 4.687$, con un r^2 0.8501

Por tanto, tal y como se muestra en la figura 16, ambos modelos son estadísticamente significativos debido a que se observa una distribución, en general, bastante uniforme entre la variable dependiente (pseudo-LAI mediana) y las independientes (MCARI1 y NDII). Es interesante observar, que el modelo A contiene valores que representan píxeles con rangos de valores de MCARI1 infraestimados, por lo que la predicción individual de ese píxel queda fuera del rango de valores observados. Ello se debe, básicamente, a que la muestra aleatoria seleccionó píxeles que representan cubiertas ajenas al pasto, como el embalse o los caminos. Dada esa incertidumbre añadida, se hace patente que este modelo ofrece un menor rendimiento en cuanto al grado de variación conjunta entre ambas variables.

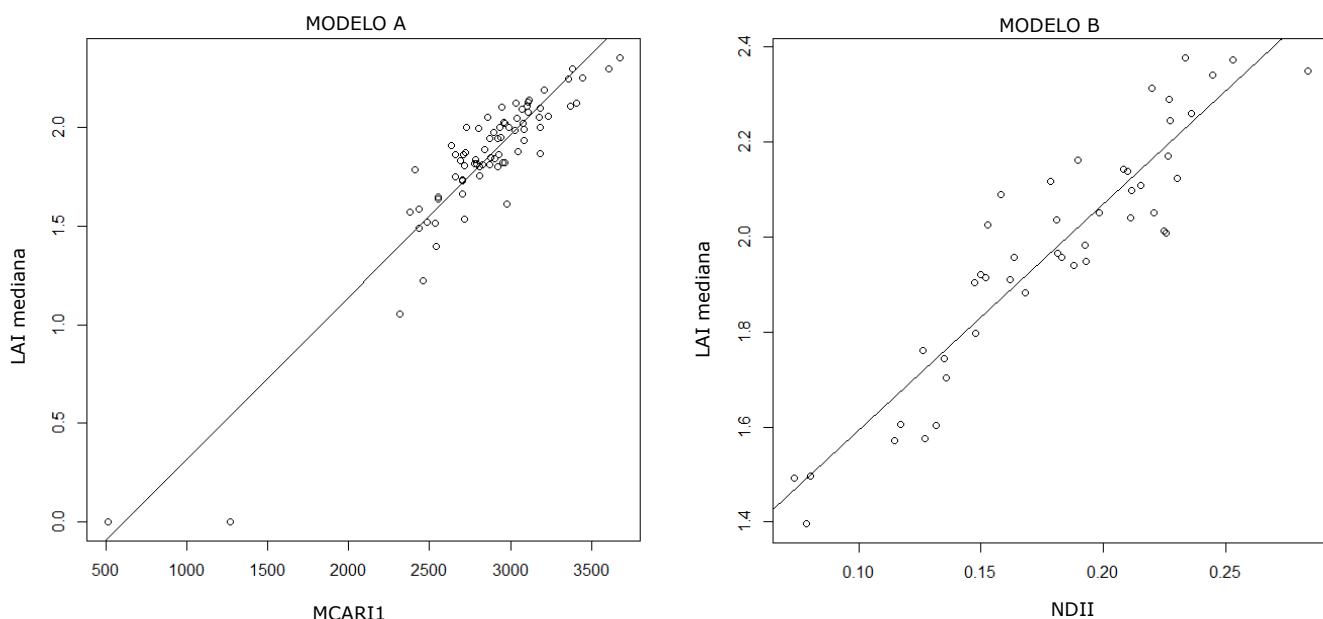


Figura 14. Relaciones empíricas entre pseudo-LAI mediana y los índices predictores seleccionados a partir TM y OLI

4.5. Validación de los ajustes estadísticos

Se aplicaron las funciones predictivas para ambos modelos con el propósito de modelizar las variables predictoras en base a los IV seleccionados y los valores pseudo-LAI. Las funciones predictivas se describen de la siguiente forma:

Modelo A

MCARI1: pseudo-LAI mediana = $-0.2432 + 0.0007304 * \text{MCARI1 (TM)}$

MCARI1: pseudo-LAI mediana = $-0.2432 + 0.0007304 * \text{MCARI1 (OLI)}$

Modelo B

NDII: pseudo-LAI mediana = $1.093 + 4.687 * \text{NDII (TM)}$

NDII: pseudo-LAI mediana = $1.093 + 4.687 * \text{NDII (OLI)}$

El análisis de regresión lineal simple demostró que ambos modelos generados son estadísticamente satisfactorios, debido a sus altos grados de asociación entre los valores predichos y los observados (figura 17). Pese a eso, el coeficiente de determinación varía entre ambos modelos desarrollados sobre una dehesa, siendo menor para MCARI1 ($r^2 = 0.77$). Por tanto, es de destacar que la dispersión entre los valores observados y los predichos a través de NDII, presentan un ajuste lineal casi perfecto, con un $r^2 = 0.93$.

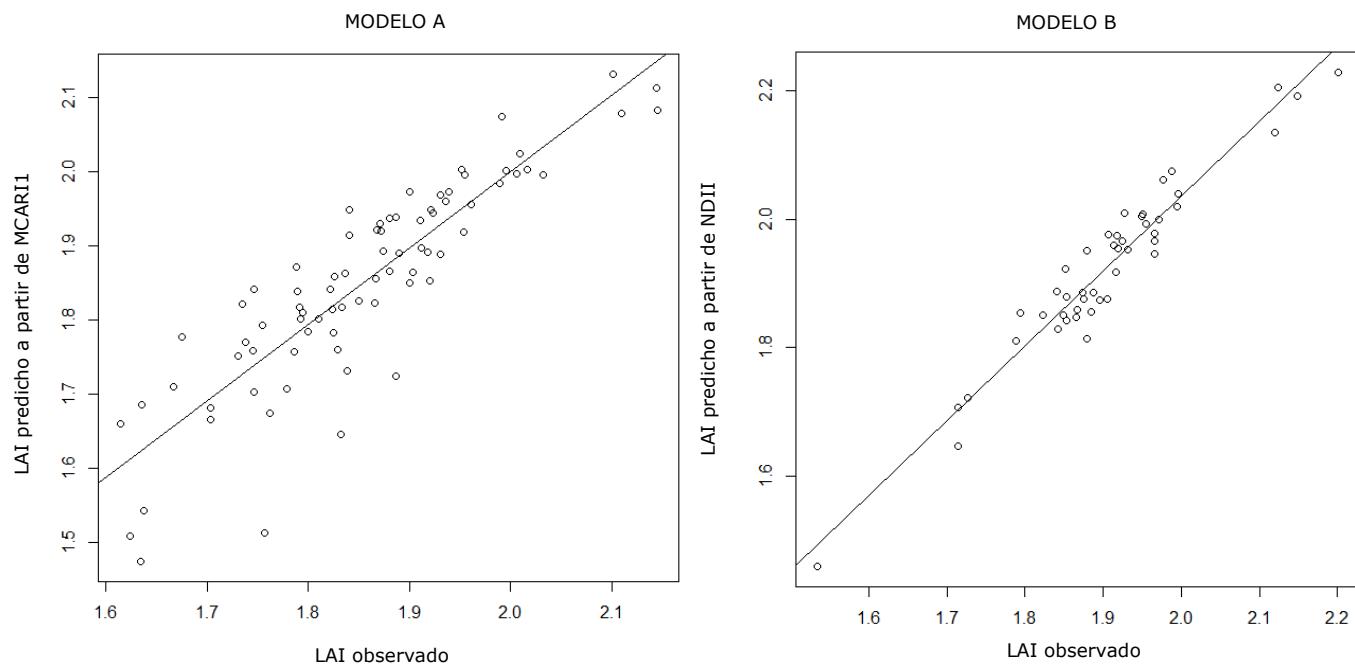


Figura 15. Relaciones empíricas entre LAI observado y pseudo-LAI predicho a partir de MCARI1 (Modelo A) y NDII (Modelo B).

4.6. Aplicación y validación de modelos: datos Landsat-8 y verdad-terreno.

En este apartado se aplican análisis de regresión simple (RLS) en relación a los valores observados y los valores predichos y, se validan los modelos predictivos para estimar LAI mediante el estadístico RMSE.

Tal y como se muestra en la figura 18, las predicciones que estiman LAI se sitúan en la mayoría de los casos en grupos conglomerados, por lo que se diferencian claramente las predicciones tomadas en distintas fechas.

Por otro lado, los modelos predictivos de NDII (modelo A) para estimar LAI acaparan los menores errores de error cuadrático medio (RMSE), siendo de 0.596 para LAI total y 0.473 para LAI verde. En cuanto a MCARI1 (modelo B), los errores RMSE son un tanto mayor que NDII, siendo de 0.614 para LAI total y 0.703 para LAI verde. Esta observación confirma que el modelo generado en base a píxeles que representan pasto y encinares ofrecen un mayor rendimiento para la predicción de LAI.

Si individualizamos los casos, la predicción de NDII referente al 28 de junio de 2015 obtuvo un grado de asociación excelente entre los valores de LAI verde medidos en campo y los estimados por NDII, con un RMSE de 0.196. Con resultados consistentes de RMSE se identifican también los modelos de predicción NDII para estimar LAI total con fecha del 28 de junio de 2015 (RMSE = 0.347) y el modelo predictivo de MCARI1 para estimar LAI verde con fecha del 8 de mayo de 2014 (RMSE = 0.335). Dados estos resultados, existe una marcada relación entre los mejores predictores de LAI derivada de las funciones predictivas (abril – mayo) con la toma de datos medidas en campo realizadas en fechas fenológicas similares, donde el pastizal de la dehesa se encuentra en su período de máximo desarrollo.

En contrapartida, los modelos predictivos realizadas para períodos invernales presentan modelos menos consistentes, cuyos RMSE varían entre 0.562 y 1.152. Del mismo modo ocurre para las predicciones otoñales en relación al sensor TM, con un RMSE = 0.723 MCARI1 y RMSE = 1.011 NDII. Se confirma, por tanto, que los modelos generados ofrecen un mayor rendimiento para los períodos fenológicos primaverales-estivales.

Tal y como indica Cohen et al. (2003), los modelos de predicción, comúnmente, siempre pueden tener predicciones individuales fuera del rango de valores observados. Esta confirmación, se traduce en este trabajo con los predictores MCARI1 y NDII para estimar LAI en fecha del 6 de marzo de 2014, donde se disponen sistemáticamente cuadrantes (304 y 211) con valores fuera de rango sobre la cual se construyó el modelo. En los casos de MCARI1 se observa sobreestimación, entorno a >1.2 sobre la línea de ajuste, mientras que para NDII ocurre infraestimación, aunque con un rango menor que MCARI1, entorno a <0.6 . Otro ejemplo ocurre para los predictores de ambos índices para estimar LAI en fecha del 31 de octubre de 2014.

Dadas estas particularidades, la exclusión u omisión de valores atípicos -en este caso representados por cuadrantes- que añaden incertidumbres a los modelos se ofrecen como una alternativa a mejorar la bondad y el ajuste de las relaciones empíricas entre los valores predichos y los observados para estimar LAI.

MODELO A

MODELO B

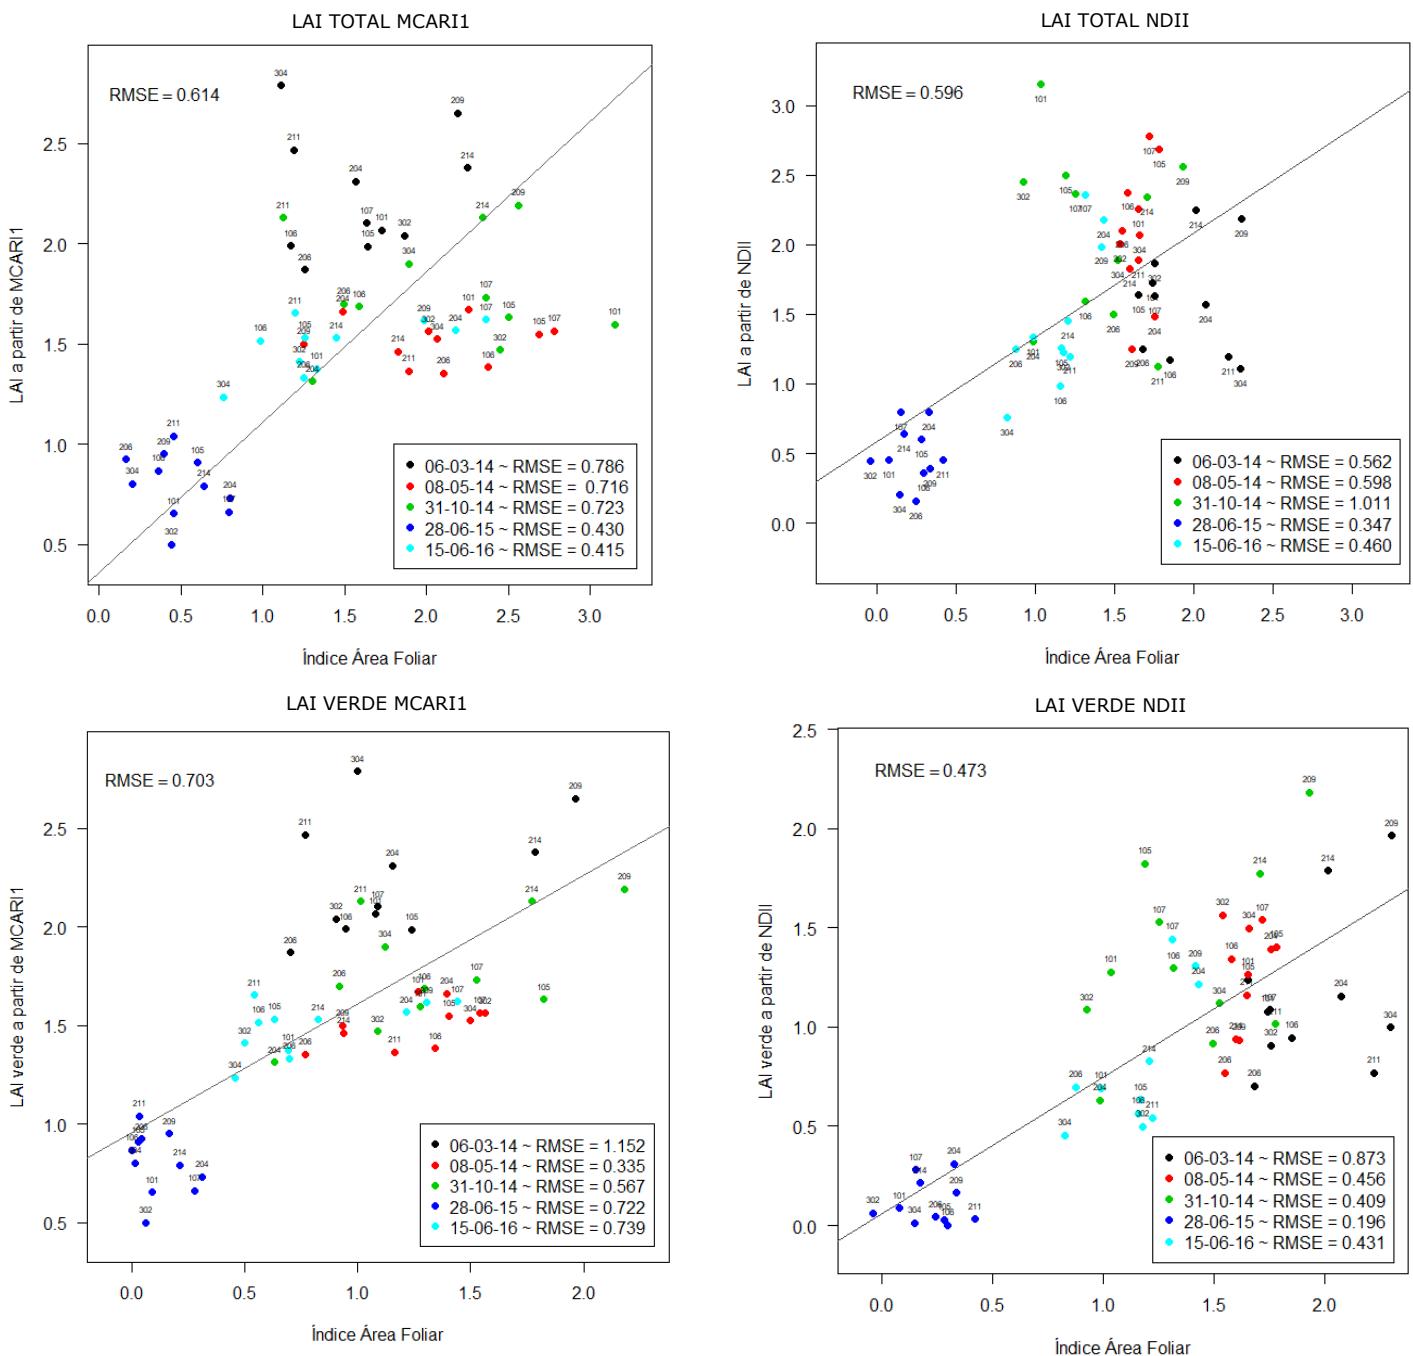


Figura 16. LAI observados vs LAI predichos. Validaciones RMSE

A continuación, se testean las funciones predictivas en base a la imagen corregida topográficamente mediante el método c-correction (Teillet *et al.* 1982) derivada de la escena Landsat-8, adquirida el 22 de abril de 2014. De este modo, se escogieron como valores observados el LAI medido en campo el 8 de mayo de 2014. El desfase temporal entre la toma de datos en campo y el escaneo a través del sensor OLI fue de -13 días, con una precipitación acumulada de aprox. 34 l/m² (REDAREX, 2018) desde un mes vista a la toma de dato de LAI en campo.

Tal y como se ilustra en la figura 17, los modelos predictivos para estimar LAI total acaparan, de manera substancial, mejores resultados RMSE, donde la nube de puntos se ajusta razonablemente a una recta con una pendiente negativa. Como ocurriera anteriormente, la parcela 304 aparece, en todos los casos, como valor atípico.

Pese a que el área de interés sea poco accidentada, los modelos predictivos para estimar LAI total basados en imágenes normalizadas han obtenido un RMSE

ligeramente mejores que los testeados anteriormente para una misma fecha. Siendo mejor para el NDII (escena c-correction) con un RMSE = 0.577 vs RMSE = 0.598 (escena sin corrección) y menor para MCARI1 (escena c-correction) con un RMSE = 0.67 vs RMSE = 0.716 (escena sin corrección).

La predicción de LAI verde (MCARI1 y NDII) en relación a la imagen c-correction decayó de manera significativa en relación a las escenas no corregidas. MCARI1(escena c-correction) con RMSE = 1.24 y mucho mejor para la escena sin corrección normalizada, con RMSE = 0.335, mientras que NDII (escena c-correction) obtuvo un RMSE = 0.959 vs RMSE = 0.456 (escena corregida)

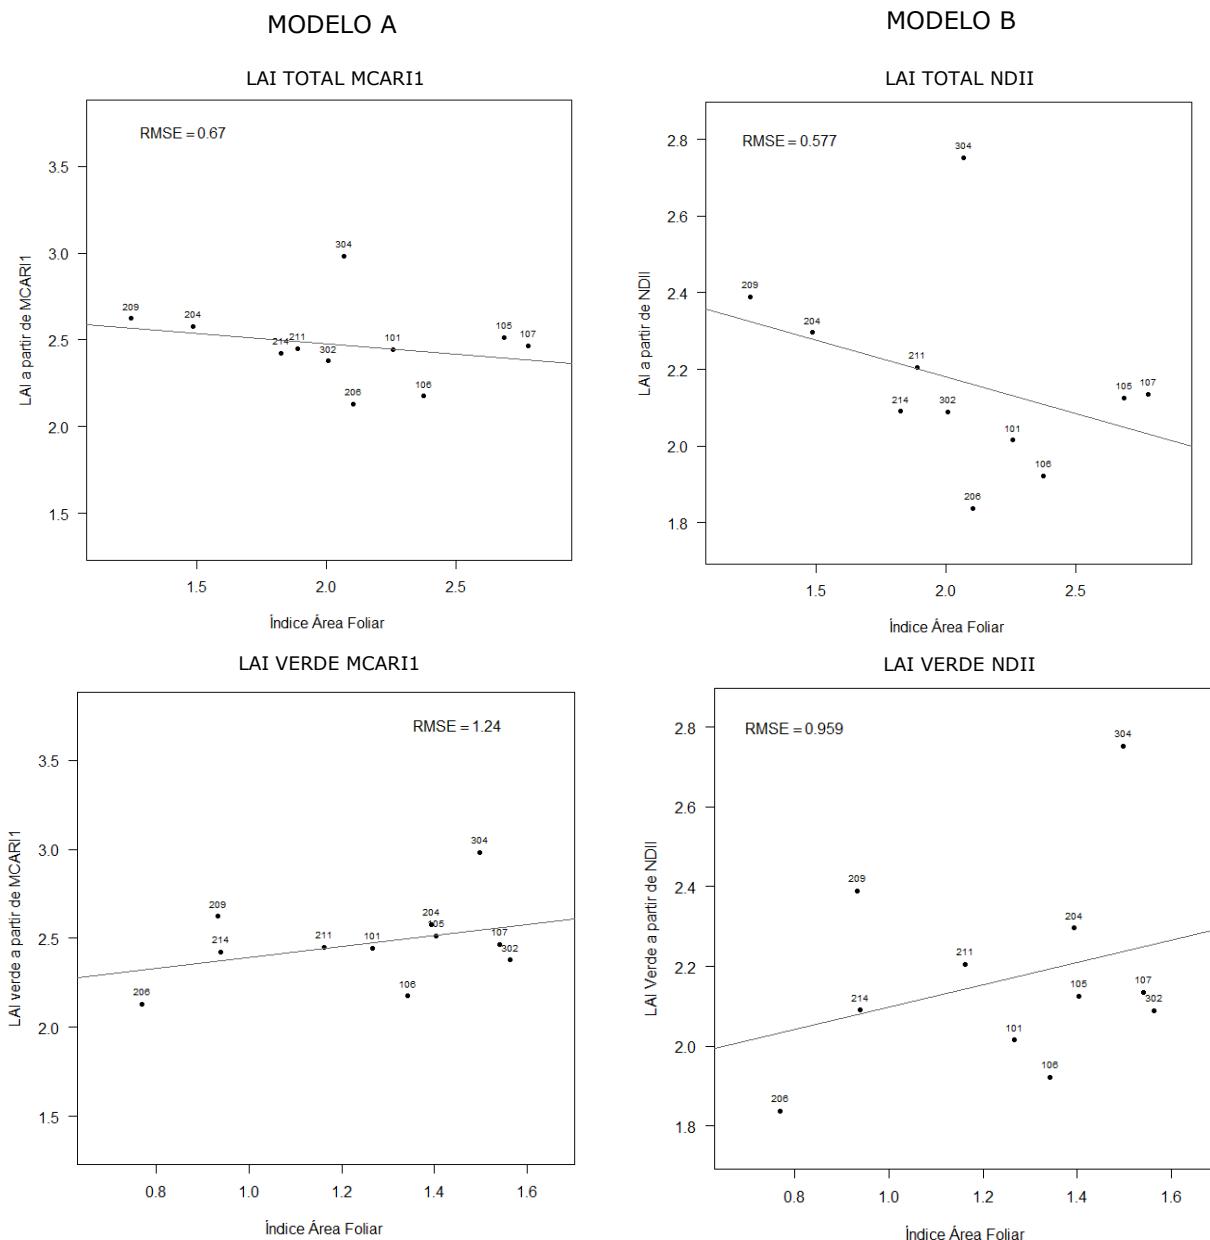


Figura 17. LAI observado vs LAI predicho. Validaciones RMSE. Utilización de imágenes normalizadas c-correction (Teillet, et al. 1983)

5. DISCUSIÓN

El objetivo del presente Trabajo Fin de Máster fue desarrollar un modelo predictivo del LAI a partir de información multiespectral de media resolución espacial (Landsat) a partir del análisis y modelización previa de las relaciones entre información hiperespectral a alta resolución espacial y LAI verdad-terreno, desarrollado para ambientes heterogéneos como son las dehesas.

La utilización de sensores hiperespectrales (CASI) y multiespectrales, como Landsat o el propio Sentinel-2 y, otros muchos más como por ejemplo MODIS, han permitido establecer relaciones empíricas para estimar el LAI a partir de datos LAI medidos en pastizales e índices espectrales propuestos en la bibliografía científica (Melendo-Vega *et al.* 2017; He *et al.* 2016; Fernández-Arango *et al.* 2015; Möckel, 2015; Martín *et al.* 2011; Lee *et al.* 2004). Los resultados obtenidos por estos autores no han sido del todo satisfactorias debido a múltiples factores, como, por ejemplo, las asociadas a la inexactitud de coincidencia de escala o por las debidas a la limitación de muestreos del LAI medidas en campo, que suelen ser costosos en términos temporales y económicos.

Para hacer frente a esos factores, en este trabajo se aplicó la técnica upscaling, lo que permitió agregar una gran magnitud de pseudo-LAI (900 pixeles; resolución 1m) a resolución Landsat (30m). Su remuestreo permitió obtener una modelización predictiva de Landsat de manera continua en el espacio y más ajustada a la realidad. Sin embargo, se encontró escasa bibliografía al respecto, debido a que estos modelos requieren de un gran capital humano, técnico y económico para llevarlo a cabo. Aun así, Korhonen *et al.* (2017) y Hufkens *et al.* (2008) incorporaron en sus modelos predictivos la técnica upscaling, permitiéndoles obtener mejores predicciones del LAI que otros estudios.

En base a los resultados obtenidos, entre los distintos grupos de índices propuestos por Haboudane *et al.* (2004), los índices desarrollados para estimar LAI verde y basados en la región comprendida entre el V-NIR (MCARI1, MTVI1 y MTVI2) obtuvieron altos grados de ajustes con pseudo-LAI en ambos modelos (A y B), aunque mayor en B. Estos resultados coinciden con el trabajo de Fernández-Arango *et al.* (2015). Ello se debe a que la expresión MCARI1 minimiza la sensibilidad a los efectos producidos por la clorofila y, a la vez, a su capacidad de aumentar la sensibilidad a los cambios del LAI (Haboudane *et al.* 2004). Sin embargo, NDII, basado en la normalización y, el GVMI como índice atmosférico (ambos V-SWIR) obtuvieron el mayor grado de variación conjunta con pseudo-LAI en el modelo A, y mermó substancialmente en el B. Sus óptimos resultados, concuerdan con otros estudios previos (Melendo-Vega *et al.* 2017; Delegido *et al.* 2015). La utilización de la banda NIR en la formulación de GVMI y NDII, hace que ambos sean más sensibles a los cambios de contenido de agua del vegetal, de ahí, que sean IV óptimos para predecir el LAI en pastizales. En base al análisis visual sobre la cartografía pseudo-LAI, se observó que GVMI se correlaciona mejor con pseudo-LAI cuando este es igual o menor a 2, en cambio, Ceccato *et al.* 2002 demostró que GVMI rinde más cuando LAI es igual o mayor a 2. Otros índices con altos ajustes con pseudo-LAI refieren a SAVI y MSAVI. Su buen rendimiento también lo obtuvieron Haboudane *et al.* (2004) y de manera tímida Melendo-Vega *et al.* (2017). Otro caso particular se dio con CLGreen, que de manera opuesta a NDII y GVMI, obtuvo de los mayores ajustes con pseudo-LAI en el modelo A, similares a MCARI1 y MTVI1.

En general, los resultados obtenidos han presentado correlaciones de r y r^2 óptimas. Sin embargo, tal y como se ha descrito anteriormente existen diferencias

en cuanto a resultados entre los distintos grupos de IV. Si bien, tal y como indican Huete (2002), si los IV se relacionan bien con LAI es porque ellas mismas están relacionadas entre sí, cada una en función del contenido de clorofila y otras características del dosel. Además, algunos índices aplicados, tal y como indica Haboudane *et al.* (2004), cuando se aproximan a niveles de saturación asintótica, LAI se satura cuando excede de 2 a 5.

El análisis RLS permitió de manera óptima evaluar el grado de bondad entre MCARI1 y NDII con pseudo-LAI. Pese a que ambos modelos son estadísticamente robustos, ambos presentan marcadas diferencias. Así, el modelo B (NDII) alcanzó el mayor grado de ajuste con pseudo-LAI ($r^2 = 0.93$) y, un tanto menor con A (MCARI1; $r^2 = 0.77$). El factor que explica esa diferencia en cuanto a resultados, sea porque el modelo B utiliza una muestra de píxeles exclusivos a pasto y encinares, por lo que no se ve tan afectada por las perturbaciones debidas a las reflectancias derivadas de las láminas de agua y caminos (Haboudane *et al.* 2004). Sin embargo, es interesante observar como en períodos secos, los encinares tienen mayor capacidad de contaminar los píxeles Landsat debido a que estos encinares tienen más capacidad de retener el contenido de humedad del dosel que el pasto.

Otra fuente de error a destacar y, que quizás haya contribuido a esas diferencias entre los resultados presentados, se relaciona con el desfase temporal derivado del escaneo de los sensores en relación a la toma de dato de LAI en campo. Por ejemplo, el desfase temporal entre el escaneo del sensor OLI y la jornada de campo fue de +14 días, con una precipitación acumulada de aproximadamente 94 l/m² (REDAREX, 2018), por lo que esa precipitación podría haber afectado a la dinámica vegetativa del pasto y, más aún cuando se trata de períodos de máximo desarrollo vegetal, como es la estación primaveral. Esto se traduce que entre ese lapsus de tiempo se obtenga para una misma localización distintos valores de LAI.

Como es sabido, los datos de campo son costosos en términos de tiempo y de trabajo humano. Cuando se dispone de una muestra de campo no lo suficiente amplia, como se da en este trabajo, es usualmente común utilizar las muestras verdad-terreno como valores observados, en lugar de excluir una serie de parcelas de muestreo como observaciones para verificar el modelo generado (Chuvieco, 2015; Cohen *et al.* 2003). En este sentido, la verificación de los modelos generados ha permitido valorar el grado de asociación con la realidad (LAI). Sin embargo, la verificación de los modelos siempre exige comparar los resultados obtenidos con una fuente externa, que para tal caso se dispuso de 11 parcelas representativas a LAI total y LAI verde. Además, la posibilidad de obtener escenas Landsat-8 OLI ajustadas en fechas coincidentes a la toma de datos de LAI medidas en campo en distintos momentos del ciclo fenológico del pasto, aportó información lo suficientemente robusta como para evaluar de manera óptima el grado de ajuste lineal entre esos datos de campo con las series multitemporales ofrecidas por el sensor OLI.

Los modelos predictivos basados a estimar LAI total y LAI verde obtuvieron resultados ligeramente diferentes. La predicción de NDII para estimar LAI verde en relación al 28 de junio de 2016 obtuvo el mejor resultado de este trabajo, en valores RMSE = 0.196 y en valores relativos RMSE (%) = 6.73 (véase tabla 7). En comparación con otro estudio relacionado a estimar LAI y realizado sobre el mismo emplazamiento geográfico, su modelo predictivo NDII -fechas similares- ofreció un menor rendimiento que el presentado en este trabajo (NDII LAI; RMSE = 18.8)

(Melendo-Vega *et al.* 2017). Además, el predictor NDII Global para estimar LAI verde obtuvo mejores resultados RMSE que el de Korhonen *et al.* (2017) (RMSE = 16.25 vs RMSE = 22.9, Korhonen *et al.* 2017), ambos utilizamos Landsat-8 OLI. Sin embargo, estos modelos no son equiparables en el sentido de que estos autores aplicaron su modelo para ambientes (clima, latitud próxima a 60°, ecosistema, etc.) totalmente distintos al utilizado en este trabajo.

Pese a que MCARI1 fue desarrollado específicamente para predecir LAI verde (Haboudane *et al.* 2004), en este trabajo, MCARI1 obtuvo resultados RMSE ligeramente mejores para predecir LAI total en lugar de LAI verde (tabla 6). Así mismo, destaca como todos los modelos predictivos relacionados con fechas finales a primavera y estivales, obtuvieron, en general, los mejores RMSE, Un factor que explique tal causa se deba a que la función predictiva utilizadas para predecir LAI fue tomada en fechas similares a la toma de datos LAI en campo, cuando el pasto suele encontrarse en su período de máximo desarrollo vegetativo.

Tabla 6. Valores RMSE y RMSE (%) calculado sobre el valor máximo de pseudo-LAI, 3.25). *Modelo A*

| MODELO A, MCARI1 | | | |
|------------------|-----------|----------|-----------|
| | LAI Total | | LAI verde |
| | RMSE | RMSE (%) | RMSE |
| 6-mar.-2014 | 0.786 | 24.18 | 1.152 |
| 8-may.-2014 | 0.716 | 22.03 | 0.335 |
| 31-oct.-2014 | 0.723 | 22.24 | 0.567 |
| 28-jun.-2015 | 0.43 | 13.23 | 0.722 |
| 15-jun.-2016 | 0.415 | 12.76 | 0.739 |
| Global | 0.614 | 18.89 | 0.703 |
| | | | 21.63 |

Tabla 7. Valores RMSE y RMSE (%) calculado sobre el valor máximo de pseudo-LAI, 2.91). *Modelo B*

| MODELO B, NDII | | | |
|----------------|-----------|----------|-----------|
| | LAI Total | | LAI verde |
| | RMSE | RMSE (%) | RMSE |
| 6-mar.-2014 | 0.562 | 19.31 | 0.873 |
| 8-may.-2014 | 0.598 | 20.54 | 0.456 |
| 31-oct.-2014 | 1.011 | 34.74 | 0.409 |
| 28-jun.-2015 | 0.347 | 11.92 | 0.196 |
| 15-jun.-2016 | 0.46 | 15.8 | 0.431 |
| Global | 0.596 | 20.48 | 0.473 |
| | | | 16.25 |

Por otra parte, en este trabajo se desarrolló un modelo para corregir topográficamente la escena mediante c-correction (Teillet *et al.* 1982). Aunque no sea prescindible su aplicación para ambientes poco accidentados, en este estudio se quiso incorporar la escena c-correction a los modelos predictivos de LAI total y LAI verde, con la finalidad de valorar su rendimiento. Pese a ello, el modelo predictivo MCARI1 y NDII para estimar LAI total obtuvo mejores RMSE en relación al modelo que no utiliza la escena corregida y, de manera deficiente el LAI verde.

Los análisis planteados en este Trabajo Fin de Máster han respondido de manera óptima la hipótesis planteada, por lo que se puede confirmar que la técnica de ampliación de escala, realizada a partir de los modelos empíricos (Hiperespectral vs LAI campo) y su remuestreo a pixeles Landsat, ha permitido obtener de manera satisfactoria predicciones de LAI más elevadas que en algunos estudios previos. Sin embargo, este modelo sigue teniendo aun incertidumbres asociadas a los procesos metodológicos (exclusión u omisión de valores atípicos), procesos de validación (verdad-terreno), a la componente meteorológica (precipitación, temperatura, humedad) contaminación de píxeles Landsat (modelo de elección A o B), desfase temporal entre la toma de dato del LAI en campo y el escaneo del sensor y características técnicas de los sensores.

A partir de ello, se plantean nuevas líneas de trabajo con el objetivo de perfeccionar las ya utilizadas en este trabajo. Se definen por i) la utilización de datos procedentes de sensores a bordo de plataformas aéreas no tripuladas (UAV) escaneados en la misma fecha a la toma de dato LAI en campo, por lo que ofrecerá testear más IV especializados a estimar LAI y reducirá la incertidumbre asociada a la componente meteorológica, ii) procesos de validación más complejos utilizando una mayor gama de muestreos de campo que permitan excluir u omitir los valores atípicos, iii) aplicar distintos modelos y establecer comparaciones entre ellos, tales como la inversión de ecuación de transferencia de radiación de vegetación y métodos geoestadísticos y, v) realizar una clasificación supervisada para obtener cartografía exclusiva de pasto, y a partir de esta cartografía aplicar los métodos y técnicas planteadas.

6. CONCLUSIONES

Durante los últimos años, la estimación de la variable biofísica LAI en ambientes de sabana, como las dehesas, ha suscitado un gran interés por parte de la comunidad científica tanto para estudios de cambio climático como para conocer el papel que ésta juega en el funcionamiento fisiológico de las plantas.

La propuesta de upscaling de este trabajo ha permitido de manera satisfactoria obtener una gran cantidad de pseudo-LAI a resolución Landsat. Pese a no representar valores reales de LAI, esta técnica ha conseguido reducir la incertidumbre asociada a la inexactitud de escala entre la resolución Landsat y la representatividad de las mediciones del LAI realizadas en campo y ha permitido de manera satisfactoria generar modelos empíricos predictivos a partir de índices de vegetación.

En cuanto a determinar cuál índice es el más adecuado para estimar LAI, su elección ha variado en función del modelo desarrollado. Se establece, pues, que los índices MCARI1 y MTVI1, basados en las regiones comprendidas entre el V-NIR, han obtenido los mayores coeficientes r y r^2 para la muestra realizada sobre todas las cubiertas (Modelo A). En cambio, los índices NDII y GVMI, basados en las regiones comprendidas entre el V-SWIR, son los que han alcanzado los mayores valores de r y r^2 para la muestra realizada sobre pasto y encinares (Modelo B), y de manera similar MCARI1 y MTVI1.

Los modelos presentan diferencias en función de la inclusión o no de otro tipo de cubiertas que no sean las estrictamente relacionadas con la vegetación, siendo los índices NDII y MCARI1 los que permitieron los ajustes más elevados ($r^2 = 0.93$ y 0.77, respectivamente).

Una nueva validación de los modelos empíricos utilizando imágenes de diferentes fechas del sensor OLI demuestra que los modelos se ajustan mejor a los períodos primaverales-estivales y que MCARI1 es el índice con mayor carga predictiva tanto de LAI total como del LAI verde.

Además, los resultados señalan que los modelos predictivos NDII para estimar LAI verde son, en general, mejores que los predictivos MCARI1, es decir, para estimar LAI total. Si concretamos los casos, se determina que el modelo predictivo NDII para estimar LAI verde en fecha del 28 de junio de 2015 fue el que obtuvo el mejor RMSE = 0.196 y RMSE (%) = 6.73. Pese a ello, a la vista de los resultados, MCARI1 se perfila como el índice más confiable, debido a que tanto rinde para LAI total, LAI verde, en ambientes heterogéneos y en otros exclusivos a pasto y encinares.

Por otra parte, la aplicación de tratamientos de normalización topográfica en los modelos predictivos solo ha contribuido a mejorar ligeramente la modelización del LAI total y, de manera deficiente el LAI verde. Se constata pues, que su utilización para ambientes poco accidentados sea prescindible.

En conclusión, se establece que el enfoque de upscaling aplicado ha permitido modelizar satisfactoriamente la distribución espacial del LAI para ecosistemas de dehesa. No obstante, debido a los múltiples factores que afectan el rendimiento de los modelos, es necesario continuar investigando en la materia y aplicar nuevos métodos que permitan obtener mejores predicciones del LAI.

BIBLIOGRAFÍA:

- Ahlstrom, A. Raupach, M.R. Schurgers, G. Smith, B. Ameth, A. Jong, M. Reichstein, M. Canadell, J.M. Friedlingstein, P. Jain, A.K. Kato, E. Poulter, B. Sitch, S. Stocker, B.D. Viovy, N. Wang, Y. Wiltshire, A. Zaehle, S. Zeng, N. 2015. The dominant role of semi-arid ecosystem in the trend and variability of the land CO₂ sink. *Science*. 348 pp. 895-899.
- Baret, F. Guyoy, G. 1991. Potentials and limits of vegetation indices for LAI and APAR assessment. *Remote Sensing of Environment*. 35(2-3); 161-173. [https://doi.org/10.1016/0034-4257\(91\)90009-U](https://doi.org/10.1016/0034-4257(91)90009-U)
- Boyer, J.S. 1995. Measuring the water status of plants and soils. Academic Press, San Diego. pp. 178.
- Breshears, D. Myers, O.B. Jhonson, S.R. Meyer, C.W. Martens, S.N. 1997. Differential use of spatially heterogeneous soil moisture by two semiarid – woodland tree species: *Pinus edulis* and *Juniperus monosperma*. *Journal of Ecology*. 85. pp. 289-172.
- Brouge, N. Leblanc, E. 2000. Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. *Remote Sensing of Environment*. 76. 156-172.
- Bustamante, J. Aragonés, D. Afán, I. Luque, J.C. Pérez-Vázquez, A. Castellanos, E. Díaz-Delgado, R. 2016. Hyperspectral Sensors as a Management Tool to Prevent the invasion of the Exotic Cordgrass *Spartina densiflora* in the Doñana Wetlands. *Remote Sensing*. 8(12), 1001. doi:[10.3390/rs8121001](https://doi.org/10.3390/rs8121001)
- Cáceres, J. Martín-Isabel, P. Salas, J. 2012. Análisis temporal del contenido de humedad en pasto en un ecosistema de DEHESA mediante imágenes Landsat, y su relación con factores climáticos. *Revista ciencias espaciales*. Vol. 5, núm. 1.
- Ceccato, P. Flasse, S. Grégoire, J.M. 2002. Designing a spectral index to estimate vegetation water content from remote sensing data: Part 2. Validation and applications. *Remote Sensing of Environment*. 82(2-3); 198-207. [https://doi.org/10.1016/S0034-4257\(02\)00036-6](https://doi.org/10.1016/S0034-4257(02)00036-6)
- Chen, J. 1996. Evaluation of vegetation indices and modified simple ratio for boreal applications. *Canadian Journal of Remote Sensing*. 22(3); 229-242. DOI: 10.1080/07038992.1996.10855178
- Chen, J. Black, T. Defining leaf area index for non-flat leaves. 1992. *Plant, Cell & Environment*. 14(4). <https://doi.org/10.1111/j.1365-3040.1992.tb00992.x>
- Chuvieco, E. Salas, F. Aguado, I. Cocero, D. Riaño, D. 2001. Estimación del estrés hídrico de la vegetación a partir de sensores de alta y baja resolución. *Geofocus*. 1. pp. 1-16.
- Cogliati, S. Rossini, M. Julitta, T. Meroni, M. Schickling, A. Burkart, A. Pinto, F. Rascher, U. Colombo, R. 2015. Continuous and long-term measurements of reflectance and subinduced chlorophyll fluorescence by using novel automated field spectroscopy systems. *Remote Sensing of Environment*. 164. pp. 270-281. <https://doi.org/10.1016/j.rse.2015.03.027>
- Cohen, W. Maiersperger, K. Gower, T. Turner, P. 2003. An improved strategy for regression of biophysical variables and Landsat ETM+ data. *Remote Sensing of Environment*. 84. pp. 561-571. [https://doi.org/10.1016/S0034-4257\(02\)00173-6](https://doi.org/10.1016/S0034-4257(02)00173-6)
- Daughtry, C. Walthall, C. Kim, M. Brown de Colstoun, E. McMurtrey, J. 2000. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. *Remote Sensing of Environment*. 74. 229-239. DOI: 10.1016/S0034-4257(00)00113-9
- de Miguel, E. Fernández-Renau, A. Prado, E. Jiménez, M. Gutiérrez de la Cámara, O. Linés, C. Martín, J.A. Muñoz, F. 2014. The processing of CASI 1500i data at INTA PAF. *EARSeL e Proceedings*, 13. 30-37.
- Delegido, J. Verrelst, J. Alonso, L. Moreno, J. 2011. Evaluation of Sentinel 2 red edge bands for empirical estimation of green LAI and Chlorophyll content. *Sensors*, 11(7). pp. 7060-7081. <https://doi.org/10.3390/s110707063>

- Fan J, Zhong H, Liang B, Shi P, Yu G. 2003. Carbon stock in grassland ecosystem and its affecting factors. *Grassland of China*, 25, 51-58.
- Fernández-Arango, D. Martín-Isabel, P. Vilar del Hoyo, L. Pacheco-Labrador, J. 2015. Estimación del contenido de humedad de la vegetación herbácea en una zona de dehesa a partir de imágenes hiperspectrales adquiridas por el sensor aeroportado CASI. *Revista Internacional de Ciencia y Tecnología de la Información Geográfica. Geofocus*. n^a 36. pp. 177-204.
- Gao, B. 1996. NDWI-Anormalized difference water index for remote sensing of vegetation liquid water from space. *Remote sensing of Environment*. 58. 257-266. [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)
- Gitelson, A. Kaufman, Y. Stark, R. Rundquist, D. 2002. Novel algorithms for remote estimation of vegetation fraction. *Remote Sensing of Environment*. 80(1); 76-87. [https://doi.org/10.1016/S0034-4257\(01\)00289-9](https://doi.org/10.1016/S0034-4257(01)00289-9)
- Gitelson, A. Viña, A. Arkebauer, T. Rundquist, D. Keydan, G. Leavitt, B. 2003. Remote estimation of leaf área index and green leaf biomass in maize canopies. *Geophysical Research Letters*. 30(5). <https://doi.org/10.1029/2002GL016450>
- Gitelson. A. Merzlyak, M. 1996. Signature analysis of leaf reflectance spectra: Algorithm development for remote sensing. *Journal of Plant Physiology*. 148. 493-500.
- González-Dugo, M.P. Chen, X. Andreu, A. Carpintero, E. Gómez-Giráldez, P. Su, Z. 2017. Evolución de la evapotranspiración y el estrés hídrico de la vegetación de dehesa en la Península Ibérica (2001-2015). *Revista de Teledetección*. 50. pp. 27-36. <https://doi.org/10.4995/raet.2017.8916>
- Grace, J. Jose, J.S. Meir, P. Miranda, H.S. Montes, R.A. 2006. Productivity and carbon fluxes of tropical savannas. *Journal of Biogeography*. 33. Pp 387-400. <https://doi.org/10.1111/j.1365-2699.2005.01448.x>
- Haboudane, D. Miller, J. Pattey, E. Zarco-Tejada, P. Strachan, I. 2004. Hyperspectral Vegetation índices and novel algorithms for predicing green LAI of crops canopies: Modeling and validation in the context of precision agriculture. *Remote Sensing Environment*. 90(3); 337-352. <https://doi.org/10.1016/j.rse.2003.12.013>
- Hao, R y Yu, D. 2018. Optimization schemes for grassland ecosystem services under climate change. *Ecological Indicators*. 85. pp. 1156-1169. <https://doi.org/10.1016/j.ecolind.2017.12.012>
- Hardisky, M. Klemas, V. Smart, R. 1983. The influence of soil salinity, growth form, and leaf moisture on the spectral radiance of *Spartina alterniflora* canopies. *Photogrammetry Engineering and Remote Sensing*. 49; 77-83
- He, Y. Bo, Y. Chai, L. Liu, X. Li, A. 2016. Linking in situ LAI and fine resolution remote sensing data to map reference LAI over cropland and grassland using geostatistical regression method. International. *Journal of Applied Earth Observation and Geoinformation*. 50. pp. 26-38. <https://doi.org/10.1016/j.jag.2016.02.010>
- Hermann I. Pimstein, A. Karnieli, A. Cogen, Y. Alchanatis, V. Bonfil, D.J. 2011. LAI assessment of whea and potato crops by Venus and Sentinel 2 bands. *Remote Sensing of Environment*. 115(8). pp. 2141-2151. <https://doi.org/10.1016/j.rse.2011.04.018>
- Hill, M. Hanan, N. Hoffmann, W. Scholes, R. Prince, S. Ferwerda, J. Lucas, R. Baker, I. Arneth, S. Higgins, I. Barnett, D. Disney, M. Hutley, L. 2011. Remote sensing and modelling of savannas. The state of the dis-union. *34th International Symposium on Remote Sensing of Environment*. Sydney, 1-6.
- Huete, A. 1988. A soil Vegetation adjusted index (SAVI). *Remote Sensing Environment*. 25; 295-309. DOI: 10.1016/0034-4257(88)90106-X
- Huete, A. Didan, K. Miura, T. Rodríguez E. Gao, X. Ferreira, L. 2002. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*. 83(1-2); 195-213. [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2)

IGN en web <http://www.ign.es/web/ign/portal>

- Jordan, C. 1969. Derivation of leaf area index from quality of light on the forest floor. *Ecology*, 50; 663-666. <https://doi.org/10.2307/1936256>
- Kaufman, Y. Tanre, D. 1992. Atmospherically resistant vegetation index (ARVI). *IEEE Trans. Geosci. Remote Sensing*. 30. 261-270. DOI: 10.1109/36.134076
- Kim, M. Daughtry, C. Chappelle, E. McMurtrey, J. Walthall, C. 1994. The use of high spectral resolution bands for estimating absorbed photosynthetically active radiation (Apar). *Proceedings of the 6th Symposium on Physical Measurements and Signatures in Remote Sensing*. 299-306.
- Korhonen, H. Packalen, P. Rautiainen, M. 2017. Comparison of Sentinel-2 and Landsat-8 in the estimation of boreal forest canopy cover and leaf area index. *Remote Sensing of Environment*. 195: 259-274. <https://doi.org/10.1016/j.rse.2017.03.021>
- Le Marie, G. François, C. Defréne, E. 2004. Towards universal broad leaf chlorophyll indices using PROSPECT simulated database and hyperspectral reflectance measurements. *Remote Sensing of Environment*. 89(1); 1-28. <https://doi.org/10.1016/j.rse.2003.09.004>
- Lee, K. Cohen, W. Kennedy, R. Maiersperger, T. Gower, S. 2004. Hyperspectral versus Multispectral data for estimating leaf area index in four different biomes. *Remote Sensing of Environment*. 99(3-4). pp 508-520. <https://doi.org/10.1016/j.rse.2004.04.010>
- Lemaire, G. Wilkins, R. Hodgson, J. 2005. Challenges for grassland science: managing research priorities. *Agriculture, Ecosystems & Environment*, 108, 99-108
- Li, P. Wang, Q. Developing and validating novel hyperspectral indices for leaf area index estimation: effect of canopy vertical heterogeneity. 2013. *Ecol. Indic.* 32. 123:130. <https://doi.org/10.1016/j.ecolind.2013.03.025>
- Lichtenthaler, H. Lang, M. Sowinska, M. Heisel, F. Miehe, J. 1996. Detection of vegetation stress via a new high-resolution fluorescence imaging system. *Plant Physiol.* 148. pp. 599-612
- MAPAMA en web <https://www.mapa.gob.es/es/>
- Martín, P. Carrara, A. Echevarría, M.P. Gajardo, J. Gallardo, M. Gimeno, C. Gómez, L. González, R. Martínez, F.J. Mendiguren, G. Nieto, H. Pacheco-Labrador, J. Pérez-Cabello, F. Riaño, D. Salas, J. Vilar, L. 2011. Obtención de información espectral a diversas escalas para la estimación de parámetros biofísicos de la vegetación Mediterránea en el contexto de cambio global (BIOSPEC). *Tele-detección. Bosques y cambio climático*. pp. 373-376
- Melendo-Vega, J.R. Martín, M.P. Vilar del Hoyo, L. Pacheco-Labrador, J. Echevarría, P. Martínez-Vega, J. 2017. Estimación de variables biofísicas del pastizal en un ecosistema de dehesa a partir de espectro-radiometría de campo e imágenes hiperespectrales aeroportadas. *Revista de Teledetección*. 48, 13-28. <https://doi.org/10.4995/raet.2017.7481>
- Möckel, T. 2015. Hyperspectral and multispectral remote sensing for mapping grassland vegetation. *Department of Physical Geography and Ecosystem Science*, Lund University. DOI: 10.13140/RG.2.1.2745.4564
- Moreno, G. Pulido, F.J. 2009. The functioning, management and persistence of dehesa. Agroforestry in Europe: current status and future prospects. *Springer Science*. Berlin. pp. 127-160. Berlin.
- Navarro-Cerillo, R. 2013. Evaluación de variables biofísicas mediante teledetección en pinares mediterráneos. *Ambienta. La revista del Ministerio de Medio Ambiente*. 105. pp. 78-88.
- Pacheco-Labrador, J. González-Gascón, R. Pilar-Martín, M. Riaño, D. 2014. Understanding the optical responses of leaf nitrogen in Mediterranean Holm oak (*Quercus ilex*) using field spectroscopy. *International Journal of Applied Earth Observation and Geoinformation*. 26. 105-118. <https://doi.org/10.1016/j.jag.2013.05.013>
- Pasqualotto, N. Delegido, J. Amin, E. Cisneros, A. Van Wittenberghe, S. Verrelst, J. Paredes-Gómez, V. Moreno, J. 2018. Estimación del Índice de Área Foliar verde y marrón de diferentes cultivos con

- Sentinel-2. *XVIII Congreso Nacional de Tecnologías de la Información Geográfica*, Valencia. pp. 202-211.
- Peña, M. 2017. Sensores hiperespectrales: Los últimos avances en teledetección. *Gestión Ambiental*. pp. 66-70. <https://www.researchgate.net/publication/259850980>
- Pinty, B. Verstraete, M. 2002. GEMI: a non-linear index to monitor global vegetation from satellites. *Vegetation*. 101(1); 15-20
- Privette, J. Asner, G. Conel, J. Huemmrich K. Olson, R, Rango, A. The EOS Prototype Exercise (PROVE) at Jornada: overview and lessons learned. *Remote Sensing Environment*. 74. 1-12
- Qi, J. Chehbouni, A. Huete, A. Keer, Y. Sorooshian, S. 1994. A modified soil vegetation adjusted index. *Remote Sensing of Environment*. 48; 119-126. DOI: 10.1016/0034-4257(94)90134-1
- REDAREX en web http://redarexplus.gobex.es/RedarexPlus/index.php?modulo=agrometeorologia&camino=Agrometeorolog%EDa&pagina=datos.php&rango=diarios&id_provincia=10&id_estacion=10
- Roberts, D. Demminson, P. Peterson, S. Sweeney, S. Rechel, J. 2006. Evaluation of AVIRIS and MODIS measures of live fuel moisture and fuel condition in a shrubland ecosystem in southern California. *Journal of Geophysical Research*. 111. G04502.
- Roig, S. Rubio, A. 2009. El sistema agroforestal dehesa como sumidero de carbono: hacia un modelo conjunto de la vegetación y el suelo. *Montes y Sociedad. 5^a congreso forestal español*. Ref: 5CFE01-234.
- Roujen, J. Breon, F. 1995. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote Sensing of Environment*, 51(3); 375-384. DOI: 10.1016/0034-4257(94)00114-3
- Rouse, J. Haas, R. Deering, D. Schell, J. Harlan, J. 1974. Monitoring the Vernal Advancement and Retrogradation (Green Wave Effect) of Natural Vegetation, NASA/GSFC Type III FinalReport, Greenbelt, MD. 371p.
- Roy, P. Guha, A. Kumar, V. 2015. An approach of surface coal fire detection from aster and Landsat-8 thermal data: Jharia coal field, India. *Observation and Geoinformation*. 39. 120-127. <https://doi.org/10.1016/j.jag.2015.03.009>
- Sampson, P. Zarco-Tejada, P. Mohammed, G. Miller, J. Noland, T. Fleming, R. 2003. Hyperspectral remote sensing of forest condition: Estimation of chlorophyll content in tolerant hardwoods. *Forest Science*. 49. pp. 381-391.
- Smith, J. Lin, T. Ranson, K. 1980. The Lambertian Assumption and Landsat Data. *Photo. Eng. Rem.* 46: 1183-1189.
- Teillet, P. Guindon, B. Goodenough, D. 1982. On slope-aspect correction of multispectral scanner data. *Canadian Journal of Remote Sensing*. 8. 84-106. <https://doi.org/10.1080/07038992.1982.10855028>
- USGS en web <https://earthexplorer.usgs.gov/>
- Vermote, E. Justice, C. Claverie, M. Franch, B. 2016. Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. *Remote Sensing of Environment*. 185. 46-56. <https://doi.org/10.1016/j.rse.2016.04.008>
- Yebra, M. Chuvieco, E. Nieto, H. Aguado, S. 2006. Comparación entre ecuaciones empíricas y modelos de simulación para estimar contenido de agua en pastizal. El acceso a la información espacial y las nuevas tecnologías geográficas. *XII Congreso Nacional de Tecnologías de la Información Geográfica*. Granada. pp. 1317-1332.
- Yebra, M. Denninson, P. Chuvieco, E. Riaño, D. Zylstra, P. Raymond-Hunt, E. Mark-Danson, F. Qi, Y. Jurdao, S. 2013. A global review of remote sensing of live fuel moisture content for fire danger

assessment: Moving towards operational products. *Remote Sensing of Environment*. 136. pp. 455-468. <https://doi.org/10.1016/j.rse.2013.05.029>

Zarco-Tejada, P. Miller, J. Noland, T. Mohammed, G. Sampson, P. 2001. Scaling-up and model inversion methods with narrow-band optical indices for chlorophyll content estimation in closed forest canopies with hyperspectral data. *IEEE Trans. Geosci. Remote Sensing*, 39; 1491-1507. DOI: 10.1109/36.934080

Zarco-Tejada, P. Ustin, S. 2001. Modelling canopy water content for carbon estimates from MODIS data at land EOS validation sites. *IGARSS 2001. Scanning the Present and Resolving the Future. Proceedings. IEEE 2001 International Geoscience and Remote Sensing Symposium*. Sidney, 1, 342-344. <https://doi.org/10.1109/igarss.2001.976152>

Zhen-wang, L. Xiao-ping, X. Tang, H. Yang, F. Chen, B. Zhang B. 2017. Estimating grassland LAI using the Random Forest approach and Landsat imagery in the meadow steppe of Hulunber, China. *Journal of Integrative Agriculture*. 16(2): 286-297.

ANEXO

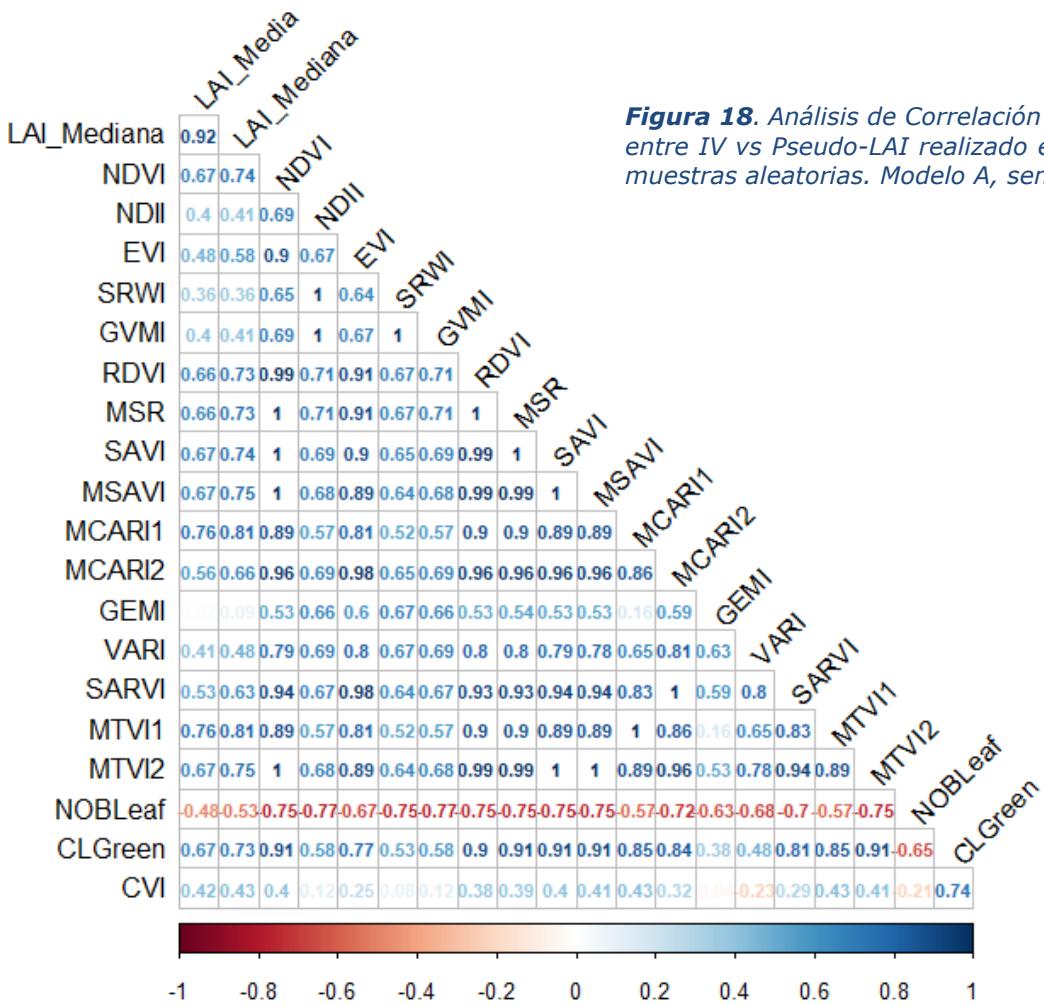


Figura 18. Análisis de Correlación de Pearson entre IV vs Pseudo-LAI realizado en base a 5 muestras aleatorias. Modelo A, sensor TM

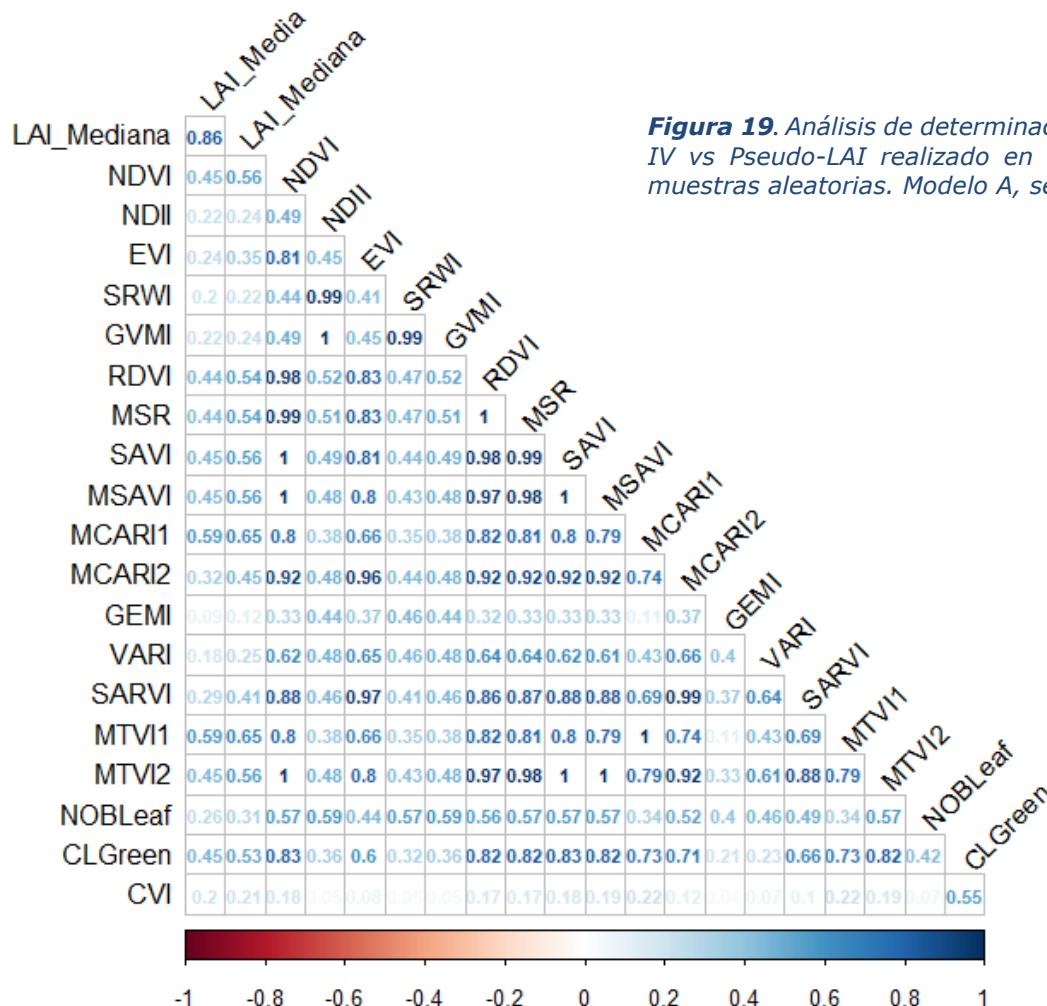


Figura 19. Análisis de determinación entre IV vs Pseudo-LAI realizado en base a 5 muestras aleatorias. Modelo A, sensor TM

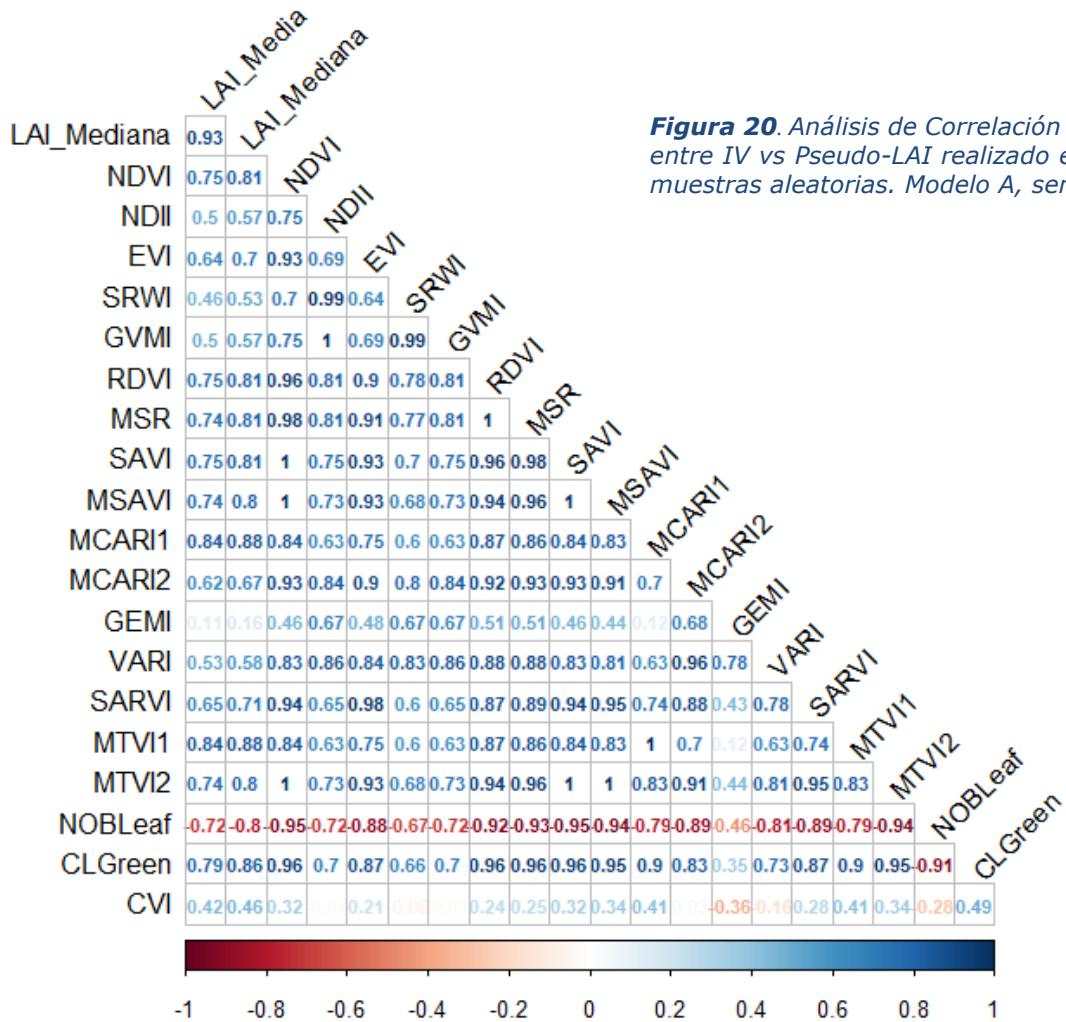


Figura 20. Análisis de Correlación de Pearson entre IV vs Pseudo-LAI realizado en base a 5 muestras aleatorias. Modelo A, sensor OLI

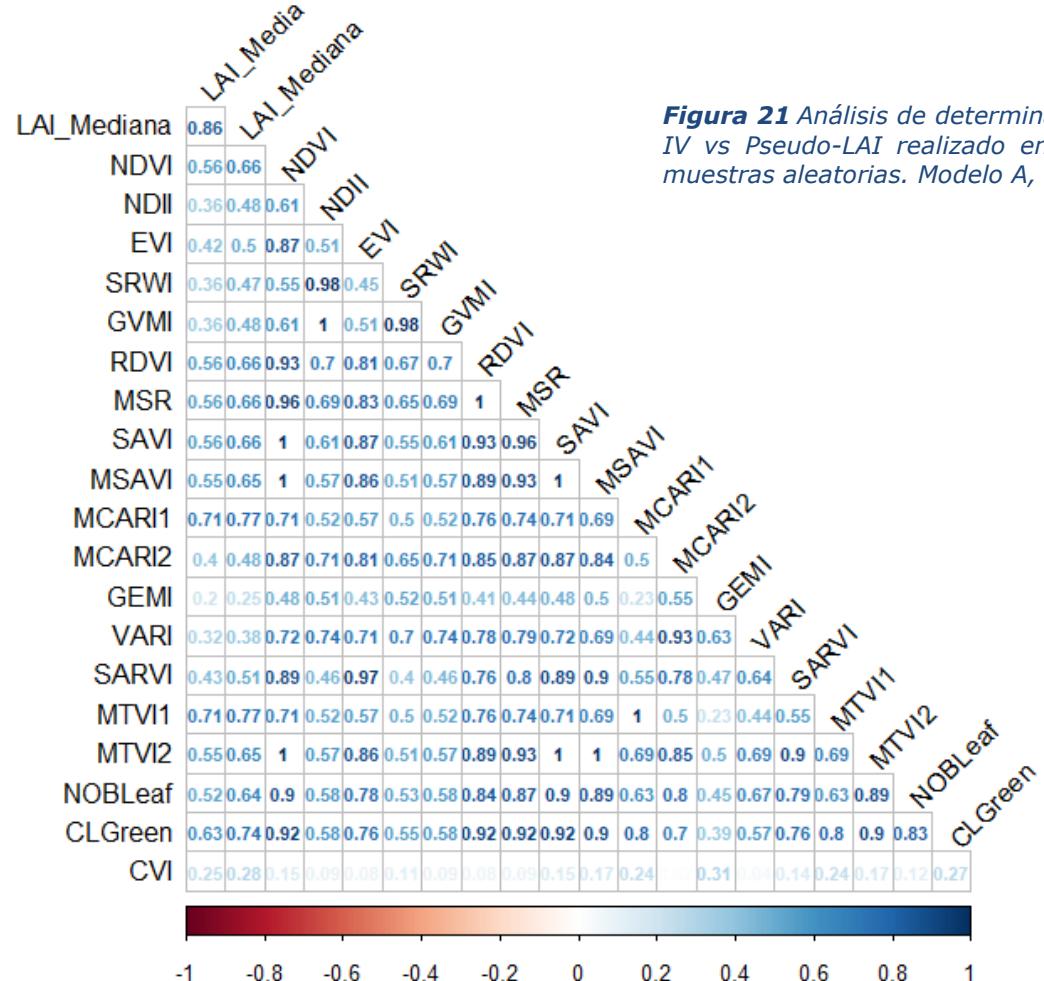


Figura 21 Análisis de determinación entre IV vs Pseudo-LAI realizado en base a 5 muestras aleatorias. Modelo A, sensor OLI

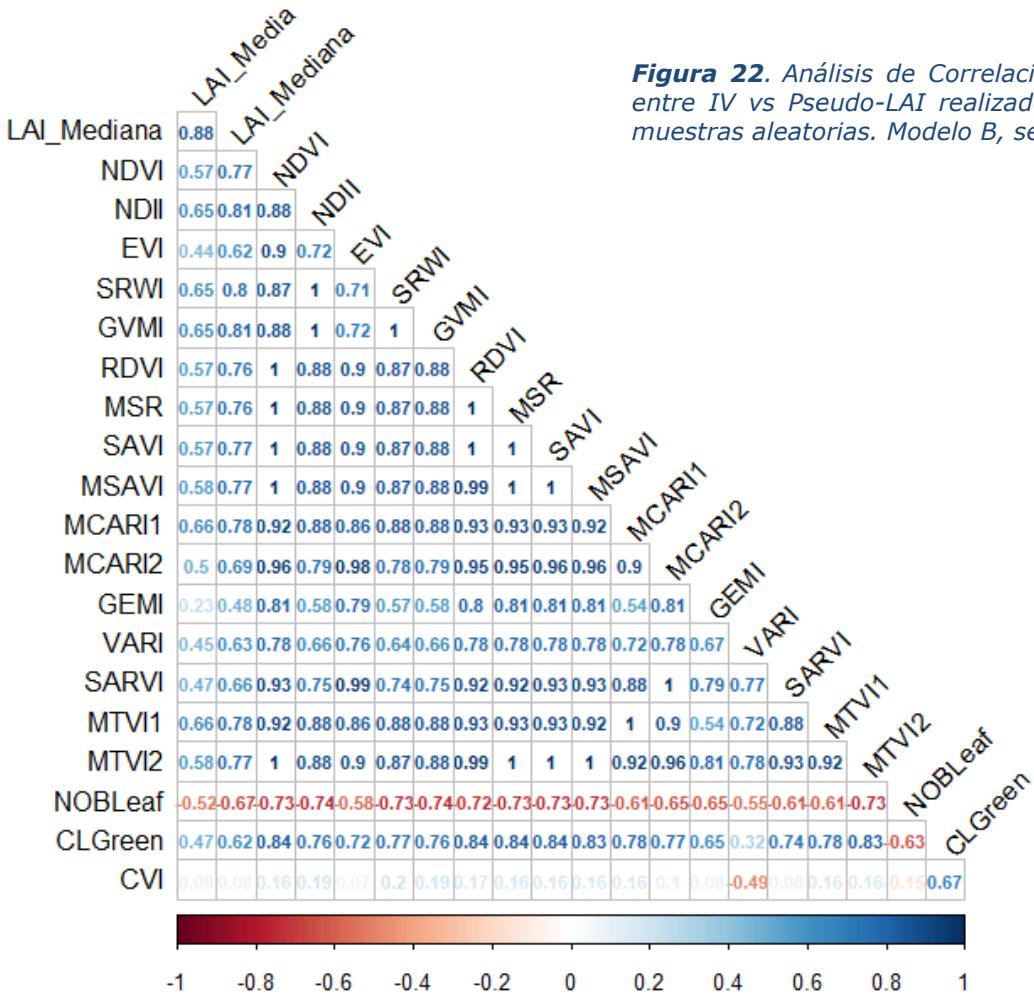


Figura 22. Análisis de Correlación de Pearson entre IV vs Pseudo-LAI realizado en base a 5 muestras aleatorias. Modelo B, sensor TM

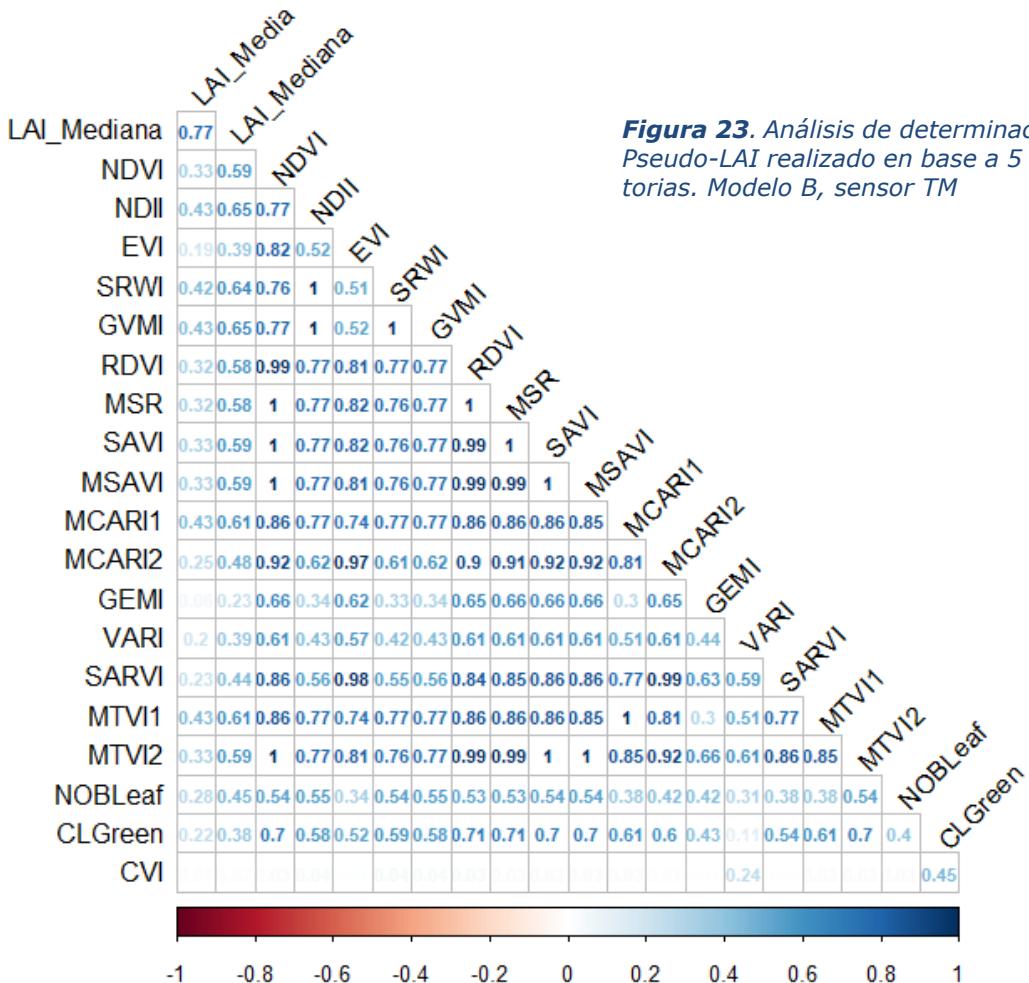


Figura 23. Análisis de determinación entre IV vs Pseudo-LAI realizado en base a 5 muestras aleatorias. Modelo B, sensor TM

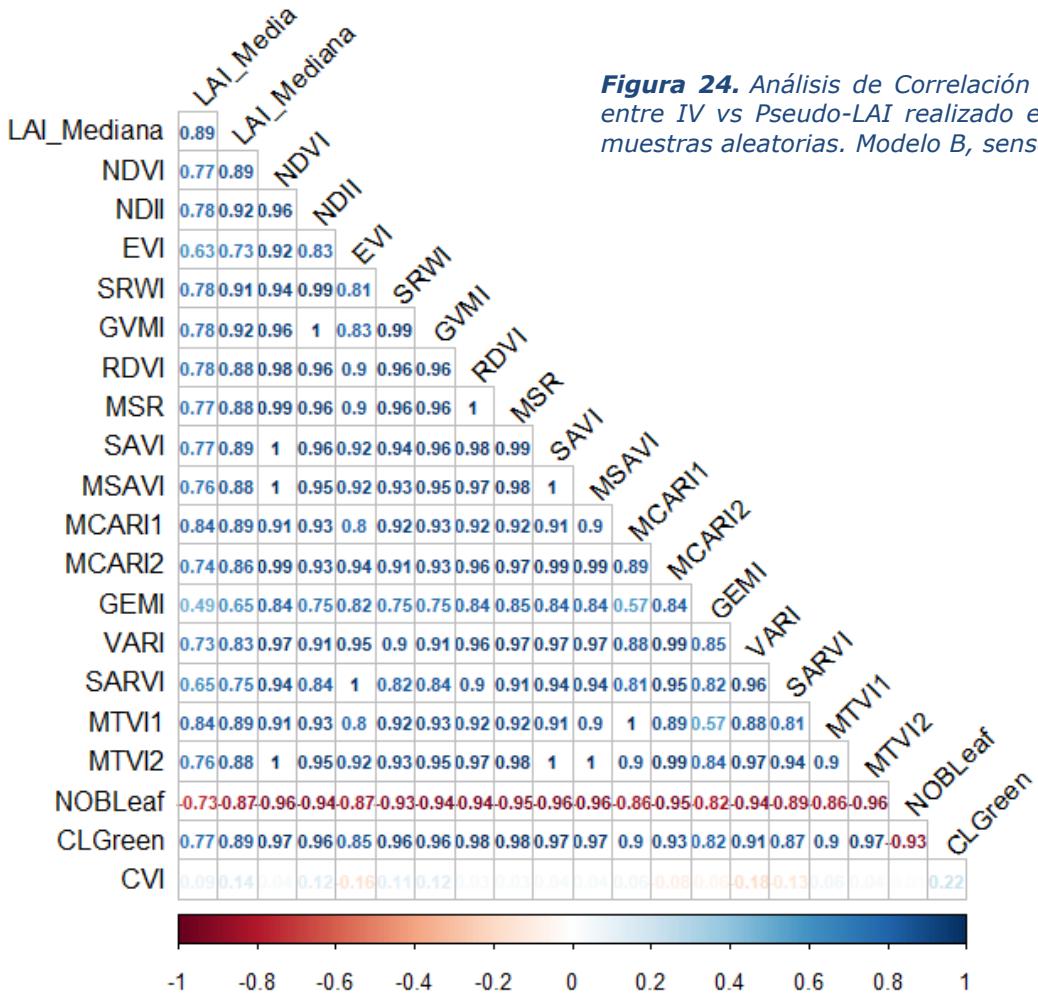


Figura 24. Análisis de Correlación de Pearson entre IV vs Pseudo-LAI realizado en base a 5 muestras aleatorias. Modelo B, sensor OLI

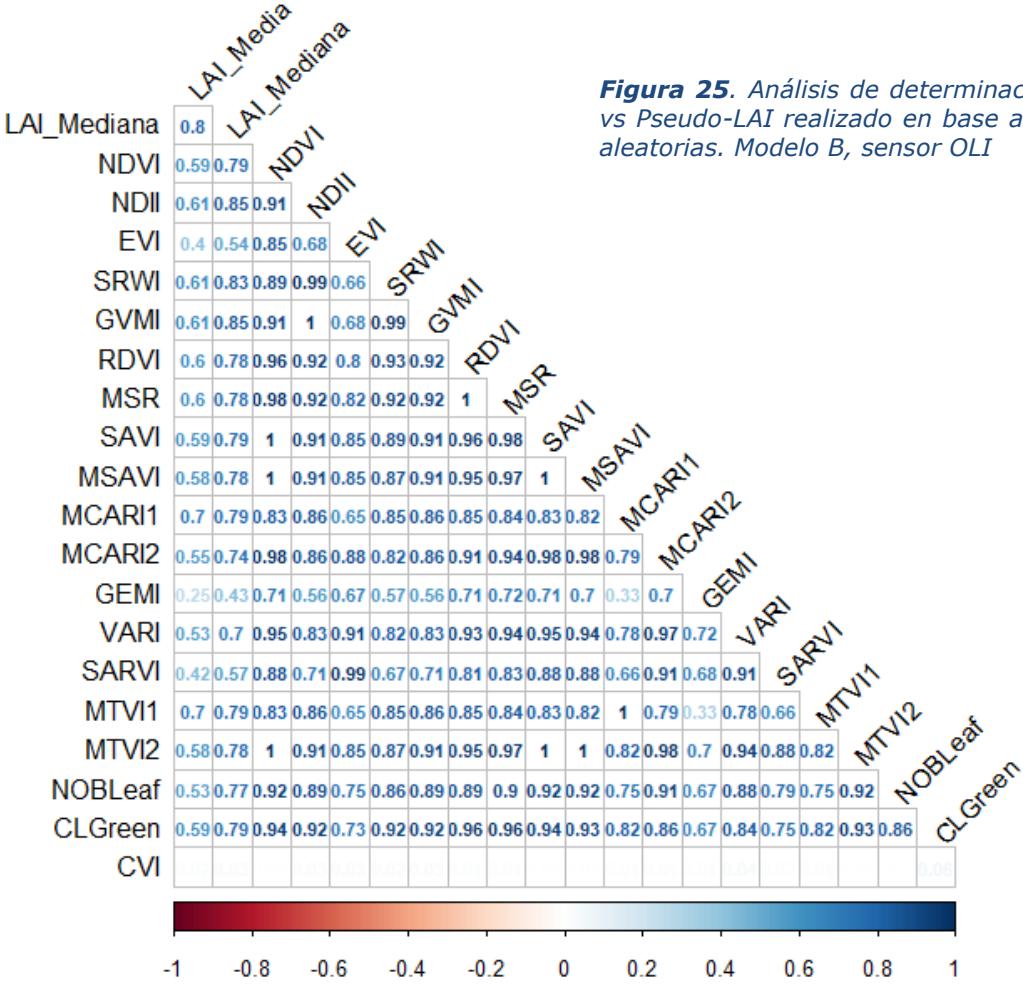
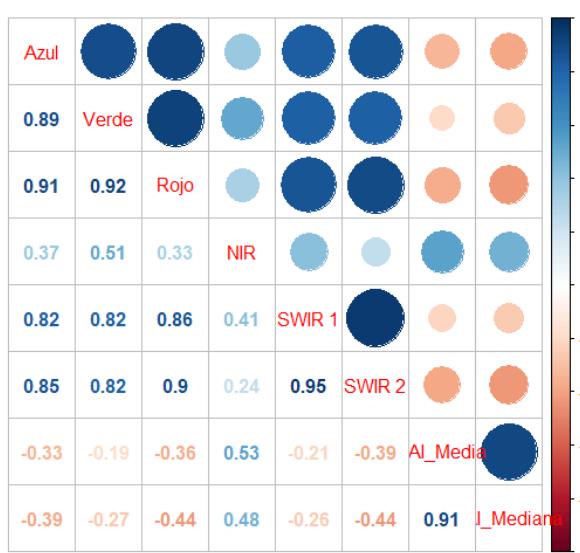
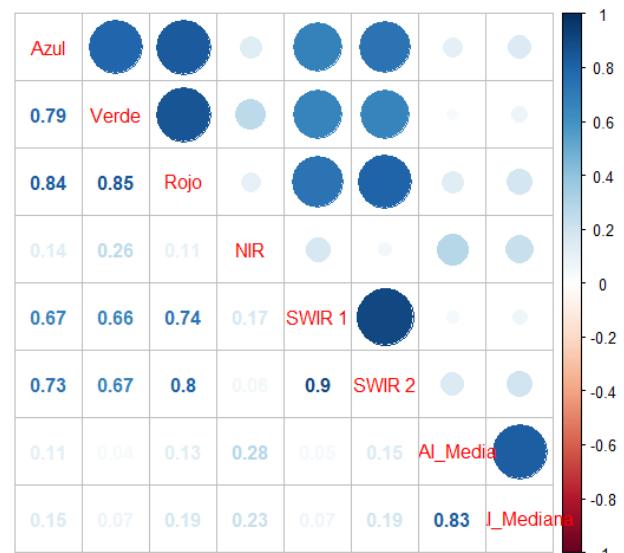


Figura 25. Análisis de determinación entre IV vs Pseudo-LAI realizado en base a 5 muestras aleatorias. Modelo B, sensor OLI

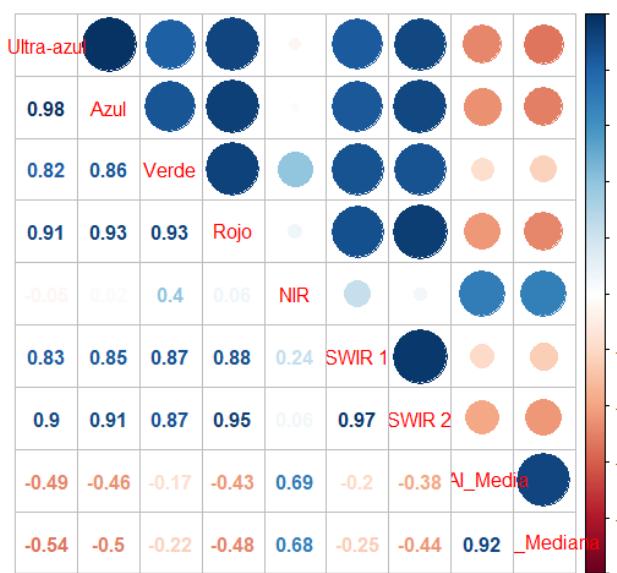
Coef. Correlación Pearson (r) bandas Landsat-5 (TM)



Coef. de determinación (r^2) bandas Landsat-5 TM



Coef. Correlación Pearson (r) bandas Landsat-8 (OLI)

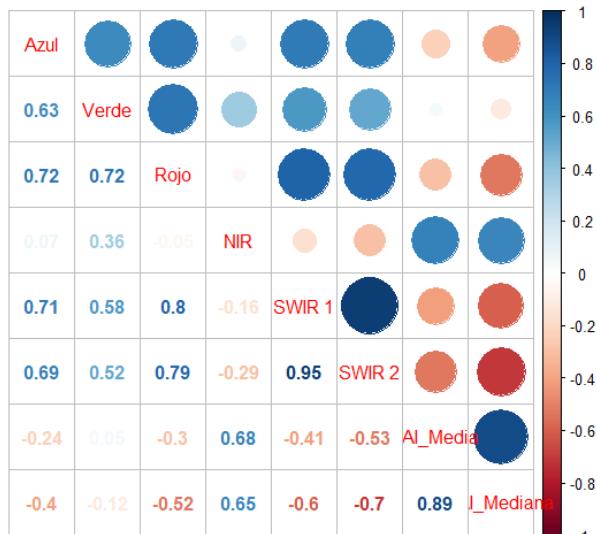


Coef. de determinación (r^2) bandas Landsat-8 OLI

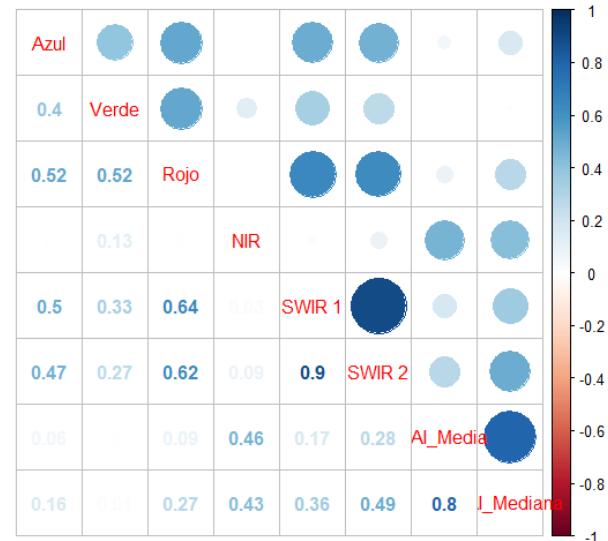


Figura 26. Análisis de Correlación de Pearson y Coeficientes de determinación realizadas entre las bandas del sensor TM (Landsat-5) y OLI (Landsat-8) y estadísticos LAI. Modelo A.

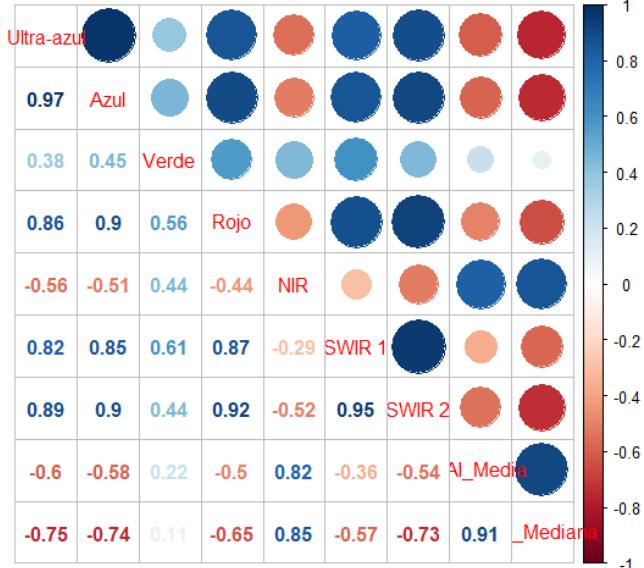
Coef. Correlación Pearson (r) bandas Landsat-5 (TM)



Coef. de determinación (r^2) bandas Landsat-5 TM



Coef. Correlación Pearson (r) bandas Landsat-8 (OLI)



Coef. de determinación (r^2) bandas Landsat-8 OLI

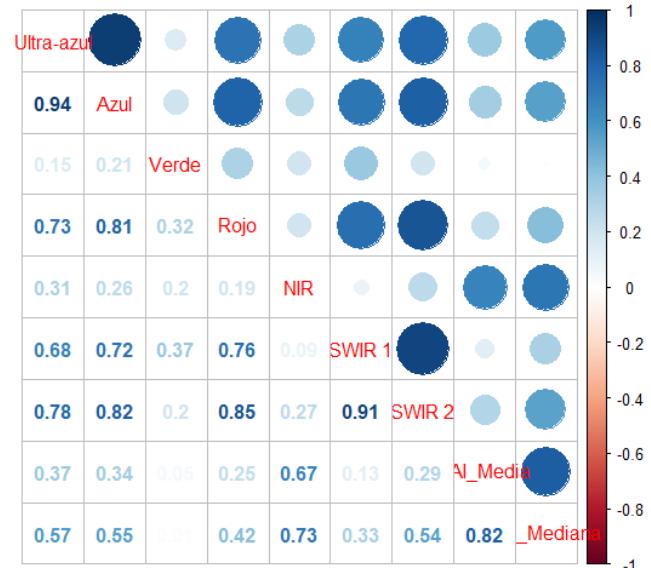


Figura 27. Análisis de Correlación de Pearson y Coeficientes de determinación realizadas entre las bandas del sensor TM (Landsat-5) y OLI (Landsat-8) y estadísticos LAI. Modelo A.