ESCUELA DE DOCTORADO
INTERNACIONAL DE LA USC

Cecilia
Alonso Rego

Tesis doctoral

Estimación de biomasa y características estructurales del combustible en comunidades de matorral desarbolado y pinares en Galicia a partir de escáner láser terrestre, láser aéreo e inventario de campo

Lugo, 2023

Programa de doctorado en Ingeniería para el Desarrollo Rural y Civil

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

TESIS DOCTORAL

Estimación de biomasa y características estructurales del combustible en comunidades de matorral desarbolado y pinares en Galicia a partir de escáner láser terrestre, láser aéreo e inventario de campo

Cecilia Alonso Rego

ESCUELA DE DOCTORADO INTERNACIONAL

DE LA UNIVERSIDAD DE SANTIAGO DE COMPOSTELA

PROGRAMA DE DOCTORADO EN INGENIERÍA PARA EL DESARROLLO RURAL Y CIVIL

LUGO

AÑO 2023

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

DECLARACIÓN DE LA AUTORA DE LA TESIS

Dña. Cecilia Alonso Rego

Título da tese: *Estimación de biomasa y características estructurales del combustible en comunidades de matorral desarbolado y pinares en Galicia a partir de escáner láser terrestre, láser aéreo e inventario de campo*

Presento mi tesis, siguiendo el procedimiento adecuado al Reglamento y declaro que:

1) La tesis abarca los resultados de la elaboración de mi trabajo.

2) De ser el caso, en la tesis se hace referencia a las colaboraciones que tuvo este trabajo.

3) Confirmo que la tesis no incurre en ningún tipo de plagio de otros autores ni de trabajos presentados por mí para la obtención de otros títulos.

Y me comprometo a presentar el Compromiso Documental de Supervisión en el caso que el original no esté depositado en la Escuela.

En Lugo, 12 de junio de 2023.

Firma electrónica

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

AUTORIZACIÓN DE LOS DIRECTORES DE LA TESIS

Estimación de biomasa y características estructurales del combustible en comunidades de matorral desarbolado y pinares en Galicia a partir de escáner láser terrestre, láser aéreo e inventario de campo

Dª. **Ana Daría Ruíz González,** Profesor Titular del Departamento de Ingeniería Agroforestal de la Universidad de Santiago de Compostela.

D. **Ramón Alberto Díaz Varela.** Profesor Contratado Doctor del Departamento de Botánica de la Universidad de Santiago de Compostela.

INFORMAN:

Que la presente tesis, se corresponde con el trabajo realizado por Dª. **Cecilia Alonso Rego,** bajo nuestra dirección, y autorizamos su presentación, considerando que reúne los requisitos exigidos en el Reglamento de Estudios de Doctorado de la USC, y que como directores de esta no incurre en las causas de abstención establecidas en la Ley 40/2015.

De acuerdo con lo indicado en el Reglamento de Estudios de Doctorado, declaramos también que la presente tesis doctoral es idónea para ser defendida en base a la modalidad de COMPENDIO DE PUBLICACIONES, en los que la participación de la doctoranda fue decisiva para su elaboración y las publicaciones se ajustan al Plan de Investigación.

En Lugo, 19 de junio de 2023

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

La presente tesis doctoral ha sido financiada por los siguientes proyectos de investigación: i) GEPRIF (RTA 2014-00011-C04: Reducción de la severidad del fuego mediante nuevas herramientas y tecnologías para la gestión integrada de la protección contra incendios forestales) del Ministerio de Economía y Competitividad; ii) VIS4FIRE (RTA 2017-0042-C05-05: Vulnerabilidad integral de los sistemas forestales frente a incendios: implicaciones en las herramientas de gestión forestal) del Ministerio de Economía, Industria y Competitividad; iii) Gestión y producción de biorrecursos (BioReDes) Agrupación Estratégica 2018 (2018-PG099); y iv) Ayuda de apoyo a la etapa predoctoral (modalidad A) en las universidades del SUG, en los organismos públicos de investigación de Galicia y en otras entidades del sistema gallego de I+D+i, financiada por la "Consejería de Educación, Universidad y Formación Profesional" y la "Consejería de Economía, Empleo e Industria" de la Xunta de Galicia y el programa operativo de la UE "FSE Galicia 2014-2020".

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

AGRADECIMIENTOS

Me gustaría escribir unas líneas que mostraran mi más profunda y sincera gratitud a todas las personas e instituciones que me han ayudado a lo largo del desarrollo de la presente tesis doctoral. Espero no olvidarme de nadie, aunque por ello pido disculpas de antemano.

En primer lugar, quiero agradecer a la Dra. Ana Daría Ruíz González y al Dr. Ramón Alberto Díaz Varela por aceptar ser mis directores de tesis. Fue, es y será siempre una suerte y un orgullo para mí haberos conocido durante mis estudios de grado de Ingeniería Forestal y del Medio Natural y de Máster en Ingeniería de Montes y después poder desarrollar esta tesis bajo vuestra dirección.

A la Dra. Ana Daría, muchas gracias por brindarme la oportunidad de iniciarme en el mundo de la investigación y por confiar en mí. Además de ser una persona con un sentido de la profesionalidad impecable y de sus inmensos conocimientos, su emoción e interés por el mundo forestal en especial por los incendios forestales, es un ejemplo a seguir. Personalmente, quiero agradecer también todos estos años trabajando a su lado, siempre positiva y afectuosa y ofreciendo ayuda en todo momento.

Al Dr. Ramón Alberto, gracias por compartir conmigo su visión y conocimientos por la teledetección, UAV y tecnología LIDAR y su pasión por el trabajo, siempre con un toque de humor.

Y aunque no figure como tutor o director de este trabajo, ha formado parte de él como tal, muchas gracias al Dr. Juan Gabriel Álvarez González por toda la ayuda que me ha prestado, en especial en lo referente a la parte estadística y de modelización.

Agradecer de nuevo a la Dra. Ana Daría y al Dr. Juan Gabriel por siempre ayudarme en la búsqueda de los fondos necesarios para llevar a cabo esta investigación e incorporarme en el grupo de trabajo UXAFORES (Unidad Ambiental y Forestal Sostenible). Dentro de este grupo de temática forestal existen grandes investigadores y profesionales del sector, que además destacan por formar un verdadero equipo dotado con una gran calidad humana. Agradezco en sí a todos y a cada uno de los integrantes del mismo, aunque no podría olvidarme de destacar a la Dra. Ana Daría, al Dr. Juan Gabriel y al Dr. Ulises Diéguez Aranda que me permitieron formar parte de sus clases. Es un honor haber podido estar en los dos lados del aula, sin duda somos unos privilegiados de poder asistir a sus clases. También, destacar a Almudena Pérez, por su afecto, preocupación y atención. Muchas gracias Almudena por ayudarme y asesorarme en cada uno de los problemas diarios que pueden surgir durante la etapa doctoral.

Agradecer a todos los coautores de los artículos publicados, en especial a la Dra. Ana Daría Ruíz González, al Dr. Stéfano Arellano Pérez y al Dr. Fernando Castedo por permitirme utilizar su red de parcelas de matorral y de ensayo de claras que ellos mismos establecieron, además de facilitarme los datos de las mediciones anteriores.

Hablando de las mediciones realizadas y del trabajo de campo, recordar afectuosamente otra de mis mayores suertes, encontrarme con mis compañeros y amigos el Dr. Stéfano Arellano y Mario López. Muchas gracias por dedicarme vuestro tiempo y enseñarme todo sobre nuestra

USC
DE COMPOSTELA

profesión, cada día de trabajo de campo a vuestro lado ha sido una verdadera suerte; destacando vuestro entusiasmo, ilusión, optimismo y profesionalidad en todo momento.

No querría olvidarme de mi etapa en la UTAD (Universidad de Tras os Montes e Alto Douro) por la que me gustaría agradecer tanto a la institución como a mi tutor durante la estancia de doctorado, el Dr. Paulo Alexander Martins Fernandes, por aceptarme en su grupo de investigación, ayudarme y asesorarme durante mi estancia. Agradezco la ayuda de apoyo a la etapa predoctoral (modalidad A) en las universidades del SUG, en los organismos públicos de investigación de Galicia y en otras entidades del sistema gallego de I+D+i, financiada por la "Consejería de Educación, Universidad y Formación Profesional" y la "Consejería de Economía, Empleo e Industria" de la Xunta de Galicia y el programa operativo de la UE "FSE Galicia 2014-2020" por la financiación de esta estancia de investigación.

No puedo expresar más que gratitud a mis compañeros del VIS4FIRE, por cada una de las reuniones, jornadas y actividades realizadas, es un honor haber podido conoceros y aprender de vosotros, un especial recuerdo para el Dr. Francisco Rodríguez y Silva † por su trabajo y profesionalidad, siempre estará presente.

Quisiera dar las gracias, a todos mis amigos y compañeros en la etapa doctoral: Dr. Stéfano Arellano, Dr. Miguel Ángel González, Dr. Juan Alberto Molina, Dr. José Mario González, Joel Rodríguez y Raquel Cela, pues siempre pude contar con vuestra ayuda, apoyo y compañía. Agradecer de manera especial a mi compañera de carrera, máster y doctorado María Flora Romay Río; tu ayuda, comprensión, dedicación y esfuerzo tanto en lo profesional como en lo personal fueron indispensables en todo el proceso. El concepto de amiga se te queda corto, muchísimas gracias por todo tu apoyo. Y por supuesto a los compañeros del café Ana, Susi, Bea, Cristina, Adela, Yago, Javier y Diego.

Agradecer tanto a la Dra. Ana Daría, por permitirme ser cotutora en un Trabajo Fin de Grado y dos Trabajos Fin de Máster, como a los alumnos Ismael Camino, María F. Romay y Noelia Lence, fue un placer poder conoceros y trabajar con gente tan dedicada y entusiasta con su trabajo.

Quiero agradecer a toda mi familia, por vuestro apoyo y ánimo constante. Me siento afortunada de contar con cada uno de vosotros. A mis abuelos, en especial a Isaura Fernández Parapar †, pues como siempre decía, eras mi segunda madre; a mi tío y padrino Manuel Rego Fernández † tu pasión por el mundo forestal y profesionalidad siempre me impresionaron, además nos demostraste que lo único imposible es aquello que no intentas. Ojalá pudieras estar con nosotros, aunque de alguna forma siempre lo estás; a mi tía y madrina María Eugenia Neira Redondas, la humildad y sencillez hecha persona; a mi amiga, prima y casi hermana Vanesa Rego Neira, tus cafés y ánimos siempre estarán conmigo; a mi ahijada Paula Prieto Rego y mi ahijado adoptado Manuel Prieto Rego; a mis primos Samuel Alonso, David Rego y José Prieto y a mis tíos José María Alonso Fernández y María Remedios Espiñeira, quiero daros las gracias a todos y a cada uno de vosotros por formar parte de mi familia y por todo vuestro cariño y apoyo.

Además, como ya he comentado, me siento afortunada, pues me han tocado los mejores padres del mundo. Muchísimas gracias a María Isabel Rego Fernández y a Juan Carlos Alonso Fernández, vuestra ayuda, trabajo, amor y dedicación lo son todo para mí. Me habéis mostrado

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

vuestro apoyo incondicional y esfuerzo incansable. Sois un ejemplo para mí, ojalá yo pueda ser para alguien tan solo una cuarta parte de lo que vosotros significáis para mí.

Finalmente, agradecer de manera especial a Amadeo Molejón Reboredo, por su paciencia, positivismo, comprensión y cariño en cada uno de estos años de tesis. Muchas gracias por tu apoyo y dedicación.

A todos, muchas gracias.

USC
UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

A mis padres, Isabel y Juan.

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

PREFACIO

La presente tesis doctoral se ha podido desarrollar gracias a la ayuda de una beca predoctoral de la Xunta de Galicia (modalidad A) en las universidades del SUG, en los organismos públicos de investigación de Galicia y en otras entidades del sistema gallego I+D+i, cofinanciadas parcialmente por el programa operativo FSE Galicia 2014-2020. Además, se enmarca dentro de las actividades contempladas en los dos proyectos de investigación competitivos que se detallan a continuación y de los cuales la doctoranda ha formado parte del equipo de trabajo:

- RTA2014-00011-C06-04. Reducción de la Severidad del Fuego Mediante Nuevas Herramientas y Tecnologías para la Gestión Integrada de la Protección contra los Incendios Forestales "GEPRIF"
- RTA2017-00042-C05-05. Vulnerabilidad integral de los sistemas forestales frente a incendios: implicaciones en las herramientas de gestión forestal "VIS4FIRE".

El documento de tesis se presenta de acuerdo con la normativa de los estudios de doctorado de la Universidad de Santiago de Compostela bajo la modalidad de "compendio de artículos". La tesis incluye tres artículos científicos publicados en revistas internacionales de acceso abierto y de revisión por pares, incorporadas a la base de datos JCR (*Journal Citation Reports*) de la plataforma *Web of Science*. Se ha añadido además al documento una contribución al 8º Congreso Forestal Español (8CFE), directamente relacionada con el artículo 1. La versión original de cada artículo, así como de la contribución al congreso se incluyen en el apartado de Anexos del presente documento.

A continuación, se detallan las referencias bibliográficas completas de los cuatro documentos, incluyendo sus índices de calidad. Después se especifica la contribución del doctorando a los mismos, así como de los principales autores. También se incluye un apartado en el que se referencian otras aportaciones científicas en las que la doctoranda ha colaborado durante la realización de su tesis al formar parte del equipo de trabajo de los proyectos de investigación anteriormente citados.

Finalmente se incorpora un breve resumen de la estructura de la tesis y de los contenidos de los diferentes capítulos.

Publicaciones incluidas en el documento de tesis con sus índices de calidad:

Artículo 1 (Anexo A)

Alonso-Rego, C., Arellano-Pérez, S., Cabo, C., Ordoñez, C., Álvarez-González, J.G., Díaz-Varela, R.A., Ruiz-González, A.D. (2020). Estimating fuel loads and structural characteristics of shrub communities by using terrestrial laser scanning. *Remote Sensing*, *12*(22), 3704. https://doi.org/10.3390/rs12223704.

Revista incluida en la base de datos JCR ocupando la posición 27 de 200 (86.75%) dentro del apartado *Geosciencies*, *Multidisciplinary* al valorar el índice de impacto (4.848) (*Journal*

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Impact Factor JIF), por lo que se trata de una revista del primer cuartil (Q1) en el año de publicación.

Revista incluida en la base de datos JCR ocupando la posición 44 de 239 (81.80%) dentro del apartado *Geosciencies*, *Multidisciplinary* al valorar el índice de citación (1.15) (*Journal Citation Indicator JCI*), por lo que se trata de una revista del primer cuartil (Q1) en el año de publicación.

Citas (26/05/2023): 10 citas en Google Scholar; 8 citas en *Web of Science*; 6 citas en Scopus

Autorización de la revista: la revista *Remote Sensing* pertenece a la editorial MPDI, que permite la reutilización del artículo por la autora como parte de su tesis doctoral: https://www.mdpi.com/authors/rights

Comunicación 8CFE (Anexo B)

Arellano-Pérez, S., Alonso-Rego, C., López-Fernández, M., Álvarez-González, J.G., Vega, J.A., Ruíz-González, A.D. (2022). Estimaciones de carga y estructura vertical de formaciones de matorral a partir de mediciones de obstrucción visual en campo. En 8º Congreso Forestal Español (8CFE-211). *Sociedad Española de Ciencias Forestales*, Lleida, 27 de junio al 1 de julio. ISBN 978-84-941695-6-4. (Ver documento de autorización en el Anexo B).

Artículo 2 (Anexo C)

Alonso-Rego, C., Arellano-Pérez, S., Guerra-Hernández, J., Molina-Valero, J.A., Martínez-Calvo, A., Pérez-Cruzado, C., Castedo-Dorado, F., González-Ferreiro, E., Álvarez-González, J.G., Ruiz-González, A.D. (2021). Estimating Stand and Fire-Related Surface and Canopy Fuel Variables in Pine Stands Using Low-Density Airborne and Single-Scan Terrestrial Laser Scanning Data. *Remote Sensing*, *13*(24), 5170. https://doi.org/10.3390/rs13245170.

Revista incluida en la base de datos JCR ocupando la posición 30 de 202 (85.40%) dentro del apartado *Geosciencies*, *Multidisciplinary* al valorar el índice de impacto (5.349) (*Journal Impact Factor JIF*), por lo que se trata de una revista del primer cuartil (Q1) en el año de publicación.

Revista incluida en la base de datos JCR ocupando la posición 49 de 245 (80.20%) dentro del apartado *Geosciencies*, *Multidisciplinary* al valorar el índice de citación (1.09) (*Journal Citation Indicator JCI*), por lo que se trata de una revista del primer cuartil (Q1) en el año de publicación.

Citas (26/05/2023): 10 citas en Google Scholar; 6 citas en *Web of Science*; 7 citas en Scopus

Autorización de la revista: la revista *Remote Sensing* pertenece a la editorial MPDI, que permite la reutilización del artículo por la autora como parte de su tesis doctoral: https://www.mdpi.com/authors/rights

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Artículo 3 (Anexo D)

Alonso-Rego, C., Fernandes, P., Álvarez-González, J.G., Arellano-Pérez, S., Ruiz-González, A.D. (2022). Individual-Tree and Stand-Level Models for Estimating Ladder Fuel Biomass Fractions in Unpruned *Pinus radiata* Plantations. *Forests*, *13*(10), 1697. https://doi.org/10.3390/f13101697.

Revista incluida en la base de datos JCR ocupando la posición 14 de 69 (80.43%) dentro del apartado *Forestry* al valorar el índice de impacto (3.282) (*Journal Impact Factor JIF*), por lo que se trata de una revista del primer cuartil (Q1) en el año de publicación.

Revista incluida en la base de datos JCR ocupando la posición 12 de 90 (87.22%) dentro del apartado *Forestry* al valorar el índice de citación (1.11) (*Journal Citation Indicator JCI*), por lo que se trata de una revista del primer cuartil (Q1) en el año de publicación.

Autorización de la revista: la revista *Forest* pertenece a la editorial MPDI, que permite la reutilización del artículo por la autora como parte de su tesis doctoral: https://www.mdpi.com/authors/rights

Este artículo deriva de una estancia realizada en la Universidad de Tras os Montes e Alto Douro (Vila Real-Portugal) bajo la supervisión del Dr. Paulo Alexander Martins Fernandes y financiada por la beca predoctoral de la Xunta de Galicia anteriormente mencionada.

Contribución del autor a las publicaciones incluidas en el documento de tesis

La autora de la presente tesis figura como primer autor en los tres artículos JCR y como segundo autor en la comunicación del 8CFE y ha tenido una contribución significativa en las siguientes tareas:

- Conceptualización del trabajo de investigación junto a los directores de tesis, la Dra. Ana Daría Ruíz González y el Dr. Ramón Alberto Díaz Varela, además del Dr. Juan Gabriel Álvarez (Artículo 1); la Dra. Ana Daría Ruíz González y el Dr. Juan Gabriel Álvarez (Artículos 2 y 3) y el tutor responsable de la estancia de investigación en la Universidad de Tras os Montes e Alto Douro, el Dr. Paulo Alexander Martins Fernandes (Artículo 3).
- Toma de datos de campo junto con Mario López Fernández y los Drs. Stéfano Arellano Pérez y Ana Daría Ruiz González.
- Procesado de la información y análisis estadístico de los datos conjuntamente con los directores, destacando además la especial ayuda del Dr. Juan Gabriel Álvarez González (Artículos 1, 2 y 3) y del Dr. Paulo Alexander Martins Fernández (Artículo 3).
- Análisis y Discusión de los resultados junto con el resto de los coautores.
- Redacción de los documentos junto con los directores de tesis y el Dr. Juan Gabriel Álvarez González, y revisión final de los mismos por los demás coautores.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Otras aportaciones científicas en las que la doctoranda ha colaborado durante el desarrollo de la tesis

Artículos científicos

Alonso-Rego, C., Ruíz-González, A.D., Arellano-Pérez, S. (2018). Evaluación y cartografiado de la severidad de los grandes incendios ocurridos en el distrito forestal XIV (Verín-Viana) entre 2006-2016. *Cuadernos de la Sociedad Española de Ciencias Forestales 44*, (2):169-182.

Arellano-Pérez, S., Castedo-Dorado, F., Álvarez-González, J.G., Alonso-Rego, C., Vega, J.A., Ruiz-González, A.D. (2020). Mid-term effects of a thin-only treatment on fuel complex, potential fire behaviour and severity and post-fire soil erosion protection in fast-growing pine plantations. *Forest Ecology and Management 460*, 117895.

Vega, J.A., Arellano-Pérez, S., Álvarez-González, J.G., Fernández, C., Jiménez, E., Fernández-Alonso, J.M., Vega-Nieva, D., Briones-Herrera, C., Alonso-Rego, C., Fontúrbel, T., Ruiz-González, A.D. (2022). Modelling aboveground biomass and fuel load components at stand level in shrub communities in NW Spain. *Forest Ecology and Management*, *505*, 119926.

Vega, J.A., Arellano-Pérez, S., Álvarez-González, J.G., Fernández, C., Jiménez, E., Cuiñas, P., Fernández-Alonso, J.M., Vega-Nieva, D.J., Castedo-Dorado, F., Alonso-Rego, C., Fontúrbel, T., Ruiz-González, A.D. (2022). Modelling fuel loads of understorey vegetation and forest floor components in pine stands in NW Spain. *Forest Ecosystems*, *9*, 100074.

Congresos y reuniones científicas

Arellano-Pérez, S., Ruíz-González, A.D., Álvarez-González, J.G., Vega-Hidalgo, J.A., Díaz-Varela, R.A., Alonso-Rego, C. (2018). Mapping fire severity levels of burned areas in Galicia (NW Spain) by Landsat images and the dNBR index: Preliminary results about the influence of topographical, meteorological and fuel factor son the highest severity level. Formato póster. En *VIII International Conference on Forest Fire Research*. Coimbra (Portugal), 10 a 16 de noviembre.

Alonso-Rego, C., Arellano-Pérez, S., Ruíz-González, A.D. (2019). Cartografiado de los niveles de severidad del fuego de las zonas quemadas y determinación de la importancia relativa de la meteorología, topografía y vegetación en el distrito forestal XIV (Verín-Viana) usando el índice RdNBR (imágenes LANDSAT). (2019). Comunicación oral. En *I congreso de la juventud investigadora en producción primaria sostenible y calidad y seguridad alimentaria (JIPAS)*. Lugo, 28 a 29 de noviembre.

Alonso-Rego, C., Arellano-Pérez, S., Molina-Valero, J.A., Martínez-Clavo, A., Pérez-Cruzado, C., Castedo-Dorado, F., González-Ferreiro, E., Álvarez-González, J.G. y Ruíz-González, A.D. (2021). Estimación de las variables del combustible de sotobosque y del dosel de copas relacionadas con el riesgo de incendios a partir de datos de un único escaneo con TLS. Comunicación oral. En *I Workshop sobre Teledetección Próxima Terrestre para Aplicaciones Forestales*. Lugo, 1 a 3 de septiembre.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Alonso-Rego, C., Arellano-Pérez, S., Ruíz-González, A.D., Álvarez-González, J.G., López-Fernández, M., Romay-Río, M.F. (2022). Variación de la humedad de los combustibles finos vivos en formaciones de matorral con predominio de *Erica australis* y *Pterospartum tridentatum* en la montaña oriental de Lugo. Comunicación oral. En 8º Congreso Forestal Español (8CFE-223). *Sociedad Española de Ciencias Forestales*, Lleida, 27 de junio al 1 de julio. ISBN 978-84-941695-6-4.

Arellano-Pérez, S., Guerra-Hernández, J., Botequim, B., Alonso-Rego, C., López-Fernández, M., Álvarez-González, J.G., Guilherme-Borges. J., Ruíz-González, A.D. (2022). Estimación de la altura del complejo de combustible en comunidades de matorral desarbolado a partir de datos LIDAR de baja densidad. Formato póster. En 8º Congreso Forestal Español (8CFE-448). *Sociedad Española de Ciencias Forestales*, Lleida, 27 de junio al 1 de julio. ISBN 978-84-941695-6-4.

Estructura de la tesis

El documento de tesis se estructura en 6 capítulos y un apartado de anexos donde se incorporan los artículos que la conforman. Previamente a los capítulos se incluye un resumen de la tesis en castellano, inglés y gallego.

El primer capítulo se corresponde con una introducción a la temática general del sector forestal de Galicia, los incendios forestales, la importancia de la carga de combustible y su estimación, proporcionado una visión global de los conceptos básicos para contextualizar el documento.

En el segundo capítulo se plantean los objetivos principales que motivaron la necesidad de esta investigación, todos ellos relacionados la estimación de cargas y características estructurales del combustible, ya sea de matorral desarbolado, sotobosque bajo pinar o dosel de copas.

El tercer capítulo, material y métodos, describe la información utilizada, así como las metodologías de análisis empleadas, detallando la localización de las áreas de estudio, la recogida de datos y los diferentes procedimientos utilizados para su tratamiento. Se estructura en función de los artículos, pues las metodologías y el tratamiento de los datos son parcialmente diferentes en cada uno de ellos. Además, para facilitar su comprensión, al inicio del apartado se muestra una tabla resumen comparando los diferentes aspectos más relevantes de cada uno de los artículos incluidos en la presente tesis.

El cuarto capítulo, resultados y discusión, se estructura separadamente por artículos, exponiendo los resultados obtenidos y aportando una discusión en base a las diferentes aportaciones de otros autores relacionados con la temática de estudio.

A continuación, se incluye el quinto capítulo con las principales conclusiones derivadas del trabajo de investigación; y, para finalizar, en el sexto capítulo se enumeran las referencias bibliográficas utilizadas.

USC
UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

ÍNDICE

RESUMEN I
RESUMO V
ABSTRACT IX
1. INTRODUCIÓN 3
1.1 Sector forestal de Galicia 3
1.1.1 Los pinares de *Pinus radiata* 5
1.1.2 Los pinares de *Pinus pinaster* 6
1.1.3 Las comunidades de matorral desarbolado 7
1.2. El combustible forestal 10
1.2.1. Clasificación por estado biológico y grosor 11
1.2.2. El complejo de combustible, su distribución vertical y el tipo de incendio 11
1.2.3. La carga de combustible de superficie 13
1.2.4 Las variables estructurales del dosel de copas y los combustibles de continuidad 14
1.2.5. La gestión del combustible 15
1.3 Uso del LiDAR aéreo y terrestre en la evaluación de los combustibles 16
1.3.1 Escáner láser Aerotransportado (ALS) 17
1.3.2 Escáner láser Terrestre (TLS) 18
1.3.3 Combinación de TLS y ALS 20
1.3.4 Técnicas estadísticas Machine Learning 21
2. OBJETIVOS 27
3. MATERIAL Y MÉTODOS 31
3.1 Artículo 1 y comunicación presentada al 8CFE 33
3.1.1. Área de estudio, selección de comunidades de matorral y de parcelas 33
3.1.2 Inventarios de campo y determinación de características del combustible 35
3.1.3 Modelos de estimación de cargas de combustible 42
3.2 Artículo 2 46
3.2.1 Área de estudio y red de parcelas 46
3.2.2 Obtención de datos y variables calculadas 48
3.2.3 Desarrollo de modelos 55
3.3. Artículo 3 57
3.3.1 Selección de parcelas, inventarios y cálculo de variables 57
3.3.2 Ecuaciones de estimación de biomasa total por fracciones para los primeros 6 m del tronco a nivel de árbol individual 61

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

3.3.3. Distribución vertical de la biomasa por fracciones en los primeros 6 m del tronco a nivel de árbol individual. 62
3.3.4 Cargas y distribución vertical de combustibles en los primeros 6 m del tronco a nivel de rodal 63
3.3.5 Análisis estadístico 63
4. RESULTADOS Y DISCUSIÓN 67
4.1 Artículo 1 y comunicación presentada al 8 CFE 67
4.1.1. Metodología de estimación directa de cargas (ED) con TLS 67
4.1.2 Metodología de estimación indirecta de cargas (EI) con TLS 71
4.1.3. Metodología de obstrucción visual en campo 77
4.2 Artículo 2 81
4.2.1. Modelos basados en métricas derivadas de TLS 81
4.2.2. Modelos basados en métricas derivadas de ALS 84
4.2.3. Modelos MARS que combinan métricas derivadas de TLS y ALS 87
4.3. Artículo 3 97
4.3.1 Ecuaciones de estimación de biomasa total por fracciones para los primeros 6 m del tronco a nivel de árbol individual y su distribución vertical 97
4.3.2. Ecuaciones de estimación de carga de combustible total por fracciones para los primeros 6 m del tronco a nivel de rodal y su distribución vertical 101
5. CONCLUSIONES 109
6. BIBLIOGRAFÍA 117
ANEXO A 141
ANEXO B 165
ANEXO C 183
ANEXO D 211

USC
UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

ÍNDICE DE FIGURAS

Figura 1. 1. Distribución geográfica de las masas de *P. radiata* en la Comunidad Autónoma de Galicia. Elaborado a partir de las teselas de Mapa Forestal Español 1:25.000 (MFE25). 5

Figura 1. 2. Distribución geográfica de las masas de *P. pinaster* en la Comunidad Autónoma de Galicia. Elaborado a partir de las teselas de Mapa Forestal Español 1:25.000 (MFE25). 7

Figura 1. 3. Distribución geográfica de las masas de matorral desarbolado en la Comunidad autónoma de Galicia. Elaborado a partir de las teselas de Mapa Forestal Español 1:25.000 (MFE25). 8

Figura 1. 4. Ejemplos de las comunidades de matorral desarbolado incluidas en la presente tesis. De arriba abajo: comunidades con dominancia de *Erica australis*, *Pterospartum tridentatum*, *Ulex gallii* y *Ulex europaeus*. 10

Figura 1. 5. Esquema de los principales tipos de aprendizaje automático (*Machine learning*), la metodología utilizada, los tipos de datos y las posibles aplicaciones en la gestión de los incendios forestales. BRT = *Boosted regression trees*; CART = *Classification and regression tree*; DT = *Decision trees*; FA = *factor analysis*; GA = *Genetic algorithms*; GAM = *Generalized additive model*; GLM = *Generalized linear model*; GMM = *Gaussian mixture models*; GP = *Gaussian processes*; KNN = *K-nearest neighbor*; KM = *k-means clustering*; LDA = *Linear discriminant analysis*; LR = *Logistic regression*; MaxEnt= *Maximum entropy*; MARS = *Multivariate adaptive regression splines*; MLR = *Multiple linear regression*; MM = *Markov models*; PCA = *Principal component analysis*; RF = *Random forest* y SVM = *Support vector machines*. Elaboración propia a partir de Jain et al. (2020). 23

Figura 3. 1. Localización geográfica de las 55 parcelas agrupadas en 4 comunidades de matorral desarbolado empleadas en el desarrollo de modelos de estimación de cargas de combustible a partir de datos de TLS y de métricas derivadas de datos de obstrucción visual..... 34

Figura 3. 2. Ejemplo de cuadrados de muestreo establecidos en comunidades dominadas por *Ulex gallii* / *Ulex minor* (arriba, izquierda), *Ulex europaeus* (arriba, derecha), *Pterospartum tridentatum* (abajo, izquierda) y *Erica australis* (abajo, derecha) para el desarrollo de modelos de estimación de cargas de combustible a partir de datos de TLS y de métricas derivadas de datos de obstrucción visual. 35

Figura 3. 3. Ejemplo de uno de los cuadrados de muestreo incluyendo el transecto lineal (perímetro y diagonal del cuadrado), la ubicación de la banda graduada (centro de la imagen) y croquis con la ubicación del TLS y las franjas limpias de vegetación (arriba, derecha)..... 36

Figura 3. 4. Imagen de la ubicación del TLS (izquierda) y de la toma de datos y escaneo (derecha) en una de las parcelas de muestreo. 38

Figura 3. 5. Ejemplos de cuadrados de muestreo en *Ulex europaeus* (superior) y *Ulex gallii* / *U. minor* (inferior) y nubes de retornos láser derivadas del escaneo del TLS obtenidas tras el procesamiento de los datos brutos. 40

Figura 3. 6. Ejemplo de la obstrucción visual provocada por la vegetación en una de las parcelas de estudio a partir de la cual estimar la carga y la estructura vertical del matorral. 41

Figura 3. 7. Localización geográfica de los 34 lugares de ensayo de clara en el área de estudio (izquierda). Ejemplo de tres parcelas de muestreo (polígonos verdes) en una de las ubicaciones de los ensayos (centro derecha). Disposición de los transectos de muestreo de combustible de superficie en cada parcela (abajo a la derecha). 47

Figura 3. 8. Ejemplos de transectos para inventario de combustible de superficie en cuatro de las parcelas de 25 x 40 m (superior). Croquis con la disposición de los transectos (inferior). 51

Figura 3. 9. Localización geográfica de las masas de *Pinus radiata* en Galicia y de las 20 parcelas incluidas en el estudio (izquierda). Vista de una de las parcelas (abajo a la derecha). 58

Figura 3. 10. Flujo de trabajo seguido para el ajuste de los sistemas de ecuaciones para árbol individual y para rodal. 64

Figura 4. 1. Gráficos de valores observados frente a predichos de las cargas de matorral y hojarasca ($W_{Shr+Litt}$), total de matorral (W_{Shr}), hojarasca (W_{Litt}), matorral grueso (W_{Shr_G23}), matorral fino (W_{Shr_G1}), matorral fino muerto ($W_{Shr_G1_dead}$) y matorral fino vivo ($W_{Shr_G1_live}$) según la metodología de estimación directa. 70

Figura 4. 2. Gráficos de valores observados frente a predichos de las cargas de matorral y hojarasca ($W_{Shr+Litt}$), total de matorral (W_{Shr}), hojarasca (W_{Litt}), matorral grueso (W_{Shr_G23}), matorral fino (W_{Shr_G1}), matorral fino muerto ($W_{Shr_G1_dead}$) y matorral fino vivo ($W_{Shr_G1_live}$) según la metodología de estimación indirecta. 74

Figura 4. 3. Distribución vertical de la frecuencia relativa de los retornos de TLS (a) en dos parcelas de combustible con diferente estructura vertical (b) *Ulex europaeus* y (c) *Ulex gallii*. 76

USC DE SANTIAGO DE COMPOSTELA

Figura 4. 4. Valores observados frente a valores predichos de las cargas de las fracciones de combustibles ajustadas para el total de las parcelas analizadas. La línea punteada es la diagonal y la línea continua es la recta ajustada a los datos. R^2 es el coeficiente de determinación del ajuste de la recta de la figura y *RMSE* es la raíz del error medio cuadrático. 80

Figura 4. 5. Importancia relativa normalizada de las variables independientes en los modelos de mejor ajuste para la estimación de las variables relacionadas con el fuego de superficie (arriba), las variables del dosel relacionadas con el fuego de copas (centro) y las variables de rodal (abajo), respectivamente. Cada círculo concéntrico representa un valor de un 20% sobre el máximo. 93

Figura 4. 6. Gráficos de los valores observados frente a los predichos con los modelos mejor ajustados para estimar las variables relacionadas con el fuego en la superficie y en el dosel y en el rodal. La línea roja representa la relación lineal entre los dos tipos de valores. 96

Figura 4. 7. (Izquierda) Gráficos de dispersión de los valores observados frente a los predichos para la distribución vertical de la biomasa de acículas ($W_{acum_needlesj}$, arriba), leñosos finos (W_{acum_G1j}, centro) y total (W_{acum_totalj}, abajo) de árbol individual. La línea roja sólida indica el modelo lineal ajustado y la línea discontinua indica el ajuste perfecto. (Derecha) Gráficos de caja de la distribución vertical de los residuos de biomasa de acículas ($W_{acum_needlesj}$, superior), leñosos finos (W_{acum_G1j}, medio), y total (W_{acum_totalj}, inferior) según la altura desde el suelo. Los puntos azules indican los valores medios. 100

Figura 4. 8. (Izquierda) Gráficos de dispersión de valores observados frente a predichos para la distribución vertical de la carga de combustible de acículas ($Wstand_{acum_needlesj}$, arriba), leñosos finos ($Wstand_{acum_G1j}$, centro) y total ($Wstand_{acum_totalj}$, abajo) del rodal. La línea roja sólida indica el modelo lineal ajustado y la línea discontinua indica el ajuste perfecto. (Derecha) Diagramas de caja de la distribución vertical de los residuos de la carga de acículas ($Wstand_{acum_needlesj}$, superior), leñosos finos ($Wstand_{acum_G1j}$, medio) y total del rodal ($Wstand_{acum_totalj}$, inferior) según la altura desde el suelo. Los puntos azules indican los valores medios. 105

USC
UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

ÍNDICE DE TABLAS

Tabla 3. 1. Resumen comparativo de las características más importantes de material y métodos de cada uno de los tres artículos que conforman el presente documento de tesis. 32

Tabla 3. 2. Comunidades de matorral, número de parcelas inventariadas (n), códigos, especies dominantes y especies secundarias más frecuentes empleadas en el desarrollo de modelos de estimación de cargas de combustible a partir de datos de TLS y de métricas derivadas de datos de obstrucción visual. 34

Tabla 3. 3. Descripción de las principales características de las capas de matorral y de hojarasca. D.s.= desviación estándar; n = número de parcelas; $hShr$ = altura media del matorral; Cov_{Shr}=cobertura del matorral; $dLitt$ = profundidad media de la hojarasca; $W_{Shr_G1_dead}$ = carga de matorral fino muerto; $W_{Shr_G1_live}$ = carga de matorral fino vivo; W_{Shr_G1} = carga de matorral fino; W_{Shr_G23} = carga de matorral grueso; W_{Shr} = carga total de matorral; W_{Litt} = carga de hojarasca; $W_{Shr+Litt}$ = carga de matorral y de hojarasca. 37

Tabla 3. 4. Métricas derivadas de las nubes de puntos del escáner láser terrestre (TLS). 39

Tabla 3. 5. Ecuaciones *h-d* generalizadas desarrolladas para *P. pinaster* y *P. radiata* en Galicia y estadísticos de bondad del ajuste (Diéguez-Aranda et al., 2009). 49

Tabla 3. 6. Estadísticos de las principales características de rodal y del dosel de copas. D.s. = desviación estándar; N = densidad; G = área basimétrica; h = altura media; H = altura dominante; V = volumen; W = biomasa aérea total; CBH = altura de la base del dosel; CFL = carga de combustible disponible en el dosel; CBD = densidad aparente del dosel; C = control, LT = clara débil y HT = clara fuerte. 50

Tabla 3. 7. Resumen estadístico de las principales variables del combustible de superficie. D.s. = desviación estándar; C= control; HT: clara fuerte; $hShr$ = altura media de la vegetación de sotobosque ponderada por la cobertura; Cov_{Shr} = cobertura del sotobosque; FSG = discontinuidad vertical entre el combustible de superficie y el dosel; W_{debris} = carga de restos leñosos caídos; W_{LFH} = carga de hojarasca y mantillo y W_{Shr} = carga de la vegetación de sotobosque. 52

Tabla 3. 8. Variables de la distribución de alturas de la nube de puntos TLS normalizada. 53

Tabla 3. 9. Estadísticos de las principales variables del árbol individual y del rodal. 60

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Tabla 4. 1. Expresión final del sistema de ecuaciones ajustado simultáneamente para estimar las cargas de combustible de cada fracción, incluyendo el mejor conjunto de variables independientes, las estimaciones de los parámetros, sus errores estándar y los estadísticos de bondad de ajuste. $W_{Shr+Litt}$ = carga de matorral y hojarasca, W_{Shr} = carga total de matorral, W_{Litt} = carga de hojarasca, W_{Shr_G23} = carga de matorral grueso, W_{Shr_G1} = carga de matorral fino, $W_{Shr_G1_dead}$ = carga de matorral fino muerto y $W_{Shr_G1_live}$ = carga de matorral fino vivo. 68

Tabla 4. 2. Expresión final de las ecuaciones ajustadas para estimar Cov_{Shr}, $hshr$ y $dLitt$ a partir de las métricas derivadas del TLS; estimaciones de los parámetros, errores estándar y estadísticos de bondad de ajuste. Cov_{Shr} = cobertura del matorral (%), $hShr$ = altura media del matorral y $dLitt$ = espesor medio de la hojarasca. 72

Tabla 4. 3. Estadísticos de bondad de ajuste obtenidas con las metodologías de estimación directa (ED) y estimación indirecta (EI) para cada fracción de combustible. 75

Tabla 4. 4. Expresión final del sistema de ecuaciones ajustado simultáneamente para estimar la carga de cada fracción de combustible. $W_{Shr+Litt.}$= carga total (matorral + hojarasca), W_{Shr}= carga total de matorral, W_{Litt}= carga de hojarasca, W_{Shr_G23} = carga de matorral grueso, W_{Shr_G1} = carga de matorral fino, $W_{Shr_G1_dead}$= carga de matorral fino muerto y $W_{Shr_G1_live}$= carga de matorral fino vivo. 78

Tabla 4. 5. Estadísticos de bondad de ajuste de los modelos obtenidos a partir de las métricas derivadas del TLS como variables independientes para las tres metodologías siguientes: MARS = *multivariate adaptive regression splines*; SVM = *support vector machine lineal* (SVM-L), *radial* (SVM-R) o *polinómico* (SVM-P); y RF = *Random Forest*. Los mejores resultados para cada variable dependiente se destacan en negrita. 81

Tabla 4. 6. Estadísticos de bondad de ajuste de los modelos obtenidos a partir de las métricas derivadas del ALS como variables independientes para las tres metodologías siguientes: MARS = *multivariate adaptive regression splines*; SVM = *Support Vector Machine Lineal* (SVM-L), R*adial* (SVM-R) o *Polinómico* (SVM-P); y RF = *Random Forest*. Los mejores resultados para cada variable dependiente se destacan en negrita. 85

Tabla 4. 7. Expresión matemática de los modelos MARS ajustados utilizando los tres conjuntos diferentes de métricas (TLS, ALS y TLS+ALS) como variables independientes para estimar las variables relacionadas con el fuego de superficie. 88

Tabla 4. 8. Expresión matemática de los modelos MARS ajustados utilizando tres conjuntos diferentes de métricas (TLS, ALS y TLS+ALS) como variables independientes para estimar las variables relacionadas con el fuego de copas..... 89

Tabla 4. 9. Expresión matemática de los modelos MARS ajustado utilizando los tres conjuntos diferentes de métricas (TLS, ALS y TLS+ALS) como variables independientes para estimar las variables del rodal. 90

Tabla 4. 10. Estadísticos de bondad de ajuste de los modelos ajustados, utilizando los tres conjuntos diferentes de métricas (TLS, ALS y TLS+ALS) como variables independientes. .. 91

Tabla 4. 11. Sistema de 8 ecuaciones ajustado para estimar la biomasa de combustible muerto y su distribución vertical por fracciones para árbol individual. 98

Tabla 4. 12. Estadísticos de las principales variables en los primeros 6 m de la copa muerta y del conjunto del dosel (vivo y muerto). 101

Tabla 4. 13. Sistema de 8 ecuaciones ajustadas para estimar la carga de combustible muerto y su distribución vertical por fracción a nivel rodal. 103

USC
UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

RESUMEN

Los incendios figuran entre las perturbaciones más destructivas de los bosques, causando importantes daños económicos, ecológicos y sociales. El creciente número de graves incendios forestales de los últimos años concuerda con las previsiones de que el cambio climático provocará fenómenos extremos más frecuentes, en forma de megaincendios, que afectarán a grandes zonas y tendrán graves efectos sobre el suelo, la vegetación, los hábitats de la fauna e incluso la pérdida de vidas humanas. Los gestores forestales tratan de prevenir el inicio y la propagación de los incendios forestales mediante la gestión del combustible, especialmente en las zonas propensas a fuegos de copas debido a su mayor intensidad y rápida propagación, que a menudo superan los esfuerzos de extinción y amenazan la seguridad.

La carga de biomasa de las formaciones vegetales, es decir, el peso seco de biomasa por unidad de superficie y su distribución por fracciones de tamaño y estado biológico (vivo/muerto), junto con otras características estructurales como su altura media, o la densidad aparente (biomasa por unidad de volumen), afectan en gran medida a la cantidad de combustible consumida durante el incendio, a la velocidad de propagación o la intensidad, así como a los potenciales efectos del fuego.

En Galicia, región en la que se enmarca principalmente este estudio, la gestión del combustible es una tarea especialmente necesaria por el rápido crecimiento de la vegetación y la gran acumulación de combustible, tanto en matorrales desarbolados como en el sotobosque bajo arbolado. Además, el creciente abandono de los terrenos agrícolas y el aumento de la interfaz urbano-forestal están favoreciendo la continuidad de la superficie forestal. Por otro lado, el aumento de la demanda de madera junto con unas condiciones climáticas favorables, han propiciado el establecimiento de plantaciones forestales de especies de crecimiento rápido como *Pinus pinaster* Ait. y *Pinus radiata* D. Don. cuya gestión es fundamental para reducir el riesgo de fuego de copas. *Pinus radiata* en concreto, es una especie con muy mala poda natural cuyos rodales, si no se gestionan tras el cierre de copas, muestran una preocupante continuidad vertical entre los combustibles de superficie y del dosel puesto que las ramas inferiores al secarse acumulan cantidades significativas de biomasa fina muerta, incluyendo ramillas y acículas suspendidas.

Una correcta gestión del combustible debe de ir acompañada de una previa caracterización del mismo que permita valorar la eficacia de diferentes alternativas mediante el uso de modelos o sistemas de simulación del comportamiento y de los efectos del fuego. De esta forma, se optimizará la repercusión de la gestión del combustible en la gestión del incendio y en su severidad. Hoy en día existen potenciales alternativas al tradicional inventario de campo para la caracterización de los combustibles, incluyendo la tecnología LiDAR, tanto terrestre (TLS) como aerotransportado (ALS), cuya principal fortaleza es su capacidad de aplicación a gran escala para facilitar el cartografiado de los combustibles.

Teniendo en cuenta lo anterior, los objetivos de esta investigación doctoral, que aparecen más desglosados en el apartado 2 son: i) evaluar el uso potencial de datos procedentes de un único escaneo de TLS y de técnicas de obstrucción visual en campo para proporcionar estimaciones precisas de cargas de combustible desagregadas por clase de tamaño y estado vegetativo en cuatro de las principales comunidades de matorral desarbolado de Galicia: *Ulex*

USC DE SANTIAGO

europaeus L, *Ulex gallii* Planch, *Pterospartum tridentatum* L. Wilk y *Erica australis* L. (Artículo 1 y comunicación 8CFE); ii) caracterizar la estructura vertical y espacial de la biomasa en rodales de *Pinus pinaster* y *Pinus radiata* mediante el empleo de sensores remotos (TLS y ALS), estudiando el uso potencial de sus métricas por separado y la integración de ambas para proporcionar estimaciones precisas de variables del combustible relacionadas con los incendios de superficie y del dosel de copas (Artículo 2); y iii) desarrollar modelos de estimación de la biomasa muerta que se acumula en las ramas secas de la parte inferior de las copas (*ladder fuels*) a nivel de árbol individual y de rodal en plantaciones de *Pinus radiata* sin podar (Artículo 3).

Para el desarrollo del primer objetivo (Artículo 1 y comunicación 8CFE), se realizaron inventarios no destructivos en un total de 55 parcelas en comunidades de matorral desarbolado con dominancia de las especies anteriormente mencionadas y distribuidas por toda Galicia. A partir de los inventarios se determinó la altura media y la cobertura de la vegetación, así como el espesor de la hojarasca y mantillo en cada parcela, estimándose las cargas a partir de ecuaciones específicas para cada especie. Además, se llevó a cabo un único escaneo con un láser terrestre (TLS) en cada parcela y se calcularon métricas relacionadas con la distribución vertical y horizontal de las nubes de puntos obtenidas. Se compararon dos enfoques alternativos para estimar las cargas de combustible desagregadas por fracciones a partir de los datos del TLS: i) estimación indirecta en dos pasos (EI) basada en el ajuste de tres ecuaciones para estimar respectivamente la altura del matorral, su cobertura y el espesor de la hojarasca a partir de los datos del TLS para después, utilizar estas estimaciones como entradas de las ecuaciones existentes de carga de combustible; y ii) estimación directa (ED), consistente en ajustar ecuaciones para cada fracción de combustible de interés, relacionando directamente las estimaciones de carga con los datos del TLS. En general, el enfoque directo produjo mejores estadísticos de bondad de ajuste para las fracciones consideradas conjuntamente, con ecuaciones que explican más del 80% de la variabilidad observada para todas las especies y fracciones, excepto para la carga de hojarasca. La técnica de obstrucción visual se basa en colocar una banda graduada verticalmente en el interior del matorral, en realizar mediciones del porcentaje de superficie de las bandas de la barra ocultado por el mismo a diferentes alturas, y en el cálculo de una serie de métricas a partir de ellas. Los modelos obtenidos a partir de estas métricas también resultaron robustos para la estimación de las cargas de todas las fracciones, explicando, en la mayoría de los casos, más del 70% de la variabilidad observada.

Para el desarrollo del segundo objetivo (Artículo 2), se utilizaron datos procedentes de inventarios de arbolado y sotobosque realizados en una red de parcelas de ensayo de claras establecidas en plantaciones puras y coetáneas de *Pinus radiata* y *Pinus pinaster* (total 102 parcelas distribuidas en 34 sitios, principalmente en Galicia). A partir de las mediciones se estimaron variables del rodal y también las variables estructurales más relacionadas con el riesgo de incendio: altura media del combustible de superficie, espesor de la hojarasca y el mantillo, cargas de vegetación del sotobosque y del combustible del suelo, altura media del rodal, altura de la base de la copa (CBH), discontinuidad vertical entre los estratos de superficie y de copas, carga de combustible disponible en el dosel (CFL) y densidad aparente (CBD). Además, a partir de las nubes de puntos obtenidas de ALS de baja densidad y de la realización de un único escaneo con TLS en cada parcela se calcularon diversas métricas relacionadas con la distribución vertical y horizontal de los combustibles forestales. Finalmente, se compararon tres técnicas no paramétricas diferentes de aprendizaje automático (*machine learning*) para evaluar su uso potencial, por separado e integrado, para proporcionar estimaciones precisas de

USC
DE COMPOSTELA

las variables anteriormente mencionadas. Las técnicas utilizadas son: i) *Multivariate Adaptive Regression Splines* (MARS), ii) *Support Vector Machine* (SVM), y iii) *Random Forest* (RF). La selección de la mejor alternativa para la modelización se basó en una comparación de la raíz del error medio cuadrático (*RMSE*) obtenido, optimizando los parámetros de cada técnica y realizando una validación cruzada. En general, los mejores resultados se obtuvieron con las técnicas MARS para los datos de ambos sensores. Los datos TLS proporcionaron los mejores resultados para las variables asociadas con las características internas de la estructura del dosel y el combustible del sotobosque, pero fueron menos fiables para estimar las variables asociadas con la parte superior del dosel, debido a la oclusión producida por la parte intermedia del dosel. La combinación de las métricas ALS y TLS mejoró la precisión de las estimaciones para todas las variables analizadas, excepto la altura y la carga de la vegetación de sotobosque. La variabilidad explicada por el uso combinado de ambos tipos de métricas osciló entre el 43.11% para la biomasa de las capas de mantillo y el 94.25% para la altura dominante del arbolado. Los resultados sugieren que la combinación de técnicas de aprendizaje automático, métricas derivadas de datos ALS de baja densidad, métricas derivadas de un solo escaneo con TLS, o una combinación de ambas métricas, puede ser una alternativa prometedora a los inventarios de campo tradicionales para obtener información valiosa sobre variables del combustible de superficie y del dosel de copas a gran escala.

En cuanto al último objetivo (Artículo 3), se ajustaron dos sistemas de ecuaciones para estimar la biomasa de combustible muerto total y por clase de tamaño en los primeros 6 m de tronco y su distribución vertical en masas puras de *P. radiata* sin podar: un sistema a nivel de árbol individual, cuyas variables independientes son variables árbol y de rodal, y un sistema a nivel de rodal basado sólo en variables de rodal. A pesar de la importante contribución de este tipo de combustible al conjunto de la biomasa de la copa y al riesgo de fuego de copas, todavía no habían sido desarrolladas ecuaciones para su estimación. Para el desarrollo de los modelos se realizaron muestreos destructivos de ramas secas hasta una altura de 6 m en un total de 65 árboles distribuidos en 20 parcelas establecidas en el área de distribución de esta especie en la provincia de Lugo. Los muestreos destructivos se acompañaron de inventarios dasométricos para la obtención de las potenciales variables regresoras de los modelos. Los estadísticos de bondad de ajuste de los dos sistemas de modelos confirmaron la robustez y precisión de las estimaciones. A nivel de árbol individual, los modelos de biomasa total y por fracciones explicaron entre un 35% y un 59% de la variabilidad observada, mientras que los modelos de biomasa acumulada a lo largo del tronco explicaron entre un 62% y un 81%. Por otro lado, a nivel de masa, los modelos de estimación de carga total y por fracciones explicaron entre un 88% y un 98% de la variabilidad observada, mientras que los de carga acumulada explicaron más del 98% de dicha variabilidad. Los resultados indican que estos sistemas permitirán a los gestores cuantificar adecuadamente los combustibles muertos en este tipo de masas de *Pinus radiata* y, por tanto, sus requisitos de gestión para reducir el riesgo de fuego de copas.

Palabras clave: Gestión del combustible forestal, carga de combustible, Galicia, riesgo de incendio, modelización del combustible, matorral desarbolado, sotobosque, combustibles de continuidad, variables estructurales del dosel de copas, escáner láser aerotransportado (ALS), escáner láser terrestre (TLS).

USC
UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

RESUMO

Os lumes figuran entre as perturbacións máis destrutivas dos bosques, causando importantes danos económicos, ecolóxicos e sociais. O crecente número de graves incendios forestais dos últimos anos concorda coas previsións de que o cambio climático provocará fenómenos extremos máis frecuentes, en forma de megaincendios, que afectarán a grandes zonas e terán graves efectos sobre o chan, a vexetación, os hábitats da fauna e mesmo a perda de vidas humanas. Os xestores forestais tratan de previr o inicio e a propagación dos lumes forestais mediante a xestión do combustible, especialmente nas zonas propensas a lumes de copas debido á súa maior intensidade e rápida propagación, que a miúdo superan os esforzos de extinción e ameazan a seguridade.

A carga de biomasa das formacións vexetais, é dicir, o peso seco de biomasa por unidade de superficie e a súa distribución por fraccións de tamaño e estado biolóxico (vivo/morto), xunto con outras características estruturais como a súa altura media, ou a densidade aparente (biomasa por unidade de volume), afectan en gran medida á cantidade de combustible consumida durante o incendio, á velocidade de propagación ou a intensidade, así como aos potenciais efectos do lume.

En Galicia, rexión na que enmarcase este estudo, a xestión do combustible é unha tarefa especialmente necesaria polo rápido crecemento da vexetación e a gran acumulación de combustible, tanto en matogueiras desarboradas como no sotobosque baixo o arborado. Ademais, o crecente abandono dos terreos agrícolas e o aumento da interface urbano-forestal están a favorecer a continuidade da superficie forestal. Doutra banda, o aumento da demanda de madeira xunto cunhas condicións climáticas favorables, propiciaron o establecemento de plantacións forestais de especies de crecemento rápido como *Pinus pinaster* Ait. e *Pinus radiata* D. Don. cuxa xestión é fundamental para reducir o risco de lume de copas. *Pinus radiata* en concreto, é unha especie con moi mala poda natural cuxos rodales, se non se xestionan tras o peche de copas, mostran unha preocupante continuidade vertical entre os combustibles de superficie e do dosel posto que as ramas inferiores ao secarse acumulan cantidades significativas de biomasa fina morta, incluíndo ramillas e acículas suspendidas.

Unha correcta xestión do combustible debe de ir acompañada dunha previa caracterización do mesmo que permita valorar a eficacia de diferentes alternativas mediante o uso de modelos ou sistemas de simulación do comportamento e dos efectos do lume. Desta forma, optimizarase a repercusión da xestión do combustible na xestión do incendio e na súa severidade. Hoxe en día existen potenciais alternativas ao tradicional inventario de campo para a caracterización dos combustibles, incluíndo a tecnoloxía LiDAR, tanto terrestre (TLS) como aerotransportado (ALS), cuxa principal fortaleza é a súa capacidade de aplicación a gran escala para facilitar o cartografiado dos combustibles.

Tendo en conta o anterior, os obxectivos desta investigación doutoral, que aparecen máis desagregados no apartado 2 son: i) avaliar o uso potencial dos datos procedentes dun único escaneo de TLS e de técnicas de obstrución visual en campo para proporcionar estimacións precisas de cargas de combustible desagregadas por clase de tamaño e estado vexetativo en catro das principais comunidades de matogueiras desarboradas de Galicia: *Ulex europaeus* L,

USC DE COMPOSTELA

Ulex gallii Planch, *Pterospartum tridentatum* L. Wilk e *Erica australis* L. (Artigo 1 e comunicación 8CFE); ii) caracterizar a estrutura vertical e espacial da biomasa en rodales de *Pinus pinaster* e *Pinus radiata* mediante o emprego de sensores remotos (TLS e ALS), estudando o uso potencial das súas métricas por separado e a integración de ámbalas para proporcionar estimacións precisas de variables do combustible relacionadas cos incendios de superficie e do dosel de copas (Artigo 2); e iii) desenvolver modelos de estimación da biomasa morta que se acumula nas ramas secas da parte inferior das copas (*ladder fuels*) a nivel de árbore individual e de rodal en plantacións de *Pinus radiata* sen podar (Artigo 3).

Para o desenvolvemento do primeiro obxectivo (Artigo 1 e comunicación 8CFE), realizáronse inventarios non destrutivos nun total de 55 parcelas en comunidades de matogueira desarboradas con dominancia das especies anteriormente mencionadas e distribuídas por toda Galicia. A partir dos inventarios determinouse a altura media e a cobertura da vexetación, así como o espesor da follaxe e mantillo en cada parcela, estimándose as cargas a partir de ecuacións específicas para cada especie. Ademais, levou a cabo un único escaneo cun láser terrestre (TLS) en cada parcela e calculáronse métricas relacionadas coa distribución vertical e horizontal das nubes de puntos obtidas. Comparáronse dous enfoques alternativos para estimar as cargas de combustible desagregadas por fraccións a partir dos datos do TLS: i) estimación indirecta en dous pasos (EI) baseada no axuste de tres ecuacións para estimar respectivamente a altura da matogueira, a súa cobertura e o espesor da follaxe a partir dos datos do TLS para despois, utilizar estas estimacións como entradas das ecuacións existentes de carga de combustible; e ii) estimación directa (ED), consistente en axustar ecuacións para cada fracción de combustible de interese, relacionando directamente as estimacións de carga cos datos do TLS. En xeral, o enfoque directo produciu mellores estatísticos de bondade de axuste para as fraccións consideradas conxuntamente, con ecuacións que explican máis do 80% da variabilidade observada para tódalas especies e fraccións, excepto para a carga de follaxe. A técnica de obstrución visual baséase en colocar unha banda graduada verticalmente no interior da matogueira, e realizar medicións da porcentaxe de superficie das bandas da barra ocupada pola mesma a diferentes alturas, e no cálculo dunha serie de métricas a partir delas. Os modelos obtidos a partir destas métricas tamén resultaron robustos para a estimación das cargas de tódalas fraccións, explicando, na maioría dos casos, máis do 70% da variabilidade observada.

Para o desenvolvemento do segundo obxectivo (Artigo 2), utilizáronse datos procedentes de inventarios de arboredo e sotobosque realizados nunha rede de parcelas de ensaio de claras establecidas en plantacións puras e coetáneas de *Pinus radiata* e *Pinus pinaster* (total 102 parcelas distribuídas en 34 sitios, principalmente en Galicia). A partir das medicións estimáronse variables do rodal e tamén as variables estruturais máis relacionadas co risco de incendio: altura media do combustible de superficie, espesor da follaxe e o mantillo, cargas de vexetación do sotobosque e do combustible do chan, altura media do rodal, altura da base da copa (CBH), descontinuidade vertical entre os estratos de superficie e de copas, carga de combustible dispoñible no dosel (CFL) e densidade aparente (CBD). Ademais, a partir das nubes de puntos obtidas de ALS de baixa densidade e da realización dun único escaneo con TLS en cada parcela calculáronse diversas métricas relacionadas coa distribución vertical e horizontal dos combustibles forestais. Finalmente, comparáronse tres técnicas non paramétricas diferentes de aprendizaxe automática (*machine learning*) para avaliar o seu uso potencial, por separado e integrado, para proporcionar estimacións precisas das variables anteriormente mencionadas. As técnicas utilizadas son: i) *Multivariate Adaptive Regression Splines* (MARS), ii) *Support Vector Machine* (SVM), e iii) *Random Forest* (RF). A selección da mellor

USC DE COMPOSTELA

alternativa para a modelización baseouse nunha comparación da raíz do erro medio cuadrático (*RMSE*) obtido, optimizando os parámetros de cada técnica e realizando unha validación cruzada. En xeral, os mellores resultados obtivéronse coas técnicas MARS para os datos de ambos os sensores. Os datos TLS proporcionaron os mellores resultados para as variables asociadas coas características internas da estrutura do dosel e o combustible do sotobosque, pero foron menos fiables para estimar as variables asociadas coa parte superior do dosel, debido á oclusión producida pola parte intermedia. A combinación das métricas ALS e TLS mellorou a precisión das estimacións para tódalas variables analizadas, excepto a altura e a carga da vexetación de sotobosque. A variabilidade explicada polo uso combinado de ambos os tipos de métricas oscilou entre o 43.11% para a biomasa das capas de mantillo e o 94.25% para a altura dominante do arborado. Os resultados suxiren que a combinación de técnicas de aprendizaxe automática, métricas derivadas de datos ALS de baixa densidade, métricas derivadas dun só escaneo con TLS, ou unha combinación de ambas as métricas, pode ser unha alternativa prometedora aos inventarios de campo tradicionais para obter información valiosa sobre variables do combustible de superficie e do dosel de copas a gran escala.

En canto ao último obxectivo (Artigo 3), axustáronse dous sistemas de ecuacións para estimar a biomasa de combustible morto total e por clase de tamaño nos primeiros 6 m de tronco e a súa distribución vertical en masas puras de *P. radiata* sen podar: un sistema a nivel de árbore individual, cuxas variables independentes son variables árbore e de rodal, e un sistema a nivel de rodal baseado só en variables de rodal. A pesar da importante contribución deste tipo de combustible ao conxunto da biomasa da copa e ao risco de lume de copas, aínda non foran desenvolvidas ecuacións para a súa estimación. Para o desenvolvemento dos modelos realizáronse mostraxes destrutivas de ramas secas ata unha altura de 6 m nun total de 65 árbores distribuídas en 20 parcelas establecidas na área de distribución desta especie na provincia de Lugo. As mostraxes destrutivas acompañáronse de inventarios dasométricos para a obtención das potenciais variables regresoras dos modelos. Os estatísticos de bondade de axuste dos dous sistemas de modelos confirmaron a robustez e precisión das estimacións. A nivel de árbore individual, os modelos de biomasa total e por fraccións explicaron entre un 35% e un 59% da variabilidade observada, mentres que os modelos de biomasa acumulada ao longo do tronco explicaron entre un 62% e un 81%. Doutra banda, a nivel de masa, os modelos de estimación de carga total e por fraccións explicaron entre un 88% e un 98% da variabilidade observada, mentres que os de carga acumulada explicaron máis do 98% da devandita variabilidade. Os resultados indican que estes sistemas permitirán aos xestores cuantificar adecuadamente os combustibles mortos neste tipo de masas de *Pinus radiata* e, por tanto, os seus requisitos de xestión para reducir o risco de lume de copas.

Palabras chave: Xestión do combustible forestal, carga de combustible, Galicia, risco de incendio, modelización do combustible, matogueira desarborado, sotobosque, combustibles de continuidade, variables estruturais do dosel de copas, escáner láser aerotransportado (ALS), escáner láser terrestre (TLS).

USC
UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

ABSTRACT

Wildfires are amongst the most destructive types of disturbance affecting forests and have important economic, ecological and social impacts. The increase in the number of severe forest fires in recent years is consistent with predictions indicating that climate change will cause more frequent extreme events in the form of megafires, which will affect large areas, with serious effects on soil, vegetation, wildlife habitats and even loss of human life. Forest managers use fuel management practices in order to prevent fire initiation and propagation, especially in zones where crown fires are likely to occur. Crown fires are usually intense, propagate rapidly and often exceed extinction efforts and threaten the safety of firefighters.

The biomass load of plant formations, i.e. the dry weight of biomass per unit of area and its distribution by size fractions and biological state (live/dead), along with other structural characteristics, such as mean height or bulk density (biomass per unit of volume), greatly affect the amount of fuel consumed during fires, the rate of fire propagation or intensity, as well as the potential impacts of the fire.

In Galicia, the region where most of the present study was carried out, fuel management is particularly important due to the rapid growth of vegetation and the accumulation of large amounts of fuel, both in treeless shrubland and in the forest understorey. In addition, the abandonment of agricultural land and the increase in the urban-forest interface are favouring the continuity of forest cover. On the one hand, the increase in demand for timber and the favourable climate conditions have promoted the establishment of plantations of rapidly growing forest species such as *Pinus pinaster* Ait. and *Pinus radiata* D. Don., management of which is essential to reduce the risk of crown fires. Stands of *P. radiata* display poor natural pruning. If these stands are not managed after crown closure, a dangerous increase in the vertical continuity between the surface fuel and the canopy will therefore occur, because the lower branches accumulate large amounts of dead biomass, including twigs and suspended needles, as they dry out.

Correct fuel management should be accompanied by prior characterization of the fuel, to evaluate the effects of different alternative methods by using fire behaviour models or simulation systems. This will enable the optimization of fuel management strategies in fire management and in its severity. Some alternatives to traditional field inventories are now available, including both terrestrial laser scanning (TLS) LiDAR and aerial laser scanning (ALS) LiDAR. The main strength of these methods is that their large scale application facilitates fuel mapping.

Taking all of the above into account, the objectives of the doctoral research reported in this thesis (presented in greater detail in section 2) were as follows: i) to evaluate the potential use of data derived from a single TLS scan and of visual obstruction measurements in the field to provide precise estimates of fuel loads disaggregated by size classes and vegetative state in four of the main treeless shrub communities in Galicia: *Ulex europaeus* L, *Ulex gallii* Planch, *Pterospartum tridentatum* L. Wilk and *Erica australis* L. (Article 1 and communication 8CFE); ii) to characterize the vertical and spatial structure of the biomass in *P. pinaster* and *P. radiata* stands by the use of remote sensors (TLS and ALS), studying the potential individual and

USC
DE COMPOSTELA

combined use of the metrics to provide precise estimates of fuel variables related to surface fires and crown fires (Article 2); and iii) to develop models for estimating the dead biomass accumulated in the branches of the lower part of the crowns (ladder fuel) at individual tree and stand levels in unpruned *P. radiata* stands (Article 3).

In order to address the first objective (Article 1 and communication 8CFE), non-destructive inventories were conducted in a total of 55 plots in treeless shrub communities dominated by the previously mentioned species and distributed across Galicia. The mean height and vegetation cover, as well as the depth of the litter and duff layer, were determined in inventories in each plot, and the loads were estimated using specific models for each species. In addition, a single TLS scan was conducted in each plot, and the metrics related to the vertical and horizontal distribution of the point clouds were determined. The TLS data were used to estimate the fuel loads disaggregated by fractions, in two different approaches: i) indirect estimation (IE) in two steps, involving fitting three equations to estimate respectively the shrub height, shrub cover and the depth of the litter and duff layer using the TLS data, and then using the estimates thus obtained as input for existing fuel load models; and ii) direct estimation (DE), consisting of fitting equations for each fuel fraction of interest and directly relating the estimated loads with the TLS data. In general, the DE approach produced better model fits for all fractions considered together, with models that explained more than 80% of the observed variability for all species and fractions, except the litter. The visual obstruction method was also evaluated. This method involves placing a banded measuring stick inside the shrub and measuring the percentage of the bands occluded by the shrub at different heights and then calculating a series of metrics from these measurements. The models obtained with these metrics also provided robust estimates of the loads of all fractions, in most cases explaining more than 70% of the observed variability.

Regarding the second objective (Article 2), the data used were derived from tree and understorey inventories conducted in a network of thinning trial plots established in pure and mixed stands of *P. radiata* and *P. pinaster* (in total 102 plots distributed across 34 sites, mainly in Galicia). The measurements were used to estimate stand variables and also the structural variables most closely related to the fire risk: mean height of the surface fuel, depth of the litter and duff layers, understorey vegetation and ground fuel loads, mean stand height, crown base height (CBH), vertical discontinuity between the surface crown layers, canopy fuel load (CFL) and canopy bulk density (CBD). In addition, the low density ALS point clouds and data from a single TLS scan in each plot were used to calculate various metrics related to the vertical and horizontal distribution of the forest fuels. Finally, three different non parametric machine learning techniques were compared in order to evaluate their potential use, individually and in combination, to provide accurate estimates of the previously mentioned variables. The following techniques were used: i) *Multivariate Adaptive Regression Splines* (MARS), ii) *Support Vector Machine* (SVM), and iii) *Random Forest* (RF). Selection of the best technique for the modelling was based on comparison of the root mean square error (*RMSE*) obtained, optimizing the parameters of each technique, and conducting crossed validation. In general, the best results were obtained with the MARS technique for data from both sensors. The TLS data provided the best results for variables associated with the internal characteristics of the canopy structure, but they were less reliable for estimating variables associated with the upper part of the canopy, due to the occlusion produced by the intermediate part of the canopy. The combination of ALS and TLS metrics improved the accuracy of the estimates of all of the variables analysed, except the height and load of understorey vegetation. The variability

USC
DE COMPOSTELA

explained by the combined use of both types of metrics ranged between 43.11% for the biomass of the litter and duff layer and 94.25% for the dominant height of the stand. The results suggest that the combination of machine learning techniques and metrics derived from low density ALS data or metrics derived from a single TLS scan or both metrics, may be a promising alternative to traditional field inventories for obtaining valuable information about surface and canopy fuel variables on a large scale.

Regarding the final objective (Article 3), two model systems were used to estimate the total biomass of dead fuel and the biomass of each size class in the first 6 m of the stem and the vertical distribution of each in pure, unpruned stands of *P. radiata*: an individual tree level system, in which the independent variables were tree and stand, and a stand level system based only on stand variables. Despite the important contribution of dead fuel to the crown biomass and to the risk of crown fire, there are not yet any specific models for estimating the amounts of this type of fuel. For model development, destructive sampling of dry branches was conducted to a height of 6 m in a total of 65 trees in 20 plots established across the area of distribution of this species in the province of Lugo. The destructive sampling was accompanied by tree measurement inventories to determine the potential regressor variables. The goodness of fit statistics for the two model systems confirmed the robustness and accuracy of the estimates. At the individual tree level, the models of total biomass and the biomass fractions explained between 35% and 59% of the observed variability, whereas the models of accumulated biomass along the stem explained between 62% and 81% of the variability. At the stand level, the models estimating the total load and the various fractions explained between 88% and 98% of the observed variability, whereas the models for the accumulated loads explained more than 98% of the variability. The results indicate that these systems will enable managers to quantify dead fuel in these types of *P. radiata* stands and therefore comply with the management requirements for reducing the risk of crown fire.

Keywords: Forest fuel management, fuel loads, Galicia, fire risk, fuel modelling, treeless shrub, understorey, ladder fuels, canopy structural variables, aerial laser scanning (ALS), terrestrial laser scanning (TLS).

USC
UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

1. Introducción

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

1. INTRODUCIÓN

En este apartado se detallan los aspectos más relevantes para la contextualización del documento de tesis. En primer lugar, se ofrece una visión del sector forestal de la Comunidad Autónoma de Galicia y se describen aspectos generales de las formaciones objeto de estudio: pinares de *Pinus pinaster* Ait. y de *Pinus radiata* D. Don y comunidades de matorral desarbolado. A continuación, se definen conceptos básicos de los incendios y de los combustibles forestales, describiéndose las variables modelizadas en la presente tesis, incluyendo cargas de combustible de superficie, variables estructurales del dosel y combustibles de continuidad. También se hace referencia a las alternativas para la evaluación de los combustibles, poniéndose especial énfasis en los sensores remotos activos utilizados: escáner láser terrestre (TLS) y escáner láser aerotransportado (ALS) y a las técnicas *machine learning* utilizadas.

1.1 Sector forestal de Galicia

Históricamente el sector forestal ha servido de sustento y abastecimiento a la sociedad a lo largo de los años, desempeñando diferentes funciones: i) económicas como resultado de la venta de madera para aprovechamiento o como activo para diferentes actividades como la construcción, o la elaboración de fármacos; ii) ambientales, ya que los bosques albergan la mayor parte de la biodiversidad terrestre (FAO y PNUMA, 2020), además, según la Declaración de Rio sobre el Medio Ambiente y el Desarrollo (ONU, 1992), los bosques desempeñan un papel esencial en la reducción de las emisiones de gases de efecto invernadero y mitigación del cambio climático, siendo grandes sumideros de carbono; y iii) sociales, de uso recreativo, paisajístico y sirviendo como fuente de alimento a la sociedad y a la fauna.

La Comunidad Autónoma de Galicia está localizada en un área geográfica caracterizada por dos influencias climáticas, la mediterránea y la atlántica, destacando por unas elevadas precipitaciones y unas temperaturas suaves, con un cierto nivel de sequía estival, siendo una de las zonas de mayor productividad forestal de Europa, aunque, como contrapartida, también implica grandes acumulaciones de combustible en las zonas forestales que favorecen los incendios de alta intensidad (Fernandes y Rigolot, 2007; Arellano-Pérez et al., 2017b; Vega et al., 2022a; 2022b).

El territorio gallego cuenta con una amplia vocación forestal, pues según el IV Inventario Forestal Nacional (MARM, 2011a), de su extensión total próxima a los 3 millones de ha, algo más de 2 millones corresponden a uso forestal, con un alto potencial de productividad (Marey-Pérez y Rodríguez-Vicente, 2009). En cuanto al terreno forestal, se conforma principalmente por monte arbolado (70% de la superficie), es decir, terrenos poblados con especies forestales arbóreas como manifestación vegetal dominante y con una fracción de cabida cubierta (FCC) superior al 5%; mientras que el 30% restante de la superficie forestal figura como monte desarbolado, es decir, terrenos poblados con especies de matorral y/o pastizal natural o con débil intervención humana, con presencia o no de árboles forestales pero, en este último caso, con una fracción de cabida cubierta inferior al 5% (MARM, 2011a).

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

De los aproximadamente 1.4 millones de ha que conforman la superficie forestal arbolada de Galicia, el 30% corresponden a masas de coníferas puras, el 20% a eucaliptales y el resto a frondosas autóctonas mezcladas con otras especies (MARM, 2011a). Dentro del grupo de las coníferas, tiene mayor representación territorial como especie dominante *Pinus pinaster*, con más del 15% de la superficie arbolada y en segundo lugar la especie *Pinus radiata*, que ocupa el 7% y aproximadamente el mismo porcentaje en existencias respecto al total gallego (MARM, 2011a). Teniendo en cuenta los datos del Anuario Forestal de Estadística de la Consellería de Medio Rural sobre los volúmenes medios de aprovechamientos madereros de Galicia (Xunta de Galicia, 2022), estas dos especies ocupan la segunda y tercera posición respectivamente, solo por detrás de los eucaliptales, con aprovechamientos de madera de más de 1.8 millones de m^3 (*P. pinaster*) y de 1.7 millones de m^3 (*P. radiata*) en el período comprendido entre 2018 y 2022, siendo Lugo la provincia con mayor volumen maderero de pino radiata y A Coruña de pino pinaster. Además, las condiciones climáticas templadas de la Comunidad y el aumento de la demanda de madera han favorecido el establecimiento de plantaciones forestales comerciales de estas coníferas de crecimiento rápido (MARM, 2011a).

Hay que destacar también que una parte importante de los montes de Galicia están incluidos en la Red Gallega de Espacios Naturales Protegidos, lo que pone de manifiesto la relevancia e importancia que éstos tienen en el mantenimiento y conservación de la riqueza y biodiversidad de la flora y fauna, sistemas hidrológicos, protección del suelo y ecosistemas en general.

No obstante, el sector forestal gallego se ve amenazado por una serie de factores entre los que destacan: i) el incremento del abandono de la propiedad forestal, evidenciado por el constante despoblamiento del medio rural; ii) el fraccionamiento de la propiedad forestal, con más de 650 mil propietarios forestales con una parcela media de aproximadamente 2-3 ha (Xunta de Galicia, 2022); y, iii) por los incendios forestales, siendo Galicia una de las regiones más afectada en Europa (Koutsias et al., 2015; San-Miguel-Ayanz et al., 2020), generando daños ambientales (FAO, 2007), económicos (Rodríguez y Silva et al., 2012) y sociales.

El régimen de incendios depende principalmente de tres factores que lo condicionan: el clima, los combustibles forestales y las fuentes de ignición (Vega et al., 2021). Todos ellos están interrelacionados entre sí, y son una de las causas de la problemática de los incendios forestales en Galicia, pues existe: i) una gran simultaneidad de puntos de ignición, ii) una elevada carga de combustible en los montes, que dificulta en gran medida a los operativos de extinción, iii) y una época estival marcada por los incendios. Autores como Vega et al. (2009a; 2021) o Barreal y Jannes (2020), explican que en los últimos dos decenios uno de los máximos en cuanto al número de incendios se da en el mes de agosto y que el máximo de superficie quemada se encuentra en dicho mes, aunque el régimen espacial y temporal del número de incendios y de superficie quemada es muy heterogéneo. Esta temática está muy desarrollada en numerosos estudios como (Chas-Amil et al., 2013; Balsa-Barreiro y Hermosilla, 2013; Barreal y Loureiro, 2015). De hecho, según el Plan de Prevención y Defensa contra Incendios de Galicia (PLADIGA) (Xunta de Galicia, 2022), en el periodo 2013-2022 la superficie media quemada cada año no llega a las 20.000 ha de las cuales el 39% corresponde a superficie arbolada y el 61% a superficie rasa. Vega et al. (2021) explican que las especies arbóreas más afectadas por los incendios forestales son las masas de *Pinus pinaster* que ocupan la segunda posición de los bosques españoles (5%) y la primera en cuanto a las coníferas de Galicia, y la especie *Pinus radiata* que ocupa la décima posición estatal y segunda conífera gallega.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

1.1.1 Los pinares de *Pinus radiata*

Pinus radiata D. Don es una conífera de la familia de las Pináceas, también conocida como pino de Monterrey, haciendo referencia a su lugar de origen (comarca californiana de Monterrey – Estados Unidos-) o como pino radiata o pino insigne. *P. radiata* puede alcanzar una altura de 20 - 30 m, tiene piñas serótinas que permanecen viables en el árbol durante muchos años y la característica más diferencial es la morfología de sus acículas, por lo general envainadas de tres en tres, de color verde intenso y miden sobre 10 - 15 cm. Presenta mayores crecimientos en zonas con abundantes precipitaciones a lo largo del año y con temperaturas suaves, florece a finales de invierno o principios de primavera, pero las piñas no maduran hasta el otoño del siguiente año de la floración (McDonald et al., 1990). La fructificación comienza entre los años 5 y 10, aunque depende en gran medida del grosor de los árboles y, por lo tanto, de la espesura de la masa forestal (McDonald et al., 1990). Se pueden establecer masas de *P. radiata* mediante regeneración natural por la fructificación de las semillas en primavera, sin embargo, en Galicia la regeneración natural de esta especie es escasa, debido a las altas densidades de las plantaciones forestales existentes y a diversos inconvenientes por la incertidumbre del regenerado, el control de su densidad, con mayores costes de clareo, problemas de competencia inicial, menores crecimientos y mayores dificultades a la hora de aplicar tratamientos silvícolas (Sánchez y Rodríguez, 2008). Esta especie, ampliamente representada en Galicia, en especial en la provincia de Lugo (ver Figura 1.1) cuenta con un gran aprecio por parte de los propietarios y las industrias forestales debido a sus características estructurales, la gran adaptación y el menor turno de corta con respecto a otras coníferas presentes en el territorio.

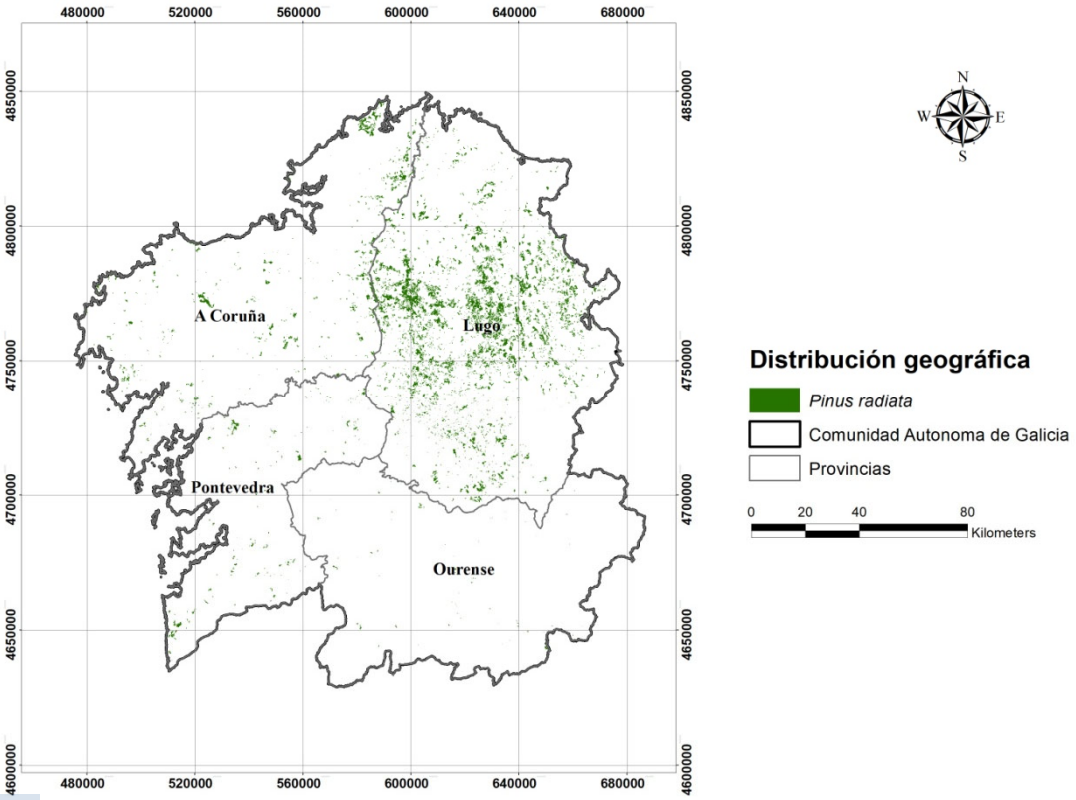

Figura 1. 1. Distribución geográfica de las masas de *P. radiata* en la Comunidad Autónoma de Galicia. Elaborado a partir de las teselas de Mapa Forestal Español 1:25.000 (MFE25).

Existen diferentes modelos silvícolas o de gestión forestal para *P. radiata* en Galicia, en función del tipo de propiedad forestal y del destino de la madera. El más común va dirigido a la obtención de madera para trituración con un pequeño porcentaje para sierra, buscando una alta productividad (Consellería de Medio Rural, 2021). Las plantaciones características de la zona emplean un marco de 3.5 x 3.5 m y una densidad de plantación de 815 - 1140 plantas ha^{-1}, con reposición posterior de marras, abonado y desbroce total en el primer año. Como tratamientos selvícolas se aplica una poda baja de hasta 2.5 - 3 m cuando el diámetro normal alcanza los 10 cm y una clara del 30 - 50% de los pies entre los años 10 - 15. Finalmente, se realiza una corta a hecho a los 20 - 30 años, dependiendo de la calidad de estación.

No obstante, gran parte de las plantaciones de *P. radiata* carecen de dicha gestión, mostrando una gran cantidad de combustible muerto distribuido verticalmente entre el combustible de superficie y la copa viva, lo que conlleva una cierta continuidad entre ambos estratos, favoreciendo la propagación vertical del fuego. Esta particularidad de las plantaciones de *Pinus radiata* se debe, además de a una falta de gestión, a su mala poda natural (Keeley y Zedley, 1998).

1.1.2 Los pinares de *Pinus pinaster*

La especie *Pinus pinaster* Ait. es originaria de la región mediterránea occidental y del oeste de Europa. Está muy presente en el noroeste español por las condiciones de clima templado y la ausencia de largos periodos de heladas o sequías, siendo la conífera más representativa de la Comunidad autónoma de Galicia (ver Figura 1.2). Se suele nombrar con otras denominaciones diferentes de pino pinaster como, pino negral, pino gallego o, dentro de Galicia, como pino del país. Es un árbol que alcanza normalmente una altura de 20-30 m. Las acículas son muy largas y gruesas, miden de 10-25 cm y se disponen en grupos de dos. Pueden vivir y desarrollarse en suelos poco fértiles y tiene una gran facilidad para regenerar. Estos pinares florecen en los meses de abril y mayo y las piñas son de gran tamaño y serótinas, maduran en otoño del siguiente año y se abren en abril y mayo del tercer año (Rodríguez y Madrigal, 2008). La intensidad y frecuencia de los tratamientos silvícolas a las masas forestales dependen del destino de la madera, es decir, si el objetivo es la obtención de madera de calidad, se les aplicará una mayor gestión silvícola, con podas para evitar nudos, y clareos y claras para obtener mayores diámetros. Sin embargo, si el destino de la madera es la trituración, o la producción de tabla de baja calidad no será necesaria la realización de podas. Las podas se pueden realizar durante todo el año, sin embargo, si las ramas están vivas es preferible que se realice entre agosto y febrero para evitar problemas fitosanitarios (Rodríguez y Madrigal, 2008)

Es una especie muy apreciada por el sector del aprovechamiento maderero, como el del aserrado y, al igual que para el pino radiata, existen diferentes modelos silvícolas para *P. pinaster* en Galicia, en función del tipo de propiedad forestal y del destino de la madera. El más común sigue siendo el modelo dirigido a la obtención de madera para trituración con un pequeño porcentaje para sierra, buscando una alta productividad (Consellería de Medio Rural, 2021). Las plantaciones típicas de la zona emplean un marco de 3.5 m entre líneas como mínimo y 2 o 2.5 m entre plantas, que conforman una densidad de plantación de 1430 o 1440 plantas

ha^{-1}, con reposición de marras, abonado y desbroce total en el primer año. Como tratamientos silvícolas, se aplica una poda baja de hasta 2.5 - 3 m cuando los árboles alcanzan una altura de 6 - 7 m y el diámetro normal medio alcanza los 10 cm, opcionalmente se puede realizar un clareo en los primeros años y una clara por lo bajo y selectiva hasta dejar 750 - 900 pies ha^{-1} (12 - 20 años), eliminando entre un 20 - 30% de los pies dependiendo del riesgo de derribo por viento, y una clara opcional a los 15 - 25 años, si se quiere aumentar el porcentaje de madera para sierra. Finalmente, se realiza una corta a hecho a los 25 - 35 años, dependiendo de la calidad de estación.

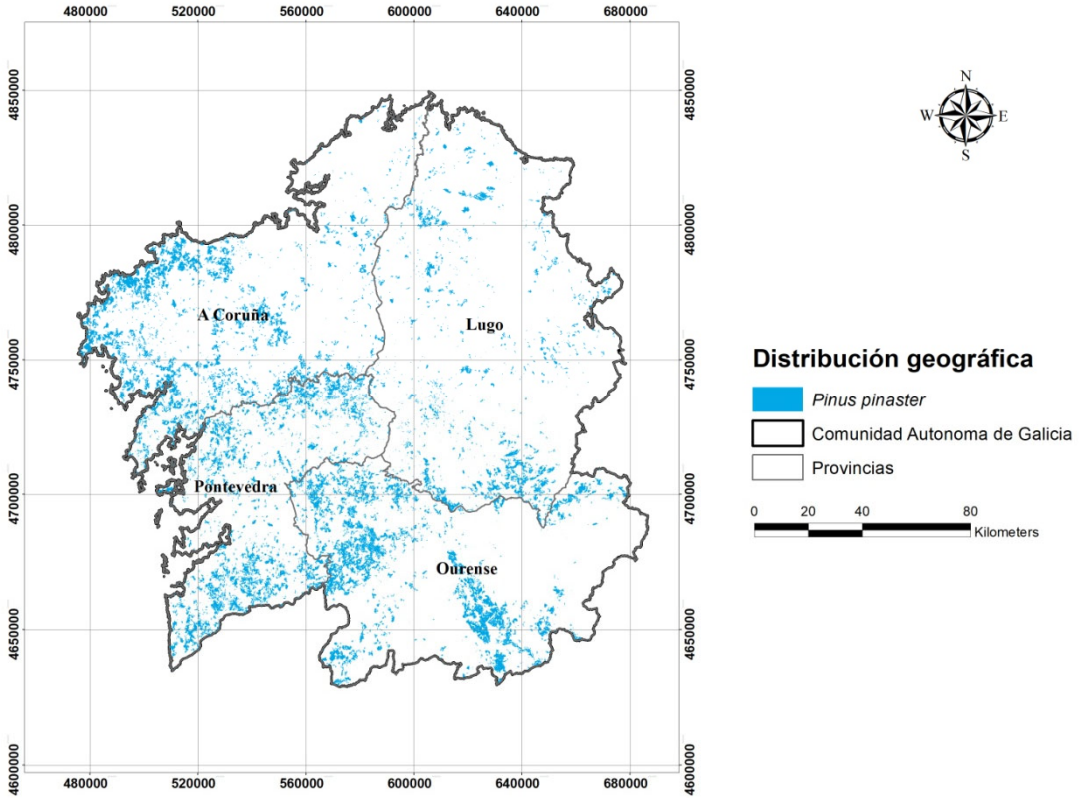

Figura 1. 2. Distribución geográfica de las masas de *P. pinaster* en la Comunidad Autónoma de Galicia. Elaborado a partir de las teselas de Mapa Forestal Español 1:25.000 (MFE25).

1.1.3 Las comunidades de matorral desarbolado

Las comunidades arbustivas o de matorral desarbolado (Figura 1.3) cubren en Galicia unas 607 mil ha, lo que supone el 20% de la superficie total de la Comunidad y el 30% de su superficie forestal, predominando los tojales (comunidades dominadas por especies del género *Ulex* como *U. europaeus* L. o *U. gallii* Planch) y los brezales (con dominancia de especies ericáceas como *Calluna vulga*ris L., *Erica australis* L., *E. arborea* L., *E. umbellata* Loefle ex L., *E mackaiana* Bab. In J. Mackay o *E. ciliaris* Loefle ex L., entre otras) que ocupan respectivamente el 55% y el 22% de dicha superficie desarbolada (MARM, 2011b). Destacan también, aunque con menor representación territorial (entorno al 11% de la superficie desarbolada) los retamares de los géneros *Cytisus*, y *Genista* o los carquesales de *Pterospartum tridentatum* (L.) Wilk. Existen además otras formaciones de matorral de distribución más restringida como los jarales o madroñales que en su conjunto ocupan una extensión limitada en

Galicia. Todas estas comunidades están constituidas por especies leñosas perennes, con tallos múltiples o de gran ramosidad, forman masas muy densas en términos de número de plantas por unidad de superficie y presentan una elevada cobertura, cercana en muchos casos al 100%, alcanzando alturas muy variadas, pudiendo llegar o incluso superar los 3 m (Arellano et al., 2017b; Vega et al., 2022b).

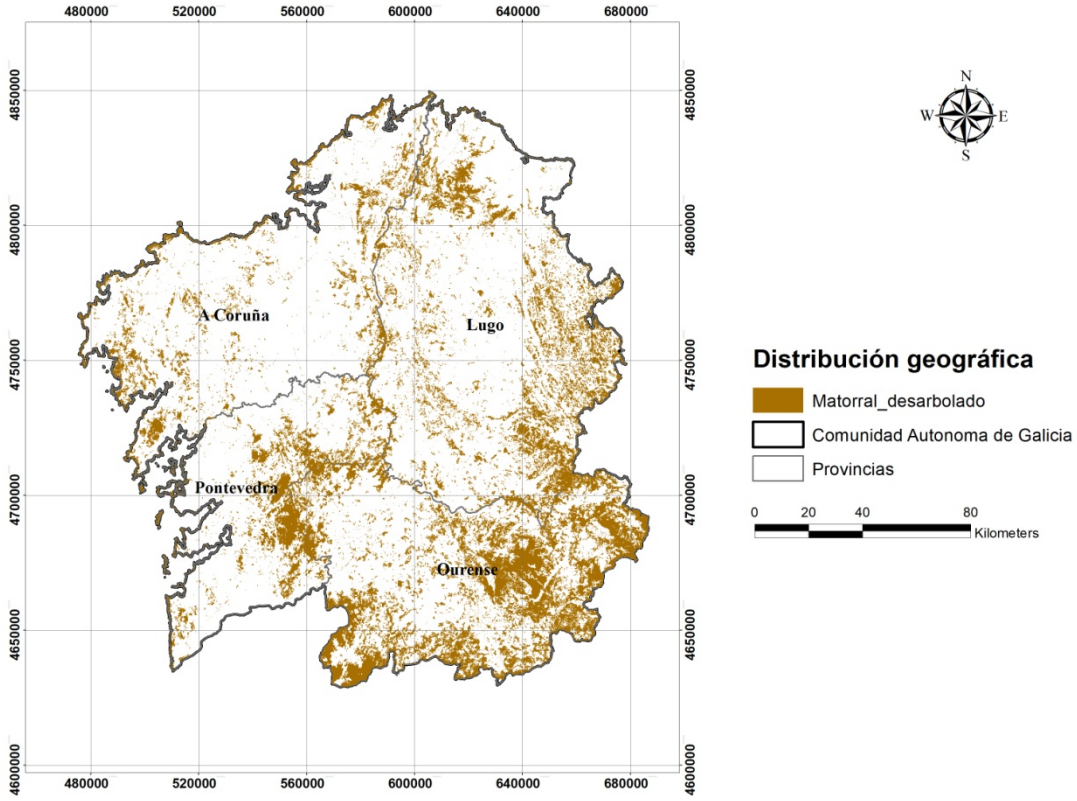

Figura 1. 3. Distribución geográfica de las masas de matorral desarbolado en la Comunidad autónoma de Galicia. Elaborado a partir de las teselas de Mapa Forestal Español 1:25.000 (MFE25).

A continuación, se especifican alguna de las características de las comunidades incluidas en el estudio (Castroviejo, 1986 - 2015) (Figura 1.4): brezales con dominancia de *Erica australis*, carquesales con dominancia de *Pterospartum tridentatum* y tojales con dominancia de *Ulex europaeus* y de *Ulex gallii*, todas ellas muy afectadas por los incendios en Galicia.

Los brezales con dominancia de *E. australis* son muy abundantes en el territorio gallego y antiguamente se utilizaban como fuente de carbón, o como leña. La especie dominante tiene gran tamaño, llegando en algunos casos a los 2 m de altura, con individuos muy ramificados, con hojas estrechas, pequeñas, perennes, de color verde y posicionadas en verticilos de 4. Florecen en primavera con flores pedunculares de color violeta.

Los carquesales con dominancia de *P. tridentatum* forman matorrales de escaso porte, normalmente entre 1 - 1.5 m de altura, y su característica más diferencial es la presencia de ramas aladas en dicha especie, que simulan las hojas. Posee flores amarillas en primavera y su fruto es una pequeña legumbre alargada.

USC DE COMPOSTELA

Ulex europaeus es un arbusto de gran porte, llegando a alcanzar los 2.5 m de altura. Posee ramas de color verde oscuro con estrías longitudinales y agujas triangulares y espinosas y florece entre diciembre y mayo con flores amarillas de hasta 2 cm. *Ulex gallii* es de menor porte, sus espinas son más pequeñas (hasta 3 cm) que las de *U. europaeus* y florece en otoño. Antiguamente los tojales de *U. europaeus* y de *U. gallii* tenían diferentes usos como forraje para los animales y posterior abono para el suelo, ya que están constituidos por un material leñoso que se descompone bien y produce humus que se integra con gran facilidad en el substrato inorgánico del suelo (Izco et al., 2006), aunque, actualmente estos usos ya no son frecuentes.

La evaluación y modelización de la biomasa aérea y de la carga de matorral son fundamentales desde el punto de vista de la ecología del fuego, el almacenamiento de carbono y de su productividad como materia prima y fuente de energía. Actualmente, la biomasa de las comunidades anteriormente mencionadas se puede utilizar como materia prima para la combustión. Viana et al. (2012b) mostraron como especies arbustivas de brezo, retamas, carquesales y tojales del noroeste peninsular y centro de Portugal tienen buenas propiedades de combustión; para combustible, obteniendo mejores resultados para la ericácea en cuanto al cumplimiento de los requisitos de la norma de biocombustibles sólidos ISO 17225-2:2014 EN plus B. Diferentes trabajos se han centrado en evaluar las propiedades de estas formaciones de matorral como fuente de energía. Por ejemplo, Viana et al. (2012b) exponen el aumento del interés en la utilización de biomasa forestal para bioenergía, como una estrategia de mitigación del cambio climático y destacan que la parte aérea de estas formaciones tiene entre un 46 - 49% de carbono, siendo la especie *Erica australis* la de mayor contenido.

Por su parte, existen numerosos trabajos que estudian la producción de biomasa, como Núñez-Regueira et al. (2004) que aportan valores medios de 20 Mg ha^{-1} para *U. europaeus* y de 15 Mg ha^{-1} para los brezales, lo que da muestra de su gran valor para un potencial aprovechamiento energético; Arellano et al. (2017) desarrollaron la ”Foto-guía de combustibles forestales de Galicia y comportamiento del fuego asociado” donde se ofrece una visión gráfica y numérica de diferentes situaciones representativas de los combustibles de la región, se clasifican según su estructura y se asocian con la estimación del posible comportamiento potencial del fuego. En dicho estudio se indica, por ejemplo, que las comunidades dominadas por *Ulex galli* o *Pterospartum tridentatum* son las que tienden a acumular mayor carga fina (< 6mm), con valores medios en torno a 25 Mg ha^{-1} mientras que los tojales de *U. europaeus* y brezales de *E. australis* acumulan algo menos, con un valor medio alrededor de 20 Mg ha^{-1}. Vega et al. (2022b), en un estudio basado en muestreos destructivos de más de 700 parcelas de matorral desarbolado, obtuvieron valores medios de carga total de matorral de 33.6, 28.4, 24.9 y 24.7 Mg ha^{-1} respectivamente para comunidades con dominancia de *U. europaeus, U. galli, Pterospartum tridentatum* y *E. australis*. Esta información fue utilizada para el desarrollo de ecuaciones de estimación de cargas por fracciones de combustible, obteniendo resultados de gran utilidad para su aplicación en la gestión del combustible y los incendios, la evaluación del almacenamiento de carbono y su potencial como fuente de energía. En la actualidad, estos estudios son de gran interés por la incansable búsqueda de nuevas fuentes de energía que sirvan de alternativas a los combustibles fósiles más convencionales, si bien han de tener en cuenta el estatus de protección de diferentes hábitats dominados por estas especies, que en muchos casos se encuentran en espacios naturales protegidos regidos por instrumentos de planificación y gestión que regulan sus aprovechamientos

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Figura 1. 4. Ejemplos de las comunidades de matorral desarbolado incluidas en la presente tesis. De arriba abajo: comunidades con dominancia de *Erica australis*, *Pterospartum tridentatum*, *Ulex gallii* y *Ulex europaeus*.

USC
UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

1.2. El combustible forestal

1.2.1. Clasificación por estado biológico y grosor

Las características de los combustibles forestales son un aspecto de gran importancia en la gestión de los incendios forestales (Scott y Reinhardt, 2001; Keyes y O´Hara, 2002), ya que son la fuente de energía necesaria para el desarrollo del fuego. Al hablar de los combustibles forestales es esencial realizar una buena caracterización, diferenciando entre aspectos que condicionan la inflamabilidad y la combustibilidad de las partículas como son su estado biológico y grosor.

Según el estado biológico del vegetal se distingue entre combustibles vivos y muertos, que se caracterizan por presentar diferentes patrones de variación de humedad. El combustible vivo está constituido por las plantas con actividad fisiológica, incluyendo árboles, arbustos y plantas herbáceas, así como musgos y líquenes; su humedad varía lentamente y presenta una limitada dependencia del tiempo atmosférico, es decir, está más supeditada a la especie y a los diferentes estados fenológicos que atraviesan las plantas a lo largo del año como la floración o el crecimiento (Pyne et al., 1996). Los combustibles muertos están compuestos principalmente por la biomasa muerta suspendida o que se encuentra sobre o en la cubierta orgánica del suelo y están inmersos en un proceso continuo de variación de la humedad en el que se alternan ciclos de humedecimiento y de secado. Esta variación, totalmente controlada por la evolución del tiempo atmosférico, es de tal relevancia que a lo largo de un solo día las partículas muertas finas, ya sean leñosas o herbáceas, pueden recorrer todo el rango de humedades acontecidas a lo largo de una estación completa (Hatton et al., 1988).

En cuanto al grosor de las partículas, tradicionalmente se han diferenciado cuatro categorías (Burgan y Rothermel, 1984): combustibles finos (diámetro inferior a 6 mm), combustibles medios (diámetro comprendido entre 6 y 25 mm), combustibles gruesos (diámetro comprendido entre 25 y 75 mm) y combustibles muy gruesos (diámetro superior a 75 mm). Estas categorías también reciben, respectivamente, el nombre de grupos 1, 2, 3 y 4 (G1 a G4) (Vega et al., 2022a; 2022b) y, en el caso de ser partículas muertas el de combustibles de 1, 10, 100 y 1000 horas de retardo (Fosberg, 1971). El tiempo de retardo es el tiempo que tarda la humedad de los combustibles muertos en alcanzar el equilibrio con el ambiente, es decir, el tiempo que necesita un determinado combustible en ganar o perder dos tercios de la diferencia entre su contenido inicial de humedad y el de la atmósfera que le rodea (Fosberg, 1971).

Estas clasificaciones del combustible se realizan con fines de simulación de incendios que posteriormente ayudarán a la toma de decisiones en la gestión del combustible y la predicción de riesgo de incendios (Finney et al., 2007; Ager et al., 2011). En los diferentes modelos ajustados en la presente tesis se ha tenido en consideración tanto el estado biológico como el tamaño de partícula.

1.2.2. El complejo de combustible, su distribución vertical y el tipo de incendio

USC UNIVERSIDADE DE SANTIAGO

Los incendios son fuegos que se propagan sin control y cuando ocurren en la naturaleza se denominan incendios forestales (Pausas, 2020). Tienen innumerables efectos ambientales, en

la vegetación y en la cubierta orgánica del suelo. Por ejemplo, el calor generado consume la materia orgánica y altera la estabilidad de los agregados (Mataix-Solera et al., 2002) y la capacidad de absorción y retención de agua, porosidad, aireación y capacidad de infiltración del suelo descubierto tras incendio, provocando así un incremento de la escorrentía superficial y por tanto de la erosión (Mataix-Solera y Guerrero, 2007).

La ocurrencia de los incendios forestales depende de tres elementos principales, que conforman el denominado triángulo del fuego: el combustible, el oxígeno y el calor. De estos tres elementos, los combustibles forestales son el único factor manipulable, es decir, que se puede gestionar directa o indirectamente. En un contexto ecológico los combustibles son la materia orgánica viva y muerta, que también se puede encontrar bajo la denominación de "biomasa" (Keane, 2015), y en un sentido más amplio son los materiales que se consumen durante la combustión que se produce en el incendio (Ruiz-González y Vega-Hidalgo, 2007).

El complejo o lecho de combustible es un término que se emplea para hacer referencia a la forma en que los combustibles se estructuran en una determinada superficie. Chandler et al. (1991) lo definen como la asociación de los vegetales vivos y muertos y de los materiales combustibles de las diferentes formas y tamaños que en una superficie se extienden desde el suelo mineral hasta el ápice de las copas. Dentro del complejo los combustibles se estructuran en diferentes capas o estratos: combustibles de suelo, de superficie y del dosel arbóreo.

Los combustibles del suelo están formados por la materia orgánica en diferentes grados de descomposición, diferenciando 3 capas: la hojarasca (capa L u horizonte *Oi*, formada principalmente por acículas u hojas y ramillas caídas recientemente), el mantillo superior (capa F, de fermentación, u horizonte *Oe*, en el que la hojarasca ha sido parcialmente meteorizada pero aún se distingue su composición) y el mantillo inferior (capa H, de humus, u horizonte *Oa*, en el que los residuos vegetales están ya altamente descompuestos de forma que no se puede distinguir su origen) (Ottmar y Andreu, 2007; Keane, 2015). Esta diferenciación entre capas es bastante clara en formaciones arboladas, como los pinares objeto del estudio, donde la hojarasca se suele considerar incluso como combustible de superficie, pero no lo es tanto en las comunidades de matorral desarbolado, también incluidas en la tesis. En este estrato de combustibles del suelo se pueden desarrollar los denominados incendios de suelo o sub-superficiales, que se caracterizan por su lenta propagación, mediante combustión sin llama, con escaso humo pero que pueden producir enormes daños al suelo debido a su persistencia y dificultad de extinción (Viegas, 1998).

Los combustibles de superficie son aquellos que se extienden entre el suelo y los dos metros de altura, incluyendo hojarasca, vegetación herbácea, matorral y restos leñosos (Keane, 2012; 2015). Por este estrato es por donde se propagan la mayoría de los incendios forestales, denominándose, por tanto, incendios de superficie, con presencia de llamas en la combustión.

Combustible aéreo o del dosel de copas es la biomasa que se encuentra por encima del estrato de superficie y, por tanto, por encima de los 2 metros de altura, en consistencia con la definición de combustible de superficie (Keane, 2015). Otras definiciones consideran que el dosel se inicia a los 6 metros (NWCG, 2006) o que el dosel hace referencia únicamente a la copa viva (Van Wagner, 1977). En cualquier caso, el espacio existente entre el combustible de la superficie y el de la copa viva con frecuencia está ocupado total o parcialmente por los combustibles de continuidad o escalera. Estos combustibles pueden estar constituidos por biomasa viva o muerta, normalmente follaje de arbolillos o arbustos y pequeñas ramas que se

extienden desde la superficie hacia hasta las copas (Keane, 2015). Proporcionan continuidad vertical y horizontal y facilitan la transición del fuego de superficie a las copas, transformando incluso incendios de superficie de intensidad relativamente baja en graves incendios de copas (Menning y Stephens, 2007). Además, la abundancia de estos combustibles dificulta la extinción del fuego e incrementa la exposición de los equipos de extinción a condiciones peligrosas, especialmente cuando el comportamiento del fuego cambia inesperadamente, al dificultar el escape a zonas de seguridad (Hirsch y Martell, 1996; Kramer et al., 2016). También pueden reducir la calidad del hábitat al disminuir la accesibilidad y la eficiencia de la búsqueda de alimento para la fauna (Norgaard, 2014).

En el caso concreto de los pinares de *P. radiata* objeto de este estudio, una vez se produce el cierre de las copas, y debido a la mala poda natural, se acumulan grandes cantidades de biomasa muerta en la parte baja del dosel, incluyendo ramitas finas y acículas en suspensión, constituyendo un buen ejemplo de combustibles de escalera.

1.2.3. La carga de combustible de superficie

La carga de combustible, definida como la cantidad de biomasa expresada en peso de materia seca por unidad de superficie, es una característica fundamental del combustible forestal ya que, junto con otras características estructurales, afecta en gran medida al comportamiento del fuego, regulando la velocidad de propagación, la intensidad lineal o la longitud de la llama (Chandler et al., 1991; Pyne et al., 1996). La adecuada caracterización de los combustibles, incluyendo la carga de combustible desagregada por clases de tamaño y estado vivo o muerto, es esencial para obtener estimaciones fiables de los simuladores de comportamiento del fuego que puedan ser utilizadas en los procesos de toma de decisiones en la gestión del combustible y la predicción del riesgo de incendios (Finney et al., 2007; Ager et al., 2011). Además, la carga de combustible es también un componente esencial en la evaluación del ciclo del carbono y de las emisiones de gases de efecto invernadero en los incendios forestales (ver, por ejemplo, Jiménez et al., 2013; Lasslop y Kloster, 2015). En Galicia, el rápido crecimiento de la vegetación como consecuencia de las suaves temperaturas anuales y las elevadas precipitaciones genera grandes acumulaciones de combustible, tanto superficial como arbóreo, que favorecen los incendios forestales de alta intensidad (Arellano et al., 2017b).

La carga de combustible de las comunidades de matorral desarbolado, así como del sotobosque, incluyendo tanto la capa arbustiva como la de hojarasca, puede cuantificarse mediante muestreos de campo destructivos o no destructivos (Catchpole y Wheeler, 1992). El muestreo destructivo es el método más preciso, pero también el más complejo y costoso en tiempo y dinero, por lo que es difícil de aplicar a grandes áreas (Bonham, 2013). El muestreo no destructivo permite la estimación indirecta de la carga de combustible, normalmente mediante el uso de relaciones alométricas entredichas cargas y variables del combustible que se miden fácilmente en el campo (De Cáceres et al., 2019; Montero et al., 2020), existiendo dos aproximaciones de muestreo para obtener y aplicar estos modelos: a nivel de planta individual y a nivel de comunidad (Vega et al., 2022a; 2022b). En el caso de los matorrales de Galicia, debido a su elevada cobertura y complejidad estructural tanto bajo arbolado como sin él, es preferible la aproximación a nivel de comunidad, que requiere para la estimación de la carga de variables como la cobertura de la vegetación o su altura media. Por otro lado, en las dos últimas décadas se han desarrollado nuevos modelos que relacionan las principales características de

USC DE SANTIAGO

estos combustibles con datos de teledetección provenientes tanto de imágenes de satélite (e.g. Riaño et al., 2002, Viana et al., 2012a) como de escáner láser aerotransportado (ALS) (e.g. Estornell et al., 2011b; Li et al., 2017) o terrestre (TLS) (e.g. Rowell et al., 2016b; 2020; Hudak et al., 2020)

1.2.4 Las variables estructurales del dosel de copas y los combustibles de continuidad

Entre las variables del complejo de combustible más relacionadas con la potencialidad para la transmisión del fuego desde la superficie hacia las copas, y para la propagación del fuego por las mismas como fuego de copas activo destacan (Van Wagner, 1977; Alexander y Cruz, 2011): i) la carga de los combustibles de superficie, anteriormente descrita; y ii) las variables estructurales del combustible del dosel arbóreo: carga de combustible disponible o *Canopy Fuel Load* (*CFL*), altura de la base de la copa o *Canopy Base Height* (*CBH*), densidad aparente del dosel o *Canopy Bulk Density* (*CBD*) y distancia vertical entre los estratos del combustible de superficie y del dosel o *Fuel Strata Gap* (*FSG*). Estas variables deben de ser correctamente evaluadas en masas arboladas propensas a sufrir fuegos de copa, como son los pinares, para así poder predecir el tipo de incendio bajo determinadas condiciones de humedad de los combustibles y de velocidad del viento y facilitar la selección de los tratamientos selvícolas apropiados para reducir su susceptibilidad a dicho fenómeno (Cruz et al., 2008).

La carga de combustible disponible (*CFL*) es la biomasa del dosel que se consumiría durante la fase de llamas de un fuego de copas activo, expresada por unidad de superficie del terreno. Con fines de modelización y de acuerdo con lo observado por Stocks et al. (2004) se considera como combustible disponible las acículas y las ramillas finas (diámetro < 6 mm) pero no existe un consenso pleno entre investigadores sobre que fracciones de biomasa de copa considerar como combustible disponible. Una mayor aclaración sobre este tema se puede encontrar en Ruiz-González y Álvarez-González (2011) o Arellano-Pérez (2021).La altura de la base de la copa (*CBH*) es definida por Cruz et al. (2004) como la distancia vertical desde la superficie de la hojarasca hasta la base de la copa de los árboles en el rodal y por Sando y Wick (1972) o Scott y Reinhardt (2001) como la menor altura sobre el suelo a la cual hay suficiente combustible de copas para propagar el fuego verticalmente hacia las mismas. La densidad aparente (*CBD*) se corresponde con la biomasa de combustible disponible por unidad de volumen del dosel (Keane, 2015).

A lo largo de los años se han seguido diferentes aproximaciones para estimar estas variables del dosel de copas, como por ejemplo las de Sando y Wick (1972), Van Wagner (1977) o Keyser y Smith (2010). Entre ellas, la aproximación más utilizada es la de Van Wagner (1977), conocida como *load-over-depth approach* que asume que todo el combustible fino de la copa se distribuye homogéneamente en el dosel. Este método es coherente con el funcionamiento de los modelos semi-empíricos que emplean los principales simuladores de comportamiento del fuego disponibles (Cruz y Alexander, 2010). El combustible fino de la copa se puede estimar a nivel de árbol individual mediante el empleo de ecuaciones que utilizan variables regresoras fáciles de medir en campo, como el diámetro normal del árbol o su altura. Algunos ejemplos son los trabajos de Ruiz-González y Álvarez-González (2011) o Fernández-Alonso et al. (2013). Sin embargo, también se puede estimar a nivel de masa utilizando modelos que son de menor precisión pero que también requieren un menor esfuerzo de muestreo. Así, por ejemplo, en el área de estudio (NW de la Península Ibérica) se han desarrollado modelos de este tipo para masas de pino propensas a los fuegos de copas a partir de variables de masa obtenidas de

inventarios de campo (Ruiz-González y Álvarez-González, 2011; Hevia et al., 2012; Gómez-Vázquez et al., 2012; Fernández-Alonso et al., 2013; Ruiz González et al., 2015; Arellano-Pérez et al., 2017a) o a partir de sensores remotos incluyendo LiDAR aéreo (Hevia et al., 2016b; González-Ferreiro et al., 2017; Alberdi et al., 2017; Fidalgo-González et al., 2019) e imágenes de satélite (Arellano-Pérez et al., 2018). Estas dos últimas aproximaciones son menos precisas que las basadas en inventario de campo, pero facilitan la elaboración de cartografía a nivel de paisaje y por tanto el uso de sistemas de simulación operativos como FlamMap (Finney, 2006).

Los modelos que existen en Galicia para la estimación de *CFL* en pinares son robustos, especialmente los basados en variables de rodal (Fernández-Alonso et al., 2013). Sin embargo, pueden llevar a una subestimación de dicha variable en rodales de *Pinus radiata* una vez que el dosel se cierra y los árboles no se podan, ya que los modelos se basan en las ecuaciones de biomasa aérea de árbol individual de Balboa-Murias et al. (2006) que sólo cuantifican la fracción viva. Por otra parte, la variable *CBH* de acuerdo con los requerimientos de los primeros modelos de iniciación del fuego de copas (Van Wagner, 1977), es decir, teniendo en cuenta únicamente el componente vivo de la copa, podría no ser una variable adecuada para evaluar la iniciación en este tipo de rodales en los que abundan los combustibles muertos de escalera. Van Wagner (1977), considera que los combustibles de escalera, si son lo suficientemente abundantes, deberían considerarse como un componente del comportamiento del fuego de superficie, lo que aumentaría la intensidad lineal del fuego y extendería la llama hacia el dosel vivo. Esto implica añadir los combustibles de continuidad al complejo de combustibles de superficie si se utiliza la modelización del comportamiento del fuego basada en Van Wagner (1977). Otra opción es el uso de modelos y sistemas de comportamiento del fuego que utilizan el valor de *FSG* (que depende de la altura a la que se inicia la copa muerta, incluyendo ramas y follaje) en vez del valor de *CBH* como la variable de entrada para evaluar la transición del fuego de superficie a las copas (Cruz et al., 2008; Cruz et al., 2004; Plucinski et al., 2017). Esta última opción parece más aconsejable, ya que el grado de implicación de los combustibles de escalera en la combustión variará en función de las condiciones meteorológicas del incendio y de la estructura del rodal (Cruz et al., 2017).

1.2.5. La gestión del combustible

La reducción de la carga del combustible de superficie y el incremento de la discontinuidad entre los estratos de superficie y de copa ayudan a disminuir la capacidad de los incendios de superficie para pasar al dosel de copas. La reducción de la carga del combustible en el dosel limitaría el potencial para la propagación del fuego por las copas como fuego de copas activo (Hoffman et al., 2018). Ottmar (2019) resalta que la eliminación del combustible de escalera mediante tratamientos selvícolas como el clareo o la poda aumentan el espacio entre los combustibles de superficie y la base de la copa, rompiendo la continuidad vertical y horizontal y favoreciendo que el fuego no pase de la superficie a las copas. Trabajos como los de Agee y Skinner (2005); Ruiz-González et al. (2015); Hevia et al. (2016a); Cruz et al. (2017); Vaillant y Reinhardt (2017) o Arellano-Pérez et al. (2020) exponen que la gestión del combustible es muy importante para reducir el potencial comportamiento del fuego y su severidad.

En los últimos años se ha producido un incremento del interés en la evaluación de las existencias de carbono en el sector forestal, debido a su influencia en el cambio climático global, llegando a considerar al sector forestal como unos de los principales sumideros de carbono. Diversos trabajos estudian la importancia de la estimación de la carga de combustible

para evaluar el ciclo de carbono y las emisiones de efecto invernadero de los incendios forestales (Jiménez et al., 2013; Lasslop y Kloster, 2015) y como pueden afectar los tratamientos selvícolas al almacenamiento de carbono en rodales forestales (Dixon et al., 1994; Laclau, 2003; Balboa-Murias et al., 2006).

1.3 Uso del LiDAR aéreo y terrestre en la evaluación de los combustibles

La utilización de datos obtenidos a partir de la teledetección se ha convertido en recurrente y esencial para la gestión forestal, en especial cuando se trabaja a grandes escalas, es decir, a nivel paisaje, ofreciendo cada vez mejores resoluciones espaciales, temporales y espectrales (Geller et al., 2017). Existen diferentes sensores con los que obtener información relevante que permita estimar características estructurales, de composición o fenológicas de la vegetación, con diferentes niveles de resolución espacial y temporal, ya sean imágenes de satélite de media (e.g. NOAA-AVHRR, MERIS, MODIS) alta o muy alta resolución (e.g. WorldView, SPOT, Sentinel-2A, Landsat), datos de fotogrametría digital aérea, nubes de puntos tridimensionales LiDAR (*Láser Imaging Detection and Ranging*) (ver, por ejemplo la excelente revisión sobre esta temática de White et al., 2016).

Este apartado trata principalmente de los sensores LiDAR que han adquirido una gran popularidad en diferentes ramas o aplicaciones (Dong y Chen, 2017), tanto forestales (tema central de este documento), fundamentalmente como herramienta de inventario para toma de decisiones en gestión forestal sostenible (e.g. Maltamo et al., 2014; Liang et al., 2016; 2018; Gale et al., 2021); como territoriales, por ejemplo para la clasificación de la cobertura del suelo urbano, el modelado de escenarios de inundaciones (Echeverry y Téllez, 2021), el cartografiado de infraestructuras urbanas (Axelsson, 1999), o la evaluación de daños; y de geociencia, al proporcionar coordenadas de alta precisión o facilitar la elaboración de cartografía litológica y formas de relieve, entre otras.

LiDAR es una técnica de teledetección activa que utiliza una fuente de luz, generalmente en intervalos del espectro electromagnético del infrarrojo cercano y un detector para medir la ubicación tridimensional de los objetos. El pulso láser generado por la fuente impacta con los objetos interpuestos en su trayectoria y los retornos son captados por el detector que determina su posición relativa con respecto al sensor. Los sistemas LiDAR se pueden clasifican por el modo en que registran la energía de la señal de los pulsos que retornan al sensor, diferenciando entre sistemas de retorno discreto o de onda completa (*full-waveform*). Para cada pulso láser emitido, los sistemas de retorno discreto registrarán retornos únicos o múltiples; por el contrario, un sistema de onda completa registrará la energía de retorno de forma continua como una onda (Lefsky et al., 2002). Otra clasificación hace referencia al modo en el que se recoge la información, distinguiendo entre sensores terrestres, que pueden ser móviles en caso de ir incorporados en vehículos, o estáticos si se fijan en un trípode; o aéreos, si van a bordo de aeronaves tripuladas como aviones o helicópteros, o no tripuladas como son los UAVs (*Unmanned Aereal Vehicles*).

En este apartado se describirá el uso en el ámbito forestal del escáner láser aerotransportado (ALS, *Airbone Laser Scanning*) y del escáner láser terrestre estático (TLS, *Terrestrial Laser Scanning*), ambos de retorno discreto, así como el uso combinado de estos sensores.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

1.3.1 Escáner láser Aerotransportado (ALS)

El escáner láser aerotransportado (ALS) es un tipo de sensor LiDAR aéreo que va incorporado en una aeronave y emite pulsos de luz infrarroja cercana hacia la superficie de la tierra. La posición y la rotación del sensor son grabadas continuamente a lo largo de la línea de vuelo usando el sistema diferencial de posicionamiento global (*Differential Global Positioning System* -DGPS-), una unidad de medición inercial (*Inertial Measurement Unit* – IMU-) y el sistema de navegación de la aeronave (*Inertial Navigation System* -INS-) de modo que conocida la orientación del sensor en cada momento, la información recogida de los retornos de cada pulso laser puede ser transformada en nubes tridimensionales de puntos georreferenciados que representan a los objetos que han reflejado el haz de luz emitido por el escáner (White et al., 2016).

El empleo de datos de ALS para la caracterización de los ecosistemas forestales puede seguir dos enfoques o metodologías diferentes: una basada en superficies determinadas de muestreo para estimar variables a escala rodal (*Area Based Approach* o ABA), y otra basada en la detección de árboles individuales (*Individual Tree Crown* o ITC, también conocida como *Individual Tree Detection* o ITD). El primer enfoque (ABA) depende de la relación estadística entre las variables predictoras derivadas de la distribución vertical de los retornos LiDAR en la nube de puntos ALS y las mediciones realizadas mediante un inventario por muestreo en el campo a nivel de parcela/masa forestal (Næsset, 2002). La combinación de ambos tipos de información permite desarrollar modelos predictivos que, posteriormente se pueden aplicar a gran escala proporcionando estimaciones de los atributos de inventario de interés para toda la cobertura de ALS. El enfoque ITC implica la segmentación de la información de la nube de puntos que corresponde a cada árbol individual para, a partir del procesado de la nube de puntos estimar variables de interés como su altura, su diámetro, las dimensiones de su copa u otros atributos utilizando mediciones de inventario en campo para la calibración. Finalmente, la agregación de los atributos de árbol individual permite obtener valores a escala de rodal (Breidenbach y Astrup, 2015).

Existen números estudios sobre las aptitudes que tiene el LiDAR aerotransportado para predecir diversidad de variables forestales, tanto de árbol individual (e.g. Chen et al., 2006; González-Ferreiro et al., 2013), como de rodal (e.g. Lefsky et al., 1999; Gonçalves-Seco et al., 2011; González-Ferreiro et al., 2012), incluyendo características estructurales de los combustibles del dosel (e.g. Andersen et al., 2005; Coops et al., 2007; González-Ferreiro et al., 2014; 2017; Hevia et al., 2016b; Engelstad et al., 2019; Fidalgo-González et al., 2019; Botequim et al., 2019; Hernando et al., 2019; Marino et al., 2022). Una revisión completa se puede encontrar en Arellano-Pérez (2021).

Sin embargo, pocos estudios han examinado el potencial de los datos de ALS para caracterizar la estructura de la parte inferior del dosel de copas, de los combustibles de superficie o de los combustibles de suelo debido a las persistentes dificultades asociadas con la presencia de elementos más altos que ocluyen los elementos subyacentes (e.g. Hilker et al., 2010; White et al., 2016). Una alternativa podría ser el empleo del ALS de onda completa que aporta información sobre la interacción entre la señal y el entorno por el que transcurre (e.g. Cao et al., 2014; Anderson et al., 2016) aunque, debido a la mayor complejidad del tratamiento de los datos brutos y a la limitada disponibilidad de herramientas accesibles de procesamiento, se le ha prestado mucha menor atención (e.g. Crespo-Peremarch et al., 2018; 2020).

USC DE SANTIAGO

De cualquier forma, en las últimas dos décadas se han desarrollado modelos que relacionan las características del complejo de combustible con datos ALS (e.g. Riaño et al., 2007; Estornell et al., 2011a; Jakubowksi et al., 2013; Greaves et al., 2016; Li et al., 2017), lo que ha permitido la elaboración de cartografía temática necesaria para la evaluación del riesgo y el comportamiento de fuego, tanto de variables del dosel (e.g. Riaño et al., 2003; Wagner et al., 2008; Mauro et al., 2021; Marino et al., 2022) como de superficie (e.g. García et al., 2011b; Marino et al., 2016; Huesca et al., 2019).

Los sensores LiDAR aéreos también tienen otros usos como la identificación y clasificación de especies arbóreas (e.g. Holmgren y Persson, 2004; Reitberger et al., 2008; Domingo et al., 2020), la cuantificación de las reservas de carbono (e.g. Hudak et al., 2012), la evaluación de criterios e indicadores de gestión forestal sostenible como la diversidad biológica, la extensión, severidad y recuperación tras perturbaciones o la productividad del ecosistema (e.g. Goodbody et al., 2021) y por supuesto la obtención de mapas topográficos de alta resolución espacial (e.g. Kraus et al., 1998; Kobler et al., 2007).

En España, el Plan Nacional de Ortofotografía Aérea (PNOA) proporciona datos LiDAR aéreos del territorio español que se pueden descargar libremente de la página web del Centro Nacional de Información Geográfica (CNIG) del Instituto Geográfico Nacional (IGN). Hasta el momento han tenido lugar dos coberturas completas del territorio, la primera durante el periodo 2009 - 2015 (densidad de 0.5 puntos m^{-2}) y la segunda entre 2015 - 2021 (densidad de 0.5 - 4 puntos m^{-2}), con una mejora sustancial en el error cometido en la estimación de las alturas.

1.3.2 Escáner láser Terrestre (TLS)

Aunque los sistemas LiDAR aerotransportados son capaces de cubrir grandes superficies forestales de forma eficiente y relativamente rentable (White et al., 2016), como se ha comentado previamente tienen el inconveniente de resultar difícil la caracterización de la vegetación de sotobosque y las características del dosel inferior, por la oclusión de los elementos situados a mayor altura (Hilker et al. 2010). Una alternativa es el empleo de los escáneres láser terrestres (TLS) que obtienen datos de la estructura del dosel desde una altura reducida sobre el terreno (Jupp et al. 2009).

El TLS es un dispositivo LiDAR que se desarrolló con el objetivo de representar superficies de objetos en el entorno próximo de forma rápida, autónoma y con alta resolución. En el campo forestal esta tecnología se utilizó inicialmente para realizar mediciones forestales básicas como la altura o el diámetro de los árboles, sin embargo, ha evolucionado como una técnica de medición no destructiva que produce datos (nubes de puntos 3D) de gran potencial para diversas aplicaciones forestales. Gracias a los avances tecnológicos, estos sensores permiten realizar estimaciones de volumen (e.g. Dassot et al., 2012; Hackenberg et al., 2015), de biomasa y de carbono a nivel de árbol individual y de rodal (e.g. Hopkinson et al., 2004; Astrup et al., 2014; Calders et al., 2015; Abegg et al., 2017; Stovall et al., 2017; González de Tanago et al., 2018; Momo-Takoudjou et al., 2018; Chen et al., 2019; Demol et al., 2022).

También, pero en menor medida, hay trabajos que analizan el potencial del TLS para caracterizar la estructura del combustible con el propósito de determinar el riesgo de incendio, el comportamiento del fuego, el consumo de combustible y las emisiones de humo (e.g.

Loudermilk et al., 2009; Olsoy et al., 2014; Greaves et al., 2015; Rowell et al., 2016a; Owers et al., 2018).

La mayoría de los estudios basados en TLS que estiman la biomasa o el volumen de los matorrales o de los arbustos se han centrado en la reconstrucción de su forma a partir de la nube de puntos, ya sea por aproximación al volumen aparente de la vegetación dividiéndola en partes de formas más sencillas y asimilando una superficie externa a la nube de puntos (envolvente convexa), o por reconstrucción a través de pequeños prismas (voxelización). Por ejemplo, Olsoy et al. (2014) estimaron la biomasa de *Artemisia tridentata* W.A.Weber (Nutt.) utilizando las dos aproximaciones mencionadas llegando a la conclusión de que una envolvente convexa tridimensional estimaba la biomasa total y viva con mayor precisión que el recuento de vóxeles. Greaves et al. (2015) también compararon ambos enfoques, en este caso, para estimar la producción de biomasa de dos especies de matorral dominantes en la tundra de Alaska. Para ello utilizaron nubes de puntos obtenidas con un TLS ubicado a corta distancia (2 m) y a distancia variable (<50 m), obteniendo mejores resultados con el recuento de vóxeles en el caso de la corta distancia y con el uso de envolventes tridimensionales para tomas de datos a distancia variable.

La mayor parte de los trabajos de caracterización de combustibles de superficie que utilizan datos TLS se han llevado a cabo en comunidades de matorral bajo cubierta arbórea, caracterizadas en general por mostrar una distribución espacial heterogénea del combustible y a menudo con el objetivo de obtener información tridimensional muy detallada y espacialmente explícita (e.g. Rowell et al., 2016a; 2020; Hudak et al., 2020) para la aplicación de modelos físicos de propagación del fuego como WRF-SFIRE-CHEM (Mandel et al., 2011; 2014), WFDSS (Mell et al., 2007; 2009) y FIRETEC (Linn et al., 2002; 2005). Tales estudios requieren de varios escaneos para reconstruir la estructura de la vegetación a través de la aproximación al volumen por el uso de una envolvente tridimensional o por voxelización.

El uso del TLS presenta también algunas limitaciones como el tiempo requerido en la adquisición y el procesado de las nubes de puntos, la extensión espacial que se consigue cubrir y el efecto de las oclusiones, fundamentalmente debidas a los troncos de los árboles, sobre la nube de puntos tridimensional. Este último inconveniente puede resolverse mediante la realización de escaneos múltiples que, posteriormente, se unen para conformar una nube de puntos única o mediante el empleo de métodos estadísticos que corrijan las oclusiones basándose en la información de la nube de puntos libre de ellas (e.g. Molina-Valero et al., 2022).

Numerosos estudios han discutido las ventajas e inconvenientes que conlleva el escaneo único frente a la combinación de múltiples escaneos, por ejemplo, Calders et al. (2014) llegaron a la conclusión de que múltiples escaneos conducen a mejores resultados de estimación de alturas del dosel de copas, y que es conveniente su utilización en lugares con una vegetación densa para reducir las posibles oclusiones que se obtendrían con un único escaneo. No obstante, lo escaneos múltiples dificultan enormemente el procesamiento posterior de las nubes de puntos para obtener una sola nube. Otros estudios, sin embargo, concluyen que el uso de datos que provienen de un único escaneo TLS proporciona estimaciones precisas de características del dosel arbóreo (e.g. Astrup et al., 2014; Molina-Valero et al., 2019), que luego son de gran importancia por ejemplo para la predicción del comportamiento del fuego o la evaluación de las existencias de carbono.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

En cuanto al problema de la cobertura especial con TLS, en un contexto de inventario forestal en el que el objetivo es producir mapas de atributos forestales en áreas relativamente grandes, el TLS no es operativo, aunque sí que puede ser muy útil como herramienta de toma de datos de campo necesarios para construir y validar modelos desarrollados utilizando datos de teledetección o ALS que tengan la extensión espacial requerida.

Otro inconveniente del uso del TLS es la elevada inversión para la adquisición de los equipos, aunque el ahorro en coste de inventario de campo que implica su uso y la reducción de los precios de los nuevos equipos hacen que, en el caso de uso continuado en inventario forestal su empleo sea una alternativa perfectamente viable (e.g. Puletti et al., 2021).

Por último, el problema de la dificultad de procesamiento de los datos de TLS se ha ido resolviendo con la aparición de algoritmos de tratamiento de las nubes de puntos, que permiten abordar los problemas de oclusión y obtener métricas similares a las que se obtienen de los datos de ALS de forma rápida y robusta. Destacar que, dentro del grupo de investigación en el que se encuadra esta tesis, se ha desarrollado un paquete para el software estadístico R (R Core Team, 2020), denominado FORTLS que automatiza todo el procesado de las nubes de puntos TLS a partir de escaneos individuales (Molina-Valero et al., 2022) y que se ha utilizado en el análisis de los datos TLS en este trabajo.

1.3.3 Combinación de TLS y ALS

Como se ha comentado en los apartados anteriores, tanto los sensores LiDAR aéreos como los terrestres tienen sus limitaciones y no son capaces de proporcionar, de forma aislada, toda la información de la estructura forestal, sobre todo en masas arboladas en las que es necesario caracterizar los diferentes estratos de vegetación.

Tanto un sensor como el otro describen la estructura del bosque mediante el empleo de nubes de puntos, pero mientras que los sensores TLS observan el dosel desde una perspectiva de abajo hacia arriba, con retornos láser que normalmente se originan en una ubicación fija, de modo que la densidad de retornos es inversamente proporcional al cuadrado de la distancia al instrumento, las nubes de puntos obtenidas de ALS están espaciadas de forma más regular y observan el dosel desde arriba hacia abajo (White et al., 2016). Dado que en ambos casos los objetos más cercanos al instrumento tienen más probabilidades de producir un retorno (distribución de Poisson), las distribuciones de nubes de puntos adquiridas a partir de ALS están, por tanto, sesgadas hacia la parte superior del dosel, mientras que las adquiridas a partir de TLS están sesgadas hacia la parte inferior de las copas de los árboles (Hilker et al., 2010). Como resultado, el TLS es muy adecuado para investigar los cambios en la estructura inferior del dosel, la densidad del rodal, la estructura del tronco, la ramificación o el sotobosque, mientras que el ALS permite caracterizar con exactitud la parte superior de dosel. Por otro lado, la resolución espacial del TLS suele ser mucho mayor que la del ALS, especialmente en las proximidades del centro de la parcela; sin embargo, el alcance espacial se limita principalmente a un radio de unos pocos cientos de metros, con alcances aún más reducidos debido a los efectos de sombreado de los troncos de los árboles y otros objetos que interceptan los haces LiDAR, mientras que los sensores aerotransportados permiten escanear grandes extensiones y, por tanto, facilitan la generación de cartografía temática (White et al., 2016).

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Una de las soluciones a los inconvenientes del uso de cada sensor por separado es su uso combinado, aumentando, de este modo, la información de la estructura forestal. En la última década diferentes autores han comparado las estimaciones de variables forestales derivadas de ALS y TLS combinados frente a las alternativas de cada sensor por separado, si bien existe la dificultad añadida del corregistro de las dos fuentes de datos para facilitar su integración. Por ejemplo en el estudio de variables del dosel, Jung et al. (2011) obtuvieron mejores resultados en la estimación de las variables de copa de árboles individuales combinando los dos tipos de sensores que usando datos ALS de forma independiente; también se ha observado que la sinergia entre TLS y ALS mejora las estimaciones de la distribución de variables como el diámetro normal (e.g. Vastaranta et al., 2014; Kankare et al., 2014) o la biomasa (Hauglin et al., 2014); Giannetti et al.(2018) evaluaron el potencial del uso combinado de datos ALS y TLS para estimar características de árbol individual, encontrando que la combinación de ambos sensores mejoraba notablemente las estimaciones de las alturas y del radio de copa de los árboles frente al uso individual de cada uno de ellos; Torralba et al. (2018) compararon el potencial del uso combinado de ALS de onda completa y TLS frente al uso de datos ALS discretos para clasificar cinco categorías de ecosistemas forestales con diferentes especies arbóreas con dos niveles de cobertura de sotobosque y obtuvieron una mejora de un 33%; o Dobre et al. (2021), quienes combinaron ambos sensores para caracterizar con fiabilidad la estructura horizontal y la distribución espacial de los árboles en rodales de *Quercus petraea* (Matt.) Liebl. *Fagus sylvatica* L. y *Picea abies* L. (Karst) en Rumania.

Aunque menos abundantes en número, también se han combinado ambos sensores para caracterizar la estructura del matorral. En general, la metodología seguida se ha basado en evaluar el potencial de las métricas derivadas de TLS como estimadores de las características del matorral para, en caso de que se obtengan buenos resultados, emplear las estimaciones del TLS como fuente de calibración de los modelos desarrollados a partir de ALS, ya que estos últimos permiten su aplicación a gran escala. Por ejemplo, Li et al. (2015), quienes emplearon esta metodología para desarrollar modelos de estimación del volumen del sotobosque en plantaciones de pino en China; Greaves et al. (2017), quienes utilizaron las nubes de puntos del TLS para calibrar con precisión las estimaciones obtenidas con ALS de biomasa aérea de matorral en la tundra ártica o Liu et al. (2017), quienes han desarrollado modelos de estimación de la biomasa aérea de *Artemisa tridentata* Nutta partir de datos ALS calibrados con mediciones de TLS.

1.3.4 Técnicas estadísticas Machine Learning

Aunque no existe una definición formal de *Machine learning* o aprendizaje automático, la interpretación más convencional hace referencia al estudio científico de algoritmos y modelos estadísticos que utilizan los sistemas informáticos para aprender de la experiencia (datos previos) y predecir resultados sin estar programados explícitamente (Mahesh, 2020). La principal ventaja de estas metodologías, conectadas con el campo más amplio de la Inteligencia Artificial es su capacidad de aprender y adaptarse sin seguir instrucciones explícitas, utilizando algoritmos y modelos estadísticos para analizar y extraer conclusiones a partir de patrones en los datos (Hamedianfar et al., 2022). Es decir, a partir de algoritmos, los ordenadores puedan analizar datos sin estar programados para ello, identificar patrones y tomar decisiones, mejorando sus predicciones automáticamente a través de la experiencia (Jordan y Mitchell, 2015). Actualmente, esta técnica está en auge debido en gran parte a la gran disponibilidad de

USC DE COMPOSTELA

datos que se pueden obtener libremente y a la necesidad de gestionarlos y relacionarlos para dar como resultado predicciones más precisas y robustas (Zhou et al., 2017).

En general, los métodos de *Machine Learning* pueden clasificarse en alguna de estas dos categorías: aprendizaje supervisado y aprendizaje no supervisado. En el aprendizaje supervisado el algoritmo genera una función que establece una correspondencia entre las variables de entrada y las de salida, todas ellas previamente conocidas. El ejemplo más típico de este tipo de métodos es el de clasificación de categorías en el que el sistema de aprendizaje trata de clasificar una serie de datos caracterizados por un vector de variables conocidas, en una de entre varias categorías diferentes empelando como base una serie de ejemplos ya previamente clasificados como muestra.

En el aprendizaje no supervisado todo el proceso se lleva a cabo sobre un conjunto de datos caracterizados por un vector de variables conocidas, pero sin información previa de muestra que sirva de base. Por lo tanto, en este caso, el sistema tiene que ser capaz de reconocer patrones para poder etiquetar (clasificación) o asignar valores (cuantificación) las nuevas entradas.

El uso de modelos de *Machine Learning* en las ciencias ambientales ha experimentado un rápido auge en la última década, como demuestran las recientes revisiones en campos como las geociencias (Karpatne et al., 2019; Salcedo-Sanz et al., 2020), la ecología forestal (Liu et al., 2018), la predicción meteorológica extrema (McGovern et al., 2017), la predicción de inundaciones (Mosavi et al., 2018), la teledetección y la detección de cambios (Lary et al., 2016; Shi et al., 2020), la gestión de los recursos hídricos (Shen, 2018; Sun y Scanlon, 2019) o el campo de los incendios forestales (Jain et al., 2020).

El uso de *Machine Learning* en el ámbito forestal ha abarcado un amplio campo de aplicaciones entre las que se incluyen la estimación de la biomasa forestal (e.g. García-Gutiérrez et al., 2016; Narine et al., 2019) y del volumen de árboles (e.g. Liu et al., 2019); la estimación de la altura del arbolado (e.g. Wang et al., 2021; Gupta y Sharma, 2022); la mejora de la capacidad predictiva de datos LiDAR en la estimación de características de rodal (e.g. Ayrey Hayes, 2018); la identificación y clasificación de especies (e.g. Guan et al., 2015;Hamraz et al., 2019; Fricker et al., 2019), la predicción de relaciones entre alturas y diámetros de árboles (e.g. Ercanlı, 2020); la detección de árboles afectados por plagas y enfermedades forestales (e.g. Safonova et al., 2019); la detección y seguimiento de incendios forestales (Chen et al., 2019); la evaluación de daños por viento (Hamdi et al., 2019); la modelización y predicción de la idoneidad de un hábitat para una determinada especie (e.g. Garzón et al., 2006; Rahmanian et al., 2021) o la detección y cartografiado de la madera muerta como indicador indirecto de la salud o la biodiversidad de los bosques a partir de imágenes aéreas (e.g. Sylvain et al., 2019).

Sin embargo, son relativamente pocos los estudios que han empleado metodologías de *Machine Learning* para modelizar características de combustibles forestales, objetivo principal de esta tesis. Cabe destacar los trabajos pioneros de Riaño et al. (2005), quienes utilizaron metodologías de *Machine Learning* para predecir y cartografiar el contenido de materia seca de muestras de hojas húmedas y secas de 49 especies de plantas de hoja ancha utilizando valores de reflectancia y transmitancia; de García et al. (2011a), quienes utilizaron *Support Vector Machine* para clasificar datos LiDAR y multiespectrales para cartografiar tipos de combustible en España; de Pierce et al. (2012) quienes utilizaron *Random Forest* para clasificar importantes variables de combustible del dosel como la cabida cubierta, la altura media, la altura de la base del dosel o su densidad aparente utilizando mediciones de campo, datos topográficos y NDVI

para producir mapas de combustible del dosel forestal; de Chirici et al. (2013), quienes compararon el uso de árboles de regresión, *Random Forest* y *Stochastic Gradient Boosting* para cartografiar combustibles en Italia; de Riley et al. (2014) quienes también emplearon *Random Forest* para cartografiar el combustible a partir de imágenes de sensores remotos combinadas con variables biofísicas o de López-Serrano et al. (2016), quienes compararon el rendimiento de *Support Vector Machine*, *K-Nearest Neighbour* y *Random Forest* en la estimación de la biomasa aérea del bosque. La Figura 1.5 muestra un esquema de las metodologías de *Machine Learning* más empleadas en el ámbito de los incendios forestales (Jain et al., 2020).

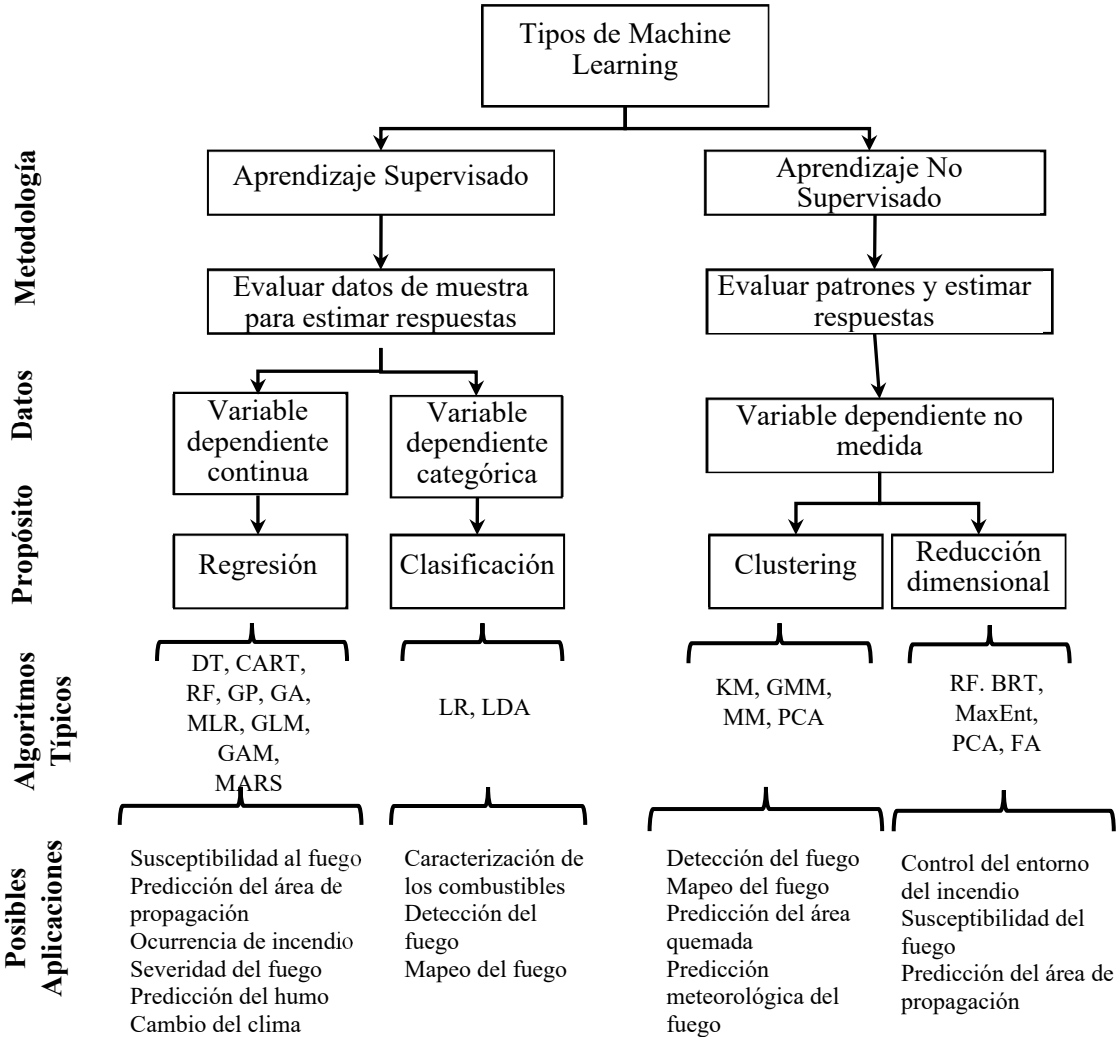

Figura 1. 5. Esquema de los principales tipos de aprendizaje automático (*Machine learning*), la metodología utilizada, los tipos de datos y las posibles aplicaciones en la gestión de los incendios forestales. BRT = *Boosted regression trees*; CART = *Classification and regression tree*; DT = *Decision trees*; FA = *factor analysis*; GA = *Genetic algorithms*; GAM = *Generalized additive model*; GLM = *Generalized linear model*; GMM = *Gaussian mixture models*; GP = *Gaussian processes*; KNN = *K-nearest neighbor*; KM = *k-means clustering*; LDA = *Linear discriminant analysis*; LR = *Logistic regression*; MaxEnt= *Maximum entropy*; MARS = *Multivariate adaptive regression splines*; MLR = *Multiple linear regression*; MM = *Markov models*; PCA = *Principal component analysis*; RF = *Random forest* y SVM = *Support vector machines*. Elaboración propia a partir de Jain et al. (2020).

USC DE COMPOSTELA

Las metodologías de *Machine Learning* utilizadas en esta tesis, y que se describirán con más detalle en el apartado de Material y Métodos, han sido *Random Forest* (RF); *Support Vector Machines* (SVM) y *Multivariate Adaptive Regression Splines* (MARS).

USC
UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

2. Objetivos

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

2. OBJETIVOS

En este proyecto de tesis se plantearon una serie de objetivos que se llevaron a cabo en formaciones vegetales de Galicia:

1. Caracterización vertical y espacial de la biomasa de formaciones vegetales de *Ulex* sp., *Pterospartum tridentatum* y *Erica australis* (Artículo 1 y Comunicación 8ºCongreso Forestal Español) y arbóreas de *Pinus pinaster* y *Pinus radiata* (Artículo 2) mediante el empleo del muestreo con sensores remotos y técnicas de obstrucción visual en campo.

2. Modelizar la estimación de la carga de biomasa empleando como variables independientes las métricas obtenidas en los muestreos con TLS (Artículo 1 y 2) y ALS (Artículo 2).

3. Probar el uso potencial de las métricas de escáner láser aéreo (ALS) de baja densidad, del escáner láser terrestre (TLS) y la integración de ambos, en rodales de *Pinus pinaster* y *P. radiata* para proporcionar estimaciones de las variables relacionadas con los incendios de superficie y del dosel de copas. (Artículo 2).

4. Comparar dos enfoques alternativos (Indirecto y Directo) para estimar las cargas de biomasa de matorral desarbolado desagregadas por fracciones de clases de tamaño y estado vivo o muerto a partir de datos TLS. (Artículo 1).

5. Evaluar el rendimiento comparativo de diferentes técnicas de aprendizaje automático no paramétrico utilizadas para estimar las principales variables relacionadas con el rodal y el fuego a partir de las métricas obtenidas con sensores remotos: *Multivariate Adaptive Regression Splines* (MARS), *Support Vector Machine* (SVM) y *Random Forest* (RF). (Artículo 2).

6. Crear modelos a nivel de árbol individual y de rodal para la estimación de la carga de biomasa seca en escalera en plantaciones de *Pinus radiata* sin podar. (Artículo 3).

USC
UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

3. Material y Métodos

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

3. MATERIAL Y MÉTODOS

En esta sección se detallan las bases de datos y metodologías empleadas en las publicaciones que se referenciaron al inicio del documento y que conforman la tesis por compendio de artículos. En primer lugar, se resumen las principales características y métodos utilizados en cada uno de los artículos en la Tabla 3.1, para facilitar la explicación y comprensión del documento para, a continuación, realizar una descripción de la red de parcelas estudiadas, detallando el diseño experimental y la metodología llevada a cabo en la recogida y posterior procesado y análisis de datos de cada uno de los artículos por separado.

En el artículo 1 (Anexo A) se estudia la distribución vertical de los combustibles de matorral desarbolado con mayor presencia en la Comunidad Autónoma de Galicia, a partir de datos tomados en campo, tanto en muestreos no destructivos a lo largo de transectos, como mediante el uso de nuevas tecnologías como los barridos con el escáner láser terrestre (TLS) o la toma visual de datos de oclusión del campo de visión por la densidad del matorral (trabajo publicado en el 8º Congreso Forestal Español).

En el artículo 2 (Anexo B) se lleva a cabo la estimación de las variables de rodal así como de combustible de superficie y del dosel arbóreo relacionadas con el fuego de las dos especies de pino más abundantes de Galicia, *Pinus pinaster* y *Pinus radiata*, evaluando el potencial de métricas del escáner láser aerotransportado (ALS) de baja densidad y del escáner láser terrestre (TLS) como variables explicativas en tres técnicas de aprendizaje automático no paramétrico: *Multivariate Adaptive Regression Splines* (MARS), *Support Vector Machine* (SVM) y *Random Forest* (RF).

Finalmente, en el artículo 3 (Anexo C) se ajustaron dos sistemas de ecuaciones para la estimación del combustible de escalera (*Ladder fuels*) muerto según la clase de tamaño y su distribución vertical en los primeros 6 m de la copa de los árboles, uno para árbol individual y otro para rodal.

USC
UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Tabla 3. 1. Resumen comparativo de las características más importantes de material y métodos de cada uno de los tres artículos que conforman el presente documento de tesis.

Artículo	**1 y 8CFE**	**2**	**3**
Área de Estudio	Galicia	Galicia Oeste de Asturias	Provincia de Lugo
Formación Vegetal	Matorral Desarbolado	Pinar	
Especies estudiadas	*Erica australis* *Ulex europaeus* *U. gallii*/*U. minor* *Pterospartum tridentatum*	*Pinus pinaster* *Pinus radiata*	*Pinus radiata*
Parcelas	55	102	20
Dimensiones parcelas	2x2 m ($4m^2$)	25 x 40 m ($1000\ m^2$)	Circular r =10 m ($314\ m^2$)
Nivel	--	Rodal	Rodal e individual
Georreferenciación	Trimble Geo 7x		Trimble TSC3
Sensor	TLS	TLS+ALS	--
Métodos estadísticos	Ajuste simultáneo (NLSUR) y regresión lineal	RF; MARS y SVM	Ajuste simultaneo (ITSUR)
Modelos desarrollados	Cargas por fracciones	Cargas y características estructurales de rodal, dosel y sotobosque	Biosmasa seca y su distribución vertical
Variables explicativas	Métricas TLS y de Oclusión de vegetación*	Métricas TLS y/o ALS	Variables de árbol y de rodal
Modelos existentes requeridos	Carga de combustible de superficie (Arellano-Pérez et al.,2020)	Biomasa de árbol (Balboa-Murias et al., 2006) Relación *h-d* y volumen de árbol (Diéguez-Aranda et al., 2009). Carga total de sotobosque y de hojarasca y mantillo (Arellano-Pérez et al., 2020)	
Software estadístico	R y SAS	R	R y SAS

Ea = *Erica australis*, *Pt* = *Pterospartum tridentatum*, *Ug* = *Ulex gallii*, *Ue* = *Ulex europaeus*, *Pp* = *Pinus pinaster*, *Pr* = *Pinus radiata*, TLS = Escáner Láser Terrestre, ALS = Escáner Láser Aerotransportado, NLSUR = Método de Regresión no lineal aparentemente no relacionada, RF = *Random Forest*, MARS = *Multivariate Adaptive Regression Splines*, SVM = *Support Vector Machine* e ITSUR = Método de regresión iterativa aparentemente no relacionada. 8CFE = Comunicación presentada al 8CFE.

3.1 Artículo 1 y comunicación presentada al 8CFE

Artículo 1: Estimación de cargas de combustible y características estructurales de comunidades de matorral desarbolado mediante escaneo con láser terrestre (*Remote Sensing*, 2020, 12 (22), 3704).

El objetivo principal de éste primer artículo es la evaluación de la potencialidad del Láser Escáner Terrestre (TLS) para la estimación precisa de cargas de combustible desagregadas por estrato (arbustivo y cubierta orgánica del suelo), clase de tamaño y estado vegetativo (vivo/muerto),en cuatro de las principales comunidades de matorral desarbolado de Galicia a partir de la información proporcionada por un único escaneo y comparando dos alternativas: estimación directa (ED) y estimación indirecta (EI).

Comunicación 8CFE: Estimaciones de carga y estructura vertical de formaciones de matorral a partir de mediciones de obstrucción visual en campo.

Paralelamente al estudio que dio origen al artículo 1 se evaluó el potencial de técnicas de obstrucción visual en la toma de datos de campo que permitan obtener métricas que puedan ser posteriormente utilizadas como variables independientes en modelos de estimación de carga de combustible, considerando las mismas fracciones y comunidades de matorral desarbolado del artículo 1. Se trata, por tanto, de trabajos complementarios.

En los apartados siguientes se detalla la metodología seguida en ambos trabajos: artículo 1 y comunicación presentada al 8º Congreso Forestal Español.

3.1.1. Área de estudio, selección de comunidades de matorral y de parcelas

Ambos estudios se han desarrollado íntegramente en Galicia, donde las áreas de matorral desarbolado están constituidas mayoritariamente por tojales (género *Ulex*), brezales (género *Erica*) y retamares (géneros *Pterospartum*, *Cytisus* y *Genista*) cubriendo el 55%, 22% y 11% de la superficie de matorral de la Comunidad, respectivamente (MARM, 2011b).

Se seleccionaron cuatro comunidades de matorral desarbolado caracterizadas por su especie dominante: brezales altos dominados por *Erica australis* (*Ea*); retamares dominados por *Pterospartum tridentatum* (*Pt*); tojales altos dominados por *Ulex europaeus* (*Ue*) y tojales bajos dominados por *Ulex gallii* o *U. minor* (*Ug*). Todas ellas son comunidades constituidas por matorral leñoso, perenne y ramificado desde la base, con amplia representación territorial en Galicia (MARM, 2011a; 2011b), además de ser de las más frecuentemente afectadas por los incendios forestales en la región.

La selección de las parcelas de estudio dentro de cada comunidad se realizó de forma subjetiva para garantizar una muestra representativa de las principales características estructurales de estas comunidades observadas en la región. Para la localización de las parcelas se empleó como base de partida la estratificación del Mapa Forestal Español (MARM, 2011; MMA, 2006), complementada con la ayuda del personal de los Servicios Forestales de la Comunidad. Finalmente se seleccionaron un total de 55 parcelas, todas ellas en áreas de alta cobertura de matorral (superior al 80%), tal y como es habitual en la región: 15 parcelas en las

comunidades dominadas por *Erica australis*, *Ulex europaeus* y *Ulex gallii/Ulex minor*, y 10 en comunidades dominadas por *Pterospartum tridentatum* (Tabla 3.2). Todas ellas se georreferenciaron con un GPS Trimble Geo 7X, mostrándose en la Figura 3.1 su distribución.

Tabla 3. 2. Comunidades de matorral, número de parcelas inventariadas (n), códigos, especies dominantes y especies secundarias más frecuentes empleadas en el desarrollo de modelos de estimación de cargas de combustible a partir de datos de TLS y de métricas derivadas de datos de obstrucción visual. Derechos de autor 2020, *Remote Sensing*.

Comunidad	n	Código	Especie dominante	Especies secundarias
Brezal alto	15	*Ea*	*Erica australis*	*Pterospartum tridentatum, Halimium alyssoides* (Lam.) Greuter*, Erica arborea L., Ulex europaeus*
Retamar	10	*Pt*	*Pterospartum tridentatum*	*Erica umbellata*, *Halimium alyssoides, Erica australis, Ulex gallii, Ulex europaeus, Pteridium aquilinum* (L.) Kuhn
Tojal alto	15	*Ue*	*Ulex europaeus*	*Ulex gallii, Erica umbellata, Pteridium aquilinum*, *Pterospartum tridentatum*
Tojal bajo	15	*Ug*	*Ulex gallii/ Ulex minor*	*Ulex europaeus, Erica umbellata, Daboecia cantábrica* (Huds.) K. Koch*, Pterospartum tridentatum, Pteridium aquilinum*

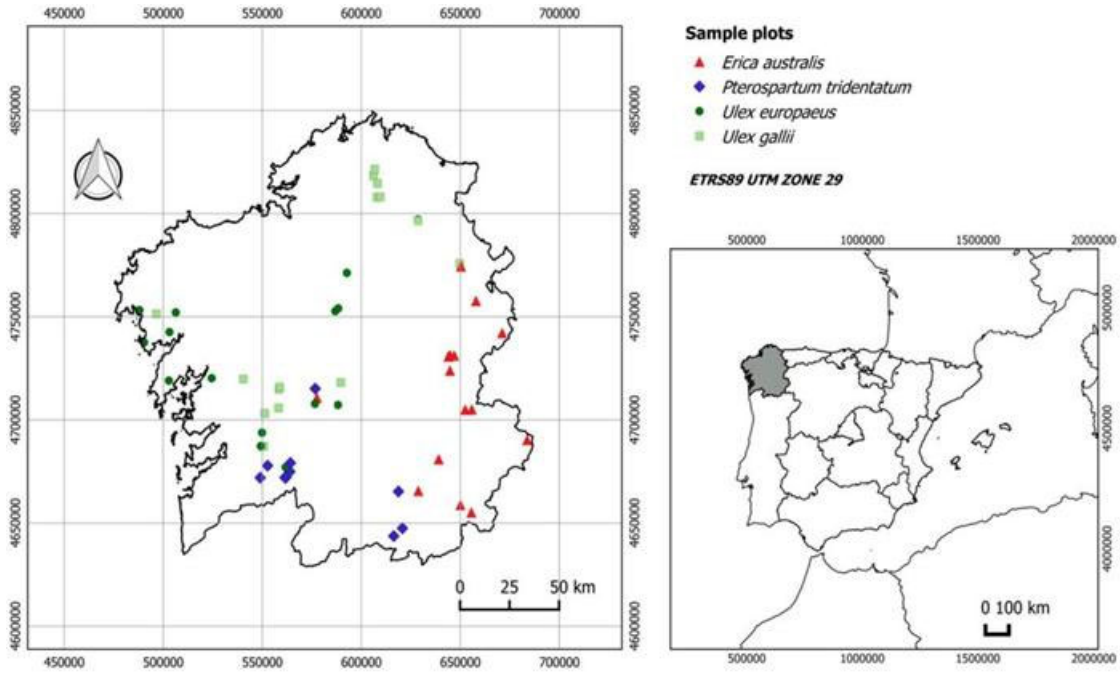

Figura 3. 1. Localización geográfica de las 55 parcelas agrupadas en 4 comunidades de matorral desarbolado empleadas en el desarrollo de modelos de estimación de cargas de combustible a partir de datos de TLS y de métricas derivadas de datos de obstrucción visual. Derechos de autor 2020, *Remote Sensing*.

3.1.2 Inventarios de campo y determinación de características del combustible

En cada parcela se replanteó sobre el terreno un cuadrado de dimensiones de 2 x 2 m (Figura 3.2), con lados paralelos a la curva de nivel y a la máxima pendiente, que se delimitó físicamente con cuatro estacas de madera. En base a dichos cuadrados se realizaron tres tipos de toma de datos de campo: i) inventarios no destructivos a lo largo de transectos lineales perimetrales y diagonales para determinación de alturas (h_{Shr}) y coberturas de vegetación (Cov_{shr}) y espesores de la capa de hojarasca y mantillo (d_{litt}); ii) escaneos con TLS y iii) mediciones de obstrucción visual de la vegetación con una barra graduada.

Figura 3. 2. Ejemplo de cuadrados de muestreo establecidos en comunidades dominadas por *Ulex gallii*/*Ulex minor* (arriba, izquierda), *Ulex europaeus* (arriba, derecha), *Pterospartum tridentatum* (abajo, izquierda) y *Erica australis* (abajo, derecha) para el desarrollo de modelos de estimación de cargas de combustible a partir de datos de TLS y de métricas derivadas de datos de obstrucción visual.

Tanto los escaneos del TLS (artículo 1) como las mediciones de la barra (comunicación al 8CFN) se utilizaron para la obtención de variables a considerar como potenciales regresoras en los modelos de estimación de cargas a desarrollar. Para facilitar las mediciones y el procesado posterior de los datos se eliminó toda la vegetación perimetral exterior en una franja de 0.5 m excepto en el lado destinado a la ubicación del TLS, donde se eliminó la vegetación en una franja de 4 m para favorecer el asentamiento de la estación de toma de datos. En la Figura 3.3

se puede observar un esquema del dispositivo de medición que se detalla en los apartados siguientes.

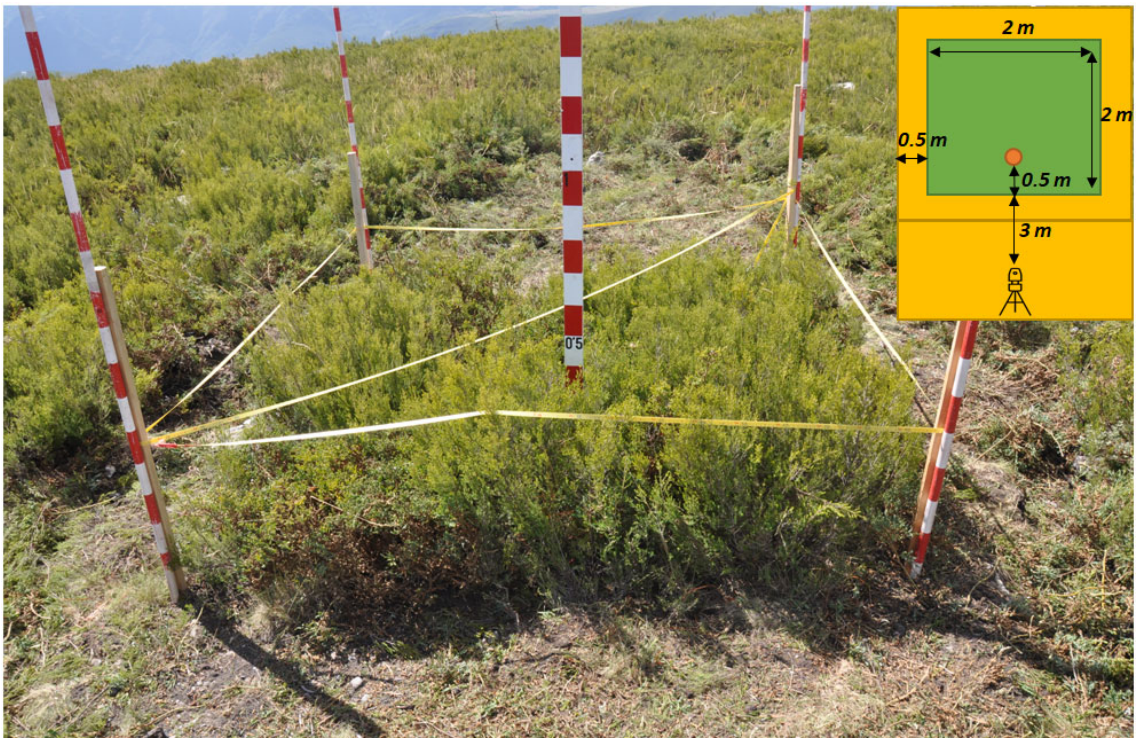

Figura 3. 3. Ejemplo de uno de los cuadrados de muestreo incluyendo el transecto lineal (perímetro y diagonal del cuadrado), la ubicación de la banda graduada (centro de la imagen) y croquis con la ubicación del TLS y las franjas limpias de vegetación (arriba, derecha).

Inventario por transectos y cálculo de cargas de combustible (artículo 1 y comunicación 8CFE)

Sobre los transectos lineales establecidos a lo largo del perímetro y de una de las diagonales interiores de cada cuadrado se realizaron las siguientes mediciones: i) longitudes horizontales de las diferentes especies de matorral interceptadas por el transecto (cm), cuya información se utilizó para calcular posteriormente la cobertura del matorral (Cov_{shr}) según el método propuesto por Canfield (1941); ii) altura de inicio del combustible vivo y muerto (cm) y altura total del matorral (cm) de cada una de las especies interceptadas cada 50 cm de longitud del transecto, y iii) espesor del conjunto de las capas de hojarasca y mantillo, también cada 50 cm de longitud del transecto. Las capas de matorral y mantillo se midieron como un todo debido a que en este tipo de comunidades en general no está claramente definida la separación entre ellas, por tanto, a partir de aquí, y tal como se hizo en el artículo 1, se hará referencia al conjunto como hojarasca (*Litter*).

A continuación, se emplearon las mediciones de alturas del matorral para obtener su altura media ($\overline{h_{Shr}}$), como la media de la altura máxima medida en cada punto del transecto; y también las mediciones de espesor de hojarasca para obtener el espesor medio de esta capa ($\overline{d_{Litt}}$).

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Las cargas de combustible de cada comunidad se estimaron utilizando los sistemas de ecuaciones de biomasa específicos para comunidades de matorral desarbolado en Galicia desarrollados por Arellano-Pérez et al. (2020), y que utilizan Cov_{shr}, $\overline{h_{Shr}}$ y $\overline{d_{Litt}}$ como variables independientes. Estos sistemas incluyen ecuaciones para cada una de las siguientes siete fracciones: carga de combustible fino muerto (diámetro<0.6 cm; $W_{shr_G1_dead}$); carga de combustible fino vivo (diámetro<0.6 cm; $W_{Shr_G1_live}$); carga de combustible fino total (diámetro<0.6 cm; W_{Shr_G1}, muerto + vivo); carga de combustible grueso (diámetro≥0.6 cm; W_{Shr_G23}); carga total de matorral (W_{Shr}, fino + grueso); carga de hojarasca (W_{Litt}) y carga total de combustible de matorral y de hojarasca (W_{shr_Litt}). En la Tabla 3.3 se muestran los estadísticos descriptivos básicos de las principales características estructurales de las capas de matorral y hojarasca de cada comunidad analizada.

Tabla 3. 3. Descripción de las principales características de las capas de matorral y de hojarasca. D.s.= desviación estándar; n = número de parcelas; $\overline{h_{Shr}}$ = altura media del matorral; Cov_{Shr}=cobertura del matorral; $\overline{d_{Litt}}$ = profundidad media de la hojarasca; $W_{Shr_G1_dead}$ = carga de matorral fino muerto; $W_{Shr_G1_live}$ = carga de matorral fino vivo; W_{Shr_G1} = carga de matorral fino; W_{Shr_G23} = carga de matorral grueso; W_{Shr} = carga total de matorral; W_{Litt} = carga de hojarasca; $W_{Shr+Litt}$ = carga de matorral y hojarasca. Derechos de autor 2020, *Remote Sensing*.

		Ea	***Pt***	***Ue***	***Ug***
Variable	**Estadístico**	n = 15	n = 10	n = 15	n = 15
$\overline{h_{Shr}}$	Media (D.s.)	84.91(31.48)	90.37(33.94)	108.18(19.95)	65.43(21.77)
(cm)	Rango	38.24-150.76	42.86-151.05	59.71-113.10	13.90-109.33
Cov_{Shr}	Media (D.s.)	99.80 (0.52)	99.34 (1.20)	99.64 (0.77)	98.32 (3.17)
(%)	Rango	98.15-100	96.3-100	97.69-100	87.5-100
$\overline{d_{Litt}}$	Media (D.s.)	2.38 (1.17)	4.03 (1.19)	5.49 (2.11)	4.56 (0.98)
(cm)	Rango	0.78-5.60	2.02-5.86	3.08-10.55	2.40-5.81
$W_{Shr_G1_dead}$	Media (D.s.)	0.41 (0.12)	0.84 (0.17)	0.89 (0.09)	0.75 (0.18)
(kg m^{-2})	Rango	0.20-0.63	0.58-1.01	0.65-1.00	0.20-1.00
$W_{Shr_G1_live}$	Media (D.s.)	1.19 (0.23)	1.47 (0.25)	1.40 (0.07)	1.53 (0.23)
(kg m^{-2})	Rango	0.76-1.53	1.08-1.73	1.18-1.48	0.72-1.69
W_{Shr_G1}	Media (D.s.)	1.60 (0.36)	2.31 (0.42)	2.29 (0.16)	2.28 (0.41)
(kg m^{-2})	Rango	0.96-2.16	1.66-2.74	1.83-2.47	0.92-2.69
W_{Shr_G23}	Media (D.s.)	0.48 (0.36)	0.62 (0.40)	1.17 (0.31)	0.37 (0.28)
(kg m^{-2})	Rango	0.06-1.38	0.12-1.37	0.46-1.58	0.00-1.09
W_{Shr}	Media (D.s.)	2.08 (0.71)	2.93 (0.80)	3.47 (0.47)	2.65 (0.63)
(kg m^{-2})	Rango	1.02-3.54	1.77-3.99	2.29-4.05	0.93-3.78
W_{Litt}	Media (D.s.)	1.00 (0.36)	1.38 (0.49)	1.89 (0.64)	1.70 (0.35)
(kg m^{-2})	Rango	0.45-1.91	0.71-2.25	1.14-3.40	0.93-2.14
$W_{Shr+Litt}$	Media (D.s.)	3.08 (0.99)	4.31 (1.11)	5.35 (1.02)	4.35 (0.84)
(kg m^{-2})	Rango	1.70-5.45	2.54-6.24	3.98-7.45	2.51-5.75

Ea = Erica australis, Pt = Pterospartum tridentatum, Ue = Ulex europaeus y *Ug = Ulex gallii*/*U. minor*.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Datos TLS (artículo 1)

La toma de datos de LiDAR terrestre se llevó a cabo empleando un dispositivo FARO Laser Scanner Focus3D X 130 TLS con una densidad de puntos equivalente a la de una malla cuadrada de puntos con ~7.67 mm de lado a una distancia del punto de estacionamiento del dispositivo de 10 m. Este equipo es un láser de clase I, con una longitud de onda de 1550 nm, con un alcance operativo de entre 0.6 y 130 m para objetos con un 90% de reflectividad y con una precisión de ±2 mm a 10 m de alcance. Se realizó un único escaneo por cuadrado de muestreo situando el TLS a una distancia de 3 m del lado del cuadrado situado en curva de nivel y en la parte más baja de la ladera (Figura 3.4).

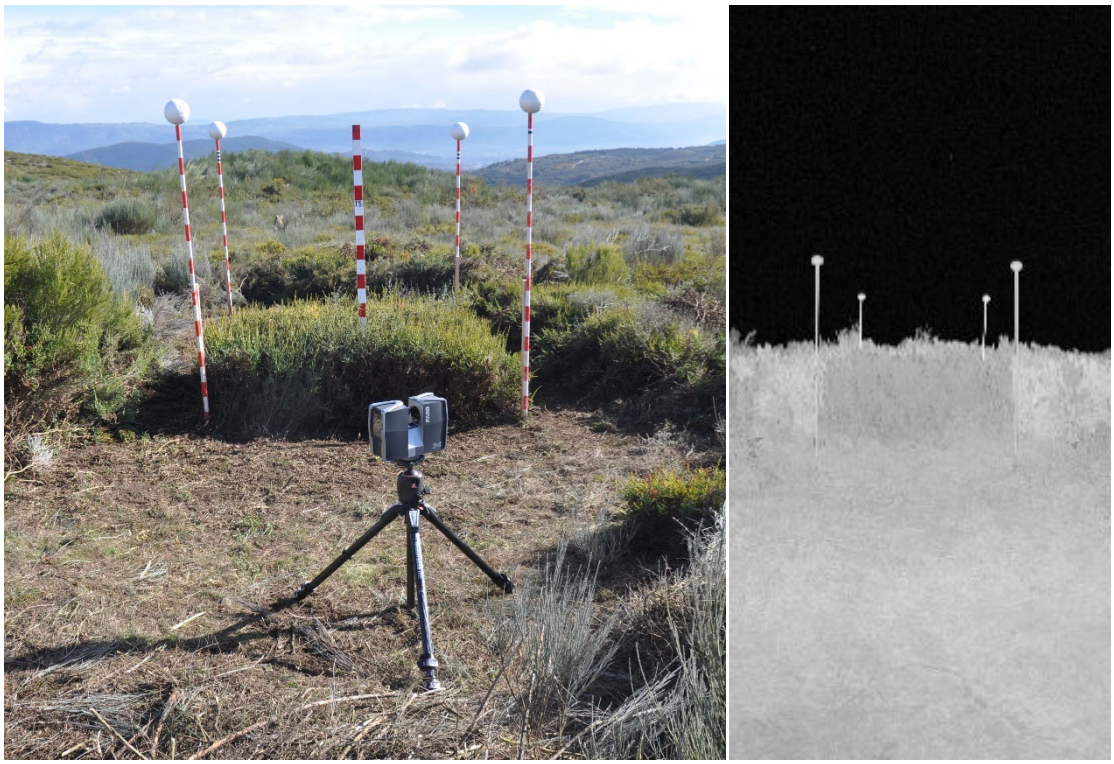

Figura 3. 4. Imagen de la ubicación del TLS (izquierda) y de la toma de datos y escaneo (derecha) en una de las parcelas de muestreo.

El fichero con los datos brutos obtenidos por el escáner se transformó a formato "*las*" para su procesado empleando el software de código abierto y licencia libre R (R Core Team, 2020). A grandes rasgos, la primera fase del procesado consistió en recortar la nube de puntos para limitarla al interior del cuadrado de muestreo. A continuación, se procedió a identificar los retornos correspondientes al suelo para, a partir de ellos, elaborar un modelo digital del terreno (MDT). Una vez determinado el MDT, se procedió a normalizar los datos de la coordenada z de cada retorno para transformarlos en valor de altura sobre el terreno (h) y finalmente se utilizaron estos valores para calcular 32 métricas relacionadas con la distribución vertical de las nubes de puntos. Las métricas y sus correspondientes descripciones se resumen en la Tabla 3.4.

USC DE SANTIAGO DE COMPOSTELA

Tabla 3. 4. Métricas derivadas de las nubes de puntos del escáner láser terrestre (TLS).

Métrica	Descripción
h_{max} (cm)	Máxima altura
h_{mean}(cm)	Altura Media
h_{mode}(cm)	Moda de las alturas
h_{median}(cm)	Mediana de las alturas
h_{SD}(cm)	Desviación estándar de las alturas
$h_{skewness}$	Coeficiente de asimetría
$h_{kurtois}$	Coeficiente de kurtosis
h_{01}, h_{05}, h_{10}, h_{15}, h_{20},…, h_{90}, h_{95}, h_{99} (cm)	Percentiles de altura
h_{25} y h_{75} (cm)	Primer y tercer cuartil de las alturas
IQR (cm)	Distancia intercuartílica (h_{75} - h_{25})
P_{Ahmean}	Ratio de retornos por encima de h_{mean}
P_{Ahmode}	Ratio de retornos por encima de h_{mode}

Uno de los principales inconvenientes del uso del TLS en el medio forestal son las oclusiones en la toma de datos debidas a la vegetación. Estas oclusiones afectan en gran medida a estas comunidades de matorral tan densas, de modo que el número de retornos obtenidos se reduce a medida que el haz de láser se adentra desde el frente de matorral hacia el interior. Para tratar de homogeneizar el proceso de toma de datos con el TLS y la obtención de unas métricas robustas, se llevó a cabo un análisis para determinar la distancia óptima desde el frente de vegetación hacia el interior a considerar en la nube de puntos, a partir de la cual se calculan dichas métricas. Para ello, y en cada parcela, se calcularon todas las métricas empleando la nube de puntos recortada a una distancia hacia el interior de 10 cm desde el frente y se repitió el proceso incrementando dicha profundidad de la nube de puntos de 5 en 5 cm, hasta llegar a una profundidad máxima de 50 cm, a partir de la cual se observó que los retornos eran muy poco frecuentes. Posteriormente se compararon las métricas obtenidas para cada profundidad y se consideró como más apropiada una distancia de 30 cm desde el frente de vegetación, puesto que se observó que para esta distancia los valores de las métricas se estabilizan, por lo que se limitaron todas las nubes de retornos láser a ese umbral de profundidad (ver Figura 3.5).

Además de las métricas de alturas también se calcularon otras dos variables representativas de la cobertura vertical y de la cobertura espacial del matorral. La teórica cobertura vertical del matorral se estimó como la ratio entre el número observado de retornos láser de la nube de puntos y el número máximo de retornos láser lr_{max_ver}, estimado como el número de retornos que se obtendrían en función de la densidad de puntos del dispositivo (distancia entre retornos de ~7.67 mm a una distancia de 10 m) considerando el frente del matorral como un plano vertical opaco con altura igual a h_{max}. Por otro lado, para la estimación de la cobertura espacial del matorral se dividió el volumen aparente de las nubes de puntos tridimensionales de cada parcela (2 x 2 x h_{max}) en cubos de 1 cm^3 y se calculó la ratio entre el número de cubos que contenían retornos y el número total de cubos. Ambas ratios se transformaron calculando la raíz cuadrada del arcoseno de sus valores en tanto por uno para estabilizar la varianza y mejorar la normalidad (Bliss, 1938), dando lugar así a las variables *TLSv*Cov$_{Shr}$ y *TLS3DCov*$_{Shr}$. Por último, se modelizó la distribución vertical de las nubes de puntos mediante la función de densidad de probabilidad (pdf) de Weibull con dos parámetros. Para ello se dividió el prisma de 2 metros de ancho, por 30 cm de profundidad y una altura igual a h_{max} que contiene la nube de puntos a analizar en capas de 1 cm de altura desde el suelo y se determinó la ratio de retornos en cada

USC DE COMPOSTELA

capa frente al total de retornos para obtener las frecuencias relativas. Los parámetros de escala (W_{scale}) y de forma (W_{shape}) de la función de probabilidad de Weibull se estimaron utilizando el primer y el segundo momento de la distribución vertical de los retornos láser en frecuencias relativas (Cao et al., 1982).

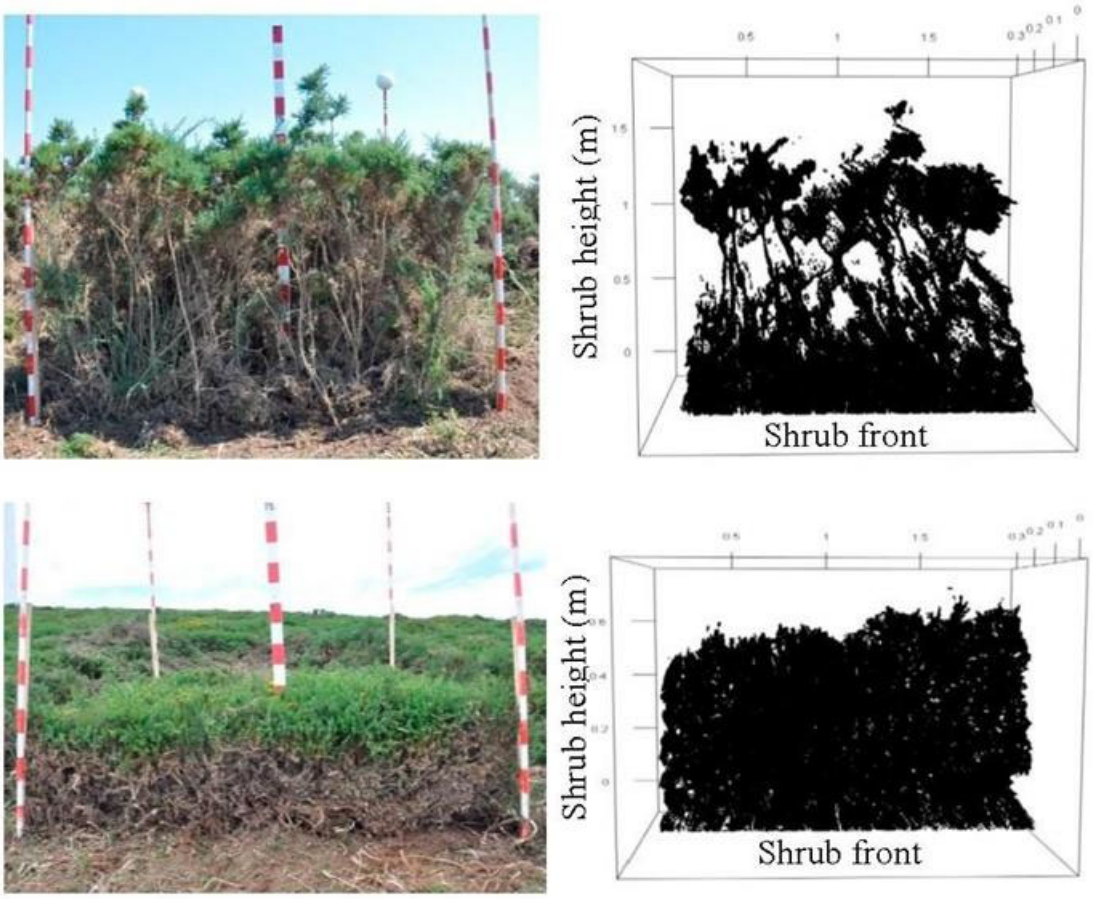

Figura 3. 5. Ejemplos de cuadrados de muestreo en *Ulex europaeus* (superior) y *Ulex gallii* / *U. minor* (inferior) y nubes de retornos láser derivadas del escaneo del TLS obtenidas tras el procesamiento de los datos brutos. Derechos de autor 2020, *Remote Sensing*.

Como se ha comentado anteriormente, todo el trabajo de procesado de nubes de puntos, de cálculo de métricas derivas del TLS y de estimación de los parámetros de la pdf de Weibul fueron programados en R (R Core Team, 2020) con el apoyo de las librerías "*rgl*" (Alder et al., 2020) y "*e1071*" (Meyer et al., 2020).

Finalmente, se consideraron como potenciales variables independientes en los modelos de estimación de las cargas de combustible las ratios *TLS v* Cov_{Shr} y *TLS3DCov*$_{Shr}$ transformadas para garantizar su normalidad, los parámetros de la función de Weibull (W_{scale} y W_{shape}) y las 32 métricas relacionadas con la distribución vertical de las nubes de puntos (Tabla 3.4).

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Datos de obstrucción visual de la vegetación (comunicación 8CFE)

Paralelamente, en cada una de las parcelas de estudio se realizaron una serie de mediciones de obstrucción visual del matorral con una barra de 2 metros de longitud y 5 cm de anchura dividida en bandas de 10 cm, siguiendo la metodología propuesta por Davies et al. (2008). El procedimiento llevado a cabo consistió en situar la barra en el interior del cuadrado de muestro de 2x2 m, a una profundidad de 50 cm del centro del frente de vegetación (ver Figura 3.6). La barra se introdujo en vertical hasta llegar a la superficie del suelo mineral cubriendo, por lo tanto, la totalidad de la capa de hojarasca. Desde el frente de vegetación se estimó visualmente la cobertura vertical del matorral en porcentaje en cada banda de 10 cm, diferenciando las especies leñosas presentes y el estado vegetativo de las mismas, es decir, vivo o muerto. Además, se estimó el espesor de la hojarasca (d_{Litt}) y la altura total del matorral (h_{Shr}), tomando como referencia para esta última la superficie de la capa de hojarasca y las alturas de cada especie (Davies et al., 2008).

Figura 3. 6. Ejemplo de la obstrucción visual provocada por la vegetación en una de las parcelas de estudio a partir de la cual estimar la carga y la estructura vertical del matorral.

Con estos datos de cobertura de la banda de cada parcela se ajustó un modelo logístico:

$$p_i = \frac{e^{a+b \cdot h_i}}{1 + e^{a+b \cdot h_i}} \tag{3.1}$$

Donde p_i es el tanto por uno de cobertura de la banda i (i = 1 a 20) y h_i es la altura a la que está el punto medio de la banda i cuando el matorral sobrepasa la banda en altura y, en el caso de que la altura del matorral no llegue a sobrepasar la banda (última banda parcialmente

ocupada), entonces h_i es la altura del punto medio de la longitud obstruida de dicha banda. Por ejemplo, si el matorral llega hasta 67 cm de altura, la última banda con matorral obstruyendo su visión va de 60 a 70 cm y el valor de h_i para esta banda sería de 63.5 cm.

Una vez estimados los parámetros *a* y *b* del modelo logístico de perfil de combustible de cada parcela se obtuvieron los valores de una serie de métricas para cada una de ellas (Davies et al., 2008): i) la suma de los tantos por uno de obstrucción de matorral en cada banda para el total de la barra (obs_{acum}); ii) el ratio entre la altura de la hojarasca y la altura total (r_{Litt}); iii) el índice *CDI* (*Canopy Density Index*) definido por Davies et al. (2008), que se corresponde con el valor del parámetro *b* que, a su vez, se corresponde con la pendiente de la recta de la transformación logarítmica de la ecuación (3.1) $log(p_i/(1-p_i)) = a + b \cdot h_i$y4) el parámetro *BM* (*Biomass Measure*), definido por Davies et al. (2008), que se corresponde con el área bajo la curva del perfil obtenido por integración del modelo logístico entre 0 y la altura máxima del matorral (h_{max}):

$$BM = \int_0^{hmax} \frac{e^{a+b*h_i}}{1+e^{a+b*h_i}}\, dh_i \tag{3.2}$$

Asumiendo que $e^{a+b*h_i} = t$, entonces $b * e^{a+b*h_i} dh_i = dt$ y por tanto se puede obtener la primitiva de la integral anterior:

$$BM = \int_0^{hmax} \frac{e^{a+b*h_i}}{1+e^{a+b*h_i}}\, dh_i = \int_{e^a}^{e^{a+b*hmax}} \frac{1}{b*(1+t)} dt \Rightarrow \tag{3.3}$$
$$\Rightarrow\ BM = \frac{1}{b}[log(1+e^{a+b*hmax}) - log(1+e^a)]$$

3.1.3 Modelos de estimación de cargas de combustible

Una vez obtenidas todas las potenciales variables regresoras, tanto de los escaneos del TLS como de las observaciones en la barra de oclusión visual, se procedió al desarrollo de modelos de estimación de cargas de combustible desagregadas por estrato, clases de tamaño y estado vegetativo. Para ello, se compararon dos enfoques diferentes, por una parte, una estimación directa (ED), empleada tanto en el artículo 1 como en la comunicación al 8CFE, y una estimación indirecta (EI), empleada únicamente en el artículo 1.

El enfoque directo (ED) se basó en el ajuste de un sistema de siete ecuaciones que relacionan directamente la carga de combustible de cada fracción de biomasa con las métricas y variables derivadas del TLS (artículo 1) o derivadas de las mediciones de obstrucción visual de la vegetación (comunicación del 8CFE). Por otro lado, la estimación indirecta (EI) se basó en el ajuste de un conjunto de tres ecuaciones que relacionan las variables Cov_{Shr}, $\overline{h_{Shr}}$ y $\overline{d_{Litt}}$ obtenidas mediante inventario de campo, con las variables y métricas derivadas del TLS, así como en el posterior uso de las ecuaciones de estimación de cargas desarrolladas específicamente para comunidades de matorral desarbolado de Galicia (Arellano-Pérez et al.,

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

2020), puesto que estas ecuaciones utilizan como variables independientes precisamente Cov$_{Shr}$, $\overline{h_{Shr}}$ y $\overline{d_{Litt}}$.

En el enfoque indirecto (EI) se utilizaron modelos lineales ($y = \alpha_0 + \alpha_i \cdot X_i$) para ajustar las ecuaciones de estimación de las variables $\overline{h_{Shr}}$ y $\overline{d_{Litt}}$ y un modelo logístico con una asíntota horizontal igual a 100 $\left[y = 100/\left(1 + e^{\beta_0 + \beta_i \cdot X_i}\right)\right]$para estimar la variable Cov$_{Shr}$. El mejor conjunto de variables independientes (X_i) se seleccionó utilizando el método de selección variables paso a paso (*stepwise*) linealizando previamente el modelo logístico mediante logaritmos.

En el enfoque ED se probaron modelos alométricos ($y = \gamma_0 \cdot X_i^{\gamma_i}$) para las siete fracciones de combustibles analizadas. Estas ecuaciones alométricas deben cumplir la propiedad de aditividad, es decir, la suma de las estimaciones de carga de las fracciones de combustible por separado debe ser igual a la estimación de carga de la fracción que las agrupa (por ejemplo, la suma de las estimaciones de carga de matorral fino muerto y de matorral fino vivo debe ser igual a la estimación de carga total de matorral fino, o la suma de las estimaciones de carga de matorral fino y de matorral grueso tiene que ser igual a la estimación de carga total de matorral). Para garantizar la propiedad de aditividad se utilizó un método de desagregación basado en definir un modelo para la estimación de la carga total de matorral y hojarasca para después ir condicionándolos parámetros de las distintas ecuaciones de estimación de cada fracción en función de las relaciones de aditividad (ver, por ejemplo, los trabajos de Tang et al., 2001 y Tang y Wang, 2002).

En un primer paso, la ecuación de cada fracción se linealizó mediante logaritmos y se ajustó por separado utilizando mínimos cuadrados ordinarios (OLS) para modelos lineales, seleccionándose el mejor conjunto de variables independientes (X_i) mediante el método de selección de variables *stepwise*. Después se ajustó simultáneamente el sistema completo de siete ecuaciones (una por fracción) para garantizar la aditividad. De este modo, la expresión general de cada una de las siete ecuaciones se derivó de la siguiente manera:

En primer lugar, se emplea una ecuación alométrica para estimar la carga total de combustible (matorral y mantillo) $\widehat{W_{Shr+Litt}}$ conjuntamente.

$$\widehat{W_{Shr+Litt}} = a_0 \cdot X_i^{a_i} \tag{3.4}$$

Se definen otras dos ecuaciones alométricas para discriminar entre la carga del combustible de matorral (W_{Shr}) y la del mantillo (W_{Litt}) por desagregación de la ecuación anterior:

$\widehat{W_{Shr}} = exp\left[\ b_{0_{Shr}} + b_{i_{Shr}} log(X_i)\right]$ y $\widehat{W_{Litt}} = exp\left[\ b_{0_{Litt}} + b_{i_{Litt}} log(X_i)\right]$;

por lo tanto:

$$\frac{\widehat{W_{Shr}}}{\widehat{W_{Shr+Litt}}} = \frac{\widehat{W_{Shr}}}{\left(\widehat{W_{Shr}} + \widehat{W_{Litt}}\right)} = \frac{1}{1 + \left(\widehat{W_{Litt}}/\widehat{W_{Shr}}\right)}$$

De este modo, la ecuación para estimar la carga de combustible de matorral fue:

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

$$\widehat{W_{Shr}} = \widehat{W_{Shr+Litt}} \cdot \frac{1}{1 + exp[b_0 + b_i \cdot log(X_i)]} \quad (3.5)$$

siendo $b_0 = b_{0Litt} - b_{0Shr}$ y $b_i = b_{iLitt} - b_{iShr}$; y la ecuación para la carga del mantillo fue:

$$\widehat{W_{Litt}} = \widehat{W_{Shr+mLitt}} - \widehat{W_{Shr}} = \widehat{W_{Shr+Litt}} \cdot \left[1 - \frac{1}{1 + exp[b_0 + b_i \cdot log(X_i)]}\right] \quad (3.6)$$

A continuación, se desagregó la ecuación (3.5) para obtener dos ecuaciones que discriminen entre la carga de combustible de matorral grueso (W_{Shr_G23}) y fino (W_{Shr_G1}):

$$\widehat{W_{Shr_G23}} = exp\left[\ c_{0_{g23}} + c_{i_{g23}} log(X_i)\right], \text{ y } \widehat{W_{Shr_G1}} = exp\left[\ c_{0_{g1}} + c_{i_{g1}} log(X_i)\right]$$

$$\frac{\widehat{W_{Shr_G23}}}{\widehat{W_{Shr}}} = \frac{\widehat{W_{Shr_G23}}}{\left(\widehat{W_{Shr_G23}} + \widehat{W_{Shr_G1}}\right)} = \frac{1}{1 + \left(\widehat{W_{Shr_G1}}/\widehat{W_{Shr_G23}}\right)}$$

De este modo la ecuación de estimación de la carga de combustible grueso fue:

$$\widehat{W_{m_G23}} = \widehat{W_{Shr}} \cdot \frac{1}{1 + exp[c_0 + c_i \cdot log(X_i)]} \quad (3.7)$$

siendo $c_0 = c_{0g1} - c_{0g23}$ y $c_i = c_{ig1} - c_{ig23}$ y la de la carga de combustible fino fue:

$$\widehat{W_{Shr_G1}} = \widehat{W_{Shr}} - \widehat{W_{Shr_G23}} = \widehat{W_{Shr}} \cdot \left[1 - \frac{1}{1 + exp[c_0 + c_i \cdot log(X_i)]}\right] \quad (3.8)$$

Finalmente, la desagregación de la ecuación (3.8) da lugar a dos ecuaciones que permiten discriminar entre la carga de combustible de matorral fino muerto ($W_{Shr_G1_dead}$) y vivo ($W_{Shr_G1_live}$):

$$\widehat{W_{Shr_G1_dead}} = exp\left[\ d_{0_{g1_d}} + d_{i_{g1_d}} log(X_i)\right] \quad \text{y}$$

$$\widehat{W_{Shr_G1_live}} = exp\left[\ d_{0_{g1_l}} + d_{i_{g1_l}} log(X_i)\right]$$

$$\frac{\widehat{W_{Shr_G1_dead}}}{\widehat{W_{Shr_G1}}} = \frac{\widehat{W_{Shr_G1_dead}}}{\left(\widehat{W_{Shr_G1_dead}} + \widehat{W_{Shr_G1_live}}\right)} = \frac{1}{1 + \left(\widehat{W_{Shr_G1_live}}/\widehat{W_{Shr_G1_dead}}\right)}$$

Por tanto, la ecuación de estimación de la carga de combustible fino muerto fue:

$$\widehat{W_{Shr_G1_dead}} = \widehat{W_{Shr_G1}} \cdot \frac{1}{1 + exp[d_0 + d_i \cdot log(X_i)]} \quad (3.9)$$

siendo $d_0 = d_{0g1_l} - d_{0g1_d}$ y $d_i = d_{ig1_l} - d_{ig1_d}$; y la ecuación de la carga de combustible fino vivo fue:

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

$$\widehat{W_{Shr_G1_live}} = \widehat{W_{Shr_G1}} - \widehat{W_{Shr_G1_dead}} = \widehat{W_{Shr_G1}}\left[1 - \frac{1}{1 + exp[d_0 + d_i \cdot log(X_i)]}\right] \quad (3.10)$$

La presencia de multicolinealidad entre las variables en las ecuaciones se evaluó a través del número de condición (*condition number "cn"*). De acuerdo con Myers (1990), valores de "*cn*" superiores a $\sqrt{1000}$ indican problemas asociados a la multicolinealidad. En el caso de detectar problemas de multicolinealidad se eliminará alguna de las variables regresoras que estén fuertemente correlacionadas. La presencia de heteroscedasticidad se evaluó mediante el test de White (White, 1980) y mediante la inspección visual de los gráficos de residuos studentizados frente a valores predichos de las cargas. En el caso de detectar problemas de heteroscedasticidad, cada observación se pondera por el inverso de su varianza estimada ($\hat{\sigma}_i^2$), asumiendo que esta varianza se puede modelar como una función potencial de las variables independientes (Cailliez, 1980), es decir, $\hat{\sigma}_i^2 = (X_i)^k$. El valor del término exponencial *k* se optimizó para proporcionar el gráfico de residuos más homogéneo utilizando el método propuesto por Harvey (1976).

Las siete ecuaciones no lineales (ecuaciones 3.4 a 3.10) constituyen un sistema y fueron ajustadas simultáneamente empleando la metodología *Non Linear Seemingly Unrelated Regression* (NLSUR), que tiene en cuenta las correlaciones entre los errores entre dichas ecuaciones del sistema. Los ajustes se realizaron con el procedimiento MODEL del programa SAS/ETS® (SAS Institute Inc., 2004) y, en el caso de que fuera necesario, el factor de ponderación para la corrección de la heteroscedasticidad se programó en el propio procedimiento.

Para evaluar la bondad de los ajustes se utilizaron dos estadísticos: el coeficiente de determinación (R^2) y la raíz del error medio cuadrático (*RMSE*):

$$R^2 = 1 - \frac{\sum_{i=1}^{n}\left(Y_i - \hat{Y}_i\right)^2}{\sum_{i=1}^{n}(Y_i - \bar{Y})^2} \quad (3.11)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n}\left(Y_i - \hat{Y}_i\right)^2}{n-1}} \quad (3.12)$$

Donde Y_i, $\hat{Y}_i$ e $\bar{Y}$ son los valores observados, predichos y medios de las variables dependientes y *n* es el número total de observaciones utilizadas para ajustar cada ecuación.

Como el número de parcelas de muestreo por comunidad de matorral es limitado no es posible ajustar un sistema para cada una de ellas por separado. Por tanto, se utilizó la base de datos completa tanto para los enfoques directo e indirecto a partir de métricas TLS (artículo 1) como para el enfoque directo a partir de métricas derivadas de la obstrucción visual de la banda (comunicación 8CFE). Sin embargo, las diferencias entre las cuatro comunidades de matorral se evaluaron en todos los casos expandiendo los parámetros a_0, b_0, c_0 y d_0 con una relación lineal que incluye parámetros asociados con variables categóricas (*dummy*) para diferenciar entre comunidades:

$$\alpha_0 = \alpha_{00} + \alpha_{01} I_{Ea} + \alpha_{02} I_{Ug} + \alpha_{03} I_{Pt}$$

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Donde α_0 es el parámetro expandido (a_0, b_0, c_0 o d_0); α_{00} es un parámetro común para todas las comunidades; α_{0i} (i = 1,…,3) es un parámetro asociado, e I_j (j = *Ea*, *Ug*, *Pt*) es una variable categórica cuyo valor es igual a 1 para la comunidad específica y 0 para las demás comunidades de matorral. Si el resultado de la prueba de la *t* de student de un parámetro asociado específico es significativo (α = 95%), esto indica que hay diferencias entre comunidades en la ecuación específica afectada por el parámetro asociado.

Por último, en el artículo 1 se compararon los resultados de los enfoques directo e indirecto comparando los valores de R^2 (ecuación 3.11), *RMSE* (ecuación 3.12), sesgo o error medio ($\bar{e}$), sesgo o error medio en valor absoluto ($|\bar{e}|$) y *RMSE* en porcentaje con respecto al valor medio de la variable dependiente (*rRMSE*%) de las cargas de combustible observadas y estimadas en las parcelas de muestreo para cada enfoque:

$$\bar{e} = \frac{\sum_{i=1}^{n}\left(Y_i - \hat{Y}_i\right)}{n} \tag{3.13}$$

$$|\bar{e}| = \frac{\sum_{i=1}^{n}\left|Y_i - \hat{Y}_i\right|}{n} \tag{3.14}$$

$$rRMSE\% = \frac{RMSE}{\bar{Y}} \cdot 100 \tag{3.15}$$

3.2 Artículo 2

Artículo 2: Estimación de variables de rodal y de variables de superficie y del dosel de copas relacionadas con el fuego en pinares a partir de escáner laser aéreo de baja densidad y de un único escaneo con láser terrestre (*Remote Sensing*, 2021, *13,* (24), 5170).

El principal objetivo de este artículo es evaluar el potencial de métricas derivadas de escaneos con láser aéreo (ALS) de baja densidad y también de escaneos simples con láser terrestre (TLS), así como de una combinación de ambos tipos de datos, para proporcionar estimaciones precisas de variables relacionadas con incendios de superficie y de copas a nivel de masa en pinares de *Pinus pinaster* y *P. radiata*. Todo ello, comparando tres metodologías diferentes: *Multivariate Adaptive Regression Splines* (MARS), *Support Vector Machine* (SVM) y *Random Forest* (RF).

3.2.1 Área de estudio y red de parcelas

El estudio se ha desarrollado en una red de parcelas de ensayo de claras establecida en plantaciones puras y coetáneas de *Pinus pinaster* y *P. radiata* en el NW peninsular. Si bien la red original se distribuye por todo el interior de Galicia y el occidente de Asturias y de León con un total de 123 parcelas en 41 localizaciones diferentes (ver Arellano et al., 2018 para una descripción más completa de la red), para este estudio solo se han utilizado los datos de 102 parcelas correspondientes a 34 localizaciones (20 de *P. pinaster* y 14 de *P. radiata)*, todas ellas localizadas en Galicia y Asturias (Figura 3.7).

La red de ensayo de claras se estableció en el año 2009 con una edad de la masa que oscilaba entre 12 y 32 años (edad media de 17.6 años) en *P. pinaster* y entre 12 y 22 años (edad media de 16.3 años) en *P. radiata*. En cada localización se replantearon 3 parcelas rectangulares de 1000 m^2 de superficie (25 x 40 m) (Figura 3.7). A cada una de las tres parcelas se le asignó al azar un tratamiento de clara diferente: control (C, sin realizar tratamiento, con extracción únicamente de los pies muertos); clara débil (LT, 20% del área basimétrica extraída en clara por lo bajo) y clara fuerte (HT, 40% del área basimétrica extraída en clara por lo bajo). Además, se aplicó el mismo tratamiento de clara en una zona de transición de 5 m de anchura alrededor de cada parcela, para evitar el efecto borde y todas las parcelas se podaron previamente a una altura mínima de 2.5 m. Las claras se llevaron a cabo aproximadamente un año después del replanteo de las parcelas. La extracción de los troncos apeados se realizó inmediatamente después de la clara, aunque en algunos casos se dejaron restos de pequeño diámetro (<10 cm) en la parcela debido a su dificultad de extracción y a los elevados costes que generaba. En este caso, los restos quedaron esparcidos en el lugar para incorporar nutrientes al suelo, una práctica que es habitual en la región. Las esquinas de las parcelas se georreferenciaron con un GPS Trimble Geo 7X (Geospatial, USA) con un procesamiento posterior de la información para obtener precisiones centimétricas de las coordenadas.

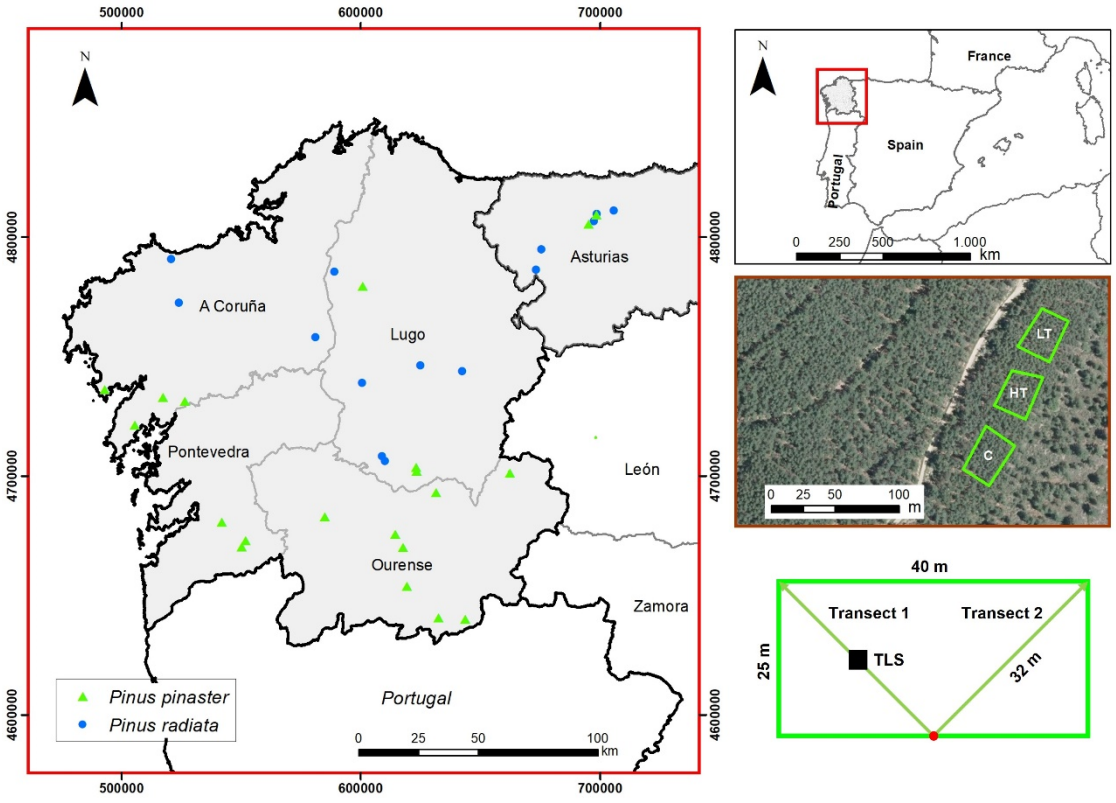

Figura 3. 7. Localización geográfica de los 34 lugares de ensayo de clara en el área de estudio (izquierda). Ejemplo de tres parcelas de muestreo (polígonos verdes) en una de las ubicaciones de los ensayos (centro derecha). Disposición de los transectos de muestreo de combustible de superficie en cada parcela (abajo a la derecha). Derechos de autor 2021, *Remote Sensing*.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

3.2.2 Obtención de datos y variables calculadas

En cada una de las parcelas se llevaron a cabo varios inventarios dasométricos: en 2009-2010 se efectuaron dos inventarios, uno antes y otro inmediatamente después de la clara, para posteriormente repetirlos en los inviernos de 2011-2012, 2013-2014 y 2015-2016 (ver Arellano-Pérez et al., 2018; 2020 para una descripción detallada de los inventarios realizados). Además, coincidente con el último inventario dasométrico (2015-16) se realizaron también mediciones en el combustible de superficie (vegetación del sotobosque, restos leñosos caídos y hojarasca y mantillo) en las parcelas de control y de clara fuerte, dejando sin inventariar las parcelas de clara moderada por la complejidad del trabajo en términos de tiempo invertido y coste, de modo que se caracterizaron detalladamente los tratamientos extremos. Por lo tanto, para las variables relacionadas con el fuego de superficie solo se analizaron los datos de las 68 parcelas con dichos tratamientos extremos (control y clara fuerte), mientras que para las variables relacionadas con los incendios de copas en este estudio se emplearon los datos de los tres tratamientos (total 102 parcelas) del último inventario.

En los apartados siguientes se describen los diferentes inventarios realizados, las variables de rodal, del dosel de copas y del combustible de superficie calculadas y la información láser terrestre y aéreo registrada y procesada.

Variables de árbol y de rodal

En los inventarios dasométricos se midieron los diámetros normales en cruz (d, cm) de todos los árboles de cada parcela con una forcípula de precisión de 0.1 cm. La altura total del árbol (h, m) y la altura de inicio de copa viva (h_{blc}, m), definida como el punto de inserción más bajo de las ramas vivas del árbol se midieron con un hipsómetro digital (Vertex-IV) de precisión 0.1 m en una muestra aleatoria de 30 árboles y en una muestra adicional, que incluía todos los árboles dominantes (la proporción de los 100 árboles de mayor diámetro por hectárea). Para estimar los valores de h de los árboles restantes se utilizaron los modelos generalizados de *h-d* (Diéguez-Aranda et al., 2009) que se muestran en la Tabla 3.5 desarrollados en el área de estudio para *P. radiata* y *P. pinaster*. Además, se estimó el volumen total, la biomasa aérea total, y la biomasa fina (biomasa de acículas y de ramillas finas con un diámetro < 6 cm) de cada árbol utilizando los modelos de volumen de árbol individual (Diéguez-Aranda et al., 2009) y los sistemas compatibles de biomasa desarrollados para *P. pinaster* y *P. radiata* en Galicia (Balboa-Murias et al., 2006).

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Tabla 3. 5. Ecuaciones *h-d* generalizadas desarrolladas para *P. pinaster* y *P. radiata* en Galicia y estadísticos de bondad del ajuste (Diéguez-Aranda et al., 2009).

Especie	Ecuación	
P. pinaster	$h = \left[1.3^a + (H^a - 1.3^a) \cdot \frac{1 - e^{-(0.04611 - 0.04734 \cdot I) \cdot d}}{1 - e^{-(0.04611 - 0.04734 \cdot I) \cdot D}}\right]^{1/a}$ con $a = 1.894 + 1.469 \cdot I$ $R^2 = 0.9380$; *RMSE* (m) = 0.87	(3.16)
P. radiata	$h = \left[1.3^{1.633} + (H^{1.633} - 1.3^{1.633}) \cdot \frac{1 - e^{-0.02961 \cdot d}}{1 - e^{-0.02961 \cdot D}}\right]^{1/1.633}$ $R^2 = 0.9330$; *RMSE* (m) = 1.28	(3.17)

Donde h es la altura total del árbol (m); d es el diámetro normal con corteza (cm); H la altura dominante del rodal (m); D el diámetro dominante del rodal (cm), definido como el diámetro medio de los 100 pies más gruesos por hectárea e I es una variable categórica que toma el valor de 1 para la zona costera y 0 para la zona interior de distribución de la especie en Galicia (Vega-Alonso et al., 1993).

A partir de las variables de árbol individual se calculó para cada parcela e inventario el número de pies por hectárea (N, pies ha^{-1}), el área basimétrica (G, m^2 ha^{-1}), la altura media ($\bar{h}$, m), la altura dominante (H, en m y definida como la altura media de los 100 árboles más gruesos por hectárea), el volumen (V, m^3 ha^{-1}) y la biomasa aérea total (W, kg ha^{-1}).

Variables del dosel de copas

A partir de las mediciones del arbolado también se calcularon las principales características estructurales del dosel relacionadas con el fuego de copas: altura de la base del dosel (*Canopy Base Height*, *CBH*), carga de combustible disponible en las copas (*Canopy Fuel Load*, *CFL*) y densidad aparente del dosel (*Canopy Bulk Density*, *CBD*). Se siguió el método *load over depth* (Van Wagner, 1977) y, por tanto, *CBH* se calculó como la media de las alturas de la base de la copa viva de los 30 árboles de la muestra aleatoria de cada parcela; *CFL* se calculó agregando la biomasa fina de copa aportada por cada uno de los árboles de la parcela y dividiendo por la superficie de esta, y *CBD* como el cociente entre *CFL* y la longitud de la copa, que a su vez fue estimada como la diferencia entre la altura media del rodal ($\bar{h}$) y *CBH*.

Los estadísticos descriptivos de las principales variables de rodal y dosel de copas del arbolado de las parcelas con tratamientos de control, clara débil y clara fuerte (C, LT y HT) de cada especie de pino se muestran en la Tabla 3.6.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Tabla 3. 6. Estadísticos de las principales características de rodal y del dosel de copas. D.s. = desviación estándar; *N* = densidad; *G* = área basimétrica; $\bar{h}$ = altura media; *H* = altura dominante; *V* = volumen; *W* = biomasa aérea total; *CBH* = altura de la base del dosel; *CFL* = carga de combustible disponible en el dosel; *CBD* = densidad aparente del dosel; *C* = control, *LT* = clara débil y *HT* = clara fuerte.

Variable	Estadístico	*Pinus pinaster*			*Pinus radiata*		
		C	**LT**	**HT**	**C**	**LT**	**HT**
N	Media	1312.57	945.53	697.70	1014.23	725.52	506.35
(pies ha^{-1})	D.s.	384.14	358.82	228.99	261.14	144.36	112.60
G	Media	45.75	38.59	33.19	39.33	31.94	27.89
(m^2 ha^{-1})	D.s.	8.93	8.57	6.95	9.32	7.39	7.56
$\bar{d}$	Media	21.02	23.40	25.02	21.46	23.16	26.03
(cm)	D.s.	3.83	4.93	4.38	2.97	3.10	3.78
$\bar{h}$	Media	14.79	15.18	15.53	19.16	19.58	20.01
(m)	D.s.	2.28	2.61	2.57	2.82	2.38	3.08
H	Media	16.31	16.39	16.55	22.99	22.42	21.76
(m)	D.s.	2.49	2.85	2.51	2.97	2.63	2.94
V	Media	297.51	256.28	223.39	349.20	282.46	245.22
(m^3 ha^{-1})	D.s.	90.41	88.14	70.34	95.83	84.04	86.85
W	Media	160.06	138.55	121.31	172.47	138.89	119.40
(Mg ha^{-1})	D.s.	45.54	44.90	35.66	46.57	40.10	41.19
CFL	Media	1.15	0.99	0.87	1.20	0.96	0.82
(kg m^{-2})	D.s.	0.26	0.26	0.20	0.28	0.21	0.21
CBH	Media	9.10	8.88	8.89	10.50	9.72	9.23
(m)	D.s.	2.06	2.36	2.33	2.66	1.89	2.83
CBD	Media	0.21	0.16	0.13	0.14	0.10	0.08
(kg m^{-3})	D.s.	0.05	0.04	0.03	0.03	0.02	0.03

Variables de sotobosque

Como se indicó anteriormente, el inventario del combustible de superficie se llevó a cabo únicamente en las parcelas control (C) y clara fuerte (HT). El inventario se realizó a lo largo de dos transectos de 32 m cada uno establecidos desde el centro de uno de los lados de 40 m de la parcela hasta los vértices del lado opuesto (Figura 3.8) y consistió en las siguientes mediciones: i) un muestreo lineal a lo largo del transecto, anotando las longitudes interceptadas por las diferentes especies (cm); ii) mediciones puntuales cada 4 m de longitud del transecto de la altura total de cada especie de matorral localizadas en dicho punto, diferenciando el inicio de las partes vivas y secas de dichas especies y iii) mediciones del espesor de la capas de hojarasca y mantillo cada 4 m de longitud del transecto. Además, se realizó un conteo del número de intercepciones de los restos leñosos de 1, 10, 100 y 1000 horas de retardo en tramos de longitudes 2 (para restos de 1 y 10 h), 5 (para restos de 100 h) y 20 m (para restos de 1000 h), a lo largo del transecto.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Las especies de sotobosque predominantes en las parcelas fueron *Ulex europaeus*, *Ulex gallii*, *Erica australis* y *Pteridium aquilinum*, aunque también, pero en menor medida, se observó la presencia de *Rubus sp*. y *Pteridium aquilinum*. En la Figura 3.8 se muestran imágenes de 4 de las parcelas.

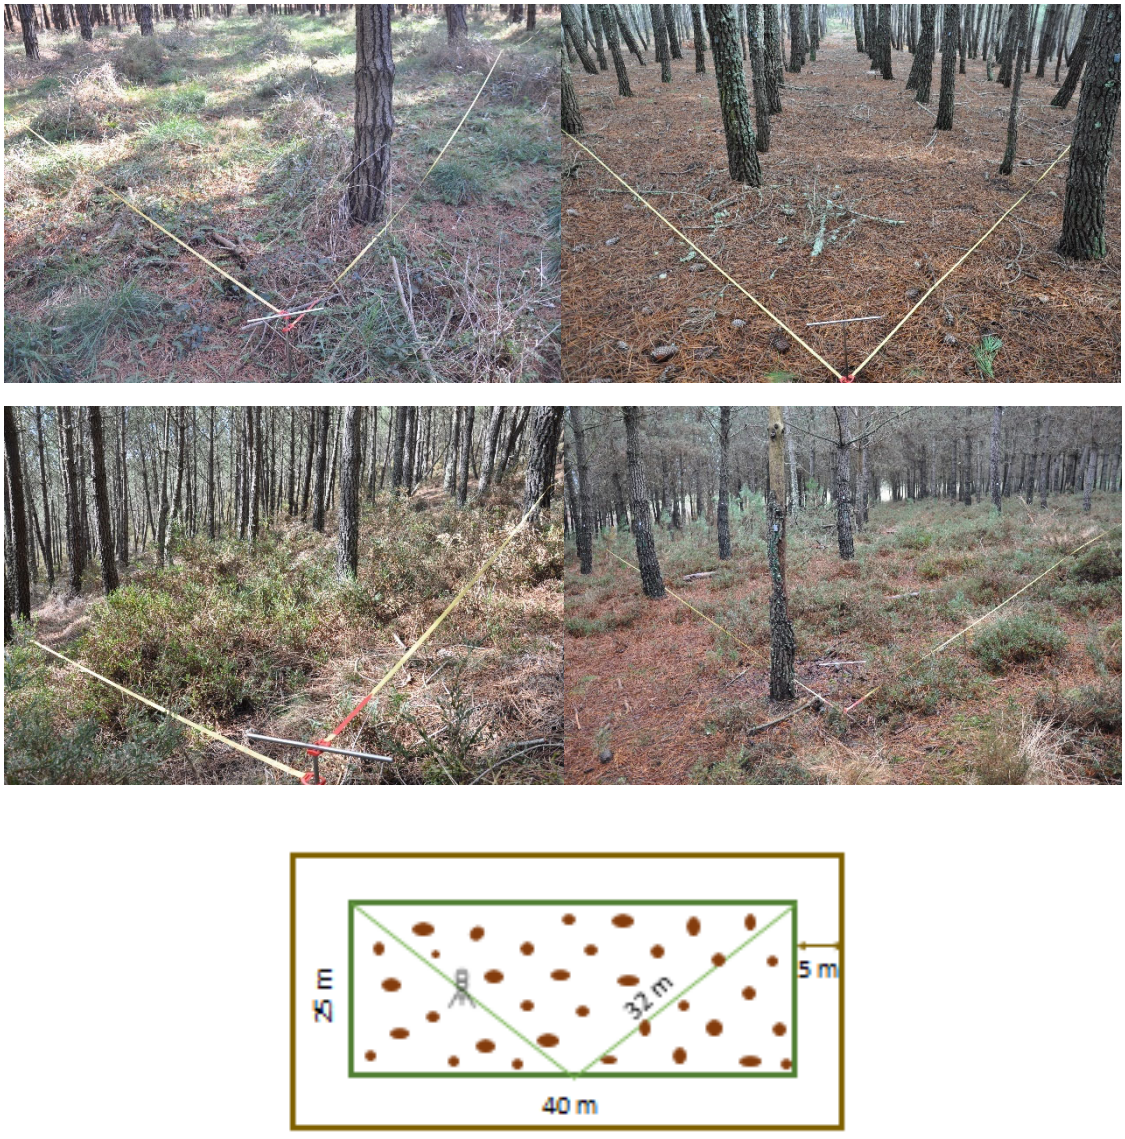

Figura 3. 8. Ejemplos de transectos para inventario de combustible de superficie en cuatro de las parcelas de 25 x 40 m (superior). Croquis con la disposición de los transectos (inferior).

Con los datos del inventario de campo se calcularon las siguientes variables necesarias para la estimación de las cargas de combustible: cobertura media de la vegetación de sotobosque (Cov_{Shr}); espesor medio de las capas de hojarasca y mantillo ($\overline{d_{LFH}}$) y altura media de la vegetación ponderada por su cobertura ($\overline{h_{Shr}}$).

A continuación, se utilizaron las ecuaciones de Arellano-Pérez et al. (2020) para estimar la carga total de la vegetación de sotobosque (W_{Shr}) y la carga de combustible de las capas de

hojarasca y mantillo (W_{LFH}), ecuaciones que son específicas para este tipo de combustibles en pinares de Galicia:

$$W_{Shr} = 0.0052 \,.\, \overline{h_{Shr}} + 0.2095 \,.\, \left(\frac{100}{\bar{h} \,.\, \sqrt{N}}\right)^{0.7035} \,.\, \overline{h_{Shr}}^{0.4514} \quad (3.18)$$

$$W_{LFH} = 0.5374 . \bar{d}_{LFH}^{0.787} \quad (3.19)$$

Donde W_{Shr} es la carga total de la vegetación de sotobosque (Kg m^{-2}), W_{LFH} es la carga de hojarasca y mantillo (Kg m^{-2}), $\overline{h_{Shr}}$ es la altura media de la vegetación del sotobosque ponderada por su cobertura (cm); $\overline{d_{LFH}}$ es el espesor (cm) de las capas de hojarasca y mantillo; $\bar{h}$ es la altura media del arbolado (m) y N es su densidad (pies ha^{-1}).

La carga de restos leñosos caídos de los diferentes tiempos de retado (W_{debris}) se estimó por el método del transecto planar (Brown, 1971; 1974) a partir de las relaciones existentes entre el número de piezas interceptadas, la longitud del transecto inventariado y la densidad de la madera.

Por último, se determinó la distancia vertical entre los estratos del combustible de superficie y del dosel (*fuel strata gap*, *FSG*) como la diferencia entre CBH y la altura media de la vegetación de sotobosque ($\overline{h_{Shr}}$). Los valores medios y las desviaciones estándar de las diferentes variables de sotobosque calculadas se muestran en la Tabla 3.7 para cada especie de pino y tipo de tratamiento.

Tabla 3. 7. Resumen estadístico de las principales variables del combustible de superficie. D.s. = desviación estándar; C= control; HT: clara fuerte; $\overline{h_{Shr}}$ = altura media de la vegetación de sotobosque ponderada por la cobertura; Cov$_{Shr}$ = cobertura del sotobosque; *FSG* = discontinuidad vertical entre el combustible de superficie y el dosel; W_{debris} = carga de restos leñosos caídos; W_{LFH} = carga de hojarasca y mantillo y W_{Shr} = carga de la vegetación de sotobosque.

		Pinus pinaster		***Pinus radiata***	
Variables	**Estadísticos**	**C**	**HT**	**C**	**HT**
$\overline{h_{Shr}}$	Media	30.39	37.57	46.19	56.96
(cm)	D.s.	21.44	25.99	24.97	24.57
Cov$_{Shr}$	Media	28.16	44.55	51.45	55.08
(%)	D.s.	26.13	27.70	32.61	32.41
FSG	Media	8.79	8.52	10.04	8.66
(m)	D.s.	2.06	2.35	2.67	2.84
W_{debris}	Media	5.78	11.89	7.22	27.66
(Mg ha^{-1})	D.s.	3.49	9.99	5.96	25.01
W_{LFH}	Media	31.34	30.47	31.20	31.41
(Mg ha^{-1})	D.s.	5.23	4.69	3.93	4.59
W$_{Shr}$	Media	4.60	6.11	7.06	8.57
(Mg ha^{-1})	D.s.	3.08	3.08	3.67	3.40

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Datos TLS (Escáner Láser Terrestre)

En cada una de las parcelas en las que se inventarió el combustible de superficie se realizó también un único escaneo con TLS, posicionándolo en el centro del transecto izquierdo (ver Figura 3.8). Las características del TLS empleado en la toma de datos son las descritas en el apartado de este capítulo dedicado al artículo 1, por haberse utilizado el mismo dispositivo. El punto central donde se estacionó el escáner se georreferenció con un GPS 7X con posterior procesamiento de la información para obtener precisiones centimétricas en las coordenadas.

Las nubes de puntos tridimensionales procedentes de cada escaneo se recortaron en un radio de 10 m para evitar incorporar cualquier información de fuera de la parcela de ensayo de clara. El procesamiento de las nubes de puntos se llevó a cabo empleando el paquete FORTLS (Molina-Valero et al., 2021) del software informático R (R Core Team, 2020). En un primer paso, se segmentaron los puntos del terreno con el algoritmo *cloth simulation filter* "c*loth*" (Zhang et al., 2016), y se generó el modelo digital de elevaciones (MDE) a través de la interpolación espacial del valor z para estos puntos, utilizando la aproximación *k-nearest-neighbor* con ponderación inversa a la distancia (KNN-IDW). A partir de estos modelos digitales de elevación se calculó la altura sobre el terreno de cada punto restando a los valores z el MDE suavizado. Los datos obtenidos se utilizaron para calcular 43 métricas TLS relacionadas con la distribución vertical de las nubes de puntos que se detallan junto con sus descripciones en la Tabla 3.8.

Tabla 3. 8. Variables de la distribución de alturas de la nube de puntos TLS normalizada.

Métrica	Descripción
$TLSh_{max}$ (cm)	Máxima altura
$TLSh_{mean}$(cm)	Media de las alturas
$TLSh_{mode}$(cm)	Modade las alturas
$TLSh_{median}$(cm)	Mediana de las alturas
$TLSh_{SD}$(cm)	Desviación estándar de las alturas
$TLSh_{var}$(cm)	Varianza
$TLSh_{CV}$(cm)	Coeficiente de variación (ratio)
$TLSh_{skw}$, $TLSh_{kurt}$	Asimetría y curtosis
$TLSh_{ID}$(cm)	Distancia intercuartílica
$TLSh_{01}$, $TLSh_{05}$, $TLSh_{10}$, …, $TLSh_{95}$, $TLSh_{99}$	Percentiles
$TLSh_{25}$y $TLSh_{75}$ (cm)	Primer y tercer cuartil
$TLSh_{L1}$, $TLSh_{L2}$, $TLSh_{L3}$, $TLSh_{L4}$	L-momentos de orden i (i = 1,…,4)
$TLSh_{L\text{-}CV}$	Ratio de momentosL2 y L1
$TLSh_{l\text{-}skw}$, $TLSh_{L\text{-}kurt}$	L-momentos de asimetría y curtosis
$TLSh_{MAD\text{-}median}$	Mediana de las desviaciones absolutas con respecto a la mediana general
$TLSh_{MAD\text{-}mode}$	Moda de las desviaciones absolutas con respecto de la moda general
$TLSP_{A2m}$	% de retornos de láser por encima de los
$TLSP_{Ahmean}$	%de retornos laser por encima de h_{mean}
$TLSP_{Ahmode}$	%de retornos laser por encima de h_{mode}
TLS_{CRR}	*Canopy relief ratio* = $TLSh_{mean}/TLSh_{max}$

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

A partir de las nubes de puntos 3D también se calcularon otras variables: i) la relación entre el número de retornos láser observados y el número máximo de retornos láser (*TLSPmax*); ii) la relación entre el número de retornos láser observados por encima de 2 m de altura y el número máximo de retornos láser por encima de 2 m de altura (*TLSPA2m_max*); y iii) la relación entre el número de retornos láser observados por debajo de 2 m de altura y el número máximo de retornos láser por debajo de 2 m de altura (*TLSPB2m_max*). El número máximo de retornos láser se estimó como el número de retornos que se obtendría, teniendo en cuenta la densidad del escaneo láser, en la superficie de un cilindro centrado en la localización del dispositivo de escaneo y con un radio de 10, con base en el suelo y altura igual a la altura máxima de los árboles de la parcela (para *TLSPmax*), o en el intervalo de altura de 0-2 m (para *TLSPA2m_max*) o de 2 m-altura máxima (para *TLSPB2m_max*). Se consideró que estas métricas deberían estar relacionadas con la densidad aparente de la vegetación total, de la vegetación de sotobosque y del dosel de copas, respectivamente.

Por último, se modelizó la distribución vertical de puntos mediante la función de densidad de probabilidad de Weibull (pdf) de dos parámetros. Para ello, se calculó la frecuencia relativa del número de retornos láser en cada capa cilíndrica de 1 cm de altura y 10 m de radio, dividiendo el número de retornos en estas capas por el número total de retornos láser. A continuación, se estimaron los parámetros de escala (W_{scale}) y de forma (W_{shape}) de la pdf de Weibull utilizando los momentos de primer y segundo orden de la distribución vertical relativa de los retornos láser (Cao et al., 1982).

En total se obtuvieron 48 variables (las 43 métricas relacionadas con la distribución vertical de las nubes de puntos 3D resumidas en la Tabla 3.8, las tres ratios que caracterizan la densidad aparente de la vegetación y los dos parámetros de la función de probabilidad de Weibull) que se consideraron como potenciales variables independientes para modelizar las diferentes variables del estudio: variables de rodal, de combustible de superficie y del dosel de copas.

Datos ALS (Escáner Láser Aerotransportado)

Los datos ALS utilizados en este estudio se corresponden con los del segundo vuelo realizado a nivel nacional dentro del Plan Nacional de Ortofotografía Aérea (PNOA) en el caso de Galicia y del primer vuelo en el caso de Asturias. Los datos se descargaron en ficheros digitales de 2 km de lado, para toda el área de estudio, a través del servidor informático del CNIG (Centro Nacional de Información Geográfica) (http://centrodedescargas.cnig.es/CentroDescargas/index.jsp). Los datos ALS utilizados se recogieron en julio-septiembre del año 2015 (zona oeste de Galicia), agosto-diciembre de 2016 y febrero de 2017 (zona este de Galicia) y mayo-octubre de 2012 (Asturias), coincidiendo aproximadamente en el tiempo con los inventarios de campo en la zona de Galicia y con un desfase asumible en el caso de Asturias. Para recoger las nubes de puntos tridimensionales ALS, se utilizaron dos sensores diferentes, un LEICA ALS50 (Leica *Geosystems* AG, Alemania) para Galicia Oeste, un LEICA ALS80 (Leica *Geosystems* AG, Alemania) para la zona de Galicia Este y un RIEGL LMS-Q680i (RIEGL *Laser Measurement Systems* GmbH, Austria) para Asturias. La densidad de pulsos láser estándar es de 0.5 primeros retornos m^{-2}; con una precisión vertical que varió entre 0.15 y 0.2 m y una precisión horizontal entre 0.3 y 0.4 m.

Una vez descargados los archivos se procesaron los datos con el software informático FUSION/LDV (McGaughey, 2021). El flujo de trabajo seguido para procesar la nube de puntos

ALS se describe con detalle en González-Ferreiro et al. (2017). De forma resumida, en primer lugar, se clasificaron los retornos ALS más bajos como "suelo" para crear el modelo digital de elevaciones (MDE) con una resolución espacial de 2 m. A continuación, se normalizaron las alturas, restando el MDE suavizado a los valores z de cada punto de la nube. Finalmente, estas alturas se emplearon para obtener una serie de métricas relacionadas con la distribución vertical de las nubes de puntos 3D, similares a las obtenidas a partir de los datos del TLS (Tabla 3.8 anterior, aunque sustituyendo en la nomenclatura el término TLS por ALS) así como para diferenciar las copas de los árboles (retornos por encima de los 2 m) de la capa de combustibles de sotobosque (retornos por debajo de los 2 m) al calcular las métricas de altura del ALS.

3.2.3 Desarrollo de modelos

En un primer paso se desarrollaron modelos de estimación de las principales variables relacionadas con el comportamiento el fuego superficie y copas y de las variables de rodal a partir de métricas derivadas del TLS y del ALS por separado y utilizando tres aproximaciones de modelización no paramétrica diferentes: *Multivariate Adaptive Regression Splines* (MARS), *Random Forest* (RF) y *Support Vector Machines* (SVM). Posteriormente, tras seleccionar la mejor aproximación, se volvieron a ajustar los modelos combinado esta vez las métricas TLS y ALS para evaluar su efecto en las estimaciones y en los estadísticos de bondad del ajuste. Para discriminar entre las dos especies de pino, además de las variables TLS y ALS también se incluyó una variable categórica (*Isp*), con un valor de 1 para *P. radiata* y de 0 para *P. pinaster.*

MARS es una técnica no paramétrica propuesta por Friedman (1991), que consiste en construir un modelo de regresión no lineal mediante la combinación de modelos lineales base, ajustados por partes en distintos intervalos del espacio de definición de la variable independiente. La forma general del modelo de regresión no paramétrica es la siguiente:

$$\hat{y} = \beta_0 + \sum_{i=1}^{M} \beta_i \, B_i(x) + \varepsilon$$

donde β_0 es el parámetro independiente del modelo, $B_i(x)$ son las funciones lineales base que se combinan, x son las variables independientes, β_i es el coeficiente de la función lineal *i-esima*, *M e*s el número de funciones base y ε es el error del modelo.

Cada función lineal base ajustada por partes puede adoptar una de las dos formas siguientes: i) una expresión de la forma (x-k) cuando x-k> 0 o (k-x) cuando k-x> 0, siendo k una constante a estimar; o ii) un producto de dos o más expresiones como la descrita que, por tanto, permiten interacciones entre variables independientes (x), definiendo el grado de la función base (1 para una única variable independiente, 2 cuando intervienen dos variables independientes y así sucesivamente).

El número de funciones de base (M) y el grado del modelo (k) se optimizaron realizando una validación cruzada, de modo que el conjunto de datos para el ajuste está formado por todas las parcelas de muestreo excepto una y el modelo se ajusta tantas veces como parcelas haya. El modelo óptimo será el que produzca el menor valor de la raíz cuadrada del error medio cuadrático (RMSE, ver ecuación 3.12). Los valores predichos usados fueron los obtenidos para las parcelas no utilizadas en cada uno de los ajustes de la validación cruzada. Se utilizó el

USC UNIVERSIDADE

paquete "*earth*" (Milborrow, 2021) implementado en el software R (R Core Team, 2020) para ajustar los modelos MARS.

RF es una técnica no paramétrica de clasificación y regresión comúnmente utilizada, propuesta por Breiman (2001), y consiste básicamente en: i) generar de forma aleatoria un subconjunto de entrenamiento con las unidades muestrales; ii) ajustar un árbol de clasificación o regresión a dicho subconjunto empleando una muestra aleatoria de todas las posibles variables predictoras; iii) asignar a las unidades muestrales no incluidas en el subconjunto de entrenamiento el valor estimado por el árbol de clasificación ajustado sin ellas; iv) repetir el proceso un cierto número de veces y v) dar una estimación final para cada unidad muestral ponderando las obtenidas con cada uno de los árboles en los que dicha unidad había sido excluida de la muestra de entrenamiento (Genuer et al., 2010). Una ventaja de esta metodología es que es relativamente insensible al número de unidades muestrales y a la multicolinealidad de los datos (Gislason et al., 2006), por lo que numerosos autores la han utilizado para relacionar datos LIDAR con las variables estructurales del complejo forestal (Domingo et al., 2017; 2018; 2019, Anderson et al., 2018, Fidalgo-González et al., 2019), o para modelar y crear cartografía de las variables de combustible forestal (por ejemplo, Pierce et al., 2012).

RF también proporciona una medida de la importancia de las variables predictoras teniendo en cuenta, para ello, el número de árboles en los que la variable es seleccionada para realizar una partición, el número de unidades muestrales a las que afecta dicha partición y la modificación que la inclusión de dicha variable tiene sobre el valor de algún estadístico de bondad del ajuste como puede ser la suma de cuadrados del error en el caso de regresión o la impureza de los nudos en el caso de una clasificación.

El ajuste del modelo RF requiere determinar el número de árboles individuales a ajustar, así como el número de variables independientes aleatoriamente seleccionadas en cada división dicotómica de cada árbol. En esta tesis se empleó el paquete "*Random Forest*" (Liaw y Wiener, 2002) del software R (R Core Team, 2020), estableciendo un número de 500 árboles a ajustar y un número de variables independientes a seleccionar igual a la raíz cuadrada del número total de variables independientes disponibles.

El modelo óptimo de RF se determinó mediante un procedimiento de validación cruzada minimizando el valor de *RMSE* obtenido, utilizando los residuos de las estimaciones ponderadas obtenidas en aquellos árboles en los que la parcela no formaba parte de la muestra de ajuste.

SVM es una metodología de aprendizaje supervisado (*machine learning*) desarrollada por (Cortes y Vapnik, 1995) que se basa en clasificar (clasificación) o asignar valores a un conjunto de datos (regresión) con n variables independientes, mediante la representación de los puntos en un espacio n-dimensional y la optimización de un hiperplano de separación (n-1 dimensional) entre ellos que minimice el error medio. Ese hiperplano de separación (en el caso de dos variables independientes se trata de una traza lineal) se apoya en algunos de los puntos del conjunto de datos que se denominan vectores de soporte (*support vectors*). El proceso se realiza mediante el empleo de una función kernel que afecta al resultado y que por tanto debe optimizarse. En este estudio se utilizaron tres funciones kernel diferentes: lineal (SVM-L), radial (SVM-R) y polinómica (SVM-P) y se optimizaron los valores de los hiperparámetros asociados a cada una de las funciones kernel para minimizar el valor del *RMSE* obtenido por validación cruzada. Como en los otros métodos no paramétricos, para realizar los ajustes se

utilizó el software R (R Core Team, 2020), empleando en este caso el paquete "*e1071*" (Meyer et al., 2019).

Para comparar los resultados obtenidos con las tres aproximaciones de modelización, se utilizaron dos estadísticos de bondad de ajuste: la raíz del error medio cuadrático en términos relativos (*rRMSE*, %, ver ecuación 3.15) y el R^2, definido como el cuadrado del coeficiente de correlación de Pearson entre los valores observados y estimados de la variable dependiente ($r^2_{yi\,\widehat{yi}}$).

3.3. Artículo 3

Artículo 3: Modelos de estimación de biomasa de combustibles de continuidad por fracciones en plantaciones de *Pinus radiata* sin podar a nivel de árbol individual y de rodal (*Forest,* 2022, *13*(10), 1697).

En este artículo el objetivo principal es la obtención de ecuaciones, tanto para árbol individual como para rodal, que permitan estimar la carga de combustibles muertos de continuidad (*ladder fuels*) según clase de tamaño, así como su distribución vertical en los primeros 6 m de la copa desde el suelo en plantaciones de *P. radiata* sin podar. Estas ecuaciones permitirán a los gestores forestales cuantificar adecuadamente este tipo de combustible e identificar con mayor facilidad los tratamientos más apropiados para reducir el riesgo de incendios de copas.

3.3.1 Selección de parcelas, inventarios y cálculo de variables

El estudio se desarrolla en una red de 20 parcelas temporales establecidas en masas maduras, puras y coetáneas de *P. radiata* distribuidas por toda la Provincia de Lugo, para cubrir la variabilidad en calidad de estación y densidad observada en el área de distribución de la especie en Galicia (Figura 3.9).

En cada rodal se estableció una parcela de muestreo circular con un radio de 10 m y el punto central fue georreferenciado con un GPS diferencial Trimble TSC3 de precisión centimétrica. En cada una de las parcelas se realizó un inventario dasométrico, midiendo el diámetro a la altura del pecho (*d*, en cm) con forcípula con una precisión de 0.1 cm, en dos direcciones perpendiculares en todos los árboles de la parcela. La altura total del árbol (*h*), la altura hasta la base de la copa viva (h_{blc}, en m) y la altura hasta la base de la copa muerta ($h_{bdc,}$ en m), que se definieron como el punto de inserción inferior de las ramas vivas y de las ramas muertas de un árbol respectivamente, se midieron con una precisión de 0.1 m con ayuda de un hipsómetro digital (Vertex IV) en una submuestra aleatoria de un tercio del total de árboles de la parcela de muestreo (237 árboles). A continuación, y a partir de las mediciones en los árboles se calcularon para cada parcela las principales variables de rodal: el número de árboles por hectárea (*N*, pies ha^{-1}), el área basimétrica del rodal (*G*, $m^2\ ha^{-1}$), el diámetro medio ($\bar{d}$, cm), el diámetro medio cuadrático (*dg*, cm), la altura media del rodal ($\bar{h}$, m), y una modificación del índice de espaciamiento relativo (*RS*), definido como $100/\left(\sqrt{N}\cdot\bar{h}\right)$. Debido al tamaño de las parcelas (314 m^2), en el estudio no se calculó la altura dominante, definida como la altura media de los 100 árboles más gruesos por ha, por considerar que su estimación podría verse fácilmente

USC DE COMPOSTELA

afectada por cualquier error de medición al realizar la media a partir únicamente de los 4 árboles más gruesos de la parcela.

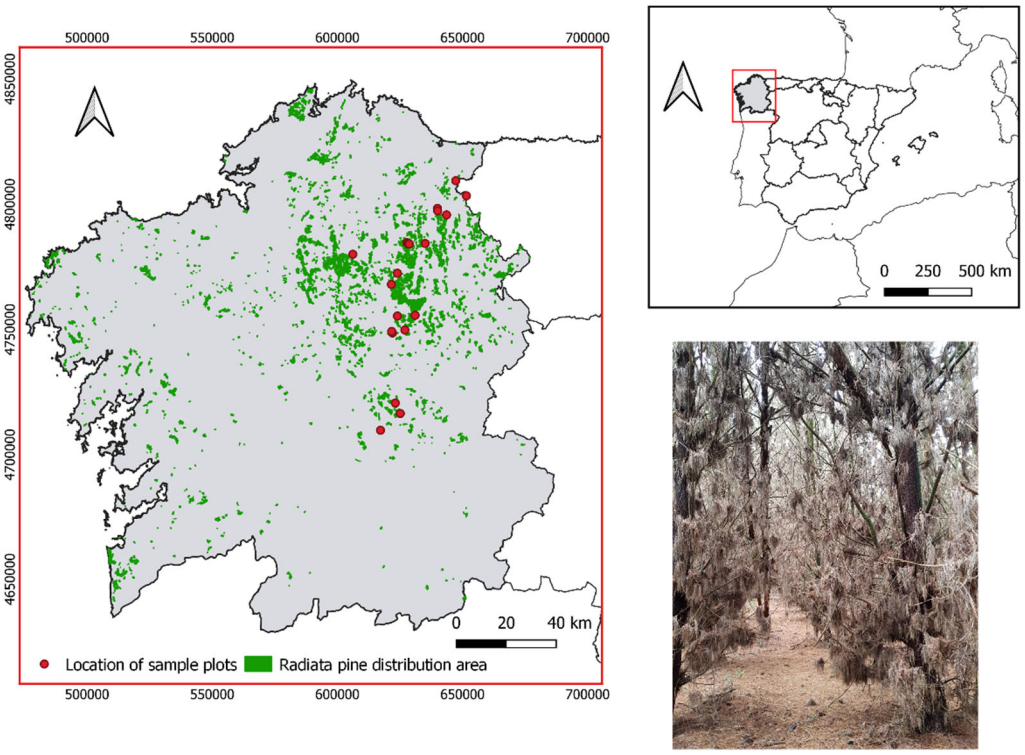

Figura 3. 9. Localización geográfica de las masas de *Pinus radiata* en Galicia y de las 20 parcelas incluidas en el estudio (izquierda). Vista de una de las parcelas (abajo a la derecha). Derechos de autor 2022, *Forest*.

Para aquellos árboles en los que no se realizaron mediciones de las diferentes alturas antes definidas se estimaron los valores de *h, h_{blc}* y *h_{bdc}* ajustando un sistema de tres ecuaciones a partir de las mediciones realizadas en la submuestra de 237 árboles. El sistema se ajustó simultáneamente utilizando el método iterativo SUR (*Iterative Seemingly Unrelated Regression*, ITSUR) del procedimiento MODEL de SAS/ETS (SAS Institute Inc, 2004). Las ecuaciones ajustadas explicaron el 78%, el 64% y el 98% de la variabilidad observad en *h, h_{blc}* y *h_{bdc}*, respectivamente. Las expresiones de las tres ecuaciones son, las siguientes:

$$h = \left(1.3^{1.6732} + \left(\bar{h}^{1.6732} - 1.3^{1.6732}\right)\frac{1 - exp(-0.0444 \cdot d)}{1 - exp(-0.0444 \cdot dg)}\right)^{1/1.6732} \quad (3.20)$$

$$RMSE = 1.94 \text{ m}$$

$$h_{blc} = h \cdot \left(\frac{exp\left[-0.8009 \cdot \frac{d}{dg} - 0.0326 \cdot \bar{h} + 0.0306 \cdot G\right]}{1 + exp\left[-0.8009 \cdot \frac{d}{dg} - 0.0326 \cdot \bar{h} + 0.0306 \cdot G\right]}\right) \quad (3.21)$$

$$RMSE = 2.21 \text{ m}$$

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

$$h_{bdc} = h \cdot \left(\frac{exp\left[-1.9083 - 0.9932 \cdot \frac{h}{\bar{h}} - 0.0246 \cdot G\right]}{1 + exp\left[-1.9083 - 0.9932 \cdot \frac{h}{\bar{h}} - 0.0246 \cdot G\right]} \right) \quad (3.22)$$

$$RMSE = 0.18 \text{ m}$$

Donde h es la altura total del árbol (m), h_{blc} es la altura de la base de la copa viva (m), h_{bdc} es la altura de la base de la copa muerta, d es el diámetro normal (cm), dg es el diámetro medio cuadrático (cm), $\bar{h}$ es la altura media del rodal (m), G es el área basimétrica (m^2 ha^{-1}) y $RMSE$ es la raíz del error medio cuadrático (ver ecuación 3.12).

En cada parcela se seleccionaron entre 2 y 4 árboles de la submuestra utilizada para la medición de las alturas tratando de cubrir el rango de diámetros observado. Se seleccionaron árboles sin daños en la copa y con un desarrollo de las ramas en consonancia con los procesos naturales de competencia intraespecífica en las condiciones particulares del estudio. En total se seleccionaron 65 árboles en los que se realizó un muestreo destructivo de las ramas muertas de la copa existentes en los primeros 6 m del tronco. Este límite se estableció por ser la altura máxima de poda para la especie en la zona de estudio. Las ramas se fueron cortando y empaquetando por secciones de 1 m desde la base del árbol y el material se llevó a laboratorio, donde se separó físicamente en diferentes tipos de combustible y clases de tamaño: acículas, combustibles leñosos finos (es decir, ramillas de diámetro <0.6 cm, en adelante identificadas como grupo 1 -G1-), combustibles leñosos medios (ramas de 0.6 ≤ diámetro < 2.5 cm, en adelante G2), y combustibles leñosos gruesos (ramas de 2.5 cm ≤ diámetro < 7.5 cm y piñas, en adelante G3). No se encontraron ramas de más de 7.5 cm de grosor (G4).

Aunque no existe un consenso total sobre lo que se considera combustible disponible (ver, por ejemplo, Ruiz-González y Álvarez-González, 2011), a efectos de la modelización del combustible del dosel con vistas a la simulación de la actividad de fuego de copas, es habitual considerar únicamente la fracción más fina, es decir, la que corresponde a las acículas y a los combustibles leñosos del grupo 1 (G1). Sin embargo, en este estudio también se consideraron los materiales muertos de mayor grosor para dar a las ecuaciones otros usos, como, por ejemplo, determinar la biomasa total aportada por las ramas muertas para diferentes alturas de poda.

Una vez clasificado por clases de tamaño, el material se pesó y se secó en una estufa de aire forzado (105ºC durante 24 h para los combustibles finos y 48 h para los más gruesos) para determinar la biomasa seca de cada categoría y a partir de ahí se definieron las siguientes fracciones que son las que fueron objeto de modelización: biomasa total (W_{total}), biomasa de las acículas ($W_{needles}$), biomasa del conjunto de los combustibles leñosos (W_{G123}), biomasa de los grupos G2 y G3 (W_{G23}), y biomasa de ramillas finas (W_{G1}). Al no contener muchos de los árboles material del G3 se agruparon las categorías G2 y G3.

Por otro lado, también se estimó la biomasa de las acículas y de las ramillas finas (<0 .6 cm de diámetro) de la copa viva de todos los árboles de la parcela mediante el sistema compatible de ecuaciones de biomasa arbórea específico para *P. radiata* en Galicia (Balboa-Murias et al., 2006).

USC DE SANTIAGO

A partir de las variables anteriores se estimaron las tres principales características estructurales del combustible del dosel relacionadas con el fuego de copas siguiendo, tal y como se explica en el artículo 2, el método *load over depth* (Van Wagner, 1977): carga de combustible

del dosel (*CFL*), altura de la base del dosel de copas (*CBH*) y densidad aparente del dosel (*CBD*). Los estadísticos de las principales variables de rodal, dosel y de árbol individual incluyendo los valores medios y la desviación estándar se muestran en la Tabla 3.9.

Tabla 3. 9. Estadísticos de las principales variables del árbol individual y del rodal. Derechos de autor 2022, *Forest*.

Variables de rodal (n = 20)				
Variable	**Media**	**Máximo**	**Mínimo**	**D.s.**
N (pies ha^{-1})	985.03	1368.73	604.79	222.62
G (m^2 ha^{-1})	39.34	60.51	25.06	9.87
$\bar{d}$ (cm)	21.47	29.24	16.94	3.26
$\bar{h}$ (m)	19.56	25.57	14.19	3.15
RS	0.17	0.24	0.12	0.03
Variables del dosel de copas vivo (n = 20)				
Variable	**Media**	**Máximo**	**Mínimo**	**D.s.**
CBH (m)	8.64	14.09	4.65	2.80
CFL (kg m^{-2})	1.19	1.78	0.75	0.28
CBD (kg m^{-3})	0.11	0.20	0.07	0.04
Variables de árbol individual (n = 629)				
Variable	**Media**	**Máximo**	**Mínimo**	**D.s.**
d (cm)	21.05	49.8	4.8	8.04
h (m)	19.77	30.4	9.9	4.17
h_{blc} (m)	8.79	19.3	2.5	3.27
h_{bdc} (m)	0.39	1.1	0.1	0.18
Biomasa de copa muerta (primeros 6 m) de los árboles con muestreo destructivo (n = 65)				
Variable	**Media**	**Máximo**	**Mínimo**	**D.s.**
W_{total} (kg)	19.06	63.92	3.12	11.68
$W_{needles}$ (kg)	3.17	11.55	0.22	2.19
W_{G1} (kg)	2.10	7.55	0.31	1.09
W_{G23} (kg)	13.79	47.06	1.82	9.41

D.s.= desviación estándar; N = densidad del arbolado; G = área basimétrica del rodal; $\bar{d}$ = diámetro medio; $\bar{h}$ = altura media; *RS* = índice de espaciamiento relativo; *CBH* = altura de la base del dosel; *CFL* = carga de combustible disponible del dosel; *CBD* = densidad aparente del dosel; d = diámetro medio del árbol; h = altura total del árbol; h_{blc}= altura hasta la base de la copa viva; h_{bdc} = altura hasta la base de la copa muerta; y W_{total}, $W_{needles}$, W_{G23}, y W_{G1} = biomasa muerta total, de acículas, leñosa media y gruesa (G23) y leñosa fina (G1), respectivamente.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

3.3.2 Ecuaciones de estimación de biomasa total por fracciones para los primeros 6 m del tronco a nivel de árbol individual

Se desarrollaron ecuaciones de estimación de biomasa de cada una de las cinco fracciones de combustible muerto de finidas (W_{total}, $W_{needles}$, W_{G123}, W_{G23}, y W_{G1}) para los primeros 6 m del tronco utilizando modelos alométricos de la forma $\widehat{W_i} = \beta_0 \cdot X_i^{\beta_i}$, donde $\widehat{W_i}$ es la biomasa de la fraccioni, Xi es un conjunto de variables independientes y β_0 y β_i son los parámetros que hay que estimar. Al igual que en el artículo 1, todas las ecuaciones ajustadas deben cumplir el principio de aditividad, es decir, la suma de las estimaciones de biomasa de las fracciones por separado debe de ser igual a las estimaciones de biomasa del modelo que las agrupa (por ejemplo, las estimaciones de $W_{needles} + W_{G123}$ tienen que ser iguales a las estimaciones de W*total* o las estimaciones de $W_{G23} + W_{G1}$ deben ser iguales a las estimaciones de W_{G123}). Por lo tanto, en primer lugar, se ajustó la ecuación para cada fracción de combustible por separado y después se ajustó simultáneamente el sistema completo de cinco ecuaciones (una por fracción) para garantizar la aditividad. También, al igual que lo descrito en el apartado de este capítulo que hace referencia al artículo 1, se utilizó el sistema *stepwise* de selección de variables independientes una vez linealizandos los modelos alométricos mediante logaritmos. Los pasos seguidos para el desarrollo del sistema de ecuaciones fueron los siguientes:

1. La expresión de la ecuación de estimación de la biomasa total $\widehat{W_{total}}$ fue la siguiente:

$$\widehat{W_{total}} = a_0 \cdot X_i^{a_i} \tag{3.23}$$

2. Mediante la desagregación de la ecuación anterior se obtienen dos nuevas ecuaciones que permiten estimar, por un lado, la biomasa de los grupos 1, 2 y 3 conjuntamente (W_{G123}) y por otro lado la biomasa de las acículas ($W_{needles}$):

$$\widehat{W_{needles}} = exp\left[b_{0_n} + b_{i_n} \cdot log(X_i)\right]$$

$$\widehat{W_{G123}} = exp\left[b_{0_G123} + b_{i_G123} \cdot log(X_i)\right]$$

$$\frac{\widehat{W_{G123}}}{\widehat{W_{total}}} = \frac{\widehat{W_{G123}}}{\left(\widehat{W_{G123}} + \widehat{W_{needles}}\right)} = \frac{1}{1 + \left(\widehat{W_{needles}}/\widehat{W_{G123}}\right)}$$

De este modo la ecuación de estimación de la biomasa de los grupos 1, 2 y 3 se obtuvo como:

$$\widehat{W_{G123}} = \widehat{W_{total}} \cdot \frac{1}{1 + exp[b_0 + b_i \cdot log(X_i)]} \tag{3.24}$$

siendo $b_0 = b_{0_n} - b_{0_G123}$ y $b_i = b_{i_n} - b_{i_G123}$; y la ecuación de estimación de la biomasa de las acículas se expresó como:

$$\widehat{W_{needles}} = \widehat{W_{total}} - \widehat{W_{G123}} = \widehat{W_{total}} \cdot \left[\frac{exp[b_0 + b_i \cdot log(X_i)]}{1 + exp[b_0 + b_i \cdot log(X_i)]}\right] \tag{3.25}$$

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

3. Finalmente, mediante la desagregación de la ecuación (3.24) se obtuvieron dos nuevas ecuaciones para estimar la biomasa de los grupos 2 y 3 conjuntamente por un lado (W_{G23}) y del grupo 1 (W_{G1}) por otro:

$$\widehat{W_{G23}} = exp\left[c_{0_G23} + c_{i_G23} \cdot log(X_i)\right]$$

$$\widehat{W_{G1}} = exp\left[c_{0_G1} + c_{i_G1} \cdot log(X_i)\right]$$

$$\frac{\widehat{W_{G23}}}{\widehat{W_{G123}}} = \frac{\widehat{W_{G23}}}{\left(\widehat{W_{G23}} + \widehat{W_{G1}}\right)} = \frac{1}{1 + \left(\widehat{W_{G1}}/\widehat{W_{G23}}\right)}$$

De este modo la ecuación de estimación de la biomasa de los grupos 2 y 3 se obtuvo como:

$$\widehat{W_{G23}} = \widehat{W_{G123}} \cdot \frac{1}{1 + exp[c_0 + c_i \cdot log(X_i)]} \tag{3.26}$$

siendo$c_0 = c_{0_G1} - c_{0_G23}yc_i = c_{i_G1} - c_{i_G23}$; y la ecuación de estimación de la biomasa de las ramillas finas muertas se expresó como:

$$\widehat{W_{G1}} = \widehat{W_{G123}} - \widehat{W_{G23}} = \widehat{W_{G123}} \cdot \left[\frac{exp[c_0 + c_i \cdot log(X_i)]}{1 + exp[c_0 + c_i \cdot log(X_i)]}\right] \tag{3.27}$$

3.3.3. Distribución vertical de la biomasa por fracciones en los primeros 6 m del tronco a nivel de árbol individual.

La distribución vertical de la biomasa del combustible muerto en función de la altura a lo largo de los primeros 6 m del tronco para cada fracción de combustible, se describió mediante la función de densidad de probabilidad (pdf) de Weibull de 2 parámetros.

$$W_{acum_ij} = W_i \cdot \left[1 - exp\left(-\left(\frac{x_j}{p_{1i}}\right)^{p_{2i}}\right)\right], \text{ con } x_j = \frac{h_j - h_{bdc}}{\min(6, h_{blc}) - h_{bdc}}$$

Donde W_{acum_ij} es la biomasa de combustible acumulado de la fracción *i* (W_{total}, $W_{needles}$, W_{G123}, W_{G23}, y W_{G1}) hasta la altura h_j dentro de los primeros 6 m del tronco; W_i es la biomasa total de combustible hasta 6 m de la fracción *i*; h_{bdc} y h_{blc} son las alturas de la base de la copa muerta y la altura de la base de la copa viva, respectivamente y W_{scale} y W_{shape} son los parámetros de escala y forma de la pdf de Weibul de 2 parámetros a estimar, respectivamente.

Para garantizar la aditividad entre las fracciones, las ecuaciones de $W_{acum_needlesj}$, W_{acum_G1j}, y W_{acum_G23j} se ajustaron de manera que las otras clases de biomasa de combustible muerto (W_{acum_G123j} y W_{acum_totalj}) se estimaran como la suma de las estimaciones de las fracciones ajustadas.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

3.3.4 Cargas y distribución vertical de combustibles en los primeros 6 m del tronco a nivel de rodal

Una vez desarrollado el sistema de 8 ecuaciones de estimación de la biomasa de combustible muerto por fracciones y su distribución vertical en los primeros 6 m de altura del tronco para árbol individual, el siguiente paso fue modelizar la carga de combustible por fracciones y su distribución vertical a nivel de rodal. Para ello se aplicaron las ecuaciones de biomasa a todos los árboles medidos en cada una de las 20 parcelas, estimando así las cargas de combustible de cada fracción y su distribución vertical para todo el rodal (Mg ha^{-1}). Por último, se utilizaron estas estimaciones para ajustar un nuevo sistema de 8 ecuaciones similar al ajustado para los árboles individuales, pero para el rodal en su conjunto.

La Figura 3.10 muestra el flujo de trabajo seguido para ajustar los sistemas de ecuaciones a nivel de árbol individual y de rodal, mostrando una visión simplificada del procedimiento descrito con detalle en los apartados anteriores.

3.3.5 Análisis estadístico

La presencia de multicolinealidad entre las variables independientes de las ecuaciones, así como la presencia de heteroscedasticidad se evaluó en este trabajo siguiendo los mismos procedimientos descritos en el apartado de este capítulo dedicado al artículo 1.

Debido a que la base de datos incluía múltiples observaciones equidistantes (1 m) para cada árbol o rodal a lo largo de la capa de 6 m sobre el suelo, era razonable esperar autocorrelación entre los residuos de cada árbol o rodal. Para tratar la posible autocorrelación, se añadió una estructura de error autorregresiva de orden 1 (AR1) a las ecuaciones para estimar la distribución vertical de las cargas de combustible. Se utilizó la prueba de Durbin-Watson para evaluar la posible presencia de autocorrelación.

Cada sistema de 8 ecuaciones, uno para árbol individual y otro para rodal, compuestos ambos por cinco ecuaciones alométricas para toda la capa de 6 m y tres ecuaciones para la distribución vertical a lo largo de dicha capa, se ajustaron simultáneamente utilizando la metodología ITSUR (*Iterative Seemingly Unrelated Regression*) en el procedimiento MODEL del software SAS/ETS (SAS Institute Inc, 2004).

La base de datos utilizada para ajustar los tres modelos de distribución vertical en función de la altura para los árboles individuales incluía K mediciones para cada árbol con un máximo de $k = 6$, que correspondían a las cargas de combustible de cada fracción hasta alturas de 1 a 6 m sobre el suelo o hasta el comienzo de la copa viva. Sin embargo, sólo había una observación de W_{total}, $W_{needles}$, W_{G123}, W_{G23}, y W_{G1} por árbol individual para ajustar las ecuaciones (3.23 a 3.27). Como el ajuste simultáneo requiere del mismo número de observaciones para cada ecuación del sistema, las observaciones de W_{total}, $W_{needles}$, W_{G123}, W_{G23}, y W_{G1} se repitieron k veces para cada árbol, de modo que esos valores en el ajuste simultáneo se ponderaron por la inversa del número de observaciones $1/k$. El mismo procedimiento se utilizó también para ajustar el sistema de ecuaciones a nivel de rodal. Esta metodología ya había sido empleada en trabajos de similares características (ver, por ejemplo, Diéguez-Aranda et al., 2006 o Hevia et al., 2017).

Para analizar la exactitud de las estimaciones se utilizaron dos estadísticos de bondad de ajuste: el coeficiente de determinación (R^2, ver ecuación 3.11) y la raíz cuadrada del error medio cuadrático (*RMSE*, ver ecuación 3.12).

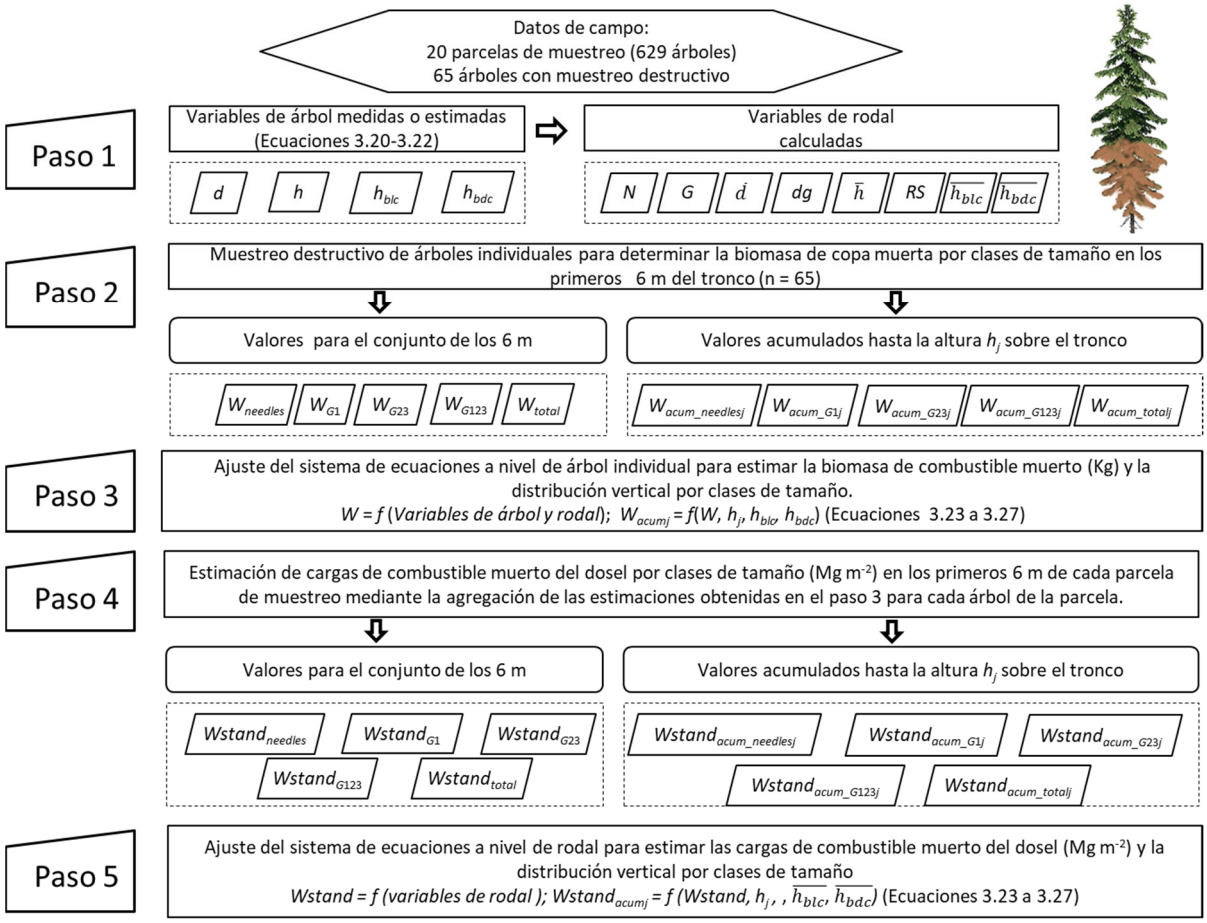

Figura 3. 10. Flujo de trabajo seguido para el ajuste de los sistemas de ecuaciones para árbol individual y para rodal. Derechos de autor 2022, *Forest*.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

4. Resultados y discusión

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

4. RESULTADOS Y DISCUSIÓN

4.1 Artículo 1 y comunicación presentada al 8 CFE

Artículo 1: Estimación de cargas de combustible y características estructurales de comunidades de matorral desarbolado mediante escaneo con láser terrestre (*Remote Sensing*, 2020, 12 (22), 3704).

Comunicación 8 CFE: Estimaciones de carga y estructura vertical de formaciones de matorral a partir de mediciones de obstrucción visual en campo.

4.1.1. Metodología de estimación directa de cargas (ED) con TLS

En la Tabla 4.1 se muestran las expresiones finales del sistema de ecuaciones ajustado a la base de datos completa (ecuaciones 3.4 a 3.10), las variables independientes que mejores resultados mostraron, los valores de los parámetros estimados, los errores estándar y los estadísticos de bondad de ajuste.

Los valores y signos de todos los parámetros fueron biológicamente consistentes y la inspección gráfica de los residuos mostró patrones aleatorios con varianza homogénea y sin tendencias apreciables. Por otra parte, los resultados del test de White y de los números de condición indicaron que no existían problemas de heteroscedasticidad o multicolinealidad en ninguna de las ecuaciones

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Tabla 4. 1. Sistema de ecuaciones ajustado simultáneamente para estimar las cargas de combustible por fracciones con las estimaciones de los parámetros, sus errores estándar y los estadísticos de bondad de ajuste. $W_{Shr+Litt}$ = carga de matorral y hojarasca, W_{Shr} = carga total de matorral, W_{Litt} = carga de hojarasca, W_{Shr_G23} = carga de matorral grueso, W_{Shr_G1} = carga de matorral fino, $W_{Shr_G1_dead}$ = carga de matorral fino muerto y $W_{Shr_G1_live}$ = carga de matorral fino vivo. Derechos de autor 2020, *Remote Sensing*.

Expresión	Par.	Estimador	Approx. Std. Error	*RMSE* (kg m^{-2})	R^2
$\widehat{W_{Shr+Litt}} = (a_{00} + a_{01}I_{Ea}) \cdot h_{95}^{a_1} \cdot TLSvCov_{Shr}^{a_2}$	a_{00}	0.2954	0.0447	0.5796	0.8033
	a_{01}	−0.0860	0.0138		
	a_1	0.6416	0.0351		
	a_2	0.1397	0.0506		
$\widehat{W_{Shr}} = \widehat{W_{Shr+Litt}} \cdot \frac{1}{1 + exp[b_1 \cdot log(IQR) + b_2 \cdot log(h_{70})]}$	b_1	0.7205	0.1964	0.2630	0.9018
$\widehat{W_{Litt}} = \widehat{W_{Shr+Litt}} \cdot \left[1 - \frac{1}{1 + exp[b_1 \cdot log(IQR) + b_2 \cdot log(h_{70})]}\right]$	b_2	−0.8301	0.1860	0.4584	0.4080
$\widehat{W_{Shr_G23}} = \widehat{W_{Shr}} \cdot \frac{1}{1 + exp[c_{00} + c_{01}I_{Ea-Pt} + c_{02}I_{Ug} + c_1 \cdot log(W_{scale})]}$	c_{00}	4.6139	0.5061	0.1957	0.8263
	c_{01}	0.3103	0.0479		
$\widehat{W_{Shr_G1}} = \widehat{W_{Shr}} \cdot \left[1 - \frac{1}{1 + exp[c_{00} + c_{01}I_{Ea-Pt} + c_{02}I_{Ug} + c_1 \cdot log(W_{scale})]}\right]$	c_{02}	0.7254	0.0807	0.1154	0.9392
	c_1	−0.9864	0.1255		
$\widehat{W_{Shr_G1_dead}} = \widehat{W_{Shr_G1}} \cdot \frac{1}{1 + exp[d_{00} + d_{01}I_{Ea-Ug} + d_1 \cdot log(IQR)]}$	d_{00}	0.9106	0.1777	0.0820	0.8848
	d_{01}	0.2900	0.0347		
$\widehat{W_{Shr_G1_live}} = \widehat{W_{Shr_G1}} \cdot \left[1 - \frac{1}{1 + exp[d_{00} + d_{01}I_{Ea-Ug} + d_1 \cdot log(IQR)]}\right]$	d_1	−0.1084	0.0451	0.0860	0.8794

I_j (j = *Ea*, *Ug*, *Pt*) = variable *dummy* cuyo valor es 1 para la comunidad específica y 0 para el resto. *Ea* = *Erica australis, Ug* = *Ulex gallii/ Ulex minor, Pt* = *Pterospartum tridentatum*. h_{95}= valor del percentil 95 de las alturas de los retornos láser (cm); $TLSvCov_{Shr}$= relación entre el número observado de retornos láser y el número máximo (lr_{max_ver}); *IQR* = distancia intercuartílica (h_{75}-h_{25}) (cm); h_{70}= valor del percentil 70 de las alturas de los retornos láser (cm); W_{scale}= parámetro de escala de la función de Weibull.

En la Figura 4.1 se muestran los gráficos de los valores observados frente a los predichos de las ecuaciones ajustadas por la metodología de estimación directa de cargas.

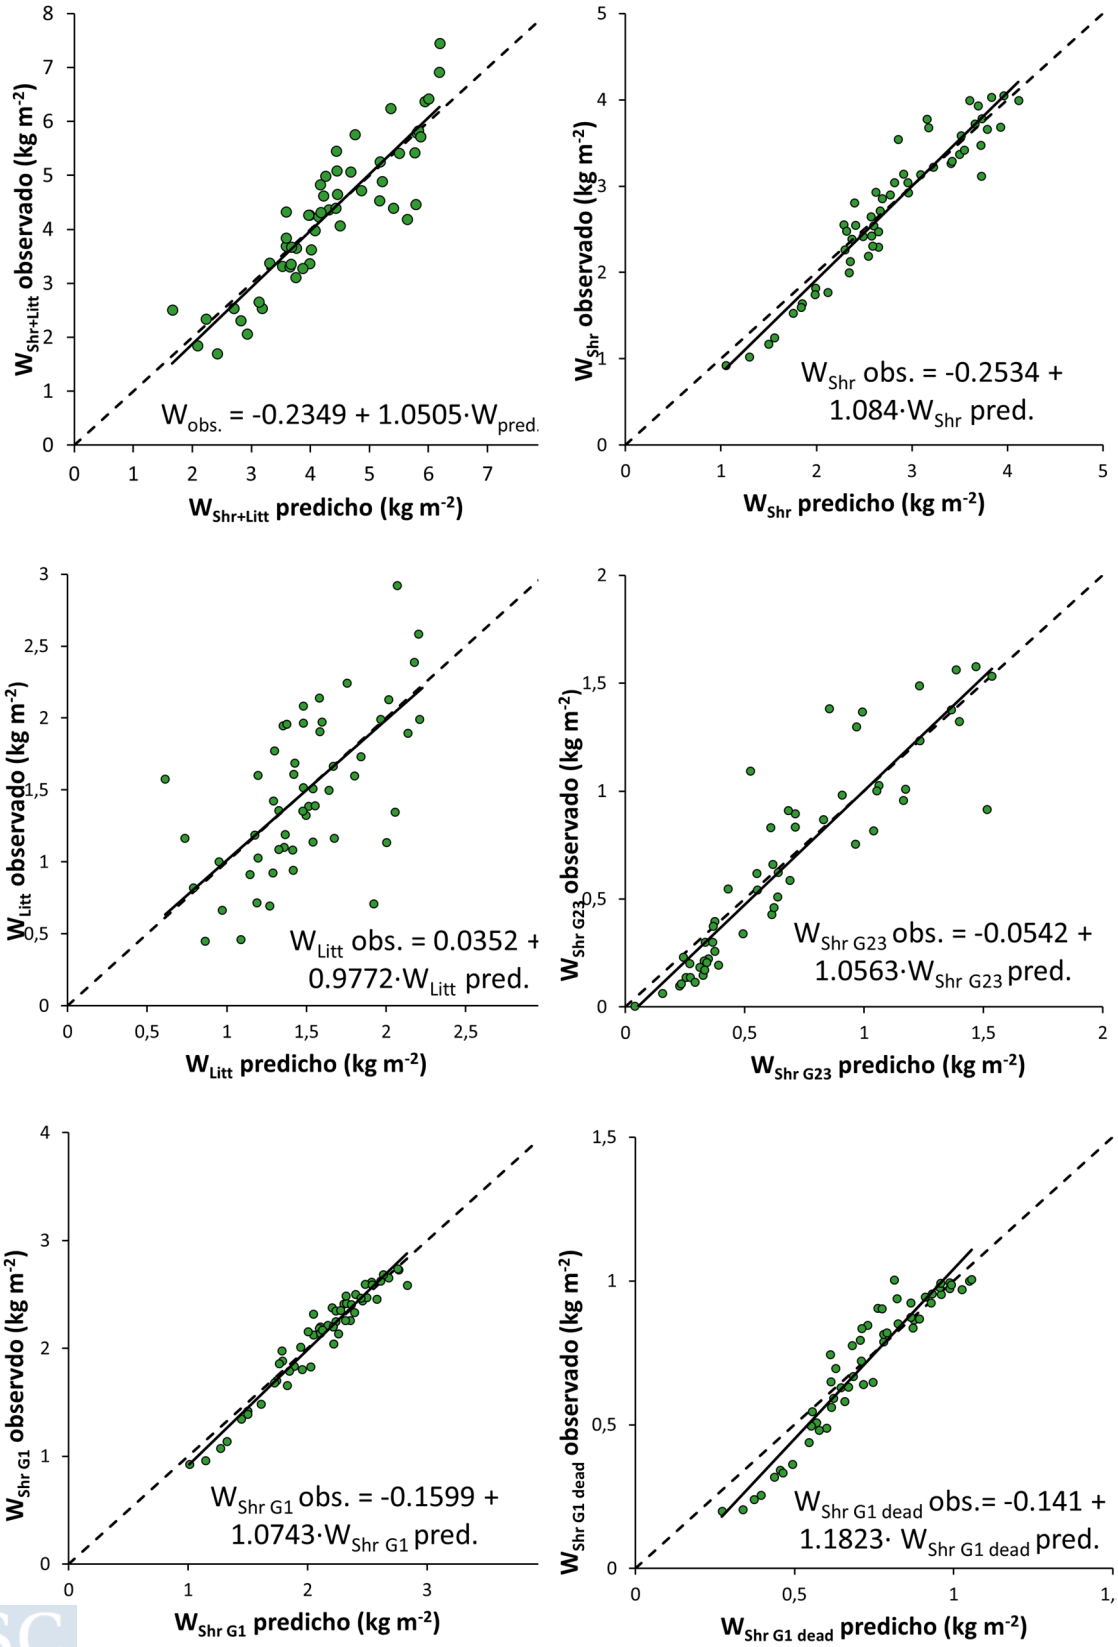

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

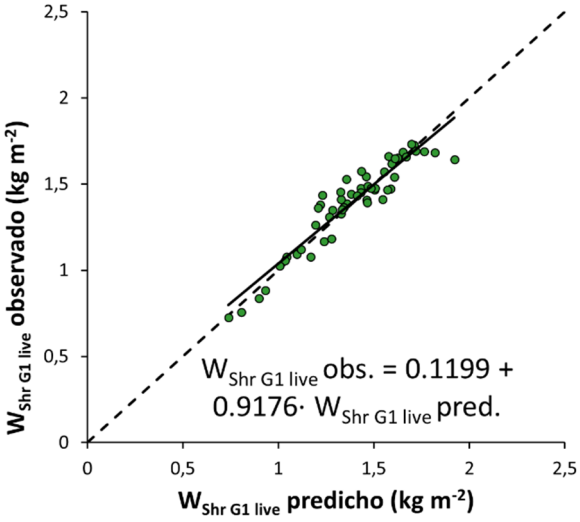

Figura 4. 1. Gráficos de valores observados frente a predichos de las cargas de matorral y hojarasca ($W_{Shr+Litt}$), total de matorral (W_{Shr}), hojarasca (W_{Litt}), matorral grueso (W_{Shr_G23}), matorral fino (W_{Shr_G1}), matorral fino muerto ($W_{Shr_G1_dead}$) y matorral fino vivo ($W_{Shr_G1_live}$) según la metodología de estimación directa.

Todas las ecuaciones ajustadas, salvo la que estima W_{Litt}, explicaron más del 80% de la variabilidad observada, con valores que oscilan entre el 80.33% y el 93.92%, superando incluso el 90% en las ecuaciones de estimación de W_{Shr} (90.18%) y W_{Shr_G1} (93.92%). Se observaron diferencias entre comunidades de matorral para la mayoría de las fracciones de combustible, con excepción de W_{Litt} y W_{Shr}. Estos resultados son similares a los obtenidos por otros autores. Así, por ejemplo, las ecuaciones propuestas por Ku et al. (2012) para estimar la biomasa de *Prosopis glandulosa* Torr. en ecosistemas del suroeste de EE.UU. explicaron porcentajes de variabilidad observada de entre el 77 y 81% dependiendo de si se empleaban como variables independientes los valores relativos de la distribución vertical de retornos láser del TLS en capas de 0.5 a 1 metros de altura o las métricas habituales derivadas de la totalidad de los retornos del TLS, respectivamente; los modelos propuestos por Olsoy et al. (2014) para estimar la biomasa total y la biomasa viva de plantas individuales de *Artemisia tridentata* Nutt. en las estepas de artemisia del oeste de EE.UU. explicaron respectivamente el 92 y el 83% de la variabilidad observada; posteriormente para la misma especie y área de estudio Li et al. (2015) propusieron un modelo que explicó el 87% de la variabilidad observada; Greaves et al. (2015) ajustaron modelos para estimar la biomasa total aérea de especies de arbustivas de bajo porte (<1.5 m) en la tundra del norte de Alaska, obteniendo valores de R^2 que oscilan entre 0.91 y 0.94 en función de las condiciones del escaneo (distancia fija de 2 metros entre el objetivo del TLS o distancia variable entre 2 y 50 metros); Owers et al. (2018) obtuvieron modelos de estimación de biomasa de vegetación de humedales costeros del sureste de Australia, que explicaban entre el 42 y el 99% de la variabilidad observada, en función de la metodología empleada para reconstruir el volumen aparente en 3D.

Las diferencias estructurales y funcionales entre las cuatro comunidades analizadas (ver Arellano-Pérez et al., 2017), se manifiestan en los modelos con la presencia de parámetros asociados a variables *dummy* específicas de dichas comunidades. Sin embargo, como se comentó en el apartado de Material y Métodos, el número limitado de parcelas de cada comunidad hace inviable ajustar sistemas de ecuaciones independientes

y sería conveniente incrementar el tamaño de la muestra, con lo que se espera una mejora de la exactitud de las estimaciones, especialmente para la carga de combustible de matorral grueso (W_{Shr_G23}), en la que la variabilidad entre especies es mayor (ver Vega et al., 2022b).

Como se explicó anteriormente, las cargas de combustible de matorral de cada fracción y comunidad no fueron muestreados destructivamente, sino que se estimaron a partir de ecuaciones previamente ajustadas, con Cov$_{Shr}$, $\overline{h_{Shr}}$ y $\overline{d_{Litt}}$ como variables independientes. Por lo tanto, como era de esperar, las variables independientes requeridas como entradas para iniciar el sistema de desagregación ajustado (ecuación $\widehat{W_{Shr+Litt}}$) son métricas derivadas del TLS relacionadas con la altura y la cobertura del matorral (h_{95} y $TLSvCov_{Shr}$). En el proceso de desagregación intervienen otras tres métricas: una relacionada con la altura del matorral (h_{70}) y otras dos relacionadas con la distribución vertical del combustible (W_{scale} y IQR). Estas dos últimas variables son las únicas que discriminan entre el combustible grueso y el fino (W_{Shr_G23} y W_{Shr_G1}) y las categorías de combustibles finos vivos y muertos ($W_{Shr_G1_live}$ y $W_{Shr_G1_dead}$), destacando la importancia de la distribución vertical de los combustibles en las cargas de biomasa de estas fracciones. Estos resultados concuerdan con los obtenidos por Rowell et al. (2016b) quienes ya destacaron la importancia de la distribución vertical de los combustibles en su carga total y el potencial de las métricas derivadas de la distribución vertical de la altura de la nube de retornos láser del TLS para ese fin. Además, las ecuaciones ajustadas para estas fracciones fueron también las más condicionadas por las diferencias estructurales entre las cuatro comunidades de arbustivas analizadas, de modo que resultaron significativos parámetros específicos por comunidades.

4.1.2 Metodología de estimación indirecta de cargas (EI) con TLS

Las expresiones matemáticas de las tres ecuaciones que relacionan Cov$_{Shr}$, $\bar{h}_{shr}$ y $\bar{d}_{Litt}$ con las métricas y variables derivadas del TLS, los valores estimados de los parámetros, sus errores estándar y los estadísticos de bondad de ajuste se muestran en la Tabla 4.2. Al igual que en caso anterior, no se detectaron problemas de multicolinealidad en ninguna de las tres ecuaciones ajustadas.

Como se esperaba, los mejores resultados de los estadísticos de bondad de ajuste se obtuvieron para $\bar{h}_{shr}$, con un modelo que explica más del 91% de la variabilidad observada; valor que se reduce al 66.26% para Cov$_{Shr}$ y las estimaciones menos exactas para $\bar{d}_{Litt}$ con un modelo que explica un 39.07% de la variabilidad observada.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Tabla 4. 2. Expresión final de las ecuaciones ajustadas para estimar *Cov*$_{Shr}$, $\overline{h_{shr}}$ y $\overline{d_{Lttt}}$ a partir de las métricas derivadas del TLS; estimaciones de los parámetros, errores estándar y estadísticos de bondad de ajuste. *Cov*$_{Shr}$ = cobertura del matorral (%), $\overline{h_{shr}}$ = altura media del matorral y $\overline{d_{Lttt}}$ = espesor medio de la hojarasca. Derechos de autor 2020, *Remote Sensing*.

Expresión	Par.	Est. (Std. E.)	RMSE	R^2
$\widehat{\text{Cov}_{Shr}} = \frac{100}{1 + exp(a_0 + a_1 \cdot h_{95})}$	a_0	-0.4742 (0.1707)	1.1226%	0.6626
	a_1	-0.0967 (0.0145)		
$\overline{h_{Shr}} = b_0 + b_1 \cdot h_{max} + b_2 \cdot h_{10}$	b_0	-9.8958 (4.2458)	9.2027 cm	0.9175
	b_1	0.8080 (0.0430)		
	b_2	2.5762 (0.5859)		
$\overline{d_{Lttt}} = c_0 + c_1 \cdot h_{kurt} + c_2 \cdot TLSvCov_{Shr} + c_3 \cdot IQR$	c_0	-2.8156 (1.2422)	1.5190 cm	0.3907
	c_1	1.9338 (0.9432)		
	c_2	7.9632 (2.0776)		
	c_3	0.1061 (0.0204)		

h_{95}= valor del percentil 95 de las alturas de los retornos láser (cm); h_{max}= altura máxima de los retornos láser (cm); h_{10}= valor del percentil 10 de las alturas de los retornos láser (cm); h_{kurt}= valor del coeficiente de curtosis de las alturas de los retornos láser; $TLSvCov_{Shr}$= relación entre el número observado de retornos láser y el número máximo (lr_{max_ver}); *IQR* distancia intercuartílica (h_{75}-h_{25}) (cm).

La revisión de otros trabajos científicos ha mostrado resultados similares en estudios de caracterización de matorral usando el TLS. Así, por ejemplo, Verling et al. (2013) obtuvieron valores de variabilidad explicada en altura y cobertura de matorral del 94 y 51%, respectivamente, en ecosistemas dominados por *Artemisia tridentata* en el este de Washington, EE.UU.; Anderson et al. (2018) ajustaron modelos con *Random Forest* para estimar la fracción de cobertura de matorral (R^2 = 0.77), gramíneas anuales (R^2 = 0.70), gramíneas perennes (R^2 = 0.36), y otras herbáceas (R^2 = 0.52) en pastizales desérticos y matorrales de artemisa en el suroeste de Idaho, EE.UU. En un estudio realizado en el ecotono agro-pastoral del norte de China, Xu et al. (2020) propusieron un modelo para estimar la altura y cobertura de pastizales a partir de datos del TLS, explicando el 70 y el 72% de la variabilidad observada, respectivamente. Mejores resultados obtuvieron Chen et al. (2016) en un estudio realizado en el sureste de Australia, donde ajustaron modelos para estimar el espesor de la hojarasca y el porcentaje de cobertura en diferentes capas verticales del sotobosque a partir de métricas del TLS, con valores de R^2 que oscilaron entre 0.8 y 0.9.

La relativamente reducida exactitud de las estimaciones de la ecuación del espesor de la hojarasca es coherente con los resultados obtenidos con la ecuación de carga de combustible de hojarasca ajustada en el enfoque ED (R^2 = 0.4080). Estos resultados coinciden con lo esperado debido a la fuerte relación entre el espesor de la capa de hojarasca y su carga y la dificultad de caracterizar este espesor a partir de las nubes de puntos del TLS por la limitada permeabilidad en estas comunidades de matorral de alta densidad (Hudak et al., 2020). Por lo tanto, debido a la importancia de esta fracción tanto en la fase de llama como en la de combustión sin llama, en situaciones en las que podría contribuir sustancialmente al flujo de energía y a las emisiones de los incendios de superficie, se requiere un muestreo destructivo para complementar el trabajo del TLS.

Las estimaciones de Cov$_{Shr}$, $\overline{h_{Shr}}$ y $\overline{d_{Litt}}$ obtenidas con los tres modelos de la Tabla 4.2 se utilizaron como valores de entrada en las ecuaciones de biomasa desarrolladas para las comunidades estudiadas en Galicia por Arellano-Pérez (2011) para estimar las cargas de $W_{Shr+Litt}$, W_{Shr}, W_{Litt}, W_{Shr_G23}, W_{Shr_G1}, $W_{Shr_G1_dead}$ y $W_{Shr_G1_live}$. Los gráficos de valores observados frente a predichos de estas siete fracciones se muestran en la Figura 4.2.

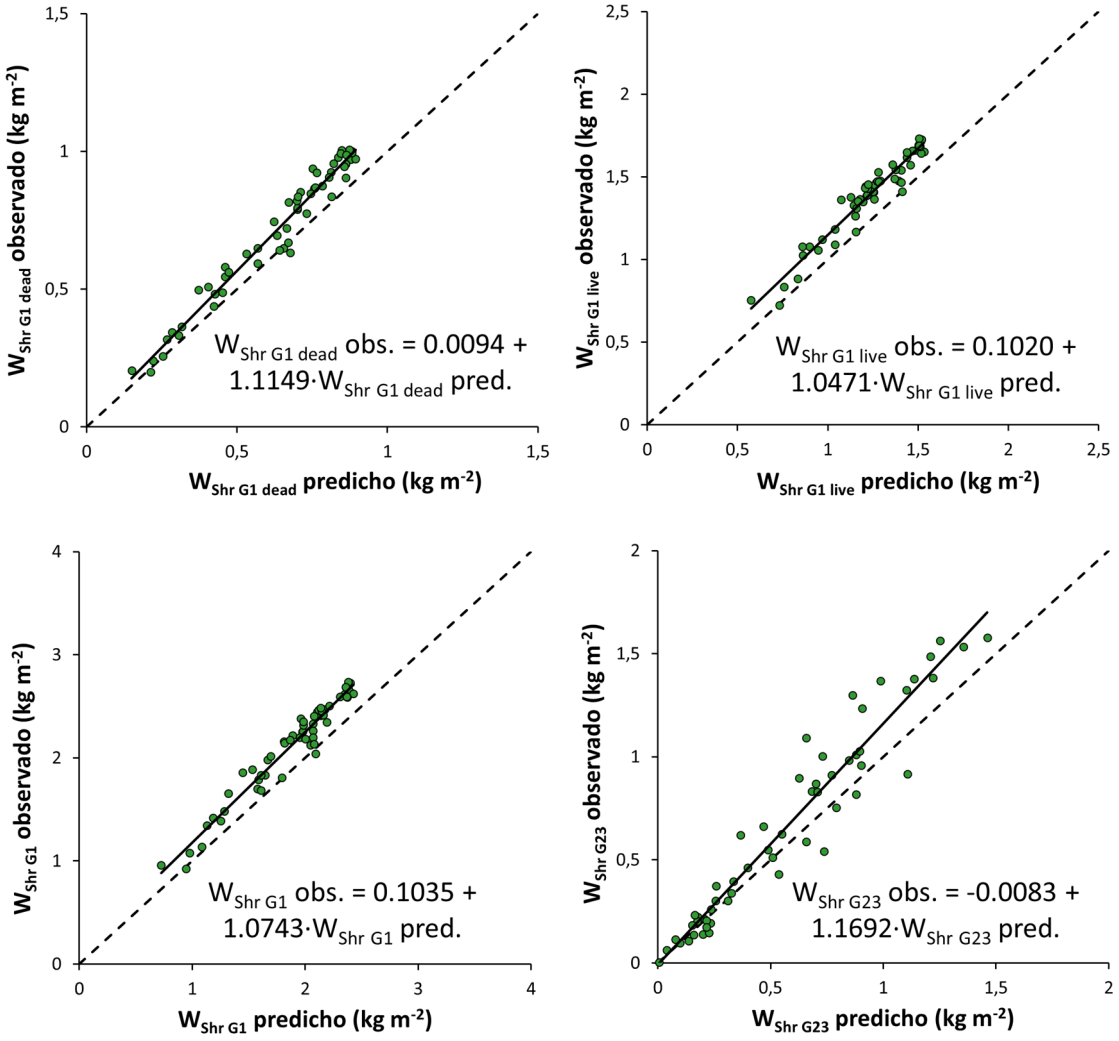

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

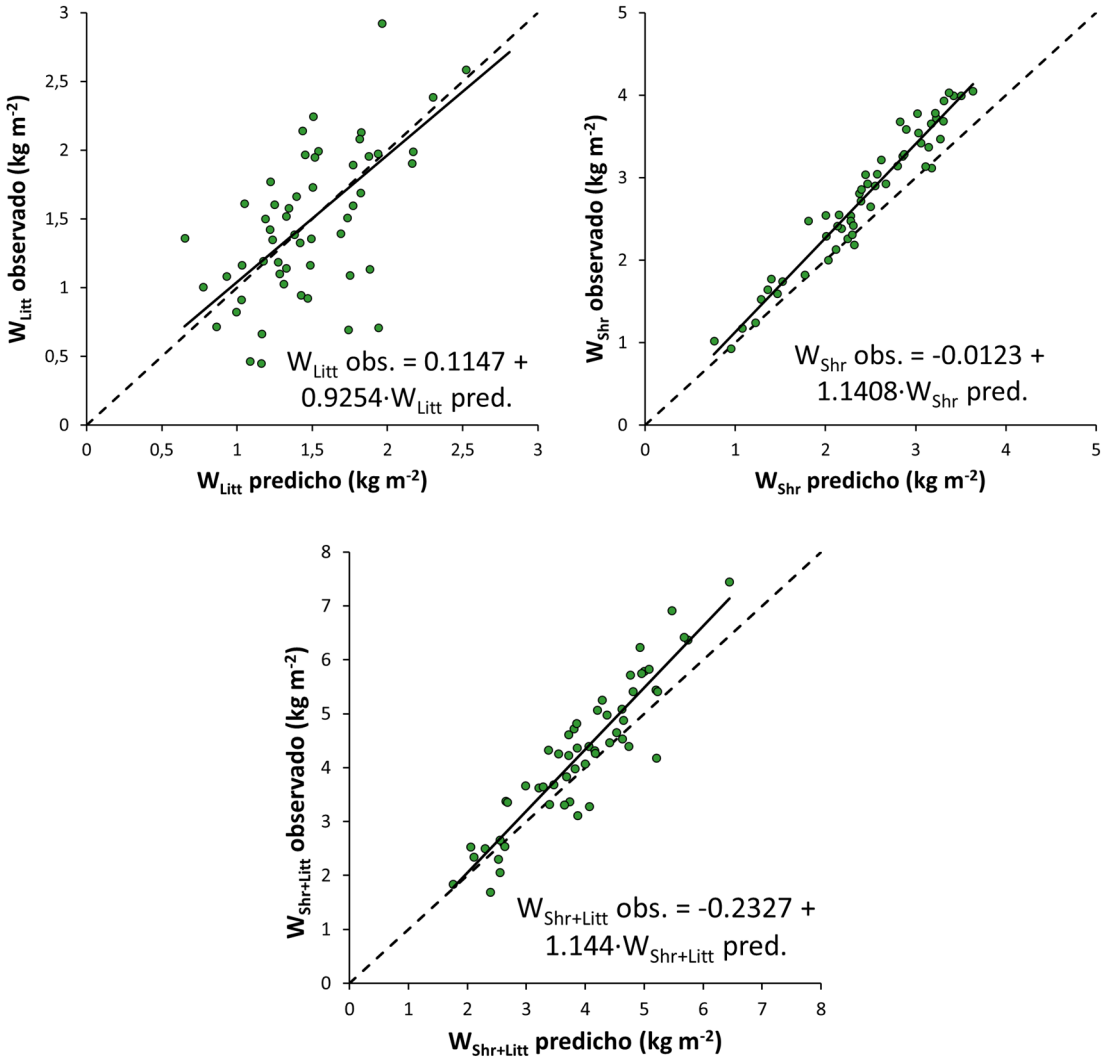

Figura 4. 2. Gráficos de valores observados frente a predichos de las cargas de matorral y hojarasca ($W_{Shr+Litt}$), total de matorral (W_{Shr}), hojarasca (W_{Litt}), matorral grueso (W_{Shr_G23}), matorral fino (W_{Shr_G1}), matorral fino muerto ($W_{Shr_G1_dead}$) y matorral fino vivo ($W_{Shr_G1_live}$) según la metodología de estimación indirecta.

Con el objeto de comparar las dos metodologías de estimación en la Tabla 4.3 se muestran los valores de R^2, *RMSE*, sesgo (error medio $\bar{e}$), el sesgo en valor absoluto (error medio en valor absoluto $\overline{|e|}$) y *rRMSE* relativo (porcentaje de *RMSE* sobre el valor medio de la variable dependiente r*RMSE%*) de ambas.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Tabla 4. 3. Estadísticos de bondad de ajuste obtenidas con las metodologías de estimación directa (ED) y estimación indirecta (EI) para cada fracción de combustible. Derechos de autor 2020, *Remote Sensing*.

Variable	Estimación Directa (ED)					Estimación Indirecta (EI)				
	R^2	*RMSE* (kg m^{-2})	$\bar{e}$	$\overline{\lvert e \rvert}$	*rRMSE* (%)	R^2	*RMSE* (kg m^{-2})	$\bar{e}$	$\overline{\lvert e \rvert}$	*rRMSE* (%)
$W_{Shr+Litt}$	0.8033	0.5796	-0.0183	0.4489	13.58	0.7642	0.6347	0.3339	0.5242	14.87
W_{Shr}	0.9018	0.2630	-0.0193	0.2121	9.50	0.7666	0.4056	0.3308	0.3393	14.65
W_{Litt}	0.4080	0.4584	0.0010	0.3572	30.55	0.4378	0.4467	0.0031	0.3482	29.78
W_{Shr_G23}	0.8263	0.1957	-0.0160	0.1440	29.51	0.8710	0.1687	0.0888	0.1235	25.44
W_{Shr_G1}	0.9392	0.1154	-0.0032	0.0958	5.48	0.6732	0.2676	0.2420	0.2444	12.71
$W_{Shr_G1_dead}$	0.8848	0.0820	-0.0090	0.0654	11.47	0.8371	0.0975	0.0821	0.0844	13.63
$W_{Shr_G1_live}$	0.8794	0.0860	0.0058	0.0640	6.19	0.5103	0.1734	0.1599	0.1602	12.47

En general, los mejores resultados, en términos de estadísticos de bondad de ajuste, se obtuvieron con el enfoque ED, aunque para W_{Litt} y W_{Shr_G23} el enfoque EI explicó una mayor parte de la variabilidad observada, con una reducción del *RMSE* de, respectivamente 2.6 y 13.8 %, en relación con el enfoque ED. Sin embargo, los gráficos de valores observados frente a predichos mostraron un ligero sesgo en todas las estimaciones del enfoque EI (Figura 4.2), con una ligera tendencia a subestimar los valores, mientras que esta tendencia no fue apreciable en los gráficos de las estimaciones del enfoque ED (Figura 4.1).

A la vista de estos resultados se propone el sistema de ecuaciones compatibles desarrollado con el enfoque ED para estimar las cargas de combustible de las comunidades de matorral analizadas. Sin embargo, las ecuaciones ajustadas con el enfoque EI son de utilidad para estimar otras tres variables relevantes para una completa caracterización del complejo del combustible de matorral (Cov$_{Shr}$, $\overline{h_{Shr}}$ y $\overline{d_{Litt}}$).

Es importante destacar que el uso del TLS simplemente como herramienta de estimación de cargas no aporta ventajas sobre el muestreo tradicional no destructivo para el que ya existen ecuaciones de estimación para todas las fracciones analizadas por comunidades (Vega et al., 2022b). Sin embargo, tal y como señalan Newnham et al. (2015), el TLS no debe considerarse sólo como una alternativa al muestreo tradicional de campo, sino como una metodología completamente diferente para caracterizar la estructura espacial a escala de parcela con un nivel de detalle sin precedentes. Las nubes de puntos del TLS pueden procesarse fácilmente con algoritmos sencillos, como los utilizados en este estudio, para proporcionar información adicional útil para la caracterización de los complejos de combustible que, de otro modo, sería imposible de obtener con un muestreo de campo no destructivo. Por ejemplo, el TLS puede caracterizar la distribución vertical de las cargas de combustible con mayor precisión y a una escala más detallada que la que ofrecen los métodos tradicionales (véase Figura 4.3). Además, los distintos contenidos de agua de la biomasa verde y la leñosa producen diferencias en la reflectividad del láser (Gao, 1996; Sims y Gamon, 2003), lo que permite descomponer la nube de puntos del TLS en fracciones vivas y muertas (Olsoy et al., 2014). Otros estudios han demostrado que el TLS permite realizar estimaciones muy precisas de variables estructurales de los complejos de combustible fundamentales en la determinación de su inflamabilidad y combustibilidad como la densidad aparente (Pimont et al., 2015; Hudak et al., 2020) o la relación de compactación (Rowell et al., 2020). Por estas razones, el TLS podría proporcionar estimaciones más robustas de las propiedades

del complejo de combustible que determinan el comportamiento del fuego, mejorando así la precisión de los simuladores de predicción (Finney, 2004; 2006).

Por otro lado, diferentes autores han destacado la utilidad que podría tener el uso de TLS en la estimación de cargas u otras variables de interés como paso intermedio para pasar de una información local a una información a gran escala espacialmente explícita sobre el terreno, mediante el uso de sensores remotos lejanos (Li et al., 2015; Liu et al., 2017; Greaves et al., 2017; Anderson et al., 2018). Por lo tanto, el desarrollo de metodologías de estimación precisas, como las que se presentan en este trabajo, basadas en un único escaneo de TLS, con la consiguiente reducción de costes y tiempo, constituyen la base para la aplicación de TLS en el inventario forestal, combinándolo con métodos de inferencia como los enfoques basados en modelos o asistidos por modelos.

Por último, las ecuaciones propuestas en este estudio podrían ser útiles no solo para caracterizar las comunidades arbustivas desde el punto de vista del comportamiento del fuego, la evaluación del riesgo de incendio o el diseño de quemas prescritas, sino también, para la simulación de los procesos de erosión, la estimación de las reservas de carbono o del potencial de la biomasa como fuente de energía y la caracterización y delimitación de hábitats de fauna.

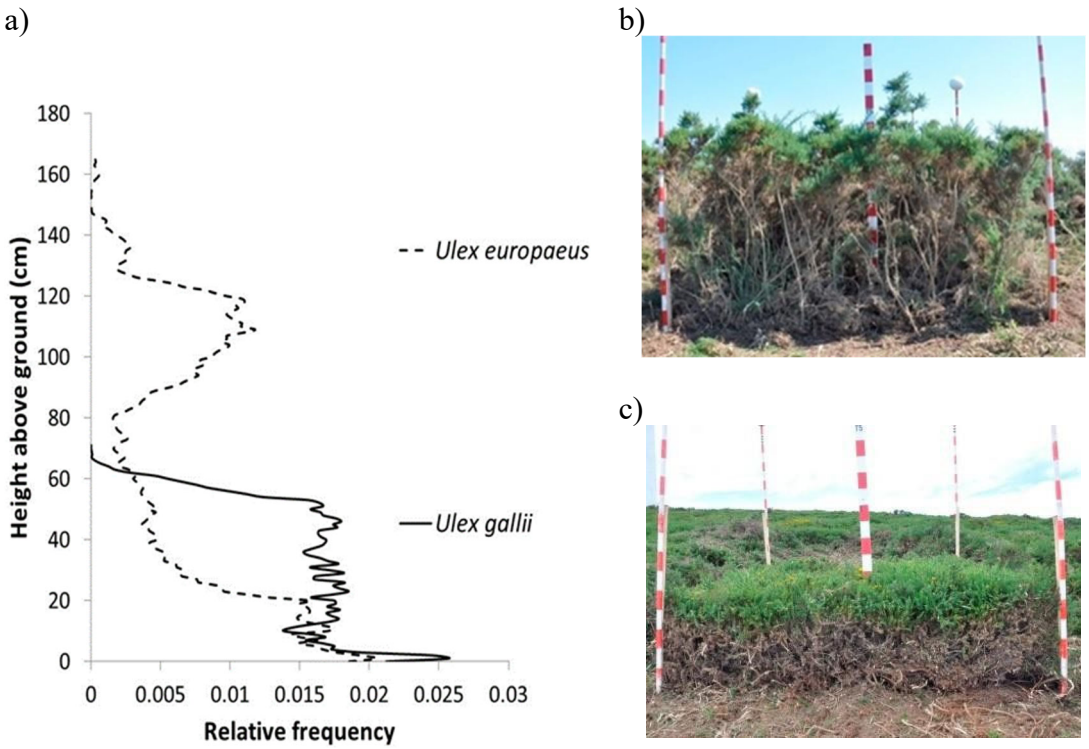

Figura 4. 3. Distribución vertical de la frecuencia relativa de los retornos de TLS (a) en dos parcelas de combustible con diferente estructura vertical (b) *Ulex europaeus* y (c) *Ulex gallii*. Derechos de autor 2020, *Remote Sensing*.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

4.1.3. Metodología de obstrucción visual en campo

En la Tabla 4.4 se muestran las expresiones finales del sistema de ecuaciones ajustado a la base de datos completa (ecuaciones 3.4 a 3.10), las variables independientes que mejores resultados mostraron y el valor de los parámetros estimados. De la misma forma que en los casos anteriores, no se observaron problemas de multicolinealidad ni de heteroscedasticidad y todos los parámetros fueron significativos ($\alpha = 0.05$).

Las variables independientes que forman parte del sistema de ecuaciones son la altura del matorral (h_{Shr}) y el espesor de la capa de hojarasca y mantillo (d_{Litt}) estimadas sobre la barra, así como el valor de *Biomass Measure* (*BM*), una métrica derivada del modelo logístico ajustado a las observaciones de obturación y que se corresponde con el área bajo la curva de dicho modelo. Tal como se indicó al hablar de las metodologías basadas en el uso del TLS, debido al tamaño de la muestra no fue posible ajustar el sistema de ecuaciones a cada una de las cuatro comunidades de matorral estudiadas; sin embargo, la inclusión de variables *dummy* para analizar diferencias entre ellas mostró diferencias significativas en los valores de dos o más parámetros en todas las ecuaciones ajustadas, lo que de nuevo indica que sería necesario contar con una muestra de parcelas mayor para cada comunidad que permita ajustar el sistema de ecuaciones para cada una de ellas, lo que permitiría mejorar la exactitud de las estimaciones.

USC
UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Tabla 4. 4. Expresión final del sistema de ecuaciones ajustado simultáneamente para estimar la carga de cada fracción de combustible. $W_{Shr+Litt}$ = carga total (matorral + hojarasca), W_{Shr} = carga total de matorral, W_{Litt} = carga de hojarasca, W_{Shr_G23} = carga de matorral grueso, W_{Shr_G1} = carga de matorral fino, $W_{Shr_G1_dead}$ = carga de matorral fino muerto y $W_{Shr_G1_live}$ = carga de matorral fino vivo.

Expresión	Par.	Estimador
$\widehat{W_{shr+Litt}} = a_0 \cdot BM^{a_1 I_{Ea+Pt}} \cdot d_{bLitt}^{a_2} \cdot h_{bShr}^{a_3 I_{Ug+Ue}}$	a_0	0.2251
	a_1	0.2748
	a_2	0.2468
	a_3	0.5855
$\widehat{W_{Shr}} = W_{\widehat{Shr+Litt}} \frac{1}{1+exp[b_{00}+b_{01}I_{Ea+Pt+Ug}+b_1 log(h_{bShr})I_{Ea+Pt+Ug}+b_2 \cdot log(d_{bLitt})]}$	b_{00}	-1.4335
	b_{01}	2.9891
$\widehat{W_{Litt}} = W_{\widehat{Shr+Litt}} \left[1-\frac{1}{1+exp[b_{00}+b_{01}I_{Ea+Pt+Ug}+b_1 log(h_{bShr})I_{Ea+Pt+Ug}+b_2 \cdot log(d_{bLitt})]}\right]$	b_1	-0.6361
	b_2	0.4501
$\widehat{W_{Shr_G23}} = \widehat{W_{Shr}} \frac{1}{1+exp[c_{00}+c_{01}I_{Ea+Pt}+c_{02}I_{Ug}+c_{10}log(h_{bShr})I_{Ea+Pt+Ue}+c_{11}log(h_{bShr})I_{Ug}]}$	c_{00}	5.5094
	c_{01}	0.4673
	c_{02}	6.9077
$\widehat{W_{Shr_G1}} = \widehat{W_{Shr}} \left[1-\frac{1}{1+exp[c_{00}+c_{01}I_{Ea+Pt}+c_{02}I_{Ug}+c_{10}log(h_{bShr})I_{Ea+Pt+Ue}+c_{11}log(h_{bShr})I_{Ug}]}\right]$	c_{10}	-1.0216
	c_{11}	-2.4011
$\widehat{W_{Shr_G1_dead}} = \widehat{W_{Shr_G1}} \frac{1}{1+exp[d_{00}+d_{01}I_{Pt}+d_{02}I_{Ue}+d_{10}log(h_{bShr})+d_{11}log(h_{bShr})I_{Pt}+d_{12}log(h_{bShr})I_{Ug}]}$	d_{00}	2.0462
	d_{01}	-1.2293
	d_{02}	-0.5330
$\widehat{W_{Shr_G1_live}} = \widehat{W_{Shr_G1}} \left[1-\frac{1}{1+exp[d_{00}+d_{01}I_{Pt}+d_{02}I_{Ue}+d_{10}log(h_{bShr})+d_{11}log(h_{bShr})I_{Pt}+d_{12}log(h_{bShr})I_{Ug}]}\right]$	d_{10}	-0.2233
	d_{11}	0.1568
	d_{12}	-0.0905

I_j (j = *Ea*, *Pt*, *Ue*, *Ug*) = variable *dummy* cuyo valor es 1 para la comunidad específica y 0 para el resto. *Ea* = *Erica australis*, *Pt* = *Pterospartum tridentatum*, *Ue* = *Ulex europaeus* y *Ug* = *Ulex gallii*/ *Ulex minor*. *BM* = *Biomass Measure* o área bajo la curva del modelo logístico ajustado, d_{bLitt} = espesor de la hojarasca, y h_{bShr} = altura del matorral, ambas estimadas sobre la barra.

En la Figura 4.4 se muestran las gráficas de valores observados frente a valores predichos para cada una de las 7 fracciones a las que se ha ajustado una ecuación. Sobre dichas gráficas se han representado la diagonal (línea que correspondería con un ajuste perfecto) y la recta ajustada relacionando los valores observados con los predichos, mostrando también la expresión de dicha relación, así como el valor del coeficiente de determinación (R^2) y de la raíz del error medio cuadrático del ajuste (*RMSE*).

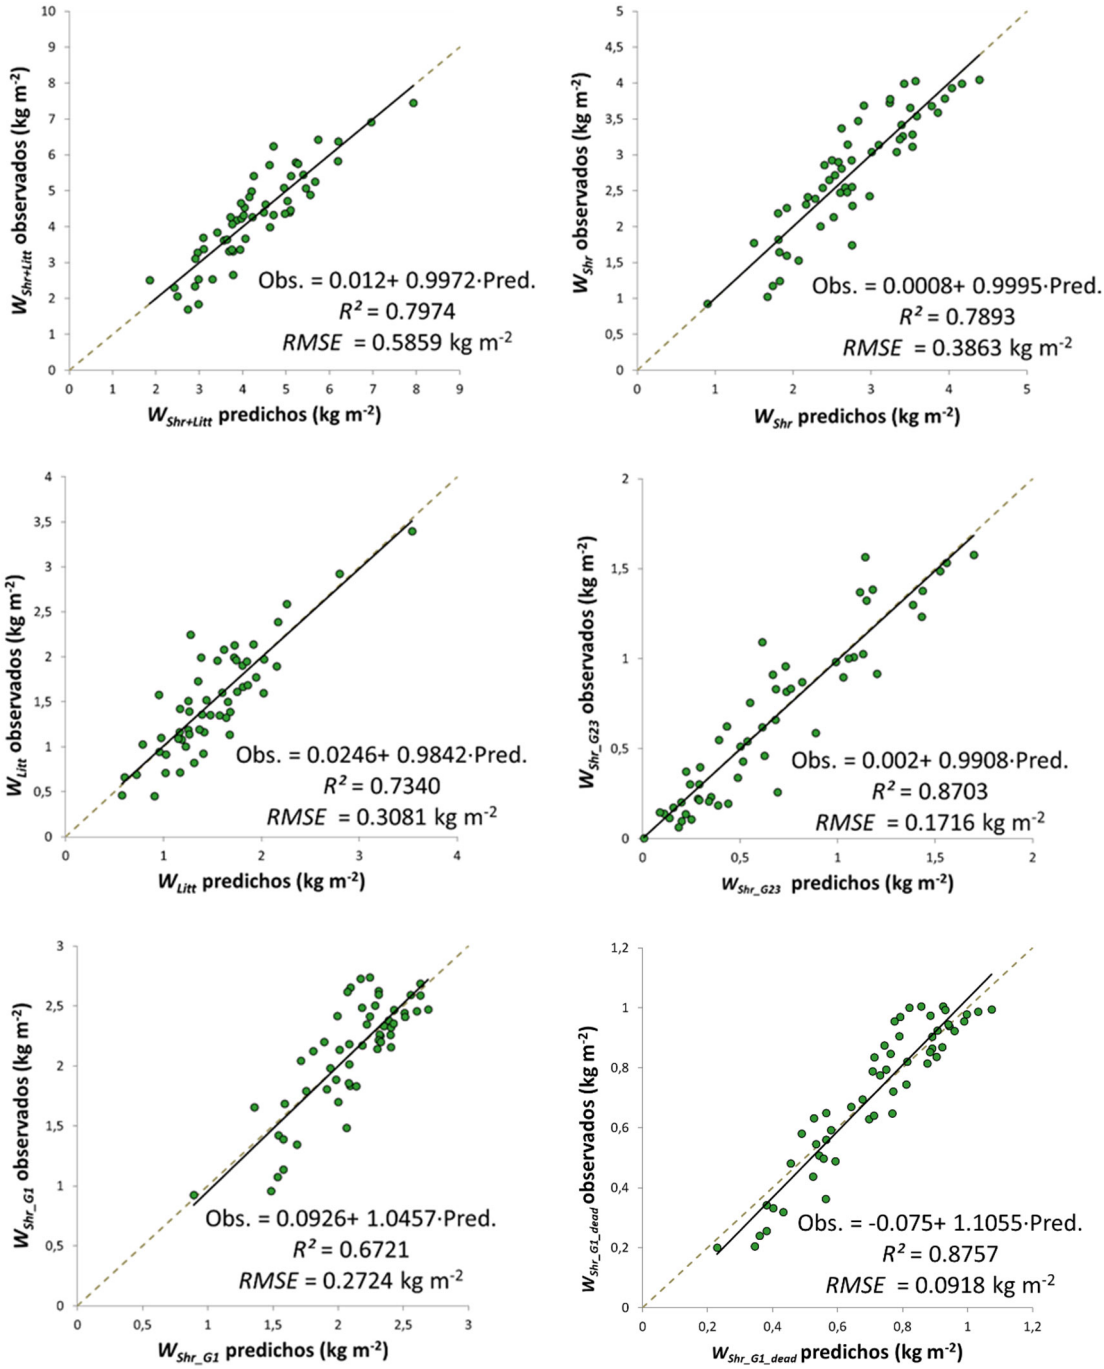

USC
UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

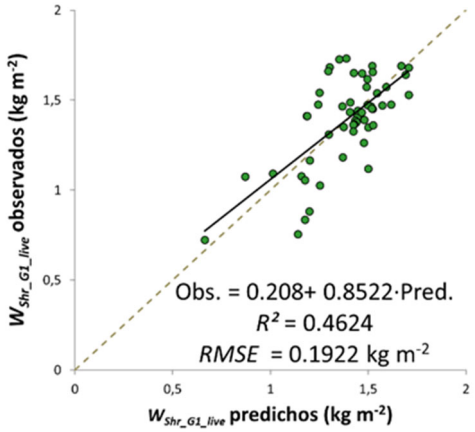

Figura 4. 4. Valores observados frente a valores predichos de las cargas de las fracciones de combustibles ajustadas para el total de las parcelas analizadas. La línea punteada es la diagonal y la línea continua es la recta ajustada a los datos. R^2 es el coeficiente de determinación del ajuste de la recta de la figura y *RMSE* es la raíz del error medio cuadrático.

Como se aprecia en las gráficas, las ecuaciones ajustadas explican una parte importante de la variabilidad observada, en la mayoría de los casos por encima del 70%, con valores que van desde el 46%, en el caso de la ecuación de estimación de la carga de combustible fino vivo de matorral, hasta casi el 88% de la ecuación de estimación de la carga de combustible grueso de matorral. En general, los modelos no presentan sesgo en sus estimaciones, salvo una ligera tendencia a subestimar cuando se trata de cargas bajas y sobreestimar para cargas altas en la ecuación de estimación de la carga de combustible fino vivo de matorral y a la inversa en la ecuación de estimación de la carga de combustible fino muerto de matorral.

En general, los estadísticos de bondad del ajuste obtenidos son ligeramente inferiores a los obtenidos con las metodologías basadas en el TLS, cuyos resultados se muestran en los apartados anteriores. La única excepción es la ecuación de estimación de la carga de hojarasca, que en este caso explica algo más del 73% de la variabilidad observada mientras que el mejor modelo derivado de métricas del TLS únicamente explicó un 44% de la variabilidad observada. Una posible explicación de esta notable diferencia en la bondad de los ajustes para esta fracción es la fuerte correlación que existe entre la carga de mantillo y la profundidad de la capa de este combustible (Vega et al., 2022b) y, mientras que la medición de dicha profundidad con la barra es sencilla y precisa, las nubes de puntos obtenidas del TLS no son de utilidad para caracterizar esta variable con exactitud tal y como indican Hudak et al. (2020) y como se hizo patente en los apartados anteriores de estimación a partir del TLS.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

4.2 Artículo 2

Artículo 2: Estimación de variables de rodal y de variables de superficie y del dosel de copas relacionadas con el fuego en pinares a partir de escáner laser aéreo de baja densidad y de un único escaneo con láser terrestre (*Remote Sensing*, 2021, *13,* (24), 5170).

4.2.1. Modelos basados en métricas derivadas de TLS

En la Tabla 4.5 se muestran los modelos ajustados a partir de las métricas derivadas del TLS junto con los estadísticos de bondad de ajuste para las tres metodologías utilizadas MARS, SVM y RF. En general, los modelos con el mayor porcentaje de variabilidad observada (R^2) y el menor *rRMSE* se obtuvieron con MARS, mientras que las estimaciones menos precisas correspondieron a los modelos obtenidos con RF. Los modelos SVM produjeron resultados en general muy similares a los modelos MARS, pero únicamente cuando se seleccionaba la función Kernel (lineal, radial o polinomial) que en cada caso mostraba mejores estadísticos de bondad de ajuste para cada variable dependiente analizada.

Como se puede observar en los estadísticos de la Tabla 4.5, los resultados de SVM empleando una función Kernel radial generan estimaciones más precisas de las variables relacionadas con la biomasa o la acumulación de volumen (W_{debris}, W_{LFH}, W_{shr}, *CFL*, *W* y *V*), mientras que para las variables relacionadas con la altura ($\overline{h_{Shr}}$, *FSG*, $\bar{h}$, *CBH* y *H*), una función Kernel lineal que requiere menos parámetros es de suficiente precisión. Finalmente, una función Kernel polinómica que es la más compleja de parametrizar, no mejora la precisión de las estimaciones, excepto en el caso de la variable W_{LFH}.

Tabla 4. 5. Estadísticos de bondad de ajuste de los modelos obtenidos a partir de las métricas derivadas del TLS como variables independientes para las tres metodologías siguientes: MARS = *multivariate adaptive regression splines*; SVM = *support vector machine lineal* (SVM-L), *radial* (SVM-R) o *polinómico* (SVM-P); y RF = *Random Forest*. Los mejores resultados para cada variable dependiente se destacan en negrita. Derechos de autor 2021, *Remote Sensing*.

Variables relacionadas con el fuego de superficie

Variable	Estadístico	MARS	SVM-L	SVM-R	SVM-P	RF
$\overline{h_{Shr}}$ (cm)	R^2	**0.5308**	0.4605	0.3816	0.4679	0.4305
	rRMSE (%)	**42.55**	45.63	48.85	45.32	46.88
FSG (m)	R^2	**0.7662**	0.6959	0.6254	0.6968	0.6556
	rRMSE (%)	**13.30**	15.17	16.84	15.15	16.14
W_{debris} (Mg ha^{-1})	R^2	**0.3653**	0.2395	0.2507	0.0737	---
	rRMSE (%)	**97.07**	106.26	105.47	117.27	---
W_{LFH} (Mg ha^{-1})	R^2	0.3496	0.3035	0.3346	**0.4225**	0.2987
	rRMSE (%)	11.96	12.38	12.10	**11.27**	12.42
W_{Shr} (Mg ha^{-1})	R^2	**0.3462**	0.3270	0.3178	0.3106	0.3180
	rRMSE (%)	**44.51**	45.16	45.46	45.70	45.46

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Variables del dosel relacionadas con el fuego de copas						
Variable	**Estadístico**	**MARS**	**SVM-L**	**SVM-R**	**SVM-P**	**RF**
$\bar{h}$	R^2	0.9250	0.9357	**0.9395**	0.9318	0.8766
(m)	*rRMSE (%)*	5.43	5.03	**4.88**	5.18	6.97
CBH	R^2	**0.7715**	0.7273	0.7417	0.7115	0.6670
(m)	*rRMSE (%)*	**11.92**	13.02	12.67	13.39	14.39
CFL	R^2	**0.4235**	0.3498	0.3783	0.3498	0.2978
(kg m^{-2})	*rRMSE (%)*	**20.42**	21.69	21.21	21.69	22.54
CBD	R^2	**0.5135**	0.4510	0.3604	0.3265	0.2660
(kg m^{-3})	*rRMSE (%)*	**26.54**	28.16	30.43	31.21	32.62
Variables de rodal						
Variable	**Estadístico**	**MARS**	**SVM-L**	**SVM-R**	**SVM-P**	**RF**
H	R^2	**0.9324**	0.9200	0.9316	0.9190	0.9066
(m)	*rRMSE (%)*	**5.39**	5.86	5.42	5.90	6.34
G	R^2	**0.5187**	0.2945	0.5125	0.2937	0.3334
(m^2 ha^{-1})	*rRMSE (%)*	**18.70**	22.64	18.82	22.66	22.01
V	R^2	0.5865	0.4976	**0.5924**	0.5236	0.4475
(m^3 ha^{-1})	*rRMSE (%)*	21.84	24.07	**21.68**	23.44	25.24
W	R^2	0.5607	0.4600	**0.6120**	0.4831	0.4603
(Mg ha^{-1})	*rRMSE (%)*	21.29	23.61	**20.01**	23.10	23.60

La capacidad explicativa de los modelos obtenidos con MARS dependió de las características de la variable dependiente analizada. Para las variables relacionadas con la altura del sotobosque o del arbolado, la variabilidad explicada por los modelos osciló entre el 53.1% para $\bar{h}_{shrub}$ (*rRMSE %* = 42.55) y valores en torno al 93% para las alturas media ($\bar{h}$) y dominante (*H*) del rodal (*rRMSE %* = 5.43 y 5.39, respectivamente), con valores en torno al 77% para *FSG* y *CBH* (*rRMSE %* = 13.30 y 11.92, respectivamente). La razón de la menor capacidad explicativa del modelo que estima $\bar{h}_{Shr}$ frente a los modelos de estimación de $\bar{h}$ y *H* se puede deber a que la primera no es una media aritmética, sino un valor ponderado por la cobertura de las diferentes especies de sotobosque presentes en la zona de estudio, por lo que la posible relación con las métricas TLS no sólo depende de la distribución vertical de la nube de puntos, sino también de su distribución horizontal.

Los valores de los estadísticos de bondad de ajuste obtenidos para los modelos de altura media y dominante están dentro del rango superior de los valores reportados en la literatura para la estimación de alturas, por ejemplo, Huang et al. (2011) obtuvieron valores de variabilidad explicada del 90.25%, con un *rRMSE%* de 6.91, para la estimación de alturas de árboles individuales en rodales mixtos de frondosas en el Bosque Nacional de la Montaña de Culai, en China; Liang y Hyyppa (2013) obtuvieron valores de *rRMSE%* que oscilaban entre el 6.9 y el 21.3% con escaneos únicos para la estimación de la altura del arbolado en un estudio que incluía tanto rodales mixtos de *P. sylvestris*, *Picea abies* y *Betula* sp. como rodales dominados por pinos y abetos en Finlandia; los modelos desarrollados por Srinivasan et al. (2015) explicaron el 92% de la variabilidad observada en la estimación de la altura de árboles individuales de *Pinus taeda* L.; Liang et al. (2018) llevaron a cabo un estudio en bosques boreales en el que analizaban el efecto que tenía, por un lado el algoritmo de tratamiento de datos y por otro la permeabilidad del escaneo (evaluada como la combinación de densidad del arbolado y vegetación de sotobosque) en la estimación de alturas de árboles individuales, obteniendo valores de *rRMSE%* para un

único escaneo que oscilaban entre el 12 y el 23% en parcelas con escasa vegetación de sotobosque y baja densidad ~600 árboles ha^{-1}, del 18 al 41% en parcelas con densidades moderadas ~1000 árboles ha^{-1} y escasa vegetación de sotobosque, y del 28 al 57% en parcelas con elevadas densidades ~2000 árboles ha^{-1} y vegetación de sotobosque densa. No obstante, estas comparaciones no son concluyentes ya que los trabajos citados se refieren a las estimaciones de alturas de árbol individual y no de variables del rodal como en la presente tesis doctoral. Por otro lado, Torralba et al. (2019) ajustaron un modelo para estimar *H* a partir de las métricas derivadas del TLS obtenidas con un único escaneo que explicaba el 73% de la variabilidad observada, con un valor de *rRMSE%* del 8% en rodales mixtos de bosque mediterráneo.

Muy pocos estudios han caracterizado la estructura vertical de los combustibles forestales utilizando datos de TLS (García et al., 2011b; Wilson et al., 2021). García et al. (2011b) ajustaron modelos de estimación de *CBH* y *FSG* en bosques de pino silvestre y alerce, así como en rodales mixtos de roble y abedul en Cheshire (Reino Unido) a partir de un único escaneo de TLS, con valores de *rRMSE%* de 46.54 y 49.68%, respectivamente, que son muy superiores a los obtenidos en este estudio (8.29 y 8.57%).

En cuanto a las variables relacionadas con la biomasa o el volumen del estrato superior (*G*, *W*, *V*, *CFL* y *CBD*), la variabilidad observada por los modelos MARS osciló entre el 42.35% para *CFL* (*rRMSE%* = 20.42) y el 58.65% para *V* (21.84%), con valores ligeramente superiores al 51% para *G* y *CBD* (*rRMSE%* = 18.70 y 26.54, respectivamente), y en torno al 56% para *W* (*rRMSE%* = 21.29). Los valores de *rRMSE%* están dentro del rango inferior de los valores observados en estudios anteriores, especialmente para *V* y *W*, aunque, en la mayoría de estos estudios, las variables del rodal se calcularon agregando valores del árbol individual obtenidos con modelos alométricos a partir del diámetro y la altura del árbol estimados con escaneos múltiples y no estimadas directamente, como en el presente estudio (Astrup et al., 2014; Panagiotidis et al., 2021). Sin embargo, la precisión de este enfoque de modelización de árbol individual depende en gran medida de la detección de los pies, que se ve afectada por los efectos de oclusión, la baja densidad de puntos y una gran cantidad de ruido en determinados lugares de la parcela, incluso cuando se utiliza el modo de escaneado múltiple (Watt y Donoghue, 2005; Liang et al., 2016). En escaneos únicos, la tasa de detección de pies varía entre el 20 y el 100%, con un valor medio del 73% en bosques con densidades de arbolado entre 400 y 1400 pies ha^{-1} (Brolly y Kiraly, 2009; Liang et al., 2012; Liang y Hyyppa, 2013; Olofsson et al., 2014).

Strahler et al. (2008) obtuvieron un error del 15.49% en la estimación del área basimétrica en masas de *Pinus ponderosa* Douglas ex C. Lawson en Nueva Gales del Sur (Australia) con un único escaneo; los modelos de Yao et al. (2011) obtenidos en bosques de frondosas y coníferas de Nueva Inglaterra, explicaron el 66% de la variabilidad observada en *G*, con un valor de *rRMSE%* de 15.24% y el 85% de la variabilidad observada en *W*, con un *rRMSE%* de 10.69%; Skowronski et al. (2011) obtuvieron valores de *rRMSE%* para las estimaciones de *CBD* y *CFL* de 18.48% y 15.68%, respectivamente, en rodales de pino propensos a los incendios forestales en Nueva Jersey; Torralba et al. (2019) explicaron el 70% de la variabilidad observada en W con un *rRMSE%* de 21% en bosques mediterráneos utilizando métricas TLS obtenidas con un único escaneo similar al procedimiento utilizado en este estudio; Molina-Valero et al. (2019) estimaron G en bosques maduros de *P. sylvestris* en España, a partir de un único escaneo explicando el 75% de la variabilidad observada con un *rRMSE%* de 21.84%.

Con respecto a los modelos MARS para estimar las cargas de combustible en superficie (W_{LFH}, W_{debris} y W_{Shr}), la variabilidad observada es muy similar, variando entre el 34.62% para W_{Shr} y el 36.53% para W_{debris}. Sin embargo, los valores del *rRMSE%* son muy diferentes (11.96% para W_{LFH}; 97.07% para W_{debris} y 44.51% para W_{Shr}), como consecuencia de la gran variabilidad observada en la carga de W_{debris}, especialmente en las parcelas sometidas a claras fuertes.

La mayoría de los estudios que estiman la biomasa de los combustibles de sotobosque utilizando datos del TLS se han centrado en reconstruir la forma de los matorrales a partir de la nube de puntos, ya sea mediante una aproximación a trozos del volumen o mediante la voxelización (Olsoy et al., 2014; Greaves et al., 2015; Rowell et al., 2020; Hudak et al., 2020). Los estudios que utilizan el TLS para predecir la distribución de la biomasa de los matorrales y otras capas de combustible sin reconstruir las formas a partir de los retornos son escasos. Por ejemplo, Chen et al. (2017) desarrollaron un modelo predictivo para estimar las cargas de combustible de superficie en bosques de eucaliptos del sureste de Australia, incluyendo la topografía y la perturbación de incendios anteriores como posibles variables independientes. El mejor modelo explicaba el 89% de la variabilidad observada, con el espesor de la hojarasca obtenido a partir del TLS, el número de años transcurridos desde el último incendio, la densidad del dosel obtenida a partir de la nube de puntos ALS, y la elevación de la parcela como variables independientes; cuando no se consideraron las variables ALS y la topografía, el porcentaje de variabilidad observada se reducía al 69%. Wallace et al. (2017) explicaron el 74% (*rRMSE%* = 16.3%) de la variabilidad observada en la biomasa aérea de superficie en bosques de tierras bajas con dominancia de eucaliptos y el 50% (*rRMSE%* = 41.2%) en bosques ribereños de llanura de inundación en Victoria (Australia) utilizando datos TLS. En el artículo primero de esta tesis se desarrolló un sistema de ecuaciones para estimar las cargas de combustible de matorral y hojarasca desagregadas por clases de tamaño para cuatro comunidades de matorral desarbolado en Galicia, utilizando métricas derivadas de un único escaneo TLS con un *rRMSE%* de 30.55% para W_{LFH} y 9.50% para W_{Shr}. Li et al. (2021) obtuvieron un modelo que explicaba el 69% de la biomasa del sotobosque en un bosque templado mixto de caducifolias y coníferas en la provincia de Jilin (China), utilizando una aproximación al volumen del matorral a partir del TLS.

4.2.2. Modelos basados en métricas derivadas de ALS

En la Tabla 4.6 se muestran los estadísticos de bondad de ajuste de los mejores modelos obtenidos para las tres metodologías descritas. Al igual que los modelos basados en las métricas TLS, los enfoques MARS y SVS superaron al enfoque RF. Teniendo en cuenta estos resultados, y para facilitar la comparación entre los modelos con diferentes tipos de métricas (TLS vs. ALS), la discusión que sigue sólo considera los estadísticos del modelo MARS.

Al igual que con los modelos basados en las métricas TLS, la precisión de las estimaciones de los modelos basados en las métricas ALS varió mucho, dependiendo de la variable dependiente analizada. Para las variables relacionadas con la altura de los árboles o el sotobosque, la variabilidad observada explicada fue muy similar a la obtenida con los modelos TLS para $\bar{h}$ (89.16%; *rRMSE%* = 6.53%), y *H* (93.07%; *rRMSE%* = 5.46%); superior para *CBH* (84,57%; *rRMSE%* = 9,79%) y *FSG* (85.51%; *rRMSE%* = 10.47%) e inferior en el caso de $\bar{h}_{Shr}$ (32.01%; *rRMSE%* = 51.22%), probablemente

debido a la dificultad de caracterizar adecuadamente el sotobosque en bosques densos utilizando datos LiDAR aéreos de baja densidad (Keane et al., 2001; Campbell et al., 2018). Estudios comparativos muestran que el ALS produce estimaciones más precisas de la altura del dosel que el TLS (Hilker et al., 2012; Crespo-Peremarch y Ruiz, 2017), mientras que el TLS produce una caracterización más precisa de la vegetación del sotobosque (Chasmer et al., 2006; Hilker et al., 2010).

En cuanto a las variables relacionadas con el volumen o la biomasa del dosel, los modelos basados en las métricas ALS fueron similares a los basados en las derivadas del TLS para *G* (R^2 = 0.4939 y *rRMSE%* = 19.18%) y mucho mejores para las demás variables (*V* con R^2 = 0.6599 y *rRMSE%* = 19.80%; *W* con R^2 = 0.6452 y *rRMSE%* = 19.14%; *CFL* con R^2 = 0.5203 y *rRMSE%* = 18.63%; y *CBD* con R^2 = 0.5587 y *rRMSE%* = 25.26%). En cuanto a las cargas de combustible de superficie, las estimaciones de los modelos basados en las métricas ALS fueron ligeramente más precisas para W_{debris} (R^2 = 0.4069; *rRMSE%* = 93.84%) y W_{Shr} (R^2 = 0.4796; *rRMSE%* = 39.71%) y mucho peores para W_{LFH} (R^2 = 0.1049; *rRMSE%* = 14.03%). Al igual que con los modelos basados en las métricas TLS, en el caso de esta última variable, el *rRMSE%* fue bajo, a pesar de que la variabilidad explicada por el modelo es muy baja (≈10%), probablemente debido a la baja variabilidad de la carga de combustible de hojarasca en las 68 parcelas analizadas; por el contrario, en el caso de la carga de restos leñosos (W_{debris}), el *rRMSE%* fue muy alto debido a la alta variabilidad observada en las parcelas, especialmente en el tratamiento de clara fuerte.

Tabla 4.6. Estadísticos de bondad de ajuste de los modelos obtenidos a partir de las métricas derivadas del ALS como variables independientes para las tres metodologías siguientes: MARS = *multivariate adaptive regression splines*; SVM = *Support Vector Machine Lineal* (SVM-L), *Radial* (SVM-R) o *Polinómico* (SVM-P); y RF = *Random Forest*. Los mejores resultados para cada variable dependiente se destacan en negrita. Derechos de autor 2021, *Remote Sensing*.

Variables relacionadas con el fuego de superficie						
Variable	**Estadístico**	**MARS**	**SVM-L**	**SVM-R**	**SVM-P**	**RF**
$\overline{h_{Shr}}$ **(cm)**	R^2	0.3201	0.3144	**0.4246**	0.4185	0.2758
	rRMSE (%)	51.22	51.44	**47.12**	47.37	52.86
FSG **(m)**	R^2	0.8551	0.7924	0.7310	**0.8624**	0.7811
	rRMSE (%)	10.47	12.53	14.27	**10.20**	12.87
W_{debris} **(Mg ha^{-1})**	R^2	**0.4069**	0.3794	0.3874	0.3244	0.3027
	rRMSE (%)	**93.84**	95.99	95.37	100.15	101.75
W_{LFH} **(Mg ha^{-1})**	R^2	0.1049	0.1556	0.1346	**0.1750**	---
	rRMSE (%)	14.03	13.63	13.80	**13.47**	---
W_{Shr} **(Mg ha^{-1})**	R^2	**0.4796**	0.4020	0.4514	0.4333	0.4542
	rRMSE (%)	**39.71**	42.56	40.77	41.44	40.67
Variables del dosel relacionadas con el fuego de copas						
Variable	**Estadístico**	**MARS**	**SVM-L**	**SVM-R**	**SVM-P**	**RF**
$\overline{h}$ **(m)**	R^2	**0.8916**	0.8457	0.8197	0.8455	0.8381
	rRMSE (%)	**6.53**	7.80	8.43	7.80	7.98
CBH **(m)**	R^2	0.8457	0.8574	0.8381	**0.8625**	0.8141
	rRMSE (%)	9.79	9.41	10.03	**9.25**	10.75
CFL **(kg m^{-2})**	R^2	**0.5203**	0.4167	0.3959	0.3985	0.3285
	rRMSE (%)	**18.63**	20.55	20.91	20.87	22.05
CBD **(kg m^{-3})**	R^2	0.5587	0.4677	0.4412	**0.5727**	0.4590
	rRMSE (%)	25.26	27.74	28.45	**24.84**	27.95

Variables de rodal

Variable	Estadístico	MARS	SVM-L	SVM-R	SVM-P	RF
H	R^2	**0.9307**	0.9201	0.8560	0.9105	0.8849
(m)	*rRMSE (%)*	**5.46**	5.86	7.87	6.20	7.03
G	R^2	0.4939	0.4867	0.4314	**0.5027**	0.3849
(m^2 ha^{-1})	*rRMSE (%)*	19.18	19.32	20.33	**19.01**	21.14
V	R^2	**0.6599**	0.5749	0.5521	0.6137	0.5638
(m^3 ha^{-1})	*rRMSE (%)*	**19.80**	22.14	22.73	21.11	22.43
W	R^2	**0.6452**	0.5199	0.5620	0.5949	0.5624
(Mg ha^{-1})	*rRMSE (%)*	**19.14**	22.26	21.26	20.45	21.25

Todos estos valores de bondad de ajuste están dentro del rango previamente reportado para datos ALS de baja densidad y bosques de características similares. Por ejemplo, para bosques puros de *P. radiata*, los modelos de volumen (*V*) desarrollados por González-Ferreiro et al. (2012) arrojaron un *rRMSE%* del 30.4% para datos ALS, con una densidad de 0.5 primeros retornos m^{-2} y del 24.98% para 8 primeros retornos m^{-2}; los modelos de estimación de biomasa aérea utilizados por los mismos autores arrojaron valores de *rRMSE%* del 26.77% para 0.5 primeros retornos m^{-2} y del 23.73% para 8 primeros retornos m^{-2}. Utilizando los mismos datos y aplicando un enfoque híbrido basado en el uso combinado de la regresión lineal múltiple (MLR) y un algoritmo genético para seleccionar el mejor conjunto de variables independientes; García-Gutiérrez et al. (2014) informaron de valores de *rRMSE%* de 23.03% y 21.29% para los modelos de área basimétrica (*G*), utilizando datos LiDAR con densidades de 0.5 y 8 primeros retornos m^{-2}, respectivamente; 27.24% y 24.63% para los modelos de volumen (*V*) ajustados a conjuntos de datos LiDAR de 0.5 y 8 primeros retornos m^{-2}, respectivamente; y para los modelos de cargas (*W*), valores de *rRMSE*% de 26.77% para 0.5 primeros retornos m^{-2} y 24.04% para una densidad de pulsos láser de 8 primeros retornos m^{-2}. Para un estudio en un bosque de *P. radiata* en Galicia, González-Ferreiro et al. (2012) obtuvieron valores de *rRMSE*% de 6.94% para $\bar{h}$; 7.13% para *CBH*; 12.40% para *CFL*; y 21.85% para *CBD* con datos ALS con una densidad de 0.5 primeros retornos m^{-2}. En otro estudio de una red de ensayos de claras en 4 rodales de *P. pinaster* puros y regulares en Asturias (NO de España), Hevia et al. (2016b) obtuvieron valores de *rRMSE*% para $\bar{h}$, *H* y *CBH* del mismo orden que los obtenidos en este estudio (5.22; 6.50 y 8.43%, respectivamente), aunque los resultados fueron mucho mejores para las variables de carga de combustible (8.09% para *CFL* y 9.78% para *CBD*); sin embargo, la densidad de datos LiDAR fue también mucho mayor (8-16 primeros retornos m^{-2}) que la utilizada en este estudio. Jiménez et al. (2017) desarrollaron modelos para la estimación de variables de rodal en bosques de *P. pinaster* y *P. radiata* en Galicia, utilizando una combinación de datos LiDAR del PNOA y datos LANDSAT-ETM en parcelas del Cuarto Inventario Forestal Nacional de España (IV-IFN) obteniendo valores de *rRMSE*% para el área basimétrica (*G*) de 41.62% para *P. pinaster* y 27.64% para *P. radiata*; los valores del mismo estadístico para la altura dominante (*H*) fueron 6.31 y 11.76%, respectivamente; para la biomasa de la copa, los valores fueron 42.86 y 26%, respectivamente, y para la biomasa del tronco, 46.92 y 23.99%, respectivamente. Utilizando también datos del IV-IFN y datos LiDAR del PNOA, González- Ferreiro et al. (2017) obtuvieron valores de *rRMSE%* para la estimación de la *CFL* del 44.35% para *P. radiata* y del 45.39% para *P. pinaster*. Por último, en un estudio en bosques de *P. pinaster* y *P. radiata* en el noroeste de España utilizando metodologías de aprendizaje automático, Novo-Fernández et al. (2019) obtuvieron valores de *rRMSE%* para la estimación de *V* de 37.95 y 37.23%, respectivamente, y 38.51 y 38.27%, respectivamente, para la estimación

de *W* a partir de los datos del IV-IFN y de los mismos datos LiDAR del PNOA utilizados en este estudio.

4.2.3. Modelos MARS que combinan métricas derivadas de TLS y ALS

A la vista de los resultados de los apartados anteriores se decidió emplear únicamente la metodología MARS para ajustar modelos de estimación combinando como variables independientes tanto las métricas TLS como las de ALS.

En las Tablas 4.7 a 4.9 se muestran las expresiones matemáticas de los modelos MARS obtenidos utilizando las métricas del TLS, del ALS y ambas combinadas como variables independientes para estimar las variables relacionadas con el fuego de superficie, con el fuego de copas y con las variables del rodal.

USC
UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Tabla 4. 7. Expresión matemática de los modelos MARS ajustados utilizando los tres conjuntos diferentes de métricas (TLS, ALS y TLS+ALS) como variables independientes para estimar las variables relacionadas con el fuego de superficie. Derechos de autor 2021, *Remote Sensing*.

Variables relacionadas con el fuego de superficie

Variable	Métricas	Modelos
$\overline{h_{Shr}}$ (m)	TLS	$\overline{h_{Shr}} = 18.36 - 572.09 \cdot (0.11 - TLSh_{01}) + 38.87 \cdot (1.81 - TLSh_{15}) + 8.23 \cdot (TLSh_{95} - 15.39)$ $+0.11 \cdot (15.39 - TLSh_{95}) \cdot TLSP_{B2m_max}$
	ALS	$\overline{h_{Shr}} = 56.18 - 343.89 \cdot (0.29 - ALSh_{CV}) + 148.79 \cdot (ALS_{CRR} - 0.59)$
	TLS+ALS	La inclusión de métricas ALS no mejora el modelo que emplea solo las métricas TLS
FSG (m)	TLS	$FSG = 11.08 - 1.13 \cdot I_{sp} - 0.92 \cdot (15.39 - TLSh_{95}) + 2.11 \cdot (TLSh_{95} - 15.39) - 0.66 \cdot TLSh_{20} \cdot (TLSh_{95} - 15.39)$
	ALS	$FSG = 6.26 + 1.77 \cdot (ALSh_{MAD-mode} - 2.69) + 2.51 \cdot (ALSh_{L2} - 1.67) + 0.79 \cdot (ALSh_{40} - 9.46)$ $-0.053 \cdot ALSP_{Ahmean} \cdot (ALSh_{MAD-mode} - 1.77)$
	TLS+ALS	$FSG = 8.86 - 1.01 \cdot (5.11 - TLSh_{SD}) + 4.41 \cdot (ALSh_{L2} - 2.19) + 0.65 \cdot (ALSh_{10} - 8.77) - 0.93 \cdot (8.12 - ALSh_{20})$
W_{debris} (Mg ha^{-1})	TLS	$W_{debris} = 36.99 - 88.39 \cdot (TLSh_{01} - 0.18) - 43.42 \cdot (0.87 - TLSh_{05}) - 4.80 \cdot (TLSh_{70} - 8.75)$ $+7.01 \cdot (TLSh_{95} - 13.50) \cdot TLSh_{05}$
	ALS	$W_{debris} = 8.51 + 219.67 \cdot (ALSh_{L-CV} - 0.09) + 10.66 \cdot (3.99 - ALSh_{05}) - 19.18 \cdot (14.83 - ALSh_{30})$ $+17.30 \cdot (16.12 - ALSh_{50})$
	TLS+ALS	$W_{debris} = 11.40 - 6.14 \cdot (6.63 - TLSh_{55}) + 15.18 \cdot (5.17 - ALSh_{05}) - 8.43 \cdot (6.70 - ALSh_{10})$ $+0.45 \cdot (42.15 - TLSP_{Ahmean}) \cdot TLSh_{90}$
W_{LFH} (Mg ha^{-1})	TLS	$W_{LFH} = 31.17 + 0.11 \cdot (TLSP_{B2m_max} - 12.32) - 16.41 \cdot (0.36 - TLSh_{skew}) + 1.56 \cdot (TLSh_{55} - 6.53)$
	ALS	$W_{LFH} = 31.68 - 8.10 \cdot (3.75 - ALSh_{var})$
	TLS+ALS	$W_{LFH} = 35.14 - 15.50 \cdot (0.34 - TLSh_{skew}) - 12.46 \cdot (TLSh_{10} - 0.80) + 15.03 \cdot (TLSh_{15} - 1.63)$ $-3.26 \cdot (1.23 - W_{shape}) \cdot ALSh_{ID}$
W_{Shr} (Mg ha^{-1})	TLS	$W_{Shr} = 7.94 + 5.82 \cdot (TLSh_{kurt} - 0.68) - 39.62 \cdot (0.11 - TLSh_{01}) - 24.23 \cdot (TLSh_{01} - 0.11)$ $-14.49 \cdot (TLSh_{01} - 0.11) \cdot TLSh_{kurt}$
	ALS	$W_{Shr} = 5.86 + 32.17 \cdot (-0.18 - ALSh_{L3}) + 1.08 \cdot (6.98 - ALSh_{01}) - 0.26 \cdot (ALSP_{Ahmean} - 29.97)$ $+4.43 \cdot (6.98 - ALSh_{01}) \cdot ALSh_{L3}$
	TLS+ALS	La inclusión de métricas TLS no mejora el modelo que emplea solo las métricas ALS

Tabla 4. 8. Expresión matemática de los modelos MARS ajustados utilizando tres conjuntos diferentes de métricas (TLS, ALS y TLS+ALS) como variables independientes para estimar las variables relacionadas con el fuego de copas. Derechos de autor 2021, *Remote Sensing*.

Variables del dosel relacionadas con el fuego de copas		
Variable	**Métricas**	**Modelos**
$\bar{h}$ **(m)**	**TLS**	$\bar{h} = 13.30 - 1.12 \cdot (12.31 - TLSh_{99}) + 1.04 \cdot (TLSh_{99} - 12.31) + 0.04 \cdot (TLSh_{99} - 12.31) \cdot (TLSP_{max} - 23.72) \cdot I_{sp}$
	ALS	$\bar{h} = 20.93 - 0.95 \cdot (22.77 - ALSh_{99}) + 0.55 \cdot (ALSh_{99} - 22.77) - 24.51 \cdot (0.53 - ALS_{CRR}) + 6.03 \cdot (22.77 - ALSh_{99}) \cdot (ALSh_{L-CV} - 0.11)$
	TLS+ALS	$\bar{h} = 13.46 - 1.23 \cdot (12.31 - TLSh_{99}) + 0.96 \cdot (TLSh_{99} - 12.31) + 0.10 \cdot (ALSh_{var} - 15.23) + 0.04 \cdot (TLSh_{99} - 12.31) \cdot (TLSP_{max} - 24.56) \cdot I_{sp}$
CBH **(m)**	**TLS**	$CBH = 12.64 - 1.14 \cdot I_{sp} - 0.09 \cdot (32.86 - TLSP_{max}) - 1.02 \cdot (15.83 - TLSh_{95}) + 0.97 \cdot (TLSh_{95} - 15.83)$
	ALS	$CBH = 9.64 - 0.34 \cdot (ALSh_{MAD-mode} - 1.76) + 6.15 \cdot (-0.19 - ALSh_{L3}) + 0.43 \cdot (ALSh_{10} - 7.96) - 0.44 \cdot (19.02 - ALSh_{90})$
	TLS+ALS	$CBH = 7.89 + 1.05 \cdot (TLSh_{SD} - 3.49) + 5.11 \cdot (-0.19 - ALSh_{L3}) + 0.45 \cdot (ALSh_{10} - 9.21) - 0.39 \cdot (11.10 - ALSh_{20})$
CFL **(kg m^{-2})**	**TLS**	$CFL = 1.39 - 0.39 \cdot (-0.58 - TLSh_{kurt}) - 0.13 \cdot (13.37 - TLSh_{95}) - 0.02 \cdot (30.55 - TLSP_{B2m_max}) \cdot I_{sp} - 0.99 \cdot TLSh_{10} \cdot TLSh_{15} \cdot (4.39 - TLSh_{55})$
	ALS	$CFL = 0.77 + 0.02 \cdot (ALSP_{A4m} - 49.60) + 0.76 \cdot (ALSh_{mode} - 10.02) \cdot (0.24 - ALSh_{L4}) - 0.03 \cdot (2.76 - ALSh_{SD}) \cdot (ALSP_{A4m} - 49.60) + 0.04 \cdot (1.40 - ALSh_{MAD-mode}) \cdot (ALSP_{A4m} - 49.60)$
	TLS+ALS	$CFL = 1.31 - 0.03 \cdot (30.55 - TLSP_{B2m_max}) - 0.11 \cdot (16.55 - TLSh_{99}) - 3.75 \cdot (ALSh_{L-CV} - 0.17) + 0.01 \cdot (ALSP_{Ahmean} - 40.04)$
CBD **(kg m^{-3})**	**TLS**	$CBD = 0.21 - 0.061 \cdot I_{sp} - 0.0053 \cdot (30.55 - TLSP_{B2m_max}) - 0.046 \cdot (10.48 - TLSh_{90}) + 0.008 \cdot (TLSh_{90} - 10.48)$
	ALS	$CBD = 0.13 - 0.47 \cdot (ALSh_{L-CV} - 0.11) + 0.025 \cdot (ALSP_{Ahmean} - 53.55) - 0.022 \cdot (0.11 - ALSh_{L-CV}) \cdot ALSP_{Ahmode} - 0.001 \cdot (ALSP_{Ahmean} - 53.55) \cdot ALSh_{99}$
	TLS+ALS	$CBD = 0.12 + 2.79 \cdot (0.11 - ALSh_{L-CV}) + 0.007 \cdot (ALSP_{Ahmean} - 53.55) - 0.017 \cdot (30.55 - TLSP_{B2m_max}) \cdot (1.58 - ALSh_{MAD-median}) - 0.001 \cdot (30.55 - TLSP_{B2m_max}) \cdot (ALSh_{MAD-median} - 1.58) \cdot TLSh_{20}$

Tabla 4. 9. Expresión matemática de los modelos MARS ajustado utilizando los tres conjuntos diferentes de métricas (TLS, ALS y TLS+ALS) como variables independientes para estimar las variables del rodal. Derechos de autor 2021, *Remote Sensing*.

Variables de rodal		
Variable	**Métricas**	**Modelos**
H **(m)**	**TLS**	$H = 18.56 + 8.94 \cdot I_{sp} - 1.12 \cdot (15.96 - TLSh_{99})$ $-0.15 \cdot TLSP_{Ahmean} \cdot I_{sp} + 0.03 \cdot TLSh_{max} \cdot (TLSh_{99} - 15.96)$
	ALS	$H = 14.88 - 0.61 \cdot (10.93 - ALSh_{25})$ $+1.14 \cdot (ALSh_{90} - 13.74) + 1.15 \cdot (35.70 - ALSP_{Ahmean}) \cdot ALSh_{L-kurt} + 0.03 \cdot ALSP_{A4m} \cdot (12.28 - ALSh_{30}) \cdot I_{sp}$
	TLS+ALS	$H = 18.75 + 7.78 \cdot I_{sp} - 1.17 \cdot (15.96 - TLSh_{99})$ $+0.75 \cdot (ALSh_{90} - 17.34) - 0.13 \cdot TLSP_{Ahmean} \cdot I_{sp}$
G **(m^2 ha^{-1})**	**TLS**	$G = 53.05 - 12.20 \cdot I_{sp} - 1.41 \cdot (28.37 - TLSP_{B2m_max}) - 12.03 \cdot (-0.35 - TLSh_{kurt}) - 8.35 \cdot (10.48 - TLSh_{90})$ $+3.42 \cdot (TLSh_{90} - 10.48)$
	ALS	$G = 21.83 + 0.96 \cdot (ALSh_{mode} - 10.02) - 13.52 \cdot (2.24 - ALSh_{SD})$ $+0.90 \cdot (15.23 - ALSh_{var}) + 0.46 \cdot (ALSP_{A4m} - 49.60)$
	TLS+ALS	$G = 24.90 - 15.55 \cdot (0.64 - TLSh_{skw}) - 8.94 \cdot (3.44 - ALSh_{ID}) + 10.47 \cdot (2.70 - ALSh_{MAD-mode})$ $+1.33 \cdot (ALSh_{01} - 1.68) + 0.69 \cdot (ALSP_{Ahmean} - 40.04)$
V **(m^3 ha^{-1})**	**TLS**	$V = 347.82 - 65.26 \cdot I_{sp} - 11.61 \cdot (28.37 - TLSP_{B2m_max})$ $+33.65 \cdot (TLSh_{99} - 14.19) - 46.29 \cdot (14.78 - TLSh_{99})$
	ALS	$V = 176.76 + 16.15 \cdot (ALSh_{mode} - 10.02) - 26.49 \cdot (3.76 - ALSh_{ID}) + 3.97 \cdot (ALSP_{A4m} - 53.21)$ $+1.47 \cdot (ALSP_{A4m} - 53.21) \cdot (48.77 - ALSP_{Ahmean})$
	TLS+ALS	$V = 385.23 - 10.92 \cdot (30.55 - TLSP_{B2m_max})$ $-28.06 \cdot (18.63 - TLSh_{99}) + 22.62 \cdot (ALSh_{mode} - 10.02) - 575.74 \cdot (ALSh_{L-CV} - 0.08) \cdot (ALSh_{10} - 9.21)$
W **(Mg ha^{-1})**	**TLS**	$W = 216.79 - 43.98 \cdot I_{sp} - 5.86 \cdot (28.37 - TLSP_{B2m_max}) - 24.18 \cdot (15.96 - TLSh_{99}) + 15.53 \cdot (TLSh_{99} - 15.96)$
	ALS	$W = 92.24 + 4.69 \cdot (ALSh_{mode} - 10.02)$ $+2.58 \cdot (ALSP_{A4m} - 49.60) + 110.67 \cdot (ALSh_{mode} - 10.02) \cdot (0.20 - ALSh_{CV}) - 2.44 \cdot (ALSP_{A4m} - 49.60) \cdot (2.76 - ALSh_{SD})$
	TLS+ALS	$W = 105.02 - 49.55 \cdot (0.64 - TLSh_{skw}) + 8.73 \cdot (ALSh_{mode} - 10.02)$ $-12.03 \cdot (ALSh_{ID} - 3.76) + 1.61 \cdot (ALSP_{A4m} - 49.59)$

La combinación de las métricas ALS y TLS mejoró la capacidad de predicción de los modelos basados en un único tipo de métrica en todos los casos, excepto para $\overline{h_{Shr}}$ y W_{Shr}, tal y como muestran los valores de los estadísticos de bondad de ajuste (Tabla 4.10) para cada conjunto de métricas (TLS, ALS y TLS+ALS). La mejora de la precisión de las estimaciones es especialmente importante para las variables relacionadas con el volumen o la biomasa del dosel, con reducciones del *rRMSE* del 7.56% para *CFL*; 9.21% para *V*; 9.52% para *CBD*; y 10.72% para *G*.

Tabla 4. 10. Estadísticos de bondad de ajuste de los modelos ajustados, utilizando los tres conjuntos diferentes de métricas (TLS, ALS y TLS+ALS) como variables independientes. Derechos de autor 2021, *Remote Sensing*.

Variables relacionadas con el fuego de superficie				
Variable	**Estadístico**	**TLS**	**ALS**	**TLS+ALS**
$\overline{h_{Shr}}$ **(cm)**	R^2	0.5308	0.3201	0.5308
	rRMSE(%)	42.55	51.22	42.55
FSG **(m)**	R^2	0.7662	0.8551	0.8987
	rRMSE(%)	13.30	10.47	8.75
W_{debris} **(Mg ha^{-1})**	R^2	0.3653	0.4069	0.4894
	rRMSE(%)	97.07	93.84	87.06
W_{LFH} **(Mg ha^{-1})**	R^2	0.3496	0.1049	0.4311
	rRMSE(%)	11.96	14.03	11.19
W_{Shr} **(Mg ha^{-1})**	R^2	0.3462	0.4796	0.3462
	rRMSE(%)	44.51	39.71	44.51
Variables del dosel relacionadas con el fuego de copas				
Variable	**Estadístico**	**TLS**	**ALS**	**TLS+ALS**
$\bar{h}$ **(m)**	R^2	0.9250	0.8916	0.9343
	rRMSE(%)	5.43	6.53	5.08
CBH **(m)**	R^2	0.7715	0.8457	0.8683
	rRMSE(%)	11.92	9.79	9.05
CFL **(kg m^{-2})**	R^2	0.4235	0.5203	0.5899
	rRMSE(%)	20.42	18.63	17.22
CBD **(kg m^{-3})**	R^2	0.5135	0.5587	0.6383
	rRMSE(%)	26.54	25.26	22.86
Variables de rodal				
Variable	**Estadístico**	**TLS**	**ALS**	**TLS+ALS**
H **(m)**	R^2	0.9324	0.9307	0.9425
	rRMSE(%)	5.39	5.46	4.97
G **(m^2 ha^{-1})**	R^2	0.5187	0.4939	0.6163
	rRMSE(%)	18.7	19.18	16.70
V **(m^3 ha^{-1})**	R^2	0.5865	0.6599	0.7197
	rRMSE(%)	21.84	19.80	17.98
W **(Mg ha^{-1})**	R^2	0.5607	0.6452	0.6512
	rRMSE(%)	21.29	19.14	18.97

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Estos resultados eran de esperar, ya que estas variables están fuertemente correlacionadas con el estado de desarrollo del dosel y su distribución vertical y horizontal, y la combinación de las métricas derivadas del ALS (considerando el ángulo cenital) con las métricas del TLS (aportando información de la parte baja del dosel) proporciona una información mucho más completa sobre su estructura espacial (Xu et al., 2021). Los modelos desarrollados para estimar W_{LFH} y W_{debris} que se ajustaron utilizando métricas de ambos sensores también mostraron apreciables reducciones de *rRMSE* con valores de 6.47 y 7.22%, respectivamente.

Para analizar la importancia que cada variable independiente incluida en los modelos tiene sobre sus estimaciones se calculó el valor de importancia relativa a partir de la reducción del *rRMSE* que supone la incorporación al modelo de dicha variable independiente, suponiendo que las demás variables independientes ya están incluidas en el mismo. Los valores de reducción de *rRMSE* se han normalizado asignando a la máxima reducción el valor de 100 y al resto proporcional a su valor. Los valores normalizados de importancia relativa se muestran en la Figura 4.5.

En general, las métricas relativas a los percentiles de altura tanto para los datos ALS como TLS fueron las variables que más contribuyeron a la variabilidad explicada por los modelos, especialmente para aquellas variables dependientes relacionadas con la altura ($\overline{h_{Shr}}$, $\bar{h}$, *FSG*, *CBH* y *H*). Sin embargo, como era de esperar, en el caso de las variables relacionadas con las cargas de combustible, con la forma del perfil (asimetría, distancia intercuartílica, L-momentos, o el parámetro de forma de la distribución de Weibull) o la distribución horizontal de la nube de puntos (*TLSPA2m_max* o *TLSPB2m_max*) contribuyeron significativamente a la reducción de los valores de *RMSE*. Estos resultados fueron similares a los obtenidos en diversos estudios que utilizaron métricas en lugar de reconstruir estructuras 3D, especialmente en el caso de nubes de puntos ALS (Hilker et al., 2012; Bouvier et al., 2015; Guerra-Hernández et al., 2016; Novo-Fernández et al., 2019; Mauro et al., 2021).

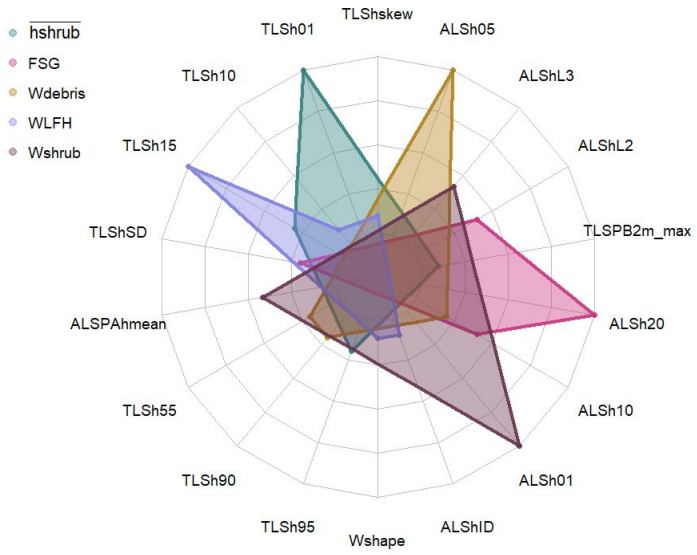

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

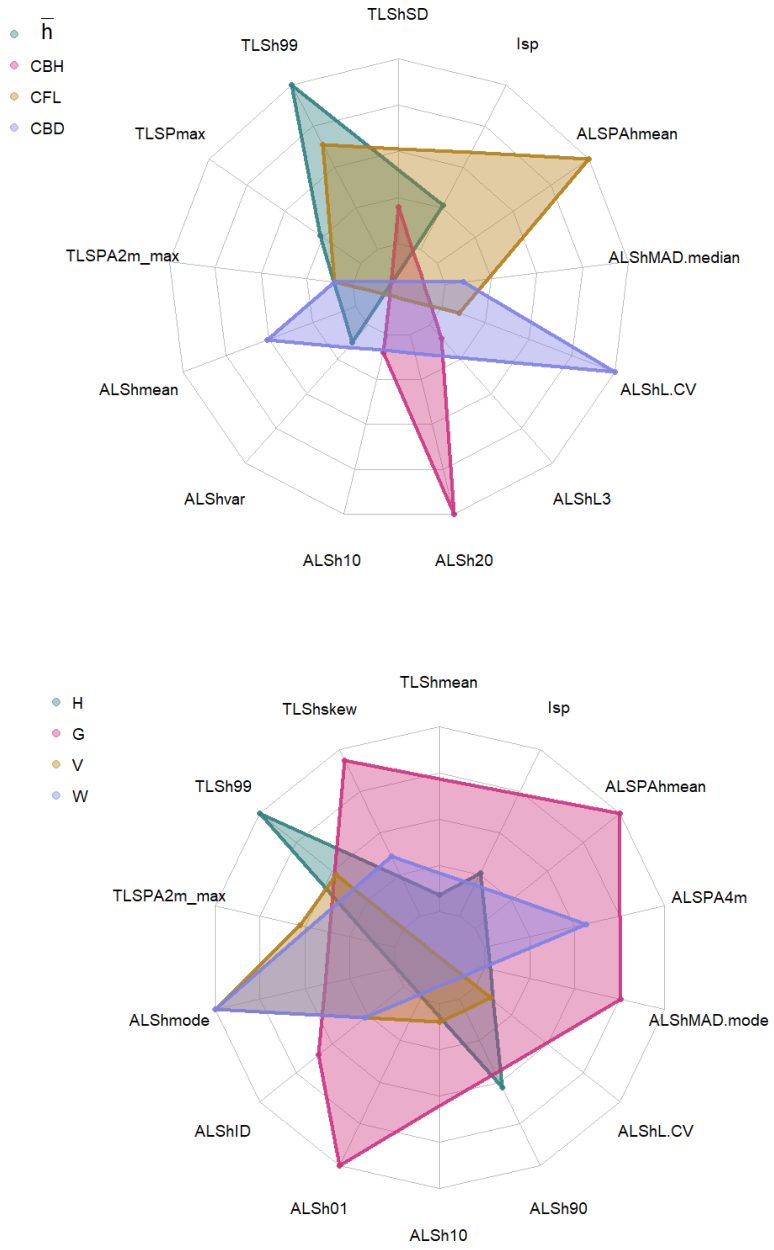

Figura 4. 5. Importancia relativa normalizada de las variables independientes en los modelos de mejor ajuste para la estimación de las variables relacionadas con el fuego de superficie (arriba), las variables del dosel relacionadas con el fuego de copas (centro) y las variables de rodal (abajo), respectivamente. Cada círculo concéntrico representa un valor de un 20% sobre el máximo. Derechos de autor 2021, *Remote Sensing*.

Estas diferencias entre especies de pino en el caso de las variables de matorral no se reflejan en los modelos probablemente porque las ecuaciones utilizadas para estimarlas no diferenciaban entre *P. pinaster* y *P. radiata*. En todo caso, los modelos ajustados por Vega et al. (2022ª) utilizando una base de datos de 283 muestreos destructivos en masas de pinar en Galicia tampoco mostraron diferencias significativas en las estimaciones de

las variables estructurales de matorral entre pinares de pinaster y radiata, aunque si se observaron estas diferencias en las masas de *P. sylvestris*.

En el caso de los modelos de altura dominante, incluso la baja densidad del ALS utilizada permite caracterizar con gran detalle la estructura de la copa superior, lo que, combinado con las notables diferencias de *H* entre especies en el conjunto de datos utilizado (16.42 m y 22.39 m para *P. pinaster* y *P. radiata*, respectivamente), da lugar a una gran variabilidad de los percentiles superiores de altura que está condicionada por la inclusión de la variable categórica que afecta a la especie. A pesar de las diferencias en la densidad de puntos de los sensores, los modelos ajustados para esta variable mostraron estadísticos de bondad de ajuste muy similares, explicando casi el 93% de la variabilidad observada.

Resultados similares ya han sido mostrados en estudios de referencia (Chasmer et al., 2006; Hilker et al., 2010; Jung et al., 2011). El hecho de que los modelos ajustados basados en las métricas ALS sean independientes de la especie, permite la elaboración de mapas sin una estratificación previa según la especie de pino o el uso añadido de modelos de clasificación utilizando datos de teledetección, que podrían aumentar la incertidumbre de las estimaciones.

Por último, la Figura 4.6 muestra los gráficos de dispersión de los valores observados frente a los predichos, obtenidos con los modelos de mejor ajuste para estimar las variables relacionadas con el fuego de superficie y de copas y con el dosel arbóreo. Estos gráficos no muestran ninguna tendencia evidente que indique sesgos de subestimación o sobreestimación para ninguna de las variables dependientes analizadas. Además, no se observaron tendencias anómalas en los modelos ajustados únicamente con métricas derivadas de ALS o TLS (gráficas no incluídos).

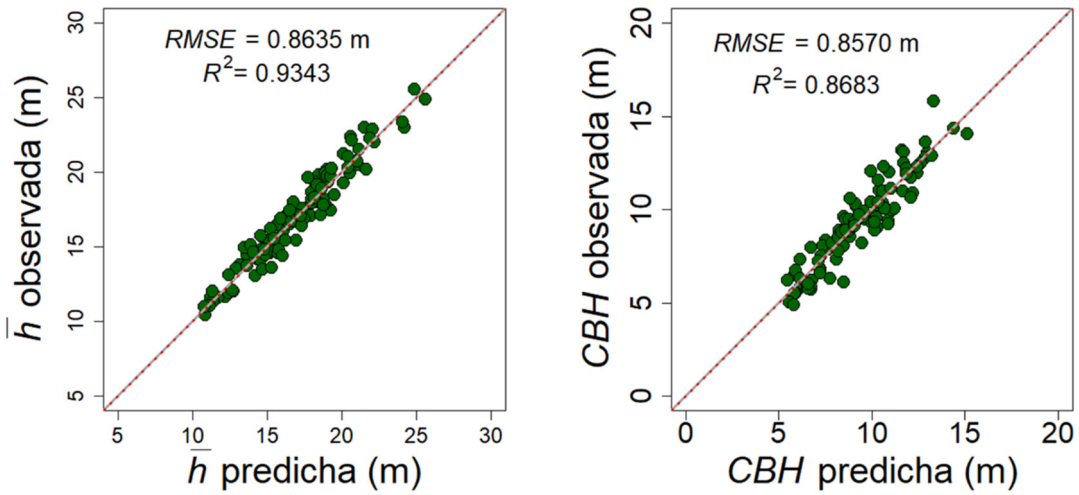

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

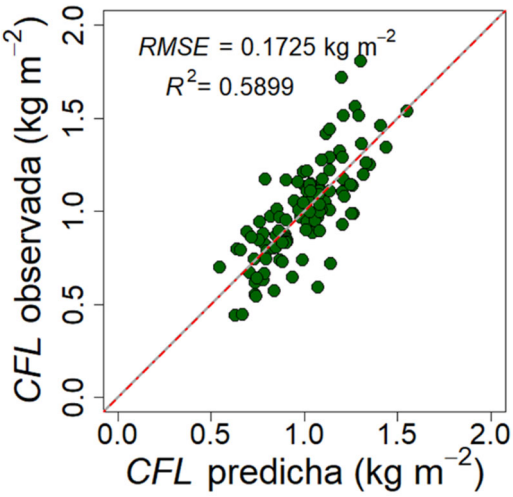
RMSE = 0.1725 kg m^{-2}
R^2= 0.5899
CFL observada (kg m^{-2})
CFL predicha (kg m^{-2})
0.0
0.5
1.0
1.5
2.0

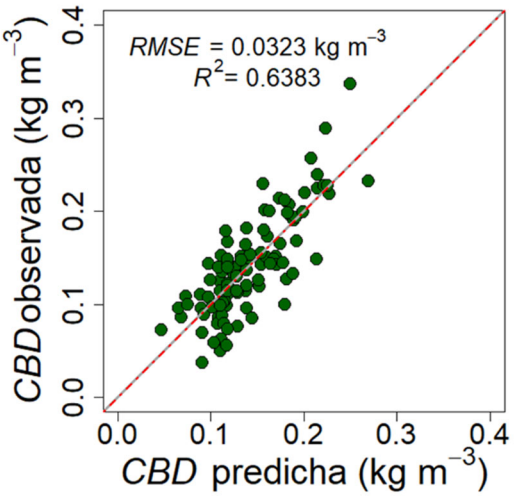
RMSE = 0.0323 kg m^{-3}
R^2= 0.6383
CBD observada (kg m^{-3})
CBD predicha (kg m^{-3})
0.0
0.1
0.2
0.3
0.4

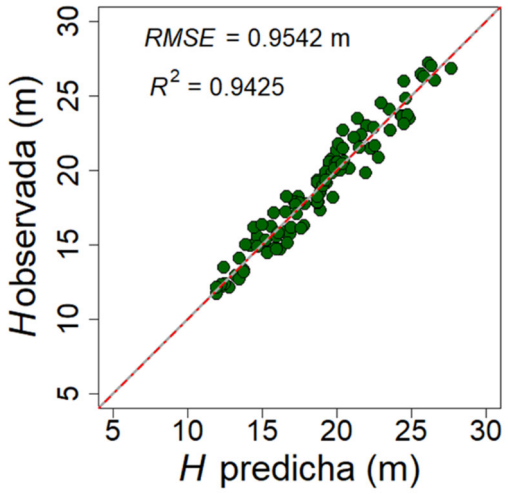
RMSE = 0.9542 m
R^2 = 0.9425
H observada (m)
H predicha (m)
5
10
15
20
25
30

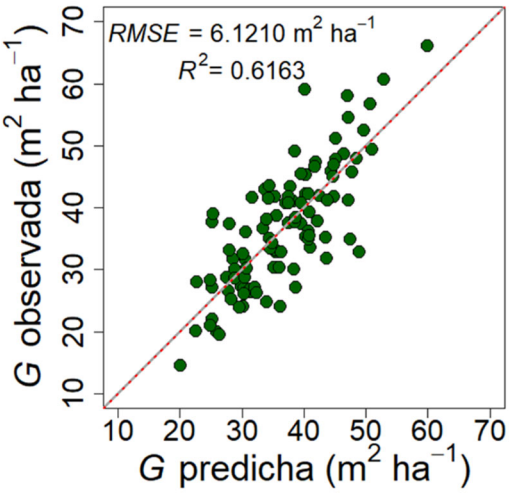
RMSE = 6.1210 m^2 ha^{-1}
R^2= 0.6163
G observada (m^2 ha^{-1})
G predicha (m^2 ha^{-1})
10
20
30
40
50
60
70

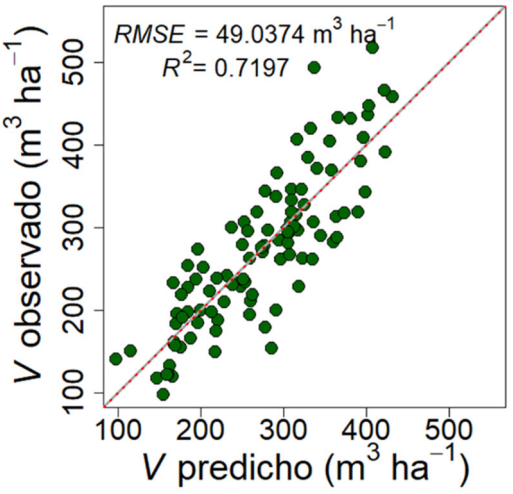
RMSE = 49.0374 m^3 ha^{-1}
R^2= 0.7197
V observado (m^3 ha^{-1})
V predicho (m^3 ha^{-1})
100
200
300
400
500

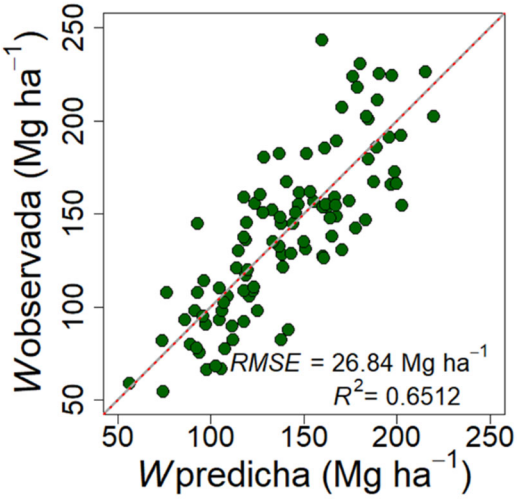
RMSE = 26.84 Mg ha^{-1}
R^2= 0.6512
W observada (Mg ha^{-1})
W predicha (Mg ha^{-1})
50
100
150
200
250

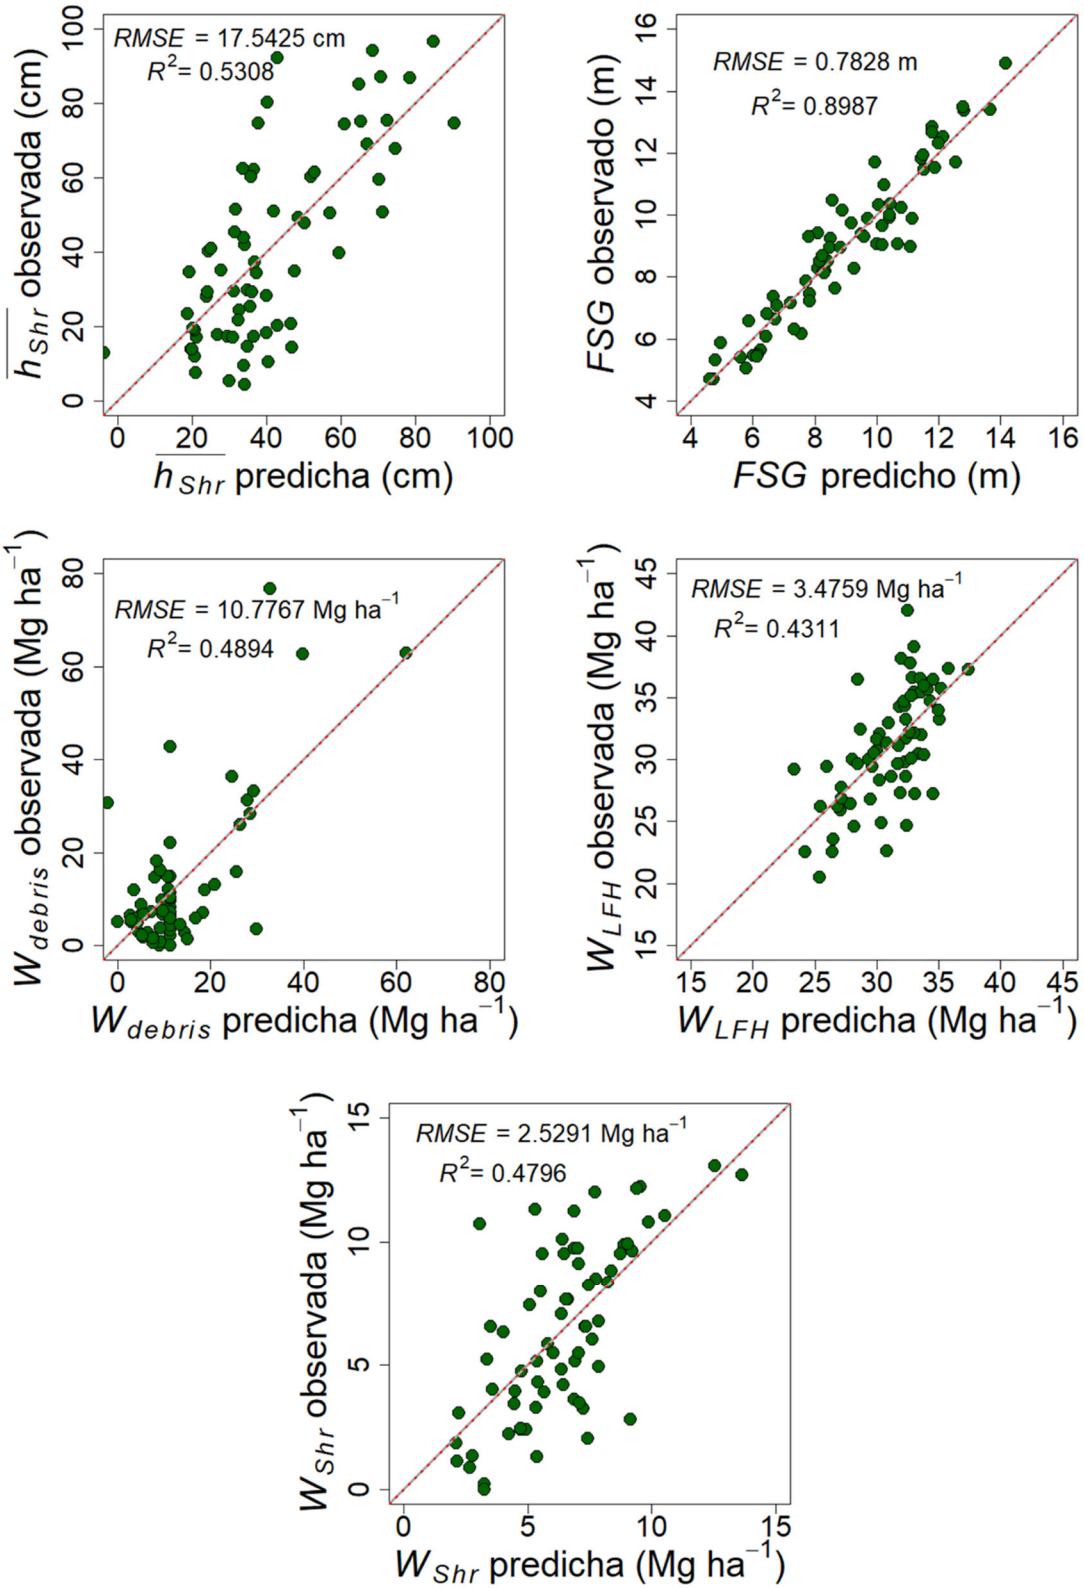

Figura 4. 6. Gráficos de los valores observados frente a los predichos con los modelos mejor ajustados para estimar las variables relacionadas con el fuego en la superficie y en el dosel y en el rodal. La línea roja representa la relación lineal entre los dos tipos de valores.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

4.3. Artículo 3

Artículo 3: Modelos de estimación de biomasa de combustibles de continuidad por fracciones en plantaciones de *Pinus radiata* sin podar a nivel de árbol individual y de rodal (*Forest,* 2022, *13*(10), 1697).

4.3.1 Ecuaciones de estimación de biomasa total por fracciones para los primeros 6 m del tronco a nivel de árbol individual y su distribución vertical

Una vez seleccionado el mejor conjunto de variables independientes para cada una de las cinco ecuaciones de estimación de la biomasa del combustible (ecuaciones 3.23 a 3.27) para el total de los primeros 6 m del tronco, se ajustó simultáneamente el sistema completo de ocho ecuaciones. Los términos autorregresivos no se incluyeron inicialmente; sin embargo, los resultados de la prueba de Durbin-Watson indicaron la presencia de autocorrelación en varias de las ecuaciones del perfil vertical, por lo que se repitió el ajuste. Tras incluir el término AR1, no se detectó autocorrelación.

Como se ha mencionado en el apartado de Material y Métodos, las estimaciones de W_{acum_G123j} y W_{acum_totalj} se obtuvieron como la suma de las estimaciones de las fracciones ajustadas de $W_{acum_G23j} + W_{acum_G1j}$ y $W_{acum_G123j} + W_{acum_needlesj}$, respectivamente, y a continuación se calcularon el R^2 y el *RMSE* para estas dos fracciones de árboles individual.

En la Tabla 4.11 se muestra el sistema de ecuaciones ajustado, los valores de los parámetros, sus errores estándar y los estadísticos de bondad de ajuste. Todos los parámetros incluidos fueron significativos ($\alpha = 0.05$), los valores del número de condición asociados a cada variable independiente y los resultados de la prueba de White no indicaron la presencia de multicolinealidad o heteroscedasticidad, respectivamente.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Tabla 4. 11. Sistema de 8 ecuaciones ajustado para estimar la biomasa de combustible muerto y su distribución vertical por fracciones para árbol individual. Derechos de autor 2022, *Forest*.

Ecuaciones de biomasa total de combustible en los primeros 6 m	Ecuaciones de distribución vertical de biomasa de combustible a lo largo de los primeros 6 m
$W_{total} = a_0 \cdot d^{a_1} \cdot {h_{bdc}}^{a_2}$ $a_0 = 0.0222\ (0.0084\ );\ a_0 = 1.9745\ (0.1046);\ \ a_0 = -0.6329\ (0.0711)$ $R^2 = 0.5676 \qquad RMSE = 7.92$ kg	$W_{acum_totalj} = W_{acum_G123j} + W_{acum_needlesj}$ $R^2 = 0.7763 \qquad RMSE = 5.02$ kg
$W_{G123} = \dfrac{W_{total}}{1 + exp\left(b_0 + b_1 \cdot h + b_2 \cdot \overline{h_{bdc}} + b_3 \cdot \overline{h_{blc}}\right)}$ $b_0 = -1.8248\ (0.2049); b_1 = -0.0792\ (0.0098); b_2 = 2.6755\ (0.2391); b_3 = 0.0733\ (0.0132)$ $R^2 = 0.5953 \qquad RMSE = 6.68$ kg	$W_{acum_G123j} = W_{acum_G23j} + W_{acum_G1j}$ $R^2 = 0.7901 \qquad RMSE = 4.13$ kg
$W_{needles} = \dfrac{W_{total} \cdot exp\left(b_0 + b_1 \cdot h + b_2 \cdot \overline{h_{bdc}} + b_3 \cdot \overline{h_{blc}}\right)}{1 + exp\left(b_0 + b_1 \cdot h + b_2 \cdot \overline{h_{bdc}} + b_3 \cdot \overline{h_{blc}}\right)}$ $b_0 = -1.8248\ (0.2049); b_1 = -0.0792\ (0.0098); b_2 = 2.6755\ (0.2391); b_3 = 0.0733\ (0.0132)$ $R^2 = 0.3530 \qquad RMSE = 1.89$ kg	$W_{acum_needlesj} = W_{needles}\left[1 - exp\left(-\left(\dfrac{x_i}{p_{1_needles}}\right)^{p_{2_needles}}\right)\right]$ $p_{1_needles} = 0.3884\ (0.0507);\ \ p_{2_needles} = 1.44\ (0.10)$ $R^2 = 0.6220 \qquad RMSE = 1.35$ kg
$W_{G23} = \dfrac{W_{G123}}{1 + exp\left(c_0 + c_1 \cdot d + c_2 \cdot RS + c_3 \cdot h_{bdc} + c_4 \cdot \frac{l_{dc}}{h}\right)}$ $c_0 = -1.8878\ (0.18); c_1 = -0.0413(0.004); c_2 = 5.536\ (0.54); c_3 = 0.9344\ (0.16);\ c_4 = -0.7637(0.18)$ $R^2 = 0.5927 \qquad RMSE = 6.15$ kg	$W_{acum_G23j} = W_{G23}\left[1 - exp\left(-\left(\dfrac{x_i}{p_{1_G23}}\right)^{p_{2_G23}}\right)\right]$ $p_{1_G23} = 0.5612\ (0.0305);\ \ p_{2_G23} = 1.87\ (0.15)$ $R^2 = 0.7805 \qquad RMSE = 3.81$ kg
$W_{G1} = \dfrac{W_{G123} \cdot exp\left(c_0 + c_1 \cdot d + c_2 \cdot RS + c_3 \cdot h_{bdc} + c_4 \cdot \frac{l_{dc}}{h}\right)}{1 + exp\left(c_0 + c_1 \cdot d + c_2 \cdot RS + c_3 \cdot h_{bdc} + c_4 \cdot \frac{l_{dc}}{h}\right)}$ $c_0 = -1.8878\ (0.18); c_1 = -0.0413(0.004); c_2 = 5.536\ (0.54); c_3 = 0.9344\ (0.16);\ c_4 = -0.7637(0.18)$ $R^2 = 0.5826 \qquad RMSE = 0.73$ kg	$W_{acum_G1j} = W_{G1}\left[1 - exp\left(-\left(\dfrac{x_i}{p_{1_G1}}\right)^{p_{2_G1}}\right)\right]$ $p_{1_G1} = 0.5365\ (0.0234);\ \ p_{2_G1} = 1.71\ (0.25)$ $R^2 = 0.8128 \qquad RMSE = 0.46$ kg

W = biomasa de combustible muerto (kg); d = diámetro del árbol (cm); h = altura del árbol (m); h_{blc} = altura hasta la base de la copa viva (m); h_{bdc} = altura hasta la base de la copa muerta (m); $\overline{h_{bdc}}$= h_{bdc} media del rodal; $\overline{h_{blc}}$ = h_{blc} media del rodal; RS = índice de espaciamiento relativo; l_{dc} = longitud de la copa muerta (h_{blc} -h_{bdc}); W_{acum_j}= biomasa de combustible muerto acumulado hasta la altura h_j sobre el tronco (kg) con max(h_j) = 6 y xi = (h_j - h_{bdc})/(min(6; h_{blc}) - h_{bdc}). Los errores estándar de las estimaciones de los parámetros figuran entre paréntesis.

Los modelos de biomasa de combustible explicaron entre el 35% y el 59% de la variabilidad observada en las ecuaciones de biomasa de acículas ($W_{needles}$) y biomasa de combustible leñoso total y grueso (W_{G_123} y W_{G_23}), respectivamente, con valores de *RMSE* que oscilaron entre 0.73 kg para los combustibles leñosos finos (W_{G1}) y 7.92 kg para el combustible total (W_{total}). Por otro lado, los modelos de biomasa de combustible acumulada hasta una determinada altura del tronco (h_j) explicaron entre el 62% ($W_{acum_needlesj}$) y el 81% (W_{acum_G1j}) de la variabilidad total observada, con valores de *RMSE* que oscilaron entre 0.46 kg para la ecuación de biomasa de combustible leñoso fino (W_{acum_G1j}) y 5.02 kg para la ecuación de biomasa de combustible total (W_{acum_totalj}).

A modo de ejemplo, la Figura 4.7 muestra los valores de biomasa observados frente a los predichos para las acículas ($W_{acum_needlesj}$), los leñosos finos (W_{acum_G1j}) y total (W_{acum_totalj}), así como la distribución vertical de los residuos de estas estimaciones para las mismas fracciones y secciones.

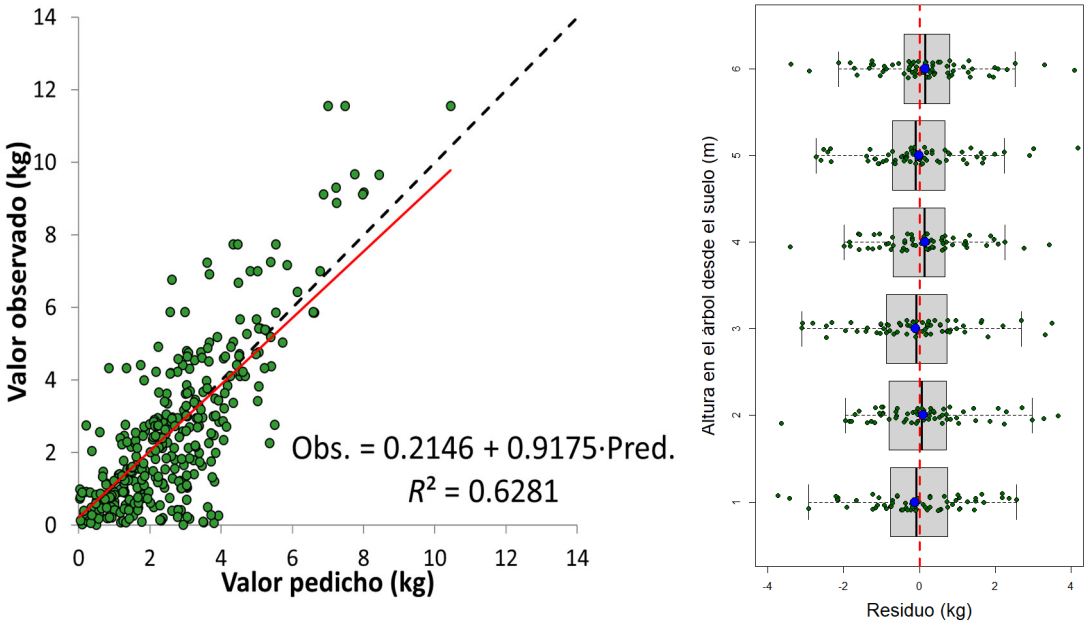

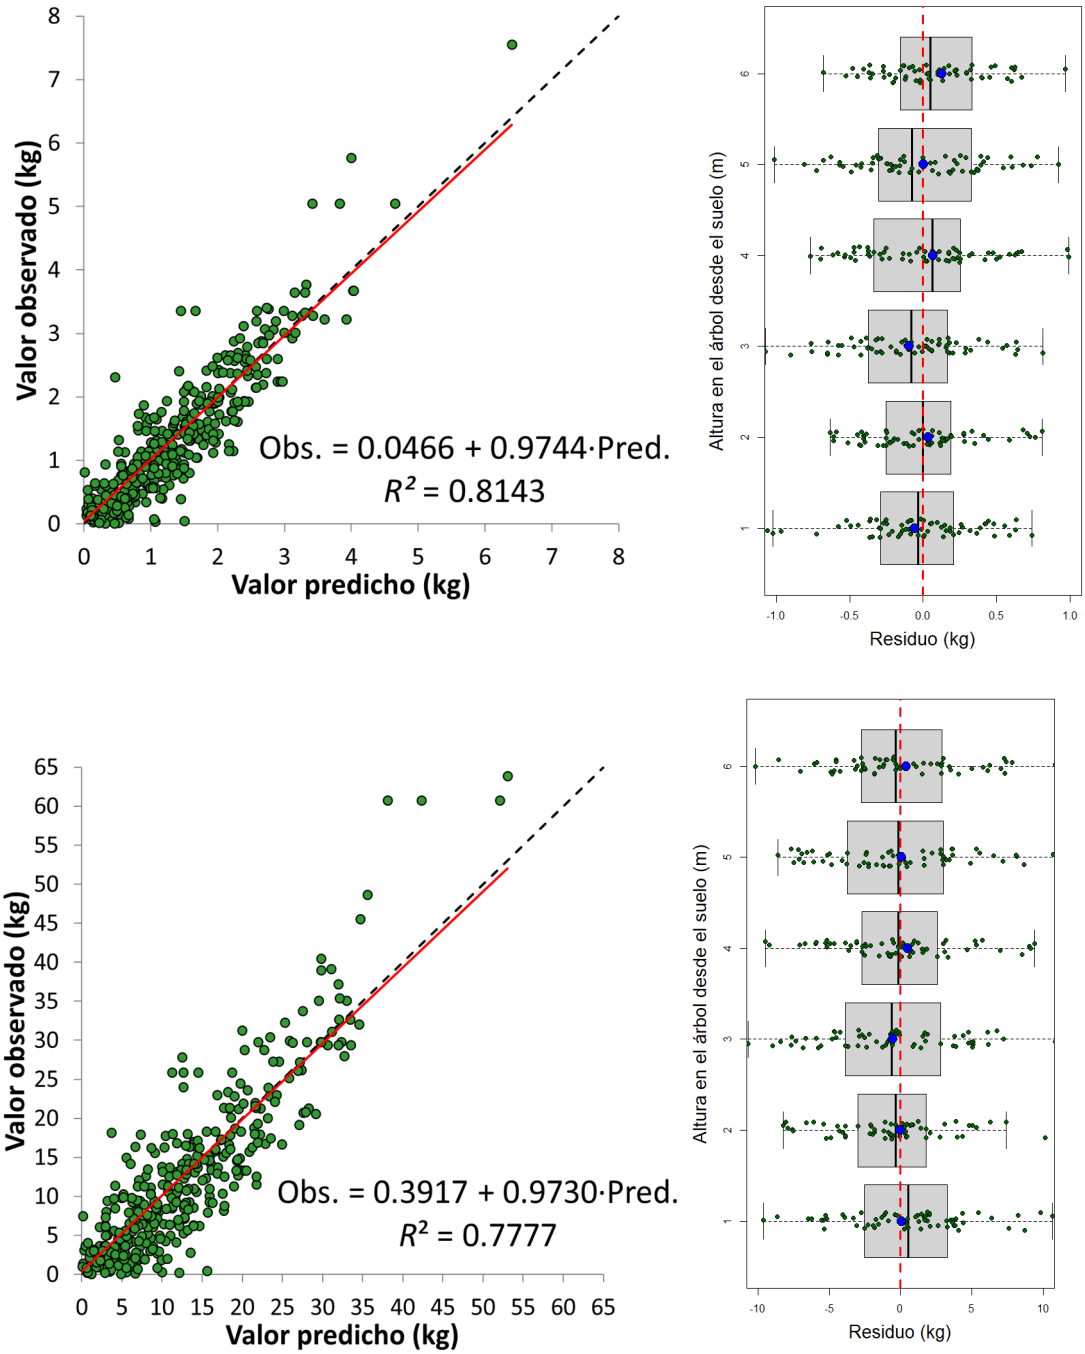

Figura 4. 7. (Izquierda) Gráficos de dispersión de los valores observados frente a los predichos para la distribución vertical de la biomasa de acículas ($W_{acum_needlesj}$, arriba), leñosos finos (W_{acum_G1j}, centro) y total (W_{acum_totalj}, abajo) de árbol individual. La línea roja sólida indica el modelo lineal ajustado y la línea discontinua indica el ajuste perfecto. (Derecha) Gráficos de caja de la distribución vertical de los residuos de biomasa de acículas ($W_{acum_needlesj}$, superior), leñosos finos (W_{acum_G1j}, medio), y total (W_{acum_totalj}, inferior) según la altura desde el suelo. Los puntos azules indican los valores medios.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

4.3.2. Ecuaciones de estimación de carga de combustible total por fracciones para los primeros 6 m del tronco a nivel de rodal y su distribución vertical

Una vez ajustadas las ecuaciones de árbol individual, se aplicaron a todos los árboles de cada parcela y se obtuvieron los valores de biomasa muerta por hectárea de las diferentes fracciones para los primeros 6 m de altura desde el suelo, agregando los valores de cada árbol (Tabla 4.12).

Tabla 4. 12. Estadísticos de las principales variables en los primeros 6 m de la copa muerta y del conjunto del dosel (vivo y muerto). Derechos de autor 2022, *Forest*.

Variables para los primeros 6 m del dosel muerto (n = 20)				
Variable	**Media**	**Máximo**	**Mínimo**	**D.s.**
$Wstand_{total}$ (Mg ha^{-1})	19.58	34.77	9.86	6.78
$Wstand_{needles}$ (Mg ha^{-1})	2.97	5.06	1.68	0.93
$Wstand_{G1}$ (Mg ha^{-1})	1.94	2.62	1.15	0.35
$Wstand_{G23}$ (Mg ha^{-1})	14.67	27.51	5.31	0.61
$\overline{h_{bdc}}$ (m)	0.41	0.83	0.24	0.14
CFL_{dead} (kg m^{-2})	0.49	0.73	0.34	0.10
$\%CFL_{dead}$	29.49	36.03	22.35	3.23
Variable para todo el dosel (muerto+vivo) (n = 20)				
Variable	**Media**	**Máximo**	**Mínimo**	**D.s.**
CFL_{total} (kg m^{-2})	1.68	2.51	1.09	0.36

D.s. = desviación estándar; $Wstand_{total}$, $Wstand_{needles}$, $Wstand_{G1}$ y $Wstand_{G\ 23}$ = carga total, de acículas, leñosa fina (G1) y leñosa media y gruesa (G23) en los primeros 6 m del dosel muerto, respectivamente; $\overline{h_{bdc}}$ = altura media hasta la base de la copa muerta en el rodal; CFL_{dead} = carga de combustible muerto disponible en los primeros 6 m del dosel (needles + G1); $\%CFL_{dead}$ = porcentaje de CFL_{dead} sobre *CFL* de todo el dosel (CFL_{total}, viva y muerta).

Al igual que en el sistema del árbol individual, una vez seleccionado el mejor conjunto de variables independientes, se ajustó simultáneamente el sistema de ocho ecuaciones (inicialmente sin incluir los términos autorregresivos). A la vista de los resultados de la prueba de Durbin-Watson, el sistema se volvió a ajustar incluyendo el término autorregresivo de orden 1 (AR1), tampoco se detectó multicolinealidad ni heteroscedasticidad en ninguna de las ocho ecuaciones ajustadas y todos los parámetros incluidos en los modelos fueron significativos ($\alpha = 0.05$). Los modelos finalmente obtenidos, así como los estadísticos de bondad de ajuste, se muestran en la Tabla 4.13.

Los valores de las variables de rodal y de las variables estructurales del dosel vivo (*CBH*, *CFL* y *CBD*) observados en este estudio están dentro del rango de valores obtenidos para *Pinus radiata* en otros estudios realizados en la misma área geográfica y bajo condiciones climáticas, fisiográficas y edáficas similares; por ejemplo, (Ruíz-González y Álvarez-González, 2011; Gómez-Vázquez et al., 2012; Fernández-Alonso et al., 2013; Arellano-Pérez et al., 2018). Además, los valores medios observados de densidad del arbolado (*N*), área basimétrica del rodal (*G*), altura media ($\bar{h}$) y *CFL* para la misma especie fueron consistentes con los mostrados por Gómez-Vázquez et al. (2012) y el valor medio de *CBD* (0.11 kg m^{-3}) fue el mismo que el

observado por Arellano-Pérez et al. (2018) superando ligeramente el umbral deducido empíricamente por Agee (1996) de 0.1 kg m^{-3} como el valor aproximado necesario para mantener un fuego de copas activo.

El valor medio de *CBH* en las parcelas analizadas en este estudio fue de 8.6 m (D.s. = 2.8 m) con un máximo de 14.1 m, mientras que la altura media de aparición del combustible muerto fue de 0.4 m (D.s. = 0.1 m) con un máximo de 0.8 m. Por lo tanto, se debería utilizar la altura de la base del dosel muerto en lugar de la altura viva para evaluar el potencial para la iniciación de fuegos de copa en masas de pino radiata de alta cobertura en las que no se ha efectuado gestión. En consecuencia, para estimar este fenómeno sería más conveniente utilizar un sistema de comportamiento del fuego basado en la *FSG* y no en la *CBH*, como, por ejemplo, el sistema PPPY (Cruz et al., 2008) o AMICUS (Plucinski et al., 2017). En el caso de los usuarios de los sistemas de simulación del *USDA Forest Service* que se basan en la ecuación de iniciación de fuego de copas de Van Wagner (1977) y que por tanto utilizan como entrada *CBH*, deberían incorporar los combustibles muertos de continuidad como parte del complejo de superficie, tal y como sugieren Scott y Reinhardt (2001) y Hall y Burke (2006). Sin embargo, esta solución sólo es parcialmente satisfactoria porque implica la creación de modelos de combustible propios o un ajuste de la intensidad lineal del fuego de superficie. En cuanto a *CFL*, el valor medio observado al incluir sólo el dosel vivo fino fue de 1.19 kg m^{-2} (D.s. = 0.28 kg m^{-2}) con un máximo de 1.78 kg m^{-2}; estos valores aumentan a 1.68 kg m^{-2} (D.s. = 0.36 kg m^{-2}) y 2.51 kg m^{-2}, respectivamente, cuando se añade la carga aportada por las acículas y las ramitas finas de las ramas muertas que se extienden desde la superficie hacia la copa viva. Por lo tanto, la importante contribución del combustible de las ramas muertas a la carga total de combustible disponible (valores medio y máximo de 29.5% (D.s. = 3.2) y 36%, respectivamente, en este estudio) debe destacarse porque implica un aumento de proporciones similares en el calor liberado por unidad de superficie en un supuesto incendio que consumiera todos los combustibles finos de la copa. Por ejemplo, según Byram (1959) y considerando un poder calorífico inferior de 18 000 kJ kg^{-1} (Cruz et al., 2008; Cruz et al., 2017), la energía liberada por las copas pasaría de 21 420 kJ m^{-2} a 30 240 kJ m^{-2}, lo que representa un aumento del 41.1% en la intensidad lineal del fuego. Los resultados del estudio confirman que estas plantaciones de pino no presentan una distribución homogénea de combustible fino vivo y muerto en el dosel, al igual que ocurre en trabajos australianos (Cruz et al., 2017). En su lugar, se muestran dos capas de combustible claramente diferenciadas: una capa inferior que comprende sobre todo combustibles muertos caracterizados por una alta inflamabilidad cuando están suficientemente secos y una capa superior formada predominantemente por combustibles vivos con una mayor densidad aparente.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Tabla 4. 13. Sistema de ecuaciones de estimación de cargas de combustible muerto y su distribución vertical por fracción a nivel rodal. Derechos de autor 2022, *Forest*.

Ecuaciones de carga total de combustible en los primeros 6 m	Ecuaciones de distribución vertical de carga a lo largo de los primeros 6 m
$Wstand_{_total} = a_0 \cdot G^{a_1} \cdot \overline{h_{bdc}}^{a_2}$ $a_0 = 0.2303\ (0.0119);\ a_1 = 1.1311\ (0.0142);\ a_2 = -0.2993\ (0.0148)$ $R^2 = 0.9780 \qquad RMSE = 1.01\ \text{Mg ha}^{-1}$	$Wstand_{acum_totalj} = Wstand_{acum_needlesj} + Wstand_{acum_G123j}$ $R^2 = 0.9909 \qquad RMSE = 0.75\ \text{Mg ha}^{-1}$
$Wstand_{_G123} = \dfrac{Wstand_{_total}}{1 + exp\left(b_0 + b_1 \cdot \overline{h_{bdc}} + b_2 \cdot \left(\overline{h} - \overline{h_{blc}}\right)\right)}$ $b_0 = -1.8633\ (0.0156);\ b_1 = 2.3581\ (0.0259);\ b_2 = -0.0740\ (0.0011)$ $R^2 = 0.9794 \qquad RMSE = 0.90\ \text{Mg ha}^{-1}$	$Wstand_{acum_G123j} = Wstand_{acum_G1j} + Wstand_{acum_G23j}$ $R^2 = 0.9911 \qquad RMSE = 0.67\ \text{Mg ha}^{-1}$
$Wstand_{_needles} = \dfrac{Wstand_{_total} \cdot exp\left(b_0 + b_1 \cdot \overline{h_{bdc}} + b_2 \cdot \left(\overline{h} - \overline{h_{blc}}\right)\right)}{1 + exp\left(b_0 + b_1 \cdot \overline{h_{bdc}} + b_2 \cdot \left(\overline{h} - \overline{h_{blc}}\right)\right)}$ $b_0 = -1.8633\ (0.0156);\ b_1 = 2.3581\ (0.0259);\ b_2 = -0.0740\ (0.0011)$ $R^2 = 0.9771 \qquad RMSE = 0.14\ \text{Mg ha}^{-1}$	$Wstand_{acum_needlesj} = Wstand_{_needles}\left[1 - exp\left(-\left(\dfrac{x_i}{p_{1_needles}}\right)^{p_{2_needles}}\right)\right]$ $p_{1_needles} = 0.4005\ (0.0021);\ p_{2_needles} = 1.58\ (0.02)$ $R^2 = 0.9912 \qquad RMSE = 0.11\ \text{Mg ha}^{-1}$
$Wstand_{_G23} = \dfrac{Wstand_{_G123}}{1 + exp\left(c_0 + c_1 \cdot G + c_2 \cdot \overline{h}\right)}$ $c_0 = -0.4127\ (0.0201);\ c_1 = -0.0226\ (0.0005);\ c_2 = -0.0342\ (0.0015)$ $R^2 = 0.9819 \qquad RMSE = 0.82\ \text{Mg ha}^{-1}$	$Wstand_{acum_G23j} = Wstand_{_G23}\left[1 - exp\left(-\left(\dfrac{x_i}{p_{1_G23}}\right)^{p_{2_G23}}\right)\right]$ $p_{1_G23} = 0.5564\ (0.0033);\ p_{2_G23} = 2.06\ (0.03)$ $R^2 = 0.9911 \qquad RMSE = 0.61\ \text{Mg ha}^{-1}$
$Wstand_{_G1} = \dfrac{Wstand_{_G123} \cdot exp\left(c_0 + c_1 \cdot G + c_2 \cdot \overline{h}\right)}{1 + exp\left(c_0 + c_1 \cdot G + c_2 \cdot \overline{h}\right)}$ $c_0 = -0.4127\ (0.0201);\ c_1 = -0.0226\ (0.0005);\ c_2 = -0.0342\ (0.0015)$ $R^2 = 0.8829 \qquad RMSE = 0.12\ \text{Mg ha}^{-1}$	$Wstand_{acum_G1j} = Wstand_{_G1}\left[1 - exp\left(-\left(\dfrac{x_i}{p_{1_G1}}\right)^{p_{2_G1}}\right)\right]$ $p_{1_G1} = 0.5280\ (0.0036);\ p_{2_G1} = 1.90\ (0.03)$ $R^2 = 0.9837 \qquad RMSE = 0.09\ \text{Mg ha}^{-1}$

Wstand = carga total de copa seca del rodal (Mg ha^{-1}); h_{blc} = altura hasta la base de la copa viva (m); h_{bdc} = altura hasta la base de la copa muerta (m); $\overline{h_{bdc}}$ = h_{bdc} media del rodal; $\overline{h_{blc}}$ = h_{blc} media del rodal; $\overline{h}$ = altura media del rodal; G = área basimétrica del rodal; $Wstand_{_acum_j}$ = carga de combustible muerto acumulada hasta la altura h_j sobre el tronco (Mg ha^{-1}) con max (h_j) = 6 y x_i = (h_j - $\overline{h}_{bdc}$) / (min (6, $\overline{h}_{blc}$- $\overline{h}_{bdc}$). Los errores estándar de las estimaciones de los parámetros figuran entre paréntesis.

Una vez ajustadas las ocho ecuaciones, los valores de $Wstand_{acum_G123j}$ y $Wstand_{acum_totalj}$ de cada rodal se estimaron como la suma de las estimaciones de $Wstand_{acum_G23j} + Wstand_{acum_G1j}$ y $Wstand_{acum_G123j} + Wstand_{acum_needlesj}$, respectivamente. A continuación, se calcularon los valores de R^2 y *RMSE* para estas dos fracciones.

Los modelos de carga de combustible explicaron entre el 88% y el 98% de la variabilidad observada en las ecuaciones para los combustibles leñosos finos ($Wstand_G1$) y para las otras fracciones ($Wstand_total$, $Wstand_G123$, $Wstand_needles$ y $Wstand_G23$), respectivamente. Los valores de *RMSE* oscilaron entre 0.12 Mg ha^{-1} para los combustibles leñosos finos ($Wstand_G1$) y 1.01 Mg ha^{-1} para el total ($Wstand_total$). Los modelos de carga de combustible acumulada explicaron más del 98% de la variabilidad total observada, con valores de *RMSE* que oscilaron entre 0.09 Mg ha^{-1} y 0.75 Mg ha^{-1} para la ecuación de combustible leñoso fino ($Wstand_{acum_G1j}$) y para la ecuación de combustible total ($Wstand_{acum_totalj}$), respectivamente.

A modo de ejemplo, la Figura 4.8 muestra los valores de carga observados frente a predichos para las acículas ($Wstand_{acum_needlesj}$), los finos leñosos ($Wstand_{acum_G1j}$) y total de combustible ($Wstand_{acum_totalj}$), así como la distribución vertical de los residuos de estas estimaciones para las mismas fracciones y secciones.

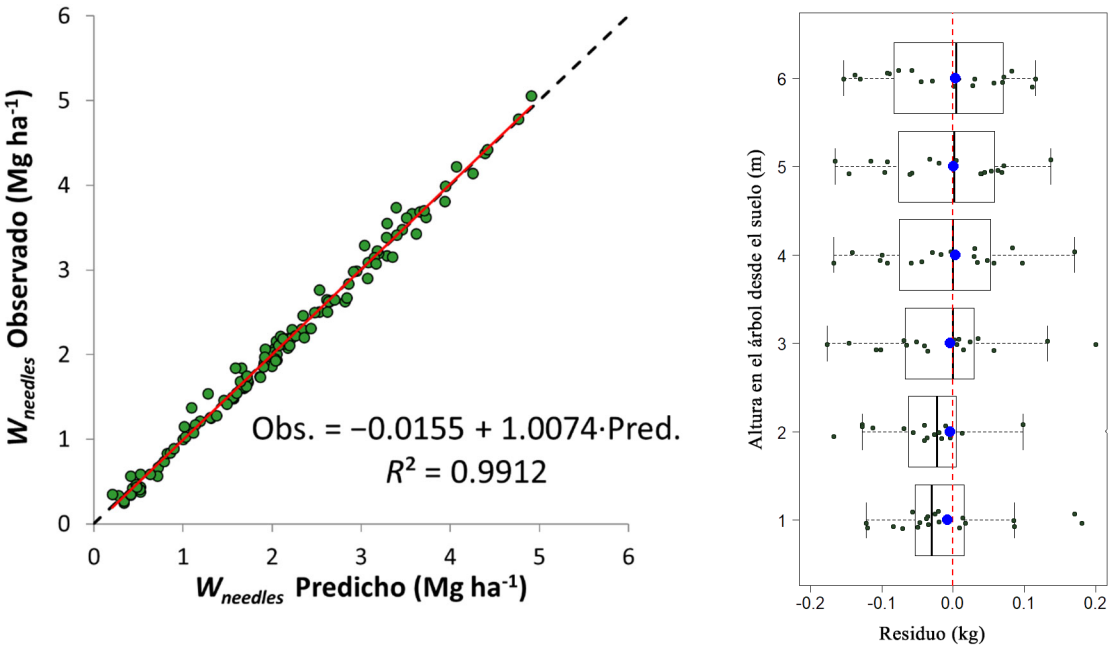

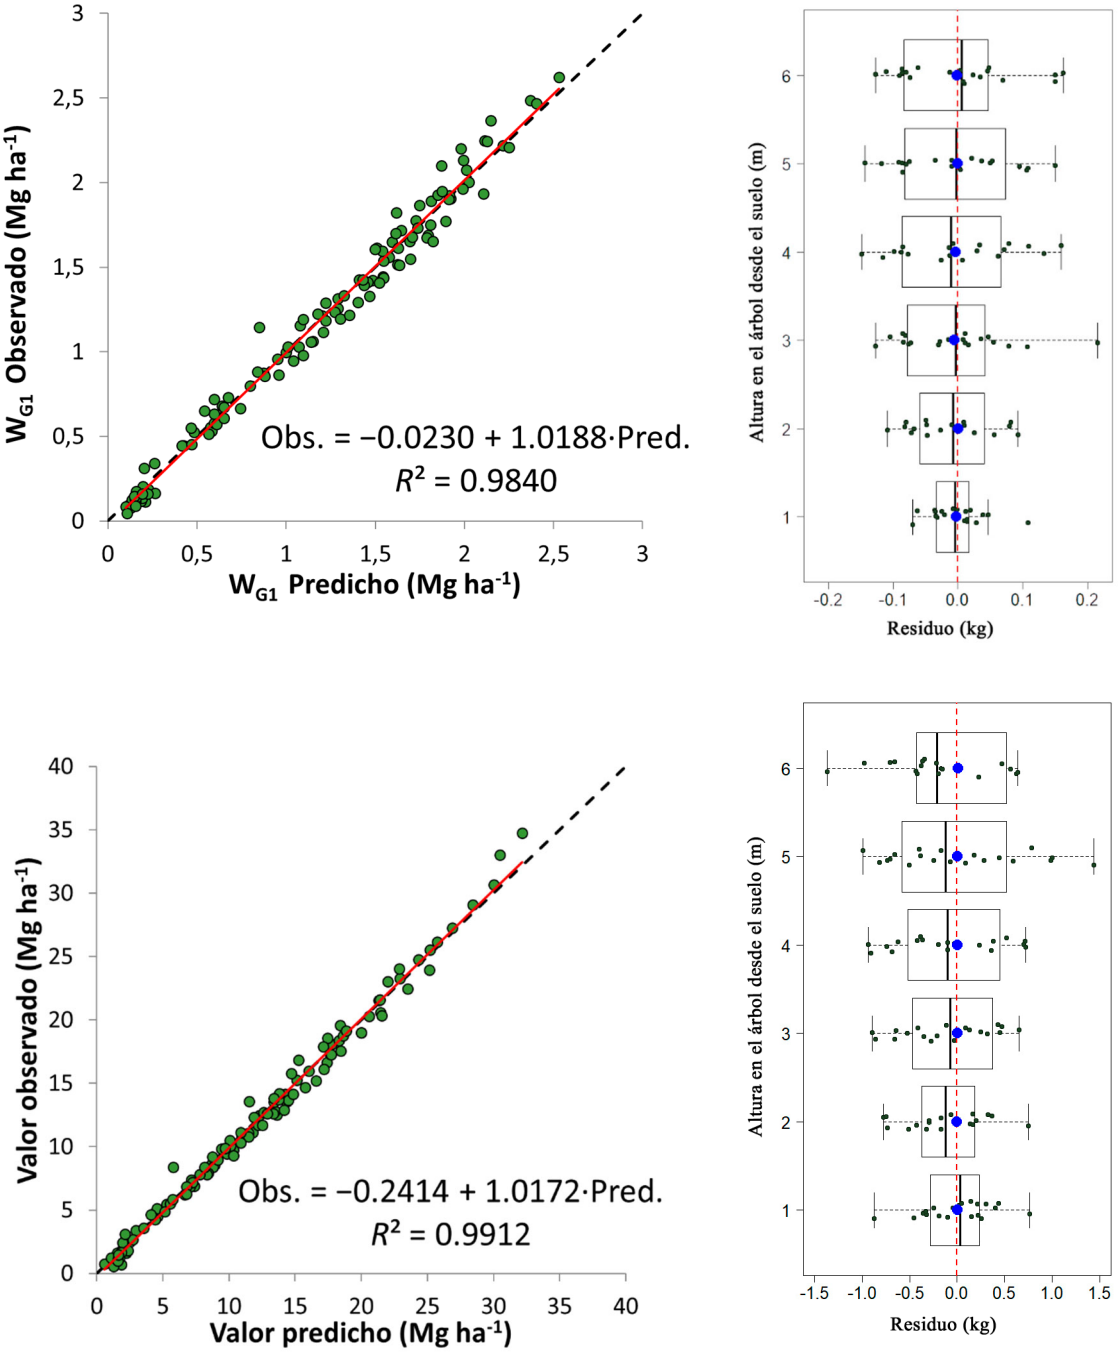

Figura 4. 8. (Izquierda) Gráficos de dispersión de valores observados frente a predichos para la distribución vertical de la carga de combustible de acículas (*Wstand*$_{acum_needlesj}$, arriba), leñosos finos (*Wstand*$_{acum_G1j}$, centro) y total (*Wstand*$_{acum_totalj}$, abajo) del rodal. La línea roja sólida indica el modelo lineal ajustado y la línea discontinua indica el ajuste perfecto. (Derecha) Diagramas de caja de la distribución vertical de los residuos de la carga de acículas (*Wstand*$_{acum_needlesj}$, superior), leñosos finos (*Wstand*$_{acum_G1j}$, medio) y total del rodal (*Wstand*$_{acum_totalj}$, inferior) según la altura desde el suelo. Los puntos azules indican los valores medios.

Los estadísticos de bondad de ajuste de los dos sistemas de ecuaciones desarrollados indicaron estimaciones robustas y precisas, por lo que estos sistemas contribuyen a llenar el

vacío sobre cómo cuantificar la biomasa de los combustibles muertos de escalera y así mejorar las estimaciones sobre el calor que un potencial incendio generaría por unidad de superficie y su intensidad lineal. Aunque ambos sistemas de ecuaciones pueden utilizarse con el mismo propósito de estimar la carga de combustibles muertos de escalera según las clases de tamaño y su distribución vertical en el rodal, deben considerarse sus ventajas y limitaciones. El uso de los sistemas de ecuaciones a nivel de árbol individual (Tabla 4.11) requiere un mayor número de variables independientes y el cálculo es más complicado que el uso directo del sistema a nivel de rodal (Tabla 4.13). El proceso consiste en calcular la biomasa de cada árbol, agregar la biomasa de todos los árboles de la parcela y expresar el resultado en relación con la unidad de superficie (ha). Sin embargo, a pesar de que los estadísticos de bondad de ajuste aparentemente son peores, el sistema a nivel de árbol es más preciso porque se basa en datos reales de biomasa de combustible muerto obtenidos a partir de árboles muestreados destructivamente, mientras que el sistema a nivel de rodal (Tabla 4.13) se basa en los valores de biomasa estimada por el sistema de árbol individual (Tabla 4.11). Por otro lado, el sistema a nivel de rodal es más sencillo de aplicar porque sólo requiere medir una muestra de árboles para obtener valores medios representativos de las alturas totales, de inicio de copa muerta y de inicio de copa viva en vez de conocer las de todos los árboles de la parcela.

En cualquier caso, el uso de uno u otro enfoque dependerá básicamente de lograr un equilibrio entre la precisión de las estimaciones (mayor precisión con el enfoque de árbol individual) y el coste que se pueda asumir en el inventario de campo (menor coste con el enfoque de rodal).

USC
UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

5. Conclusiones/Conclusions

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

5. CONCLUSIONES

En el noroeste de España, el abandono de los terrenos agrícolas, entre otros factores, ha generado un gran aumento de la interfaz urbano-forestal, creando complejos mosaicos en los que predominan comunidades arbustivas de gran inflamabilidad que enlazan con el medio tradicionalmente forestal. La gestión eficiente de los ecosistemas forestales exige cada vez más una cartografía de combustibles precisa y detallada para comparar y priorizar diferentes estrategias de reducción de combustible, así como para servir de base en la planificación de la extinción y en restauración de los ecosistemas. Esta tarea requerirá unir y combinar bases de datos obtenidas, tanto de muestreo tradicional como del uso de sensores remotos, que faciliten la obtención de información a nivel espacial.

En este documento de tesis se han desarrollado diferentes sistemas de ecuaciones de estimación de carga de combustible forestal a nivel de masa o de árbol individual, englobando distintas situaciones: matorral desarbolado, sotobosque bajo pinar, combustibles de escalera y dosel de copas. Se incluyen modelos basados en técnicas remotas relativamente novedosas como la utilización de datos LiDAR aéreos (ALS) y/o terrestres (TLS), pero también modelos basados en inventarios tradicionales de campo. Si bien la orientación de la presente tesis es el uso de estos modelos en el campo de los incendios forestales, especialmente como apoyo en la gestión del combustible, también pueden tener otras utilidades como, por ejemplo, la estimación de las existencias de carbono o la caracterización de hábitats.

A continuación, se sintetizan las conclusiones, organizadas por los artículos que conforman la presente tesis:

Artículo 1: Estimación de cargas de combustible y características estructurales de comunidades de matorral desarbolado mediante escaneo con láser terrestre (*Remote Sensing*, 2020, 12 (22), 3704).

Comunicación 8CFE: Estimaciones de carga y estructura vertical de formaciones de matorral a partir de mediciones de obstrucción visual en campo.

1. Los estudios que evalúan la utilidad del TLS en la estimación de características de los combustibles de superficie son escasos, utilizan múltiples escaneos y se orientan hacia su uso en modelos físicos de comportamiento del fuego que requieren datos tridimensionales y espacialmente explícitos sobre el terreno. Además, la mayor parte de los estudios analizan únicamente la biomasa total aérea, distinguiendo en el mejor de los casos entre combustibles vivos y muertos. En nuestro estudio se ha comprobado que el uso de métricas derivadas de un único escaneo del TLS produce estimaciones suficientemente precisas de la carga de matorral desarbolado desagregada por estado biológico y clase de tamaño, así como de otras características estructurales, simplificando, además, el trabajo de campo y el procesado de la información en relación con las metodologías que utilizan escaneos múltiples.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

2. De las dos metodologías seguidas en la presente tesis, el enfoque de estimación directa de cargas a partir de las métricas TLS ha resultado más preciso que el de estimación indirecta a partir de la estimación previa de alturas y coberturas del matorral y del espesor de hojarasca y mantillo.

3. El uso de la banda graduada también ha resultado ser una metodología apropiada para la estimación de cargas de matorral en las mismas comunidades, aunque los estadísticos de bondad de los ajustes resultaron, en general, ligeramente inferiores que los obtenidos con las métricas derivadas del TLS, salvo para la ecuación de estimación de la carga de combustible de hojarasca y mantillo.

4. Hay que resaltar, sin embargo, algunas de las fortalezas y debilidades de estas dos metodologías. El uso de la banda graduada tiene la ventaja de ser accesible para cualquier gestor por ser económico, rápido y de fácil utilización. Su principal debilidad es, sin embargo, la subjetividad que se da en el proceso de medición, pues siempre está sujeto a las decisiones del operario que está llevando a cabo el inventario. Este inconveniente se puede subsanar realizando fotografías de la banda ocluida por la vegetación para posteriormente, en laboratorio utilizar un software de tratamiento de imágenes. En cuanto al uso del TLS una de las principales ventajas es que la toma de datos es automática y ofrece resultados con un gran nivel de detalle, incluyendo la distribución espacial y vertical del combustible. Sin embargo, esta metodología requiere mayor tiempo en la toma de datos, es más costosa y por lo tanto menos accesible para los gestores. Además, el procesado de la información continúa siendo uno de los principales inconvenientes, ya que, no existe una metodología estándar para procesar las nubes de puntos completamente automatizada y aún se requiere de conocimientos específicos de programación.

Artículo 2: Estimación de variables de rodal y de variables de superficie y del dosel de copas relacionadas con el fuego en pinares a partir de escáner laser aéreo de baja densidad y de un único escaneo con láser terrestre (*Remote Sensing*, 2021, *13,* (24), 5170).

5. Los resultados obtenidos indican que el uso de métricas derivadas tanto de ALS de baja densidad como de un único escaneo con TLS es prometedor para caracterizar las principales variables del combustible de superficie y de copas relacionadas con el riesgo de incendio. Sin embargo, cada plataforma tiene sus características, que como era de esperar, afectan a las estimaciones de los modelos. El ALS capta la estructura de la vegetación desde arriba, proporcionando un mayor nivel de detalle de la parte superior del dosel, disminuyendo su precisión conforme se va profundizando en el mismo, especialmente para especies con copas densas, como los pinares estudiados y nubes de puntos de baja densidad como las utilizadas. Por el contrario, el TLS captura la estructura de la vegetación desde abajo, proporcionando datos de alta resolución sobre las características de la parte inferior del dosel y de la vegetación de sotobosque. Sin embargo, es menos adecuado para estimar las características de la parte superior del dosel debido a la oclusión producida por el follaje de la parte intermedia.

6. La combinación de las ventajas de ambos sensores mediante la integración de ambos conjuntos de métricas como variables predictoras en los modelos mejora la precisión de

las estimaciones, indicando claramente el potencial del uso combinado de los sistemas ALS y TLS en los inventarios forestales.

7. En los modelos desarrollados se han integrado métricas derivadas de ALS y TLS obtenidas de forma independiente de cada nube de puntos; de esta manera se ha evitado el tener que realizar un complejo post-procesado de cada nube para combinarlas en una única. Sin embargo, a medida que el tratamiento de la información se estandarice, la combinación de ambas nubes de puntos, sobre todo si se trata de datos ALS con mayor densidad, permitirá realizar una caracterización más completa y detallada en 3D de la estructura del bosque.

8. En todo caso, hay que tener en cuenta que las conclusiones de los artículos 1 y 2 referentes al estrato de matorral se basan en estimaciones de carga y no en valores obtenidos de muestreos destructivos, por lo que son, en cierta medida, preliminares. Por esta razón, en el marco de un nuevo proyecto de investigación se está realizando un inventario destructivo para obtener una muestra más completa que cubra todas las combinaciones de desarrollo vegetativo y calidad de estación de las comunidades analizadas, con valores de cargas reales, no estimadas, que permita validar los resultados aquí obtenidos.

Artículo 3: Modelos de estimación de biomasa de combustibles de continuidad por fracciones en plantaciones de *Pinus radiata* sin podar a nivel de árbol individual y de rodal (*Forest,* 2022, *13*(10), 1697).

9. Los combustibles muertos de escalera en pinares de alta densidad, con mala poda natural y que no han sido podados, como los de *Pinus radiata* del estudio, pueden dificultar en gran medida los esfuerzos y la seguridad en la extinción; la presencia de ramas secas casi hasta el suelo limita la movilidad de los operarios y la visibilidad. Los sistemas de modelos ajustados tanto a nivel de árbol individual como de rodal han demostrado su aptitud para cuantificar este tipo de combustible. Por tanto, permitirán a los gestores forestales simular la forma en que podas realizadas a diferentes alturas pueden afectar al potencial para el desarrollo de fuego de copas bajo diferentes escenarios de tiempo atmosférico, humedad de los combustibles y alternativas de gestión de los residuos generados: extracción, trituración y no gestión.

10. Si se pretende evaluar la carga de combustible fino de las copas en rodales de *Pinus radiata*, habría que añadir la carga estimada con estos modelos de copa muerta a la estimada mediante el uso de modelos de carga de copa viva disponible existentes para la especie. De esta forma, se evitaría la subestimación de la carga disponible del dosel y la sobreestimación de la discontinuidad vertical entre estratos. Por tanto, se limitarían los errores al evaluar el potencial para el desarrollo de fuego de copas, incluyendo la iniciación, el tipo de fuego (activo o pasivo) y las características del comportamiento asociadas.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

CONCLUSIONS

In north-western Spain, agricultural land abandonment, among other factors, has generated a large increase in the urban-forest interface, creating complex mosaics in which highly flammable shrub communities are connected to traditional forest environments. Efficient management of forest ecosystems increasingly demands accurate, detailed fuel mapping to enable comparison and prioritization of different fuel reduction strategies, to serve as the basis for fire-fighting and ecosystem restoration plans. This task requires unifying and combining the data obtained by both traditional sampling and the use of remote sensors, which facilitate data collection at spatial scales.

In the research reported in this thesis we have developed different systems of equations for estimating forest fuel loads at stand and individual tree level and encompassing different scenarios: treeless shrubland, pine understorey vegetation, ladder fuels and forest canopy. The models used are based on relatively new remote sensing techniques, such as airborne laser scanning (ALS) Lidar and/or terrestrial laser scanning (TLS) Lidar, as well as on traditional field inventories. Although the present thesis focuses on the use of these models in relation to forest fires, especially as support tools for fuel management, the models may also have other uses, e.g. for carbon stock estimation and habitat characterization.

The conclusions reached are summarized below in relation to each of the published articles conforming the thesis:

Article 1: Estimating fuel loads and structural characteristics of shrub communities by using terrestrial laser scanning (*Remote Sensing*, 2020, *12* (22), 3704).

Communication 8CFE: Estimating loads and vertical structure of shrub formations from visual obstruction measurements in the field.

1. Studies evaluating the utility of TLS for estimating the characteristics of surface fuels are scarce, use multiple scans and are focused to be used on physical fire behaviour models that require three dimensional, spatially explicit data about the landscape. In addition, most studies only analyse the total aerial biomass, at best distinguishing between live and dead fuel. We have demonstrated that using metrics derived from single-scan TLS produces acceptably accurate estimates of shrublands fuel loads disaggregated by biological state and size class, as well as other structural characteristics. Use of this method also simplifies the fieldwork and data processing, relative to methods that use multiple scans.

2. Of the two TLS-based methodologies used in the research reported in this thesis, that focusing on the direct estimation of fuel loads from TLS-derived metrics proved more accurate than the indirect approach, which involves prior estimation of shrub height and cover and of the thickness of the litter and duff layer.

3. Use of the visual obstruction method, with a banded measurement stick, also proved suitable for estimating shrub fuel loads in the same communities, although the goodness

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

of fit statistics generally indicated slightly poorer fits than those obtained with the TLS-derived metrics, except for the equation used to estimate the litter and duff fuel load.

4. The strengths and weaknesses of both methods must be recognised. Use of the visual obstruction method has the advantage of being highly accessible as it is inexpensive, rapid and easy to apply. However, the weakness of this method lies in the subjectivity associated with the measurement process, as it depends on the decisions made by the operator conducting the inventory. This disadvantage can be overcome by taking photographs of the banded measurement stick that is occluded by vegetation and then applying image-processing software in the laboratory. Regarding the use of TLS, one of the main advantages is that the data capture is automatic and produces a high level of detail, including the spatial and vertical distribution of the fuel. However, data capture takes longer with this method, which is also more expensive and therefore less available to forest managers. In addition, the data processing stage remains one of the main disadvantages, as a standardised, fully automatic method of processing the point clouds is not yet available, and specific programming knowledge is required.

Article 2: Estimating stand and fire-related surface and canopy fuel variables in pine stands using low-density and single-scan terrestrial laser scanning data (*Remote Sensing*, 2021, *13,* (24), 5170).

5. The results obtained in this research indicate that the use of metrics derived from both low-density ALS and single-scan TLS appears promising for characterising the main surface and canopy variables related to fire risk. However, each platform has different features that affect the model estimates. ALS captures the vegetation structure from above, providing a greater level of detail of the upper part of the canopy. However, the accuracy of the estimates decreases in the lower layers of the canopy, especially in species with dense canopies, such as the pines under study and with the low density point clouds used. By contrast, TLS captures the vegetation structure from below, providing high resolution data on the characteristics of the lower part of the canopy and the understorey vegetation. However, this method is less suitable for estimating the characteristics of the upper part of the canopy due to the occlusion produced by the crowns in the intermediate part.

6. Combining the advantages of both sensors by including both sets of metrics and predictive variables in the models improves the accuracy of the estimates, clearly indicating the potential of the combined use of ASL and TLS systems in forest inventories.

7. The models developed include ALS and TLS-derived metrics obtained independently from each point cloud; this avoids having to carry out complex post-processing of each cloud to combine them in a single unit. However, as data processing becomes standardized, combining both point clouds, particularly of high density ALS data, will enable more complete, detailed characterization of the 3D structure of forests.

8. The conclusions reached in articles 1 and 2 regarding the shrub layer are based on fuel load estimates and not on values obtained by destructive sampling and should therefore

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

be considered preliminary. A destructive inventory is currently being carried out, in a new research project, to obtain a more complete sample that covers all combinations of plant development and site quality in the communities analyzed, with real values, rather than estimates. These values will be used to validate the results obtained in the present research.

Article 3: Individual-tree and stand-level models for estimating ladder fuel biomass fractions in unpruned *Pinus radiata* plantations (*Forest,* 2022, *13*(10), 1697).

9. Dead ladder fuel in high density pine stands with poor self-pruning capacity and that have not been artificially pruned, such as the *Pinus radiata* stands under study, may hamper fire-fighting efforts and the safety of such efforts. The presence of dry branches that almost reach the ground limits access and visibility of the site to firefighters. The individual tree and stand model systems developed proved capable of quantifying this type of fuel. They will therefore enable forest managers to simulate the way in which pruning conducted at different heights may affect the potential development of crown fire under different atmospheric conditions, fuel moisture content and alternative management of the waste generated: extraction, chipping and no management.

10. For evaluation of the fine fuel loads in the crowns of *Pinus radiata* stands, the fuels loads estimated by dead crown models must be added to those estimated by the use of existing models of live crown fuel loads for the species. This will prevent underestimation of the available fuel load in the canopy and overestimation of the vertical discontinuity between the strata. This will limit the errors when evaluating the potential development of crown fires, including the initiation, type of fire (active or passive) and the characteristics of the associated fire behaviour.

USC
UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

6. Bibliografía

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

6. BIBLIOGRAFÍA

Abegg, M., Kükenbrink, D., Zell, J., Schaepman, M. E., Morsdorf, F. (2017). Terrestrial laser scanning for forest inventories—tree diameter distribution and scanner location impact on occlusion. *Forests*, *8*(6), 184.

Agee, J.K. (1996). The influence of forest structure on fire behavior. In Proceedings of the 17th Annual Forest Vegetation Management Conference, Sacramento, California, USA, 16–18.

Agee, J.K., Skinner, C.N. (2005). Basic principles of forest fuel reduction treatments. *Forest Ecology and Management*, *211*(1-2), 83-96.

Ager, A., Vaillant, N., Finney, M. (2011): Integrating fire behavior models and geospatial analysis for wildland fire risk assessment and fuel management planning. *Journal of Combustion*, 1-19.

Alberdi, I., Vallejo, R., Álvarez-González, J.G., Condés, S., González-Ferreiro, E., Guerrero, S., Hernández, L., Martínez-Jauregui, M., Montes, F., Oliveira, N., Pasalodos-Tato, M., Robla, E., Ruiz-González, A.D., Sánchez-González, M., Sandoval, V., San Miguel, A., Sixto, H., Cañellas, I. (2017). The multi-objective Spanish National Forest Inventory. *Forest Systems*, *26*(2), 1–17.

Adler, D., Murdoch, D., Nenadic, O., Urbanek, S., Chen, M., Gebhardt, A., Bolker, B., Csardi, G., Strzelecki, A., Senger, A. rgl: 3D Visualization Using OpenGL. R package version 0.100.54. https://CRAN.R- project.org/package=rgl.

Alexander, M.E., Cruz, M.G. (2011). Crown fire dynamics in conifer forests. En P.A. Werth, B.E. Potter, C.B. Clements, M.A. Finney, S.L. Goodrick, M.E. Alexander, M.G. Cruz, J.M. Forthofer, y S.S. Mcallister (eds.), Synthesis of knowledge of extreme fire behavior: Volume I for Fire Managers. Gen. Tech. Rep. PNW-GTR-854, 107-143.

Andersen, H.E., McGaughey, R.J., Reutebuch, S.E. (2005). Estimating forest canopy fuel parameters using LIDAR data. *Remote Sensing of Environment*, *94*(4), 441-449.

Anderson, K., Hancock, S., Disney, M., Gaston, K.J. (2016). Is waveform worth it? A comparison of LiDAR approaches for vegetation and landscape characterization. *Remote Sensing in Ecology and Conservation*, *2*, 5–15.

Anderson, K.E., Glenn, N.F., Spaete, L.P., Shinneman, D.J., Pilliod, D.S., Arkle, R.S., McIlroy, S.K., Derryberry, D.R. (2018). Estimating vegetation biomass and cover across large plots in shrub and grass dominated dry land susing terrestrial lidar and machine learning. *Ecological Indicators, 84*, 793–802.

Arellano-Pérez, S. (2011). Modelos de Combustibles Forestales de Galicia. Trabajo Fin de Máster, Universidad de Santiago de Compostela, Lugo, España.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Arellano-Pérez, S., Álvarez-González, J.G., Vega Hidalgo, J.A., Ruiz González, A.D. (2017a). Modelos de estimación de la distribución vertical de combustibles finos de copa en masas de pinar a partir de datos del IV Inventario Forestal Nacional. VII Congreso Forestal Español: Gestión Del Monte: Servicios Ambientales y Bioeconomía. Plasencia, Cáceres (España), 10 p.

Arellano-Pérez, S., Vega, J.A., Ruíz, A.D., Arellano, A., Álvarez, J.G., Vega, D., Pérez, E. (2017b). Foto-guía de combustibles forestales de Galicia y comportamiento del fuego asociado. Andavira Editora S.L. Santiago de Compostela, 244pp.

Arellano-Pérez, S., Castedo-Dorado, F., López-Sánchez, C.A., González-Ferreiro, E., Yang, Z., Díaz-Varela, R.A., Álvarez-González, J.G., Vega, J.A., Ruiz-González, A.D. (2018). Potential of Sentinel-2A data tomodel surface and canopy fuel characteristics in relation to crown fire hazard. *Remote Sensing, 10,* 1645, 1-23.

Arellano-Pérez, S., Castedo-Dorado, F., Álvarez-González, J.G., Alonso-Rego, C., Vega, J.A., Ruiz-González, A.D. (2020). Mid-term effects of a thin-only treatment on fuel complex, potential fire behaviour and severity and post-fire soil erosion protection in fast-growing pine plantations. *Forest Ecology and Management*, *460*, 117895.

Arellano-Pérez, S. (2021). Caracterización del combustible del dosel arbóreo mediante sensores remotos y evaluación del efecto de las claras sobre el comportamiento y severidad potenciales del fuego en pinares del NO de España. Tesis doctoral. Universidad de Santiago de Compostela, Lugo.

Astrup, R., Ducey, M.J., Granhus, A., Ritter, T., VonLüpke, N. (2014). Approaches for estimating stand-level volume using terrestrial laser scanning in a single-scan mode. *Canadian Journal of Forest Research, 44*, 666–676.

Axelsson, P. (1999). Processing of laser scanner data—algorithms and applications. *ISPRS Journal of Photogrammetry and Remote Sensing*, *54*(2-3), 138-147.

Ayrey, E., Hayes, D.J. (2018). The use of three-dimensional convolutional neural networks to interpret LiDAR for forest inventory. *Remote Sensing*, *10*(4), 649.

Balboa-Murias, M.A., Rodríguez Soalleiro, R., Merino, A., Álvarez González, J.G. (2006). Temporal variations and distribution of carbon stocks in aboveground biomass of radiate pine and maritime pine pure stands under different silvicultural alternatives. *Forest Ecology and Management*, *237*, 29-38.

Balsa-Barreiro, J., Hermosilla, T. (2013). Socio-geographic analysis of wildland fires causes of the 2006´s wildfires in Galicia (Spain). *Forest Systems*, *22*, 497-509.

Barreal, J., Loureiro, M.L. (2015). Modelling spatial patterns and temporal trends of wildfires in Galicia (NW Spain). *Forest Systems*, *24*, 2, e022.

Barreal, J., Gil, J. (2020). Spatial and temporal wildfire decomposition as a tool for assessment and planning of an efficient forest policy in Galicia (Spain), *Forest*, *11*, 811.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Bliss, C. (1938). The Transformation of Percentages for Use in the Analysis of Variance. *Ohio Journal of Science*, *38*, 9–12.

Bonham, C.D. (2013). *Measurements for terrestrial vegetation*, 2nd Edition. Wiley-Blackwell, Oxford, OX, United Kingdom, 264 pp.

Botequim, B., Fernandes, P.M., Borges, J.G., González-Ferreiro, E., Guerra-Hernández, J. (2019). Improving silvicultural practices for Mediterranean forests through fire behaviour modelling using LiDAR-derived canopy fuel characteristics. *International Journal of Wildland Fire*, *28*(11), 823-839.

Breidenbach, J., Astrup, R. (2015). The semi-individual tree crown approach. In: Maltamo, M., Næsset, E., Vauhkonen, J. (eds.). Forestry Applications of Airborne Laser Scanning, Concepts and Case Studies. Springer, New York. Pp 113-133.

Breiman, L. (2001). Random forests. *Machine Learning*, *45*, 5–32.

Brown, J.K. (1971). A Planar Intersect Method for Sampling Fuel Volume and Surface Area. *Forest Science*, *17*, 96–102.

Brown, J.K. (1974). Handbook for Inventorying Downed Woody Material; General Technical Report GTR-INT-16; USDA Forest Service, Intermountain Forest and Range Experiment Station: Ogden, UT, USA.

Bouvier, M., Durrieu, S., Fournier, R.A. y Renaud, J.P. (2015). Generalizing predictive models of forest inventory attributes using an area-based approach with airborne LiDAR data. *Remote Sensing of Environment, 156*, 322–334.

Brolly, G., Kiraly, G. (2009). Algorithms for stem mapping by means of terrestrial laser scanning. *Acta Silvatica et Lignaria Hungarica, 5*, 119–130.

Burgan, R.E., Rothermel, R.C. (1984). BEHAVE: Fire Behavior Prediction and Fuel Modeling System, FUEL Subsystem. USDA Forest Service, Intermountain Forest and Range Experiment Station. Gen. Tech. Rep. INT-167, 126 pp.

Byram, G.M. (1959). Combustion of forest fuels. En Forest Fire: Control and Use; K.P. Davis, (ed.); McGraw-Hill: New York, NY, USA, pp. 61–89.

Caillez, F. (1980). Estimación del volumen forestal y predicción del rendimiento vol. 1. Estimación del volumen. Organización de las Naciones Unidas para la Agricultura y la Alimentación.

Calders, K., Armston, J., Newnham, G., Herold, M., Goodwin, N. (2014). Implications of sensor configuration and topography on vertical plant profiles derived from terrestrial LiDAR. *Agricultural and Forest Meteorology*, *194*, 104-117.

Calders, K., Newnham, G., Burt, A., Murphy, S., Raumonen, P., Herold, M., Culvenor, D., Avitabile, V., Disney, M., Armston, J., Kaasalainen, M. (2015). Non destructive estimates of above-ground biomass using terrestrial laser scanning. *Methods in Ecology and Evolution*, *6*(2), 198-208.

Campbell, M.J., Dennison, P.E., Hudak, A.T., Parham, L.M., Butler, B.W. (2018). Quantifying understory vegetation density using small-foot print airborne lidar. *Remote Sensing and Environment, 215*, 330–342.

Canfield, R.H. (1941). Application of the line interception method in sampling range vegetation. *Journal of forestry*, *39*(4), 388-394.

Cao, Q.V., Burkhart, H.E., Lemin Jr, R.C. (1982). Diameter distributions and yields of thinned loblolly pine plantations. School of Forestry and Wildlife Resourcebalsa; FWS, 1-82.

Cao, L., Coops, N.C., Hermosilla, T., Innes, J., Dai, J., She, G. (2014). Using small-footprint discrete and full-waveform airborne LiDAR metrics to estimate total biomass and biomass components in subtropical forests. *Remote Sensing*, *7*, 110–7135.

Castroviejo, S. (1986-2015). Flora Ibérica: Plantas vasculares de la Península Ibérica e Islas Baleares. Real Jardín Botánico, CSIC, Madrid.

Carrión-Prieto, P., Martín-Ramos, P., Hernández-Navarro, S., Sánchez-Sastre, L.F., Marcos-Robles, J.L., Martín-Gil, J. (2017). Valorization of *Cistus ladanifer* and *Erica arborea* shrubs for fuel: Wood and bark thermal characterization. *Maderas. Ciencia y tecnología, 19*(4), 443-454.

Catchpole, W.R., Wheeler, C.J., (1992). Estimating plant biomass: a review of techniques. *Australian Journal of Ecology*, *17*(2), 121-131.

Chandler, C., Cheney, P., Thomas, P., Trabaud, L., Williams, D. (1991). Fire in forestry. Volume I: Forest fire behavior and effects. Krieger Publishing Company. Malabar, Florida.

Chas-Amil, M.L., Touza, J., García-Martínez, E. (2013). Forest fires in the wildland urban interface: A spatial analysis of forest fragmentation and human impacts. *Applied Geography, 43*, 127-137.

Chasmer, L., Hopkinson, C., Treitz, P. (2006). Investigating laser pulse penetration through a conifer canopy by integrating airborne and terrestrial lidar. *Canadian Journal of Remote Sensing, 32*, 116–125.

Chen, Q., Baldocchi, D., Gong, P., Kelly, M. (2006). Isolating individual trees in a savanna woodland using small footprint lidar data. *Photogrammetric Engineering and Remote Sensing*, *72*(8), 923–932.

Chen, Y., Zhu, X., Yebra, M.,Harris, S., Tapper, N. (2016). Strata-based forest fuel classification for wildfire hazard assessment using terrestrial LiDAR. *Journal Applied Remote Sensing, 10*, 046025.

Chen, Y., Zhu, X., Yebra, M., Harris, S., Tapper, N. (2017). Development of apredictive model for estimating forest surface fuel load in Australian eucalypt forests with LiDAR data. *Environment Modelling & Software, 97*, 61–71.

Chen, Y., Zhang, Y., Xin, J., Wang, G., Mu, L., Yi, Y., Liu, H., Liu, D. (2019). UAV Image-based Forest Fire Detection Approach Using Convolutional Neural Network. En 14th

IEEE Conferenceon Industrial Electronics and Applications (ICIEA), Xi'an, China, pp. 2118-2123.

Chen, S., Feng, Z., Chen, P., Ullah Khan, T., Lian, Y. (2019). Non destructive estimation of the above-ground biomass of multiple tree species in boreal forests of China using terrestrial laser scanning. *Forests*, *10*(11), 936.

Chirici, G., Scotti, R., Montaghi, A., Barbati, A., Cartisano, R., Lopez, G., Marchetti, M., McRoberts, R.E., Olsson, H., Corona, P. (2013). Stochastic gradient boosting classification trees for forest fuel types mapping through airborne laser scanning and IRS LISS-III imagery. *International Journal of Applied Earth Observation and Geoinformation*, *25*(1), 87–97.

Consellería de Medio Rural (2021). ORDEN de 9 de febrero de 2021 por la que se modifica el anexo I de la Orden de 19 de mayo de 2014 por la que se establecen los modelos silvícolas o de gestión forestal orientativos y referentes de buenas prácticas forestales para los distritos forestales de Galicia.

Coops, N.C., Hilker, T., Wulder, M.A., St-Onge, B., Newnham, G., Siggins, A., Trofymow, J.A. (2007). Estimating canopy structure of Douglas-fir forest stands from discrete-return LiDAR. *Trees*, *21*(3), 295-310.

Cortes, C., Vapnik, V. (1995). Support-vector networks. *Machine learning*, *20*, 273-297.

Crespo-Peremarch, P., Ruiz, L. (2017). Análisis comparativo del potencial del ALS y TLS en la caracterización estructural de la masa forestal basado en voxelización. En Nuevas Plataformas y Sensores de Teledetección, Proceeding soft the XVII Congreso de la Asociación Española de Teledetección, Murcia, Spain, 3–7 October 2017; L.A., Ruiz, J., Estornell, M., Erena, (eds.). Universitat Politécnica de Valencia: Valencia, España, pp. 131–135.

Crespo-Peremarch, P., Ruiz, L.Á., Balaguer-Beser, Á., Estornell, J. (2018). Analyzing the role of pulse density and voxelization parameters on full-waveform LiDAR-derived metrics. *ISPRS Journal Photogrammetry and Remote Sensing, 146*, 453–464.

Crespo-Peremarch, P., Fournier, R.A., Nguyen, V.-T., van Lier, O.R., Ruiz, L.Á. (2020). A comparative assessment of the vertical distribution of forest components using full-waveform airborne, discrete airborne and discrete terrestrial laser scanning data. *Forest Ecology and Management, 473*, 118268.

Cruz, M.G., Alexander, M.E., Wakimoto, R.H. (2004). Modeling the likelihood of crown fire occurrence in coniferous forest stands. *Forest Science, 50*, 640-658.

Cruz, M.G., Alexander, M.E., Fernandes, P.M. (2008). Development of a model system to predict wildfire behaviour in pine plantations. *Australian Forestry*, *71*, 113–121.

Cruz, M.G., Alexander, M.E. (2010). Assessing crown fire potential in coniferous forests of western North America: A critique of current approaches and recent simulation studies. *International Journal of Wildland Fire*, *19*(4), 377–398.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Cruz, M.G., Alexander, M.E., Plucinski, M.P. (2017). The effect of silvicultural treatments on fire behaviour potential in radiata pine plantations of South Australia. *Forest Ecology and Managenment, 397*, 27–38.

Dassot, M., Colin, A., Santenoise, P., Fournier, M., Constant, T. (2012). Terrestrial laser scanning for measuring the solid wood volume, including branches, of adult standing trees in the forest environment. *Computers and Electronics in Agriculture*, *89*, 86-93.

Davies, G.M., Hamilton, A., Smith, A., Legg, C.J. (2008). Using visual obstruction to estimate heathland fuel load and structure. *International Journal of Wildland Fire*, *17*(3), 380-389.

De Cáceres, M., Casals, P., Gabriel, E., Castro, X. (2019). Scaling-up individual-level allometric equations to predict stand-level fuel loading in Mediterranean shrublands. *Annals of Forest Science*, *76*(3), 1-17

Demol, M., Verbeeck, H., Gielen, B., Armston, J., Burt, A., Disney, M., Ducanson, L., Hackenberg, J., Hukenbrink, D., Lau, A., Ploton, P., Sewdien, A., Stovall, A., Momo Takoudjou, S., Volkova, L., Weston, C., Wortel, V., Calders, K. (2022). Estimating forest above-ground biomass with terrestrial laser scanning: Current status and future directions. *Methods in Ecology and Evolution*, *13*(8), 1628-1639.

Diéguez-Aranda, U., Castedo-Dorado, F., Álvarez-González, J.G., Rojo, A. 2006. Compatible taper function for Scots pine plantations in northwestern Spain. *Canadian Journal of Forest Research, 3*6(5), 1190–1205.

Dieguez-Aranda, U., Rojo-Alboreca, A., Castedo-Dorado, F., Álvarez-González, J.G., Barrio-Anta, M., Crecente-Campo, F., González-González, J.M., Pérez-Cruzado, C., Rodriguez-Soalleiro, R., López-Sánchez, C.A., Balboa-Murias, M.A., Gorgoso-Varela, J.J., Sánchez-Rodriguez, F. (2009). Herramientas Selvícolas Para la Gestión Forestal Sostenible en Galicia; Xunta de Galicia: Santiago de Compostela, España.

Dixon, R.K., Solomon, A.M., Brown, S., Houghton, R.A., Trexier, M.C., Wisniewski, J. (1994). Carbon pools and flux of global forest ecosystems. *Science*, *263*(5144), 185-190.

Dobre, A.C., Pascu, I.S., Leca, Ș., Garcia-Duro, J., Dobrota, C.E., Tudoran, G.M., Badea, O. (2021). Applications of TLS and ALS in Evaluating Forest Ecosystem Services: A Southern Carpathians Case Study. *Forests*, *12*, 9, 1269.

Domingo, D., Lamelas-Gracia, M.T., Montealegre-Gracia, A.L., de la Riva-Fernández, J. (2017). Comparison of regression models to estimate biomass losses and CO_2 emissions using low-density airborne laser scanning data in a burnt Aleppo pine forest. *European Journal of Remote Sensing*, *50*(1), 384–396.

Domingo, D., Lamelas, M.T., Montealegre, A.L., García-Martín, A., de la Riva, J. (2018). Estimation of total biomass in Aleppo pine forest stands applying parametric and nonparametric methods to low- density airborne laser scanning data. *Forests*, *9*(4), 158.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Domingo, D., Alonso, R., Lamelas, M.T., Montealegre, A.L., Rodríguez, F., de la Riva, J. (2019). Temporal transferability of pine forest attributes modeling using low-density airborne laser scanning data. *Remote Sensing*, *11*(3), 261.

Domingo, D., de la Riva, J., Lamelas, M.T., García-Martín, A., Ibarra, P., Echeverría, M., Hoffrén, R. (2020). Fuel type classification using airborne laser scanning and Sentinel 2 data in mediterranean forest affected by wildfires. *Remote Sensing*, *12*(21), 3660.

Dong, P., Chen, Q. (2017). LiDAR remote sensing and applications. CRC Press.

Echeverry, C.T., Téllez, E.J. (2021). Modelamiento de escenarios de inundación utilizando modelos digitales de terreno generados a partir de datos batimétricos y lidar, para el municipio de Tumaco, Nariño. Trabajo de Grado. Universidad de Manizales, Colombia.

Engelstad, P.S., Falkowski, M., Wolter, P., Poznanovic, A., Johnson, P. (2019). Estimating canopy fuel attributes from low-density LiDAR. *Fire*, *2*(3), 38.

Ercanlı, İ. (2020). Innovative deep learning artificial intelligence applications for predicting relationships between individual tree height and diameter at breast height. *Forest Ecosystems*, *7*(1), 1-18.

Estornell, J., Ruiz, L.A., Velázquez-Martí, B. (2011a). Study of shrub cover and height using LiDAR data in a Mediterranean area. *Forest Science*, *57*(3), 171-179.

Estornell, J., Ruiz, L.A., Velázquez-Martí, B., Fernández-Sarría, A. (2011b). Estimation of shrub biomass by airborne LiDAR data in small forest stands. *Forest Ecology and Management*, *262*(9), 1697-1703.

FAO y PNUMA. (2020). El estado de los bosques del mundo 2020. Los bosques, la biodiversidad y las personas. Roma. https://doi.org/10.4060/ca8642es

FAO. (2007). Situación de los bosques del mundo. Roma. http://www.fao.org/3/a-a0773s.pdf

Fernandes, P.M., Rigolot, E. (2007). The fire ecology and management of maritime pine (*Pinus pinaster* Ait.). *Forest Ecology and Management*, *241*(1-3), 1-13.

Fernández-Alonso, J.M., Alberdi, I., Álvarez-González, J.G., Vega, J.A., Cañellas, I., Ruiz-González, A.D. (2013). Canopy fuel characteristics in relation to crown fire potential in pine stands: Analysis, modelling and classification. *European Journal of Forest Research, 132*, 363–377.

Fidalgo-González, L., Arellano-Pérez, S., Castedo-Dorado, F., Ruiz-González, A.D., González-Ferreiro, E. (2019). Estimación de la distribución vertical de combustibles finos del dosel de copas en masas de *Pinus sylvestris* empleando datos LiDAR de baja densidad. *Revista de Teledetección*, *53*, 1-16.

Finney, M. A. (2004). Landscape Fire Simulation and Fuel Treatment Optimization. En J. L. Hayes, A. Ager, R. Barbour (eds.), Methods for integrating modeling of landscape change:

USC UNIVERSIDADE DE COMPOSTELA

Interior Northwest Landscape Analysis System (pp. 117-131.). Gen. Tech. Rep. PNW-GTR-610. Portland, OR: US Department of Agriculture, Forest Service, Pacific North.

Finney, M.A. (2006). An Overview of FlamMap Fire Modeling Capabilities. En P.L. Andrews, B.W. Butler (eds.), Fuel Management-How to Measure Success. Conference Proceedings. 28-30 March 2006; Portland, OR: Proceedings RMRS-P-41. Fort Collins, CO: USDA Forest Service, Rocky Mountain Research Station.

Finney, M.A., Seli, R.C., McHugh, C.W., Ager, A.A., Bahro, B., Agee, J.K. (2007). Simulation of long-term landscape-level fuel treatment effects on large wildfires. *International Journal of Wildland Fire*, *16*(6), 712-727.

Fosberg, M.A. (1971). Moisture calculations for the 100 hour timelag fuels for fire danger rating. USDA Forest Service. Research Note RM, 199, 7 p.

Fricker, G.A., Ventura, J.D., Wolf, J.A., North, M.P., Davis, F.W., Franklin, J. (2019). A convolutional neural network classifier identifies tree species in mixed-conifer forest from hyperspectral imagery. *Remote Sensing*, *11*(19), 2326.

Friedman, J.H. (1991). Multivariate adaptive regression splines (with discussion). *Annals of Statistics*, *19*, 79–141.

Gale, M.G., Cary, G.J., Van Dijk, A.I., Yebra, M. (2021). Forest fire fuel through the lens of remote sensing: Review of approaches, challenges and future directions in the remote sensing of biotic determinants of fire behaviour. *Remote Sensing of Environment*, *255*, 112282.

Gao, B., (1996). NDWI -A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing Environment*, *58* (3), 257–266.

García, M., Riaño, D., Chuvieco, E., Salas, J., Danson, F.M. (2011a). Multispectral and LiDAR data fusion for fuel type mapping using Support Vector Machine and decision rules. *Remote Sensing of Environment*, *115*(6), 1369-1379.

García, M., Danson, F.M., Riaño, D., Chuvieco, E., Ramirez, F.A., Bandugula, V. (2011b). Terrestrial laser scanning to estimate plot-level forest canopy fuel properties. *International Journal Applied Earth Observation and Geoinformation, 13*, 636–645.

García-Gutiérrez, J., Gonzalez-Ferreiro, E., Riquelme-Santos, J.C., Miranda, D., Dieguez-Aranda, U., Navarro-Cerrillo, R.M. (2014). Evolutionary feature selection to estimate forest stands variables using LiDAR. *International Journal Applied Earth Observation and Geoinformation, 26*, 119–131.

García-Gutiérrez, J., González-Ferreiro, E., Mateos-García, D., Riquelme-Santos, J.C. (2016). A preliminary study of the suitability of deep learning to improve LiDAR-derived biomass estimation. En F., Martínez-Álvarez, A., Troncoso, H., Quintián, E., Corchado (eds.). Hybrid Artificial Intelligent Systems. HAIS 2016. Lecture Notes in Computer Science, 9648. Springer. pp. 588–596.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Garzon, M.B., Blazek, R., Neteler, M., De Dios, R.S., Ollero, H.S., Furlanello, C. (2006). Predicting habitat suitability with machine learning models: the potential area of *Pinus sylvestris* L. in the Iberian Peninsula. *Ecological modelling*, *197*(3-4), 383-393.

Geller, G.N., Halpin, P.N., Helmuth, B., Hestir, E.L., Skidmore, A., Abrams, M.J., Aguirre, N., Blair, M., Botha, E., Colloff, M., Dawson, T., Franklin, J., Horning, N., James, C., Magnusson, W., Santos, M.J., Schill, S.R., Williams, K. (2017). Remote sensing for biodiversity. En The GEO handbook on biodiversity observation networks. Springer. pp. 187-210

Genuer, R., Poggi, J.M., Tuleau-Malot, C. (2010). Variable selection using random forests. *Pattern Recognition Letters*, *31*, 2225–2236.

Giannetti, F., Puletti, N., Quatrini, V., Travaglini, D., Bottalico, F., Corona, P., Chirici, G. (2018). Integrating terrestrial and airborne laser scanning for the assessment of single-tree attributes in Mediterranean forest stands. *European Journal of Remote Sensing*, *51*, 1, 795-807.

Gómez-Vázquez, I., Crecente-Campo, F., Diéguez-Aranda, U., Castedo-Dorado, F. (2012). Modelling canopy fuel variables in *Pinus pinaster* Ait. and *Pinus radiata* D. Don stands in northwestern Spain. *Annals of Forest Science, 70*, 161–172.

Gonçalves-Seco, L., González-Ferreiro, E., Diéguez-Aranda, U., Fraga-Bugallo, B., Crecente, R., Miranda, D. (2011). Assessing the attributes of high-density *Eucalyptus globulus* stands using airborne laser scanner data. *International Journal of Remote Sensing*, *32*(24), 9821-9841.

González de Tanago, J., Lau, A., Bartholomeus, H., Herold, M., Avitabile, V., Raumonen, P., Martius, C., Goodman, R.C., Disney, M., Manuri, S., Burt, A., Calders, K. (2018). Estimation of above-ground biomass of large tropical trees with terrestrial LiDAR. *Methods in Ecology and Evolution*, *9*(2), 223-234.

González-Ferreiro, E., Diéguez-Aranda, U., Miranda, D. (2012). Estimation of stand variables in *Pinus radiata* D. Don plantations using different LiDAR pulse densities. *Forestry, 85*, 281–292.

González-Ferreiro, E., Diéguez-Aranda, U., Barreiro-Fernández, L., Buján, S., Barbosa, M., Suárez, J. C., Lain J.B., Miranda, D. (2013). A mixed pixel-and region-based approach for using airborne laser scanning data for individual tree crown delineation in *Pinus radiata* D. Don plantations. *International Journal of Remote Sensing, 34*, 21, 7671-7690.

González-Ferreiro, E., Diéguez-Aranda, U., Crecente-Campo, F., Barreiro-Fernández, L., Miranda, D., Castedo-Dorado, F. (2014). Modelling canopy fuel variables for *Pinus radiata* D. Don in NW Spain with low-density LiDAR data. *International Journal of Wildland Fire*, *23*(3), 350-362.

González-Ferreiro, E., Arellano-Pérez, S., Castedo-Dorado, F., Hevia, A., Vega, J.A., Vega-Nieva, D., Álvarez-González, J.G., Ruíz-González, A.D. (2017). Modelling the vertical distribution of canopy fuel load using national forest inventory and low-density airbone laser scanning data. *PLoSONE, 12*, e0176114.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Goodbody, T.R., Coops, N.C., Luther, J.E., Tompalski, P., Mulverhill, C., Frizzle, C., Fournier, R., Furze, S., Herniman, S. (2021). Airborne laser scanning for quantifying criteria and indicators of sustainable forest management in Canada. *Canadian Journal of Forest Research, 51*, 7, 972-985.

Greaves, H.E., Vierling, L.A., Eitel, J.U.H., Boelman, N.T., Troy, S.T., Magney, T.S., Prager, C. M., Griffin, K.L. (2015). Estimating aboveground biomass and leaf area of low-stature Arctic shrubs with terrestrial LiDAR. *Remote Sensing of Environment, 164*, 26-35.

Greaves, H.E., Vierling, L.A., Eitel ,J.U.H., Boelman, N.T., Magney, T.S., Prager, C.M., Griffin, K.L. (2016). High-resolution mapping of above ground shrub biomass in Arctic tundra using airborne lidar and imagery. *Remote Sensing of Environment, 184*, 361–373.

Greaves, H.E., Vierling, L.A., Eitel, J.U., Boelman, N.T., Magney, T.S., Prager, C.M., Griffin, K.L. (2017). Applying terrestrial lidar for evaluation and calibration of airborne lidar-derived shrub biomass estimates in Arctic tundra. *Remote Sensing Letters*, *8*(2), 175-184.

Gislason, P.O., Benediktsson, J.A., Sveinsson, J.R. (2006). Random Forests for land cover classification. *Pattern Recognition Letters*, *27*, 294–300.

Guan, H., Yu, Y., Ji, Z., Li, J., Zhang, Q. (2015). Deeplearning-based tree classification using mobile LiDAR data. *Remote Sensing Letters*, *6*, 11, 864-873.

Guerra-Hernández, J., Bastos Görgens, E., García-Gutiérrez, J., Estraviz-Rodriguez, L.C., Tom, M., González-Ferreiro, E. (2016). Comparison of ALS based models fore stimating aboveground biomass in three types of Mediterranean forest. *European Journal of Remote Sensing, 49*, 185–204.

Gupta, R., Sharma, L.K. (2022). Mixed tropical forests canopy height mapping from spaceborne LiDAR GEDI and multisensor imagery using machine learning models. *Remote Sensing Applications: Society and Environment*, *27*, 100817.

Hackenberg, J., Wassenberg, M., Spiecker, H., Sun, D. (2015). Non destructive method for biomass prediction combining TLS derived tree volume and wood density. *Forests*, *6*(4), 1274-1300.

Hall, S.A., Burke, I.C. (2006). Considerations for characterizing fuels as inputs for fire behavior models. *Forest Ecology and Management,227*,102–114.

Hamdi, Z.M., Brandmeier, M., Straub, C. (2019). Forest damage assessment using deep learning on high resolution remote sensing data. *Remote Sensing*, *11*(17), 1976.

Hamedianfar, A., Mohamedou, C., Kangas, A., Vauhkonen, J. (2022). Deep learning for forest inventory and planning: a critical review on the remote sensing approaches so far and prospects for further applications. *Forestry, 95,* 4, 451–465.

Hamraz, H., Jacobs, N.B., Contreras, M.A., Clark, C.H. (2019). Deep learning for conifer/deciduous classification of airborne LiDAR 3D point clouds representing individual trees. *ISPRS Journal of Photogrammetry and Remote Sensing*, *158*, 219-230.

USC
DE SANTIAGO
DE COMPOSTELA

Harvey, A.C. (1976). Estimating regression models with multiplicative heteroscedasticity. *Econometrica*, *44*, 461–465.

Hatton, T.J., Viney, N.R., Catchpole, E.A., De Mestre, N.J. (1988). The influence of soil moisture on *Eucalyptus* leaf litter moisture. *Forest Science*, *34*(2), 292-301.

Hauglin, M., Gobakken, T., Astrup, R., Ene, L., Næsset, E. (2014). Estimating single-tree crown biomass of Norway spruce by airborne laser scanning: a comparison of methods with and without the use of terrestrial laser scanning to obtain the ground reference data. *Forests*, *5*, 384–403.

Hernando, A., Puerto, L., Mola-Yudego, B., García-Abril, A., Maltamo, M., Valbuena, R. (2019). Estimation of forest biomass components using airborne LiDAR and multispectral sensors. *I Forest - Biogeosciences and Forestry*, *12*, 207–213.

Hevia, A., Crabiffosse, A., Majada, J., Álvarez-González, J.G., Ruiz-González, A.D. (2012). Modelo de distribución de la carga de combustibles finos en el dosel de copas de rodales regulares de *Pinus pinaster*: efecto de claras combinadas con podas. *Cuadernos de la Sociedad Española de Ciencias Forestales*, *34*, 123–133.

Hevia, A., Álvarez-González, J.G., Majada, J. (2016a). Comparison of pruning effects on tree growth, productivity and dominance of two major timber conifer species. *Forest Ecology and Management*, *374*, 82-92.

Hevia, A., Álvarez-González, J.G., Ruiz-Fernández, E., Prendes, C., Ruiz-González, A.D., Majada, J., González-Ferreiro, E. (2016b). Modelling canopy fuel and forest stand variables and characterizing the influence of thinning in the stand structure using airborne LiDAR. *Revista de Teledetección*, *45*, 41-55.

Hevia, A., Crabiffosse, A., Álvarez-González, J.G., Ruiz-González, A.D., Majada, J. (2017). Novel approach to assessing residual biomass from pruning: A case study in Atlantic *Pinus pinaster* Ait. timber forests. *Renewable Energy*, *107*, 620–628.

Hilker, T., van Leeuwen, M., Coops, N.C., Wulder, M.A., Newnham, G.J., Jupp, D. L., Culvenor, D.S. (2010). Comparing canopy metrics derived from terrestrial and airborne laser scanning in a Douglas-fir dominated forest stand. *Trees*, *24*(5), 819-832.

Hilker, T., Coops, N.C., Newnham, G.J., VanLeeuwen, M., Wulder, M.A., Stewart, J., Culvenor, D.S. (2012). Comparison of terrestrial and airborne LiDAR indescribing stand structure of at hinned lodge pole pine forest. *Journal of Forestry, 110*, 97–104.

Hirsch, K., Martell, D. (1996). A review of initial attack fire crew productivity and effectiveness. *International Journal of Wildland Fire*, *6*, 199-215.

Hoffman, C.M., Collins, B., Battaglia, M. (2018). Wildland fuel treatments. En S., Manzello (ed.). Encyclopedia of wildfires and wildland-urban interface (WUI) fires. Springer International Publishing.

Holmgren, J., Persson, Å. (2004). Identifying species of individual trees using airborne laser scanner. *Remote Sensing of Environment*, *90*(4), 415-423.

USC UNIVERSIDADE DE SANTIAGO

Hopkinson, C., Chasmer, L., Young-Pow, C., Treitz, P. (2004). Assessing forest metrics with a ground-based scanning lidar. *Canadian Journal of Forest Research*, *34*(3), 573-583.

Huang, H., Li, Z., Gong, P., Cheng, X., Clinton, N., Cao, C., Ni, W., Wang, L. (2011). Automated methods for measuring DBH and tree heights with a commercial scanning lidar. *Photogramametric Engineering & Remote Sensing, 77*, 219–227.

Hudak, A.T., Strand, E.K., Vierling, L.A., Byrne, J.C., Eitel, J.U., Martinuzzi, S., Falkowski, M.J. (2012). Quantifying aboveground forest carbon pools and fluxes from repeat LiDAR surveys. *Remote Sensing of Environment*, *123*, 25-40.

Hudak, A.T., Kato, A., Bright, B.C., Loudermilk, E.L., Hawley, C., Restaino, J.C., Ottmar, R.D., Prata, G.A., Cabo, C., Prichard, S.J., Rowell, E.M., Weise, D.R. (2020). Towards spatially explicit quantification of pre-and postfire fuels and fuel consumption from traditional and point cloud measurements. *Forest Science*, *66*(4), 428-442.

Huesca, M., Riaño, D., Ustin, S.L. (2019). Spectral mapping methods applied to LiDAR data: Application to fuel type mapping. *International Journal of Applied Earth Observation and Geoinformation*, *74*, 159–168.

Izco, J., Amigo, J., Ramil-Rego, P., Díaz, R., Sánchez, J.M. (2006). Brezales: biodiversidad, usos y conservación. *Recursos rurais*, (2), 5-24.

Jain, P., Coogan, S.C.P., Subramanian, S.G., Crowley, M., Taylor, S., Flannigan, M.D. (2020). A review of machine learning applications in wildfire science and management. *Environmental Reviews*, *28*, 478–505.

Jakubowski, M.K., Li, W., Guo, Q., Kelly, M. (2013). Delineating individual trees from lidar data: A comparison of vector- and raster-based segmentation approaches. *Remote Sensing*, *5*(9), 4163–4186.

Jiménez, E., Vega, J.A., Fernández-Alonso, J.M., Vega-Nieva, D., Ortiz, L., Lopez-Serrano, P.M., López-Sánchez, C.A. (2017). Estimation of aboveground forest biomass in Galicia (NW Spain) by the combined use of LiDAR, LANDSAT ETM+ and National Forest Inventory data. *iForest-Biogeosciences and Forestry*, *10*(3), 590.

Jiménez, E., Vega, J.A., Ruiz-González, A.D., Guijarro, M., Alvarez-González, J.G., Madrigal, J., Cuiñas, O., Hernando, C., Fernández-Alonso, J.M. (2013). Carbon emissions and vertical pattern of canopy fuel consumption in three *Pinus pinaster* Ait. active crown fires in Galicia (NW Spain). *Ecological Engineering*, *54*, 202-209.

Jordan, M.I., Mitchell, T.M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, *349*(6245), 255-260.

Jung, S.E., Kwak, D.A., Park, T., Lee, W.K., Yoo, S. (2011). Estimating crown variables of individual trees using airborne and terrestrial laser scanners. *Remote Sensing, 3*(11), 2346–2363.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Jupp, D.L.B., Culvenor, D.S., Lovell, J.L., Newnham, G.J., Strahler, A.H., Woodcock, C.E. (2009). Estimating forest LAI profiles and structural parameters using a ground-based laser called 'Echidna'. *Tree Physiology*, *2*9, 171–181.

Kankare, V., Vauhkonen, J., Tanhuanpää, T., Holopainen, M., Vastaranta, M., Joensuu, M., Krooks, A., Hyyppä, J., Hyyppä, H., Alho, P., Viitala, R. (2014). Accuracy in estimation of timber assortments and stem distribution–A comparison of airborne and terrestrial laser scanning techniques. *ISPRS Journal of Photogrammetry and Remote Sensing*, *97*, 89-97.

Karpatne, A., Ebert-Uphoff, I., Ravela, S., Babaie, H.A., Kumar, V. (2019). Machine learning for the geosciences: challenges and opportunities. *IEEE Transactions on Knowledge and Data Engineering, 31*(8), 1544-1554.

Keane, R.E., Burgan, R., VanWagtendonk, J. (2001). Mapping wildland fuels for fire management across multiple scales: Integrating remote sensing, GIS, and biophysical modeling. *International Journal of Wildland Fire, 10*, 301–319.

Keane, R.E. (2012). Describing wildland surface fuel loading for fire management: a review of approaches, method sand systems. *International Journal of Wildland Fire, 22*(1), 51-62.

Keane, R.E. (2015). Wildland fuel fundamentals and applications. Springer International Publishing: New York, USA.

Keeley, J.E., Zedler, P.H. (1998). Evolution of life histories in Pinus. En Ecology and Biogeography of *Pinus*; D.M., Richardson (ed.); Cambridge University Press: Cambridge, UK; pp. 219–250.

Keyes, C.R., O'Hara, K.L. (2002). Quantifying stand targets for silvicultural prevention of crown fires. *Western Journal of Applied Forestry* , *17* (2), 101-109.

Keyser, T., Smith, F.W. (2010). Influence of crown biomass estimat or sand distribution on canopy fuel characteristics in ponderosa pine stands of the Black Hills. *Forest Science*, *56*(2), 156–165.

Kobler, A., Pfeifer, N., Ogrinc, P., Todorovski, L., Oštir, K., Džeroski, S. (2007). Repetitive interpolation: A robust algorithm for DTM generation from Aerial Laser Scanner Data in forested terrain. *Remote sensing of environment*, *108*(1), 9-23.

Koutsias, N., Allogower, B., Kalabokidis, K., Mallinis, G., Balatsos, P., Goldammer, J.G. (2015). Fire occurrence zoning from local to global scale in the European Mediterranean basin: implications for multi-scale fire management and polity. *iForest-Biogeosciences and Forestry, 9*, 195-204.

Kramer, H.A., Collins, B.M., Lake, F.K., Jakubowski, M.K., Stephens, S.L., Kelly, M. (2016). Estimating ladder fuels: A new approach combining field photography with LiDAR. *Remote Sensing*, *8*, 766.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Kraus, K., Pfeifer, N. (1998). Determination of terrain models in wooded areas with airborne laser scanner data. *ISPRS Journal of Photogrammetry and remote Sensing*, *53*(4), 193-203.

Ku, N., Popescu, S.C.,Ansley, R.J., Perotto-Baldivieso, H.L., Filippi, A.M. (2012). Assessment of available range land woody plant biomass with a terrestrial lidar system. *Photogrammetric Engineering & Remote Sensing, 78*, 349–361.

Laclau, P. (2003). Biomass and carbon sequestration of ponderosa pine plantations and native cypress forests in northwest Patagonia. *Forest ecology and management*, *180*(1-3), 317-333.

LaRue, E.A., Wagner, F.W., Fei, S., Atkins, J.W., Fahey, R.T., Gough, C.M., Hardiman, B.S. (2020). Compatibility of Aeria land Terrestrial LiDAR for Quantifying Forest Structural Diversity. *Remote Sensing, 12*, 1407.

Lary, D.J., Alavi, A.H., Gandomi, A.H., Walker, A.L. (2016). Machine learning in geosciences and remote sensing. *Geoscience Frontiers*, *7*(1), 3–10.

Lasslop, G., Kloster, S. (2015). Impact of fuel variability on wildfire emission estimates. *Atmospheric Environment*, *121*, 93-102.

Lefsky, M.A., Cohen, W.B., Acker, S.A., Parker, G.G., Spies, T.A., Harding, D. (1999). Lidar remote sensing of the canopy structure and biophysical properties of Douglas-fir western hemlock forests. *Remote sensing of environment*, *70*(3), 339-361.

Lefsky, M.A., Cohen, W.B., Parker, G.G., Harding, D.J. (2002). LiDAR remote sensing for ecosystem studies. *Bioscience*, *52*, 19–30.

Li, A., Glenn, N.F., Olsoy, P.J., Mitchell, J.J., Shrestha, R. (2015). Aboveground biomass estimates of sagebrush using terrestrial and airborne LiDAR data in a dryland ecosystem. *Agricultural and Forest Meteorology*, *213*, 138-147.

Li, A., Dhakal, S., Glenn, N.F., Spaete, L.P., Shinneman, D.J., Pilliod, D S., Arkle, R.S., McIlroy, S.K. (2017). Lidar aboveground vegetation biomass estimates in shrublands: Prediction, uncertainties and application to coarser scales. *Remote Sensing*, *9*(9), 903.

Li, S., Wang, T., Hou, Z., Gong, Y., Feng, L., Ge, J. (2021). Harnessing terrestrial laser scanning to predict understory biomass in temperate mixed forests. *Ecological Indicators, 121*, 107011.

Liang, X., Hyyppä, J., Kaartinen, H., Lehtomäki, M., Pyörälä, J., Pfeifer, N., Holopainen, M., Brolly, G., Francesco, P., Hackenberg, J., Huang, H., Jo, H.W., Katoh, M., Liu, L., Mokros, M., Morel, J., Olofsson, K., Poveda-López, J., Trochta, D. W., Linn, R.R., Reisner, J., Colmann, J.J., Winterkamp, J. (2002). Studying wildfire behavior using FIRETEC. *International Journal of Wildland Fire*, *11*, 233–246.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Liang, X., Litkey, P., Hyyppa, J., Kaartinen, H., Vastaranta, M., Holopainen, M. (2012). Automatic stem mapping using single-scan terrestrial laser scanning. *IEEE Transactions on Geoscience and Remote Sensing, 50*, 661–670.

Liang, X., Hyyppa, J. (2013). Automatic Stem Mapping by Merging Several Terrestrial Laser Scans at the Feature and Decision Levels. *Sensors, 13*, 1614–1634.

Liang, X., Kankare, V., Hyyppä, J., Wang, Y., Kukko, A., Haggrén, H., Yu, X., Kaartinen, H., Jaakkola, A., Guan, F. Holopainen, M., Vastaranta, M. (2016). Terrestrial laser scanning in forest inventories. *ISPRS Journal of Photogrammetry and Remote Sensing, 115*, 63–77.

Liang, X., Hyyppä, J., Kaartinen, H., Lehtomäki, M., Pyörälä, J., Pfeifer, N., Holopainen, M., Brolly, G., Francesco, P., Hackenberg, J., Huang, H., Jo, Hyun-Woo, Katoh, M., Liu, L., Mokros, M., Morel, J., Olofsson, K., Poveda-Lopez, J., Trochta, J., Wang, D., Wang, Y. (2018). International benchmarking of terrestrial laser scanning approaches for forest inventories. *ISPRS journal of photogrammetry and remote sensing*, *144*, 137-179.

Liaw, A., Wiener, M. (2002). Classification and Regression by RandomForest. *R News*, *2*(3), 18–22.

Linn, R.R., Reisner, J., Colmann, J.J., Winterkamp, J. (2002). Studying wildfire behavior using FIRETEC. *International Journal of Wildland Fire*, *11*, 233–246.

Linn, R.R., Winterkamp, J., Colman, J.J., Edminster, C., Bailey, J.D. (2005). Modeling interactions between fire and atmosphere in discrete element fuelbeds. *International Journal of Wildland Fire*, *14*, 37–48.

Liu, L., Pang, Y., Li, Z., Si, L., Liao, S. (2017). Combining Airborne and Terrestrial Laser Scanning Technologies to Measure Forest Understorey Volume. *Forests, 8*(4), 111.

Liu, Z., Peng, C., Work, T., Candau, J.N., DesRochers, A., Kneeshaw, D. (2018). Application of machine-learning methods in forest ecology: recent progress and future challenges. *Environmental Reviews*, *26*(4), 339–350.

Liu, J., Wang, X., Wang, T. (2019). Classification of tree species and stock volume estimation in ground forest images using Deep Learning. *Computers and Electronics in Agriculture*, *166*, 105012.

López-Serrano, P.M., López-Sánchez, C.A., Álvarez-González, J.G., García-Gutiérrez, J. (2016). A comparison of machine learning techniques applied to Landsat-5 TM spectral data for biomass estimation. *Canadian Journal of Remote Sensing*, *42*, 6, 690–705.

Loudermilk, E.L., Hiers, J.K., O'Brien, J.J., Mitchell, R.J., Singhania, A., Fernandez, J.C., Slatton, K.C. (2009). Ground-based LIDAR: a novel approach to quantify fine-scale fuelbed characteristics. *International Journal of Wildland Fire*, *18*, 676–685.

Mahesh, B. (2020). Machine learning algorithms-a review. *International Journal of Science and Research (IJSR), 9*, 381-386.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Maltamo, M., Næsset, E., Vauhkonen, J. (2014). Forestry applications of airborne laser scanning. Concepts and case studies. Book Series: Managing Forest Ecosystems, 27, Springer, 460 pp.

Mandel, J., Beezley, J.D., Kochanski, A.K. (2011). Coupled atmosphere–wildland fire modeling with WRF 3.3 and SFIRE 2011. *Geoscientific Model Development*, *4*, 591–610.

Mandel, J., Amram, S., Beezley, J.D., Kelman, G., Kochanski, A.K., Kondratenko, V.Y., Lynn, B.H., Regev, B., Vejmelka, M. (2014). Recent advances and applications of WRF-SFIRE. *Natural Hazards and Earth System Sciences*, *14*, 2829–2845.

Marey-Pérez, M.F., Rodríguez-Vicente, V. (2009). Forest transition in Northern Spain: Local responses on large-scale programmes of field-afforestation. *Land Use and Policy*, *26*(1), 139-156.

Marino, E., Ranz, P., Tomé, J.L., Noriega, M.Á., Esteban, J., Madrigal, J. (2016). Generation of high-resolution fuel model maps from discrete airborne laser scanner and Landsat-8 OLI: A low-cost and highly updated methodology for large areas. *Remote Sensing of Environment*, *187*, 267-280.

Marino, E., Tomé, J.L., Hernando, C., Guijarro, M., Madrigal, J. (2022). Transferability of Airborne LiDAR Data for Canopy Fuel Mapping: Effect of Pulse Density and Model Formulation. *Fire*, *5*(5), 126.

MARM. (2011a). Cuarto Inventario Forestal Nacional. Galicia. Dirección General de Medio Natural y Política Forestal. Ministerio de Medio Ambiente y Medio Rural y Marino. 49 p.

MARM. (2011b). Mapa forestal de España. Galicia. Escala 1:25.000. Ministerio de Medio Ambiente y Medio Rural y Marino. Madrid.

MMA. (2006). Mapa Forestal Nacional. Escala 1:50.000. Ministerio de Agricultura, Pesca y Alimentación: Madrid, Spain.

Mataix-Solera, J., Gómez, I., Navarro-Pedreño, J., Guerrero, C., Moral, R. (2002). Soil organic matter and aggregates affected by wildfire in a *Pinus halepensis* forest in Mediterranean environment. *International Journal of Wildland Fire11*: 107-114.

Mataix-Solera, J., Guerrero, C. (2007). Efectos de los incendios forestales en las propiedades edáficas. *Incendios forestales, suelos y erosión hídrica*, 5-40.

Mauro, F., Hudak, A.T., Fekety, P.A., Frank, B., Temesgen, H., Bell, D.M., Gregory, M.J., McCarley, T.R. (2021). Regional modeling of forest fuels and structural attributes using airborne laser scanning data in Oregon. *Remote Sensing*, *13*(2), 261.

McDonald, P.M., Laacke, R.J., Burns, R., Honkala, B. (1990). *Pinus radiata* D. Don Monterey Pine. *Silvics of North America*, *1*, 433-441.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

McGaughey, R.J. (2021). FUSION/LDV: Software for LIDAR Data Analysis and Visualization; US Department of Agriculture, Forest Service: Pacific Northwest Research Station: Seattle, WA, USA. http://forsys.sefs.uw.edu/fusion/fusion_ overview. html.

McGovern, A., Elmore, K.L., Gagne, D.J., Haupt, S.E., Karstens, C.D., Lagerquist, R., Smith, T., Williams, J.K. (2017). Using artificial intelligence to improve real-time decision-making for high-impact weather. *Bulletin of the American Meteorological Society*, *98*, 10, 2073–2090.

Mell, W., Jenkins, M.A., Gould, J., Cheney, P. (2007). A physics-based approach to modeling grassland fires. *International Journal of Wildland Fire*, *16*, 1–22.

Mell, W., Maranghides, A., McDermott, R., Manzello, S.L. (2009). Numerical simulation and experiments of burning Douglas-fir trees. *Combustion and Flame*, *156*, 2023–2041.

Menning, K.M., Stephens, S.L. (2007). Fire climbing in the forest: A semiqualitative, semiquantitative approach to assessing ladder fuel hazards. *Western Journal of Applied Forestry*, *22*, 88–93.

Meyer, D., Dimitriadou, E., Hornik, K., Weingessel, A., Leisch, F. (2019). e1071: Misc Functions of the Department of Statistics, Probability Theory Group (Formerly: E1071). R package version 1.7-2.

Milborrow, S. (2021). Derived from Mda: Mars by Hastie T and Tibshirani R. Uses Alan Miller's Fortran Utilities with Thomas Lumley's Leaps Wrapper. Earth: Multivariate Adaptive Regression Splines. R Package Version 4.5.1.

Molina-Valero, J.A., Ginzo, V., Novo, P., Álvarez-González, J.G., Pérez-Cruzado, C. (2019). Estimating basal area in mature stands of *Pinus sylvestris* using single-scan terrestrial laser scanner (TLS). *Cuadernos de la Sociedad Española de Ciencias Forestales*,*45*(3), 97-115.

Molina-Valero, J.A., Ginzo Villamayor, M.J., Novo Pérez, A.M., Martínez-Calvo, A., Álvarez-González, J.G., Montes, F., Pérez- Cruzado, C. (2021). FORTLS: Automatic Processing of TLS Point Cloud Data for Forestry Purposes. R Package Version 1.0.3. 2021.

Molina-Valero, J.A., Martínez-Calvo, A., Villamayor, M.J.G., Pérez, M.A.N., Álvarez-González, J.G., Montes, F., Pérez-Cruzado, C. (2022). Operationalizing the use of TLS in forest inventories: The R package FORTLS. *Environmental Modelling & Software*, *150*, 105337.

Momo-Takoudjou, S., Ploton, P., Sonké, B., Hackenberg, J., Griffon, S., De Coligny, F., Kamdem, N.G., Libalah, M., Mofack, G., Le Moguédec, G., Pélissier, R., Barbier, N. (2018). Using terrestrial laser scanning data to estimate large tropical trees biomass and calibrate allometric models: A comparison with traditional destructive approach. *Methods in Ecology and Evolution*, *9*(4), 905-916.

Montero, G., López-Leiva, C., Ruiz-Peinado, R., López-Senespleda, E., Onrubia, R., Pasalodos, M. (2020). Producción de biomasa y fijación de carbono por los matorrales españoles y por el horizonte orgánico superficial de los suelos forestales. Ministerio de Agricultura, Pesca y Alimentación: Madrid, España.

USC UNIVERSIDADE DE COMPOSTELA

Mosavi, A., Ozturk, P., Chau, K.W. (2018). Flood prediction using machine learning models: literature review. *Water*, *10*(11), 1536.

Myers, R.H. (1990). Classical and Modern Regression with Applications, 2nd ed.; Duxbury Press: Pacific Grove, CA, USA.

Næsset, E. (2002). Predicting forest stand characteristics with airborne scanning laserusing a practical two-stage procedure and field data. *Remote Sensing of Environment*, *80*, 88–99.

Narine, L.L., Popescu, S.C., Malambo, L. (2019). Synergy of ICESat-2 and Landsat for mapping forest aboveground biomass with deep learning. *Remote Sensing*, *11*, 12, 1503.

Newnham, G.J., Armston, J.D., Calders, K., Disney, M.I., Lovell, J.L., Schaaf, C.B., Strahler, A.H., Danson, F.M. (2015). Terrestrial laser scanning for plot-scale forest measurement. *Current Forestry Reports*, *1*, 239-251.

Norgaard, K.M. (2014). The Politics of fire and the social impacts of fire exclusion on the Klamath. *Humboldt Journal of Social Relations*, *36*, 77–101.

Novo-Fernández, A., Barrio-Anta, M., Recondo, C., Cámara-Obregón, A., López-Sánchez, C.A. (2019). Integration of National Forest Inventory and Nation wide Airborne Laser Scanning Data to Improve Forest Yield Predictions in North-Western Spain. *Remote Sensing, 11*, 1693.

Núñez-Regueira, L., Proupín-Castiñeiras, J., Rodrıguez-Anón, J.A. (2004). Energy evaluation of forest residues originated from shrub species in Galicia. *Bioresource Technology*, *91*(2), 215-221.

NWCG (2006). National Wildfire Coordination Group Glossary of Fire Terminology. http://www.nwcg.gow/pms/pubs/glossary/

Olofsson, K., Holmgren, J., Olsson, H. (2014). Tree stem and height measurement susing terrestrial laser scanning and the RANSA Calgorithm. *Remote Sensing, 6*, 4323–4344.

Olsoy, P.J., Glenn, N.F., Clark, P.E., Derryberry, D.R. (2014). Aboveground total and green biomass of dryland shrub derived from terrestrial laser scanning. *ISPRS Journal of Photogrammetry and Remote Sensing*, *88*, 166-173.

ONU (1992). United Nations Framework Convention Climate Change. New York, USA. https://unfccc.int/resource/docs/ convkp/conveng.pdf.

Ottmar, R., Andreu, A. (2007). Litter and duff bulk densities in the southern United States. Final report, JFSP project, 04-2.

Ottmar, R.D. (2019). Ladder Fuels. En: S., Manzello (ed.) Encyclopedia of Wildfires and Wildland-Urban Interface (WUI) Fires. Springer.

Owers, C.J., Rogers, K., Woodroffe, C.D. (2018). Terrestrial laser scanning to quantify above-ground biomass of structurally complex coastal wetland vegetation. *Estuarine, Coastal and Shelf Science*, *204*, 164-176.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Panagiotidis, D., Abdollahnejad, A., Slavík, M. (2021). Assessment of Stem Volume on Plots Using Terrestrial Laser Scanner: A Precision Forestry Application. *Sensors, 21*, 301.

Pausas, J.G. (2020). Incendios forestales. Una visión desde la ecología. Colección ¿Qué sabemos de?. Consejo Superior de Investigaciones Científicas. Madrid.

Pierce, A.D., Farris, C.A., Taylor, A.H. 2012. Use of random forests for modeling and mapping forest canopy fuels for fire behavior analysis in Lassen Volcanic National Park, California, U.S.A. *Forest Ecology and Management*, *279*, 77–89.

Pimont, F., Dupuy, J.L., Rigolot, E., Prat, V., Piboule, A. (2015). Estimating leaf bulk density distribution in a tree canopy using terrestrial LiDAR and a straightforward calibration procedure. *Remote Sensing*, *7*(6), 7995-8018.

Plucinski, M.P., Sullivan, A.L., Rucinski, C.J., Prakash, M. (2017). Improving the reliability and utility of operational bushfire behaviour predictions in Australian vegetation. *Environmental Modelling & Software*, *91*, 1–12.

Puletti, N., Grotti, M., Ferrara, C., Scalercio, S. (2021). Traditionaland TLS-based forest inventories of beechand pine forests located in Sila National Park: A dataset. *Data in Brief*, *34*, 106617.

Pyne, S.J., Andrews, P.L, Laven, R.D. (1996). Introduction to wildland fire. John Wiley & Sons, Inc. USA. 769 pp.

R Core Team (2020). R: A Language and Environment for Statistical Computing; R Foundation for Statistical Computing: Vienna, Austria. https://www.R-project.org/.

Rahmanian, S., Pourghasemi, H.R., Pouyan, S., Karami, S. (2021). Habitat potential modelling and mapping of Teucriumpolium using machine learning techniques. *Environmental Monitoring and Assessment*, *193*, 1-21,

Reitberger, J., Schnörr, C., Krzystek, P., Stilla, U. (2008). 3D segmentation of full waveform LIDAR data for single tree detection using normalized cut. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, *37*(Part 3A), 77-83.

Riaño, D., Chuvieco, E., Salas, J., Palacios-Orueta, A., Bastarrika, A. (2002). Generation of fuel type maps from Landsat TM images and ancillary data in Mediterranean ecosystems. *Canadian Journal of Forest Research*, *32*, 1301–1315.

Riaño D., Meier E., Allgöwer B., Chuvieco E., Ustin, S.L. (2003) Modeling airborne laser scanning data for the spatial generation of critical forest parameters in fire behavior modeling. *Remote Sensing of Environment, 86*, 177–186.

Riaño, D., Ustin, S.L., Usero, L., Patricio, M.A. (2005). Estimation of fuel moisture content using neural networks. En J., Mira, J.R., Álvarez (eds.) IWINAC 2005: Artificial Intelligence and Knowledge Engineering Applications: A Bioinspired Approach. Lecture Notes in Computer Science, Springer, Berlin, Heidelberg. Vol. 3562, 489–498

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Riaño, D., Chuvieco, E., Ustin, S.L., Salas, J., Rodríguez-Pérez, J.R., Ribeiro, L.M., Viegas, D.X., Moreno, J.M., Fernández, H. (2007). Estimation of shrub height for fuel-type mapping combining airborne LiDAR and simultaneous color infrared ortho imaging. *International Journal of Wildland Fire*, *16*(3), 341-348.

Riley, K.L., Grenfell, I.C., Finney, M.A., Crookston, N.L. (2014). Utilizing random forests imputation of forest plot data for landscape-level wildfire analyses. En D.X., Viegas (ed.). Advances in Forest Fire Research. Coimbra, Portugal, 583-590.

Rodríguez, R.J., Madrigal, A. (2008). Selvicultura de *Pinus pinaster* Ait. Sub sp. *atlantica* H. de Vill. En R., Serrada, G., Montero, J.A., Reque (eds.). Compendio de selvicultura aplicada en España. Instituto Nacional de Investigación y Tecnología Agraria y Alimentaria. Madrid.

Rodríguez y Silva, F.R., Molina, J.R., González-Cabán, A., Machuca, M.Á.H. (2012). Economic vulnerability of timber resources to forest fires. *Journal of Environmental Management*, *100*, 16-21.

Rowell, E., Loudermilk, E.L., Seielstad, C., O'Brien, J.J. (2016a). Using simulated 3D surface fuelbeds and terrestrial laser scan data to develop inputs to fire behavior models. *Canadian Journal of Remote Sensing*, *42*(5), 443-459.

Rowell, E.M., Seielstad, C.A., Ottmar, R.D. (2016b). Development and validation of fuel height models for terrestrial lidar—RxCADRE 2012. *International Journal of Wildland Fire, 25*, 38–47.

Rowell, E., Loudermilk, E.L., Hawley, C., Pokswinski, S., Seielstad, C., Queen, L., O´Brien, J., Hudak, A.T., Goodrick, S., Hiers, J.K. (2020). Coupling terrestrial laser scanning with 3D fuel biomass sampling for advancing wildland fuels characterization. *Forest Ecology and Management*, *462*, 117945.

Ruiz González, A.D., Vega Hidalgo, J.A. (2007). Modelos de predicción de la humedad de los combustibles muertos: fundamentos y aplicación. Monografías INIA: Serie Forestal nº15. Madrid.

Ruiz-González, A.D., Álvarez-González, J.G. (2011). Canopy bulk density and canopy base height equations for assessing crown fire hazard in *Pinus radiata* plantations. *Canadian Journal of Forest Research, 41*, 839–850.

Ruíz-González, A.D., Castedo-Dorado, F., Vega, J.A., Jiménez, E., Fernández-Alonso, J.M., Álvarez-González, J.G. (2015). Modelling canopy fuel dynamics of maritime pine stands in north-west Spain. *International Journal of Wildland Fire*, *24*(1), 92-102.

Safonova, A., Tabik, S., Alcaraz-Segura, D., Rubtsov, A., Maglinets, Y., Herrera, F. (2019). Detection of firtrees (*Abies sibirica*) damaged by the bark beetle inunmanned aerial vehicle images with deep learning. *Remote Sensing*, *11*(6), 643.

Salcedo-Sanz, S., Ghamisi, P., Piles, M., Werner, M., Cuadra, L., Moreno-Martínez, A., Izquierdo-Verdiguier, E., Muñoz-Marí, J., Mosavi, A., Camps-Valls, G. (2020). Machine

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

learning information fusion in earth observation: a comprehensive review of methods, applications and data sources. *Information Fusion*, *22*, 480–545.

Sánchez, F., Rodríguez, R.J. (2008). Selvicultura de *Pinus radiata* D. Don. En R., Serrada, G., Montero, J.A., Reque (eds.). Compendio de selvicultura aplicada en España. Instituto Nacional de Investigación y Tecnología Agraria y Alimentaria. Madrid.

Sando, R.W., Wick, C.H. (1972). A Method of Evaluating Crown Fuels in Forest Stands. USDA Forest Service. North Central Forest Experiment Station. Res. Pap. NC-84. St. Paul, Minnesota 10 p.

San-Miguel-Ayanz, J., Durrant, T., Boca, R., Libertà, G., Branco, A., De Rigo, D., Ferrari, D., Pfeiffer, H., Grecchi, R., Nuitjen, D., Artes-Vivancos, T., Oom, D., Maianti, P. (2020). Advance EFFIS report on forest fires in Europe, Middle East and North Africa 2019. EUR 30222 EN, Publications Office of the European Union, Luxembourg, 2020.

SAS Institute Inc. SAS/ETS®9.1 User's Guide; SAS Institute Inc.: Cary, NC, USA, 2004.

Scott, J.H., Reinhardt, E.D. (2001). Assessing Crown Fire Potential by Linking Models of Surface and Crown Fire Behavior. USDA Forest Service, Rocky Mountain Research Station, Res. Pap. RMRS-RP-29: Fort Collins, CO, USA.

Shen, C. (2018). A transdisciplinary review of deep learning research and its relevance for water resources scientists. *Water Resources Research*, *54*(11), 8558–8593.

Shi, W., Zhang, M., Zhang, R., Chen, S. (2020). Change detection based on artificial intelligence: state-of-the-art and challenges. *Remote Sensing*, *12*(10), 1688.

Sims, D.A., Gamon, J.A., (2003). Estimation of vegetation water content and photosynthetic tissue area from spectral reflectance: a comparison of indices based on liquid water and chlorophyll absorption features. *Remote Sensing of Environment*, *84*(4), 526–537.

Skowronski, N.S., Clark, K.L., Duveneck, M., Hom, J. (2011). Three-dimensional canopy fuel loading predicted using upward and downward sensing LiDAR systems. *Remote Sensing of Environment, 115*, 703–714.

Srinivasan, S., Popescu, S., Eriksson, M., Sheridan, R.D., Ku, N.W. (2015). Terrestrial Laser Scanning as an Effective Tool to Retrieve Tree Level Height, Crown Width, and Stem Diameter. *Remote Sensing, 7*, 1877–1896.

Stocks, B.J., Alexander, M.E., Wotton, B.M., Stefner, C.N., Flannigan, M.D., Taylor, S.W., Lavoie, N., Mason, J.A., Hartley, G.R., Maffey, M.E., Dalrymple, G.N., Blake, T.W., Cruz, M.G., Lanoville, R.A. (2004). Crown fire behaviour in a northern jack pine - Black spruce forest. *Canadian Journal of Forest Research*, *34*(8), 1548–1560.

Stovall, A.E., Vorster, A.G., Anderson, R.S., Evangelista, P.H., Shugart, H.H. (2017). Non-destructive aboveground biomass estimation of coniferous trees using terrestrial LiDAR. *Remote Sensing of Environment*, *200*, 31-42.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Strahler, A.H., Jupp, D.L.B., Woodcock, C.E., Schaaf, C.B., Yao, T., Zhao, F., Yang, X., Lovell, J., Culvenor, D., Newnham,G., Ni-Miester, W., Boykin-Morris, W. (2008). Retrieval of forest structural parameters using aground-based lidar instrument (Echidna®). *Canadian Journal of Remote Sensing, 34*, S426–S440.

Sun, A.Y., Scanlon, B.R. (2019). How can big data and machine learning benefit environment and water management: a survey of methods, applications, and future directions. *Environmental Research Letters*, *14*.

Sylvain, J.D., Drolet, G., Brown, N. (2019). Mapping dead forest cover using a deep convolutional neural network and digital aerial photography. *ISPRS Journal of Photogrammetry and Remote Sensing*, *156*, 14-26.

Tang, S., Li, Y., Wang, Y. (2001). Simultaneous equations, error-invariable models, and model integration in systems ecology. *Ecological Modellling*, *142*, 285–294.

Tang, S., Wang, Y.A. (2002) A parameter estimation program for the error-in-variable model. *Ecological Modellling*, 156, 225–236.

Torralba, J., Crespo-Peremarch, P., Ruiz, L.Á. (2018). Assessingthe use of discrete, full-wave form LiDAR and TLS to classify Mediterranean forest species composition. *Revista de Teledetección*, *52*, 27-40.

Torralba, J., Ruiz, L.A., Carbonell-Rivera, J.P., Crespo-Peremarch, P. (2019). Análisis de posiciones y densidades TLS (Terrestrial Laser Scanning) para optimizar la estimación de parámetros forestales. En Teledetección: Hacia una Visión Global del Cambio Climático. L.A., Ruiz, J., Estornell, A., Calle, J.C., Antuña-Sánchez (eds.). Universidad de Valladolid, Valladolid, España, pp. 443–446.

Vaillant, N.M., Reinhardt, E.D. (2017). An evaluation of the Forest Service Hazardous Fuels Treatment Program—Are we treating enough to promote resiliency or reduce hazard?. *Journal of Forestry*, *115*(4), 300-308.

Van Wagner, C.E. (1977). Conditions for the start and spread of crown fire. *Canadian Journal of Forest Research, 7,* 23–34.

Vastaranta, M., Saarinen, N., Kankare, V., Holopainen, M., Kaartinen, H., Hyyppä, J., Hyyppä, H. (2014). Multisource single-tree inventory in the prediction of tree quality variables and logging recoveries. *Remote Sensing*, *6*, 3475–3491.

Vega Alonso, P., Vega Alonso, G., González Rosales, M., Rodríguez San José, A. (1993). Mejora del *Pinus pinaster* Ait. en Galicia. I Congreso Forestal Español, 14–18 de junio de 1993, Lourizán, Pontevedra. pp. 129–134. Tomo II.

Vega, J.A., Fernández, C., Jimémez, E., Ruíz-González, A.D. (2009a). Impacto dun escenario de cambio climático sobre o perigo de incendios forestais en Galicia. En Pérez Muñuzuri, V., Fernández Cañamero, M., Gómez Gesteira, J.L. (coords.). Evidencias e impactos do cambio climático en Galicia, Santiago de Compostela, Xunta de Galicia, 583-607.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Vega, J.A., Arellano-Pérez, S.A., Fernández, C., Lliteras, M.T.F., Ruíz-González, A.D. (2021). Os incendios forestais do cambio global xa están aquí: un desafío e unha ocasión para lograr unha resposta social consensuada. En Unha nova xeración de lumes?. Actas do Coloquio Galaico-Portugués sobre Incendios Forestais. Consello da Cultura Galega. pp. 49-119

Vega, J.A., Arellano-Pérez, S., Álvarez-González, J.G., Fernández, C., Jiménez, E., Cuiñas, P., Fernandez-Alonso, J.M., Vega-Nieva, D.J., Castedo-Dorado, F., Alonso-Rego, C., Fontúrbel, T., Ruiz-González, A.D. (2022a). Modelling fuel loads of understorey vegetation and forest floor components in pine stands in NW Spain. *Forest Ecosystems*, *9*, 100074.

Vega, J.A., Arellano-Pérez, S., Álvarez-González, J.G., Fernández, C., Jiménez, E., Fernández-Alonso, J.M., Vega-Nieva, D.J., Briones Herrera, C., Alonso-Rego, C., Fontúrbel, T., Ruiz-González, A.D. (2022b). Modelling aboveground biomass and fuel load components at stand level in shrub communities in NW Spain. *Forest Ecology and Management*, *505*, 119926.

Viana, H., Aranha, J., Lopes, D., Cohen, W.B. (2012a). Estimation of crown biomass of *Pinus pinaster* stands and shrubland above-ground biomass using forest inventory data, remotely sensed imagery and spatial prediction models. *Ecological Modelling*, *226*, 22-35.

Viana, H., Vega-Nieva, D.J., Torres, L.O., Lousada, J., Aranha, J. (2012b). Fuel characterization and biomass combustion properties of selected native woody shrub species from central Portugal and NW Spain. *Fuel*, *102*, 737-745.

Viegas, D.X. (1998). Forest fire propagation. *Philosophical Transactions of the Royal Society of London*. *Series A: Mathematical, Physical and Engineering Sciences*, *356*(1748), 2907-2928.

Vierling, L.A., Xu, Y., Eitel, J.U.H., Oldow, J.S. (2013). Shrub characterization using terrestrial laser scanning and implications for airborne LiDAR assessment. *Canadian Journal of Remote Sensing, 38*,709–722.

Wagner, W., Hollaus, M., Briese, C., Ducic, V. (2008). 3D vegetation mapping using small-footprint full-waveform airborne laser scanners. *International Journal of Remote Sensing*, *29*(5), 1433-1452.

Wallace, L., Hillman, S., Reinke, K., Hally, B. (2017). Non-destructive estimation of above-ground surface and near-surface biomass using 3D terrestrial remote sensing techniques. *Methods in Ecology and Evolution, 8*, 1607–1616.

Wang, J., Xi, Z., Yang, B., Zheng, G., Kankare, V., Luoma, V., Yu, X., Chen, L., Vastaranta, M., Saarinen, N., Wang, Y. (2018). International benchmarking of terrestrial laser scanning approaches for forest inventories. *ISPRS Journal of Photogrammetry and Remote Sensing*, *144*, 137-179.

Wang, H., Seaborn, T., Wang, Z., Caudill, C.C., Link, T.E. (2021). Modeling tree canopy height using machine learning over mixed vegetation landscapes. *International Journal of Applied Earth Observations and Geoinformation*, *101*, 102353.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Watt, P.J., Donoghue, D.N.M. (2005). Measuring forest structure with terrestrial laser scanning. *International Journal of Remote Sensing, 26*, 1437–1446.

White, H. (1980). A heteroskedasticity-consistent covariance matrix estimator and a direct test for heteroskedasticity. *Econometrica*, *48*, 817–838.

White, J.C., Coops, N.C., Wulder, M.A., Vastaranta, M., Hilker, T., Tompalski, P. (2016). Remote sensing technologies for enhancing forest inventories: A review. *Canadian Journal of Remote Sensing*, *42*(5), 619-641.

Wilson, N., Bradstock, R., Bedward, M. (2021). Detecting the effects of logging and wildfire on forest fuel structure using terrestrial laser scanning (TLS). *Forest Ecology and Management, 488*, 119037.

Xu, D., Wang, H., Xu, W., Luan, Z., Xu, X. (2021). LiDAR Applications to Estimate Forest Biomass at Individual Tree Scale: Opportunities, Challenges and Future Perspectives. *Forests, 12*, 550.

Xu, K., Su, Y., Liu, J., Hu, T., Jin, S., Ma, Q., Zhai, Q., Wang, R., Zhang, J., Li, Y., Liu, H., Guo, Q. (2020). Estimation of degraded grass land aboveground biomass using machine learning methods from terrestrial laser scanning data. *Ecological Indicators, 108*,105747.

Xunta de Galicia (2022). Anuario de Estadística Forestal de Galicia 2022. Santiago de Compostela. Dirección Xeral de Montes e Medio Ambiente Natural. https://mediorural.xunta.gal/es/recursos/estadisticas/estadisticas-forestales

Xunta de Galicia (2022). PLADIGA. Consellería de Medio Rural. https://mediorural.xunta.gal/sites/default/files/temas/forestal/pladiga/2022/01_Memoria_Pladiga_2022_Cast.pdf

Yao, T., Yang, X., Zhao, F., Wang, Z., Zhang, Q., Jupp, D., Lovell, J., Culvenor, D., Newnham, G., Ni-Meister, W., Schaaf, C., Woodcock, C., Wang, J., Li, X., Strahler, A. (2011). Measuring forest structure and biomass in New England forest stands using Echidna ground-based lidar. *Remote Sensing of Environment, 115*, 2965–2974.

Zhang, W., Qi, J., Wan, P., Wang, H., Xie, D., Wang, X., Yan, G. (2016). An easy-to-use airborne LiDAR data filtering method based on cloth simulation. *Remote Sensing, 8*, 501.

Zhou, L., Pan, S., Wang, J., Vasilakos, A.V. (2017). Machine learning on big data: Opportunities and challenges. *Neurocomputing*, *237*, 350-361.

USC
UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

ANEXO A

Estimating Fuel Loads and Structural Characteristics of Shrub Communities by Using Terrestrial Laser Scanning

(Artículo 1)

Cecilia Alonso-Rego

Stéfano Arellano-Pérez

Carlos Cabo

Celestino Ordoñez

Juan Gabriel Álvarez-González

Ramón Alberto Díaz-Varela

Ana Daría Ruíz-González

Remote Sensing, 2020, 12, 3704

https://doi.org/10.3390/rs12223704

La revista *Remote Sensing* pertenece a la editorial MPDI, que permite la reutilización del artículo por la autora como parte de su tesis doctoral: https://www.mdpi.com/authors/rights

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

remote sensing

MDPI

Article

Estimating Fuel Loads and Structural Characteristics of Shrub Communities by Using Terrestrial Laser Scanning

Cecilia Alonso-Rego [1], Stéfano Arellano-Pérez [1], Carlos Cabo [2,3], Celestino Ordoñez [2], Juan Gabriel Álvarez-González [1], Ramón Alberto Díaz-Varela [4] and Ana Daría Ruiz-González [1,*]

1 Departamento de Ingeniería Agroforestal, Escola Politécnica Superior de Enxeñaría, Universidade de Santiago de Compostela, Campus Universitario s/n, 27002 Lugo, Spain; c.alonso.rego@usc.es (C.A.-R.); stefano.arellano@usc.es (S.A.-P.); juangabriel.alvarez@usc.es (J.G.Á.-G.)
2 Departamento de Explotación y Prospección de Minas, Universidad de Oviedo, 33003 Oviedo, Spain; carloscabo@uniovi.es (C.C.); ordonezcelestino@uniovi.es (C.O.)
3 College of Science, Swansea University, Singleton Campus, Swansea SA2 8PP, UK
4 GI-1809-BioAplic, Departamento de Botánica, Escola Politécnica Superior de Enxeñaría, Universidade de Santiago de Compostela, Campus Universitario s/n, 27002 Lugo, Spain; ramon.diaz@usc.es
* Correspondence: anadaria.ruiz@usc.es

Received: 16 October 2020; Accepted: 9 November 2020; Published: 11 November 2020

Abstract: Forest fuel loads and structural characteristics strongly affect fire behavior, regulating the rate of spread, fireline intensity, and flame length. Accurate fuel characterization, including disaggregation of the fuel load by size classes, is therefore essential to obtain reliable predictions from fire behavior simulators and to support decision-making in fuel management and fire hazard prediction. A total of 55 sample plots of four of the main non-tree covered shrub communities in NW Spain were non-destructively sampled to estimate litter depth and shrub cover and height for species. Fuel loads were estimated from species-specific equations. Moreover, a single terrestrial laser scanning (TLS) scan was collected in each sample plot and features related to the vertical and horizontal distribution of the cloud points were calculated. Two alternative approaches for estimating size-disaggregated fuel loads and live/dead fractions from TLS data were compared: (i) a two-steps indirect estimation approach (IE) based on fitting three equations to estimate shrub height and cover and litter depth from TLS data and then use those estimates as inputs of the existing species-specific fuel load equations by size fractions based on these three variables; and (ii) a direct estimation approach (DE), consisting of fitting seven equations, one for each fuel fraction, to relate the fuel load estimates to TLS data. Overall, the direct approach produced more balanced goodness-of-fit statistics for the seven fractions considered jointly, suggesting that it performed better than the indirect approach, with equations explaining more than 80% of the observed variability for all species and fractions, except the litter loads.

Keywords: live/dead fuel fractions; shrub cover; shrub height; litter depth; simultaneous fitting; fuel load additivity; stand level equations

1. Introduction

Fuel load, defined as the fuel dry biomass per unit area, is a particularly important forest fuel characteristic [1,2] as it represents the amount of live and dead biomass available for ignition and combustion. Along with other structural characteristics, fuel load strongly affects fire behavior, regulating the rate of spread, fireline intensity, and flame length [3,4]. Accurate fuel characterization, including the

fuel load disaggregated by size classes and vegetative status (live and dead fractions), is essential to obtain reliable predictions from fire behavior simulators in order to support decision-making in fuel management and fire hazard prediction [5,6]. Fuel load is also an essential component in carbon cycle assessment and in models used to predict fire emissions and smoke impacts [7–10].

In the NW Iberian Peninsula, the fast shrub growth associated with mild annual temperatures and high rainfall promotes large accumulations of surface fuel that favor high intensity surface wildfires [11]. Indeed, the area is one of the most severely affected by fire in Europe [12,13]. Recent studies have reported an increase in fire activity in terms of both frequency and burnt area, mainly corresponding to eastern flows during summer, with a substantial contribution from southeastern advections in winter [14–16]. In Galicia, located in the westernmost part of this region, the problem is especially important in shrublands, as 63% of the total area burned in this region in the last 20 years has affected non-tree shrub communities [17], even though these communities represent only about 30% of the total forest area and 20% of the total area of the region [18].

The fuel load of shrub communities, i.e., shrub and litter layers, can be quantified by different methods, including destructive and non-destructive sampling [19]. Destructive sampling is the most accurate method of determining fuel load, but also the most complex and costly in time and money, and it is therefore difficult to apply to large areas [2,20]. Non-destructive sampling enables indirect estimation of the fuel load, usually by using allometric relationships between fuel loads and fuel characteristics that are easily measured in the field [21–23].

In the last two decades new models relating fuelbed characteristics to remotely sensed data have been developed by using information obtained from satellite images [24–28] or airborne laser scanner (ALS) data [29–33]. This has enabled the construction of thematic fuel maps for fire simulation and fire risk assessment. However, the accuracy of the model estimates largely depends on the accuracy of the digital terrain model (DTM) generated, which is, in turn, affected by the density of the vegetation and the orography [34]. Thus, in very dense shrubland and rugged terrain, typical of the Galician territory, shrub height and volume tend to be underestimated [35–37].

Terrestrial laser scanning (TLS) has evolved as a non-destructive measurement technique that produces data (3D point clouds) of great potential for use in forestry applications. Such uses include the assessment of tree and stand level biomass and carbon [38–41] and also the accurate quantification of relevant fuelbed characteristics for determining fire behavior, fuel consumed and smoke emissions [42–45]. In addition, studies in which TLS data are combined or compared with ALS data [46–50], data from unmanned aerial vehicles [51,52] or satellite images [53] have become more frequent in recent years for various forestry applications.

Most TLS-based studies estimating shrub biomass or volume have focused on the reconstruction of the shrub shape from the point cloud, either by piecewise approximation of the volume or by voxelization. For example, Olsoy et al. [43] estimated the biomass of sagebrush (*Artemisia tridentata*) using both voxel counting and a 3-D convex hull approach, concluding that the 3-D convex hull model estimated total and green biomass more accurately than the voxelization approach. Greaves et al. [54] also compared both approaches for estimating harvested biomass of two dominant Alaskan tundra shrub species, using point clouds obtained from close-range (2 m) and variable-range (<50 m) TLS, and reported better results for voxel counting in close-range data and stronger relationships for the surface difference approach for variable-range data. Hudak et al. [49] and Rowell et al. [55] adapted the "3D field sampling protocol" proposed by Hawley et al. [56] to infer fine-scale fuel mass in 3D, observing that mass was strongly related to the voxel-occupancy volume, porosity, and surface area, which were used to develop equations for fine-scale prediction.

In general, fuel characterization studies with TLS are carried out in tree-covered shrub communities, often characterized by a heterogeneous spatial distribution on the ground, and they usually focus on obtaining detailed fuel information for applying physical-based fire models, such as WRF-SFIRE-CHEM [57,58], WFDSS [59,60], and FIRETEC [61,62], which require spatially explicit, three-dimensional data [63]. However, the use of TLS data should not be restricted to obtaining geometric information on a scale as detailed as that

required for the use of physical-based models that operate in 3D, but should be tested for potential use in obtaining the fuel characteristics required for the application of more operational simulators such as Farsite and Flammap [64,65]. In addition, such detailed studies require several scans from different positions, often at least 5 to 9 scans, indicating a very time-consuming field inventory and subsequent processing of the point clouds to obtain a single cloud. Studies that use TLS to predict biomass distribution without reconstructing shapes from the returns are scarce. Accordingly, the aim of this study was to test the potential use of TLS data to provide accurate fuel load estimates of size-disaggregated shrub and litter and live/dead fractions for four of the main non-tree covered shrub communities in Galicia (NW Spain) by using data from a single scan. For this purpose, two alternative approaches will be compared, one direct estimation approach and a two-steps indirect estimation approach.

2. Materials and Methods

2.1. Shrub Communities and Plots

Shrubland areas in the study area (Galicia, NW Spain) are usually covered by gorse (genus *Ulex*), heath (genus *Erica*) and broom (genera *Pterospartum*, *Cytisus* and *Genista*), covering 55%, 22%, and 11% of the shrubland area, respectively [66]. Four treeless shrub communities were selected and characterized by the dominant species (Table 1). The communities selected are widely represented in Galicia [18,66] and are among the most frequently affected by wildfires in the region. All the communities considered are multiannual woody shrubs with stems branching from the base.

Table 1. Shrub community, number of plots, codes, and dominant and secondary species.

Shrub Community	No. of Plots	Code	Dominant Shrub Species	Secondary Species
High heath	15	*Ea*	*Erica australis* L.	*Pterospartum tridentatum*, *Halimium alyssoides* (Lam.) Greuter, *Erica arborea* L., *Ulex europaeus*
Prickled broom	10	*Pt*	*Pterospartum tridentatum* (L) Willk.	*Erica umbellata* Loefle ex L., *Halimium alyssoides*, *Erica australis* L., *Ulex gallii*, *Ulex europaeus*, *Pteridium aquilinum* (L.) Kuhn
High gorse	15	*Ue*	*Ulex europaeus* L.	*Ulex gallii*, *Erica umbellata*, *Pteridium aquilinum*, *Pterospartum tridentatum*,
Low gorse	15	*Ug*	*Ulex gallii* Planch./ *Ulex minor* Roth.	*Ulex europaeus*, *Erica umbellata*, *Daboecia cantábrica* (Huds.) K.Koch, *Pterospartum tridentatum*, *Pteridium aquilinum*

Subjective sampling was carried out to select a representative sample of each of the 4 shrub communities by taking the main structural fuel attributes observed in the study area into account. The plots were located using information obtained from different sources, particularly the Spanish Forest Map [66,67]. A total of 55 sample sites were selected in areas where the dominant shrub species of each community predominated, and shrub cover was higher than 80%. The spatial distribution of the sampled plots throughout the study area is shown in Figure 1.

2.2. Field Inventories and Determination of Fuel Characteristics

Field measurements were made in the shrub and litter layers of each sample plot by randomly locating a 2 × 2 m sampling square with sides parallel to the contour line and to the maximum slope. Each sampling square was delimited with four wooden stakes and all the vegetation in a 0.5-m strip around the square was removed, except the side where the TLS was located, where a 4-m strip of vegetation was removed.

A sampling transect consisting of the plot perimeter plus one diagonal of the square was outlined. The horizontal lengths of the intercepted shrub species (cm) were measured along this linear transect,

to estimate the linear shrub cover (Cov_{Shr}) according to the method proposed by Canfield [68]. Moreover, dead and live base height, total shrub height of the intercepted species (cm) and litter depth were also measured (every 50 cm). As the separation between the litter and duff layers is not always very clear in shrub communities, both layers were sampled together as litter. Shrub height was measured as the vertical distance between the litter layer and the top of vegetation. All the shrub and litter structural measurements were averaged to produce the mean shrub height ($\overline{h_{Shr}}$) and mean litter depth ($\overline{d_{Litt}}$).

For each community, the fuel loads were estimated using the species-specific biomass equations systems at stand level developed for treeless shrub communities in Galicia [69], with Cov_{Shr}, $\overline{h_{Shr}}$ and $\overline{d_{Litt}}$ as inputs. These systems include equations for each of the following seven fractions: dead fine shrub load (diameter < 0.6 cm; $W_{Shr_G1_dead}$); live fine shrub load (diameter < 0.6 cm; $W_{Shr_G1_live}$); fine shrub load (diameter < 0.6 cm; W_{Shr_G1}, dead + live); coarse shrub load (diameter ≥ 0.6 cm; W_{Shr_G23}); total shrub load (W_{Shr}, fine + coarse); litter load (W_{Litt}); and total shrub; and litter fuel load ($W_{Shr+Litt}$). The basic descriptive statistics of shrub and litter layers for the main structural characteristics of each shrub community are shown in Table 2.

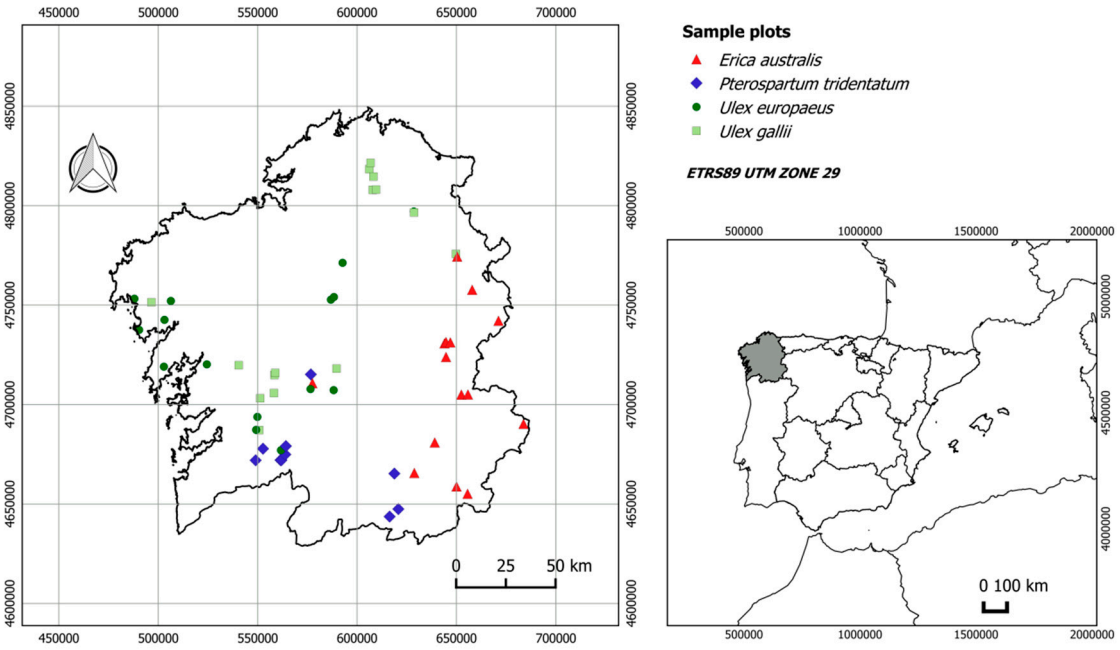

Figure 1. Geographical location of the 55 plots in Galicia grouped in 4 shrub communities.

2.3. TLS Data

Each sampling square was scanned once using a FARO Laser Scanner Focus3D X 130 TLS to collect three-dimensional point clouds with a density of ~7.67 mm point spacing at 10 m. The TLS is a class I laser (wavelength = 1550 nm) with a range of 0.6 to 130 m for objects with 90% reflectivity and with an accuracy of ±2 mm at 10 m range. Scanning was conducted by locating the TLS at a distance of 3 m from the contour line side of the square sampling located downhill.

The point clouds from the single scans on each sampling square were cropped and height was normalized. All points outside of the squares were removed, and the height above the terrain of each point (h) was calculated from digital elevation models (DEMs) created from each scan. DEMs were generated by interpolation, according to the lowest laser return within a 2 × 2 cm grid, in order to maintain consistency with the field measurements. The heights were then calculated by subtracting the smoothed DEM from the z values. These values were used to calculate 32 metrics related to the vertical distribution of the point clouds. The metrics and the corresponding descriptions are summarized in Table 3.

USC UNIVERSIDADE DE COMPOSTELA

Table 2. Description of the main shrub and litter characteristics. Std. dev. is the standard deviation, n is the number of plots, $\overline{h_{Shr}}$ is the mean shrub height, Cov_{Shr} is the shrub cover, $\overline{d_{Litt}}$ is the mean litter depth, $W_{Shr_G1_dead}$ is the dead fine shrub fuel load, $W_{Shr_G1_live}$ is the live fine shrub fuel load, W_{Shr_G1} is the fine shrub fuel load, W_{Shr_G23} is the coarse shrub fuel load, W_{Shr} is the total shrub fuel load, W_{Litt} is the litter fuel load, and $W_{Shr+Litt}$ is the shrub and litter fuel load.

Variable	Statistic	Ea	Pt	Ue	Ug
	n	15	10	15	15
$\overline{h_{Shr}}$ (cm)	Mean (std. dev.)	84.91 (31.48)	90.37 (33.94)	108.18 (19.95)	65.43 (21.77)
	Range	38.24–150.76	42.86–151.05	59.71–113.10	13.90–109.33
Cov_{Shr} (%)	Mean (std. dev.)	99.80 (0.52)	99.34 (1.20)	99.64 (0.77)	98.32 (3.17)
	Range	98.15–100	96.3–100	97.69–100	87.5–100
$\overline{d_{Litt}}$ (cm)	Mean (std. dev.)	2.38 (1.17)	4.03 (1.19)	5.49 (2.11)	4.56 (0.98)
	Range	0.78–5.60	2.02–5.86	3.08–10.55	2.40–5.81
$W_{Shr_G1_dead}$ (kg m^{-2})	Mean (std. dev.)	0.41 (0.12)	0.84 (0.17)	0.89 (0.09)	0.75 (0.18)
	Range	0.20–0.63	0.58–1.01	0.65–1.00	0.20–1.00
$W_{Shr_G1_live}$ (kg m^{-2})	Mean (std. dev.)	1.19 (0.23)	1.47 (0.25)	1.40 (0.07)	1.53 (0.23)
	Range	0.76–1.53	1.08–1.73	1.18–1.48	0.72–1.69
W_{Shr_G1} (kg m^{-2})	Mean (std. dev.)	1.60 (0.36)	2.31 (0.42)	2.29 (0.16)	2.28 (0.41)
	Range	0.96–2.16	1.66–2.74	1.83–2.47	0.92–2.69
W_{Shr_G23} (kg m^{-2})	Mean (std. dev.)	0.48 (0.36)	0.62 (0.40)	1.17 (0.31)	0.37 (0.28)
	Range	0.06–1.38	0.12–1.37	0.46–1.58	0–1.09
W_{Shr} (kg m^{-2})	Mean (std. dev.)	2.08 (0.71)	2.93 (0.80)	3.47 (0.47)	2.65 (0.63)
	Range	1.02–3.54	1.77–3.99	2.29–4.05	0.93–3.78
W_{Litt} (kg m^{-2})	Mean (std. dev.)	1.00 (0.36)	1.38 (0.49)	1.89 (0.64)	1.70 (0.35)
	Range	0.45–1.91	0.71–2.25	1.14–3.40	0.93–2.14
$W_{Shr+Litt}$ (kg m^{-2})	Mean (std. dev.)	3.08 (0.99)	4.31 (1.11)	5.35 (1.02)	4.35 (0.84)
	Range	1.70–5.45	2.54–6.24	3.98–7.45	2.51–5.75

Ea = *Erica australis*, Pt = *Pterospartium tridentatum*, Ue = *Ulex europaeus* and Ug = *Ulex gallii*/*Ulex minor*.

Table 3. Potential independent variables related to height distribution.

Metric	Description
h_{max} (cm)	maximum
h_{mean} (cm)	mean
h_{mode} (cm)	mode
h_{median} (cm)	median
h_{SD} (cm)	standard deviation
h_{skw}	skewness
h_{kurt}	kurtosis
h_{ID} (cm)	interquartile distance
h_{01}, h_{05}, h_{10}, h_{15}, h_{20}, … , h_{90}, h_{95}, h_{99} (cm)	percentiles
h_{25} and h_{75} (cm)	first and third quartiles
IQR (cm)	Interquartile range (h_{75}–h_{25})
P_{Ahmean}	ratio of laser returns above h_{mean} to total laser returns
P_{Ahmode}	ratio of laser returns above h_{mode} to total laser returns

Due to shrub occlusions, the TLS-derived metrics vary as the depth of the analyzed laser returns cloud measured from the shrub front increases. Therefore, analysis was carried out to determine the optimum depth (measured from the vertical plane defined by the lowest side of the square) from which the metric values are stabilized, by comparing the values for depths varying from 10 to 50 cm, by 1 cm. This procedure is equivalent to constructing a virtual vertical plane parallel to the sampling square front and extracting all the points that are closer to the scanner than that plane. The results indicated

that 30 cm depth of the laser returns cloud was adequate for all of the sampled plots, so the laser returns clouds were limited to this depth threshold (Figure 2).

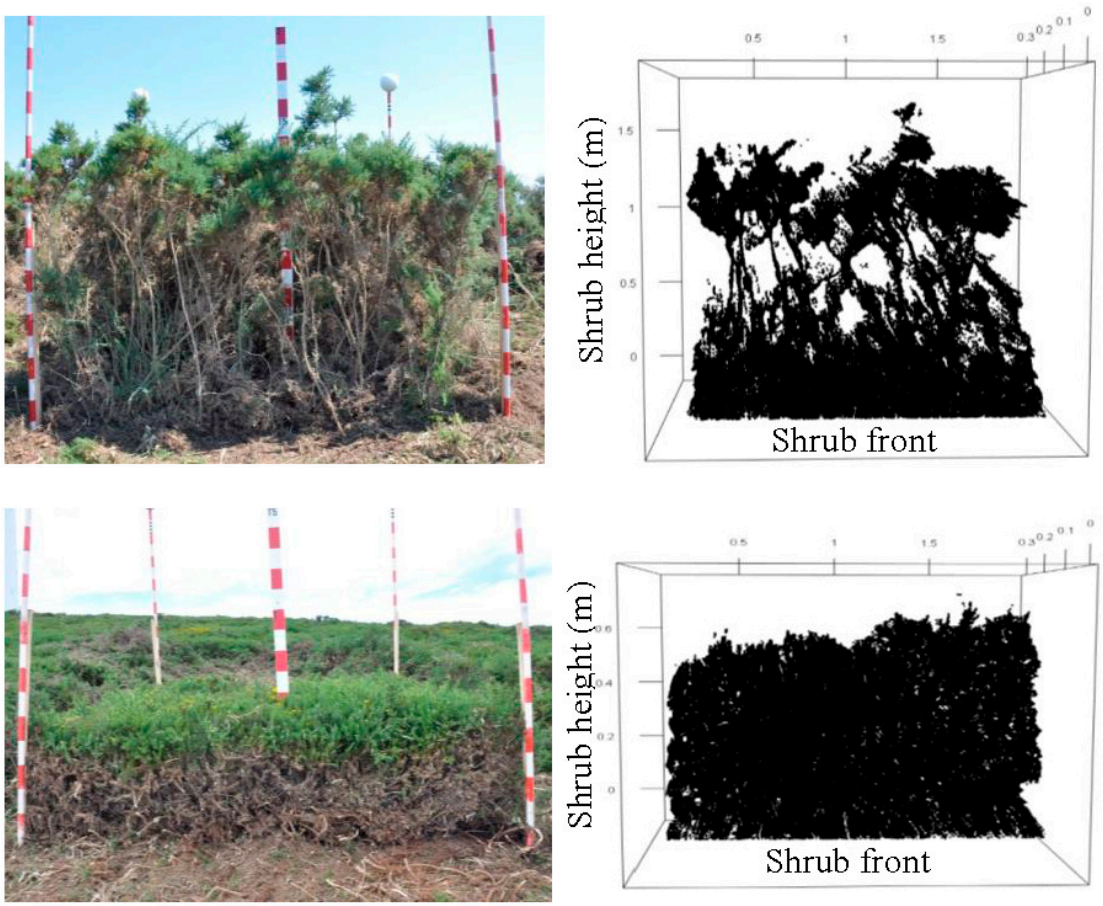

Figure 2. Examples of sample plots with *Ulex europaeus* (**upper**) and *Ulex gallii* (**lower**) and terrestrial laser scanning (TLS)-derived laser returns cloud obtained after raw data processing.

The theoretical vertical shrub cover was estimated as the ratio between the observed number of laser returns and the maximum number of laser returns lr_{max_ver}. The maximum number was estimated considering the vertical plane defined by the lowest side of the square as a continuous solid with height equal to h_{max} and taking the laser scanner density into account. Moreover, the 3-D point clouds for each sample plot ($2 \times 2 \times h_{max}$) were divided into voxels (1 cm^3), and the volume of shrub cover was calculated as the ratio between the number of voxels containing points and the total number of voxels. Both of these ratios were transformed by calculating the arcsine-square root of their values to stabilize the variance and improve normality [70], thus producing the Bliss variables $TLSvCov_{Shr}$ and $TLS3DCov_{Shr}$. Finally, the vertical point distribution was modelled using the two-parameter Weibull probability density function (pdf). For this purpose, the relative frequency of the number of laser returns in each layer of height 1 cm and depth 30 cm was calculated by dividing the number of returns in this layer by the total number of laser returns. The scale (W_{scale}) and shape (W_{shape}) parameters of the Weibull pdf were then estimated using the first and the second moments of the relative distribution of vertical laser returns [71].

Point cloud processing, calculation of the metrics derived from the TLS and estimation of the parameters of the Weibull pdf were programmed in R [72] with the support of the rgl [73] and e1071 [74] libraries.

USC DE COMPOSTELA

The Bliss transformed ratios ($TLSvCov_{Shr}$ and $TLS3DCov_{Shr}$), the Weibull pdf parameters (W_{scale} and W_{shape}) and the 32 metrics related to the vertical distribution of the point clouds (Table 3) were finally considered as potential independent variables in the models for estimating fuel loads.

2.4. Models for Estimating Fuel Loads

Two different approaches for estimating fuel loads from community and biomass fractions were compared: indirect estimation (IE) and direct estimation (DE). The IE approach is based on fitting a set of three equations relating the inputs of the biomass equations developed for these shrub communities in Galicia [69] from usual field measurements (Cov_{Shr}, $\overline{h_{Shr}}$ and $\overline{d_{Litt}}$) to TLS-based metrics and variables and then estimating the fuel loads by using these equations. The DE approach is based on fitting a system of seven equations relating the fuel load of each biomass fraction to TLS-based metrics and variables.

Linear models ($y = \alpha_0 + \alpha_i X_i$) were used to fit $\overline{h_{Shr}}$ and $\overline{d_{Litt}}$ equations in the IE approach and a logistic model with a horizontal asymptote equal to 100 ($y = 100/(1 + \exp(\beta_0 + \beta_i X_i))$ was used for Cov_{Shr}. The best set of independent variables (X_i) was selected using the stepwise variable selection method by previously log-linearization of the logistic model.

Allometric models ($y = \gamma_0 \cdot X_i^{\gamma_i}$) were tested for the seven biomass fractions fitted in the DE approach. These allometric equations must fulfil the property of additivity, i.e., the sum of biomass predictions from separate fuel fractions must equal the biomass prediction from the total biomass model (e.g., the sum of dead fine and live fine shrub load estimates must equal fine shrub load estimates or the sum of fine and coarse shrub load estimates have to equal total shrub load estimates). A disaggregation method focused first on specifying an equation for total biomass and then constrained the form or parameters of fraction equations to ensure additivity was used [75,76].

In the first step, the equation of each fraction was log-linearized and fitted separately using ordinary least squares (OLS) for linear models. The stepwise approach was used to select the best set of independent variables (X_i), and the complete system of seven equations (one per fraction) was then fitted simultaneously to guarantee additivity. The final system of seven equations to be fitted consisted of the following:

1. An equation for estimating total shrub and litter fuel load $\widehat{W_{Shr+Litt}}$

$$\widehat{W_{Shr+Litt}} = a_0 \cdot X_i^{a_i} \quad (1)$$

2. Two allometric equations to estimate total shrub load ($\widehat{W_{Shr}}$) and litter load ($\widehat{W_{Litt}}$): $\widehat{W_{Shr}} = exp\left[b_{0_{Shr}} + b_{i_{Shr}} log(X_i)\right]$ and $\widehat{W_{Litt}} = exp\left[b_{0_{Litt}} + b_{i_{Litt}} log(X_i)\right]$; therefore, considering the ratio between $\widehat{W_{Shr}}$ and $\widehat{W_{Shr+Litt}}$

$$\frac{\widehat{W_{Shr}}}{\widehat{W_{Shr+Litt}}} = \frac{\widehat{W_{Shr}}}{\left(\widehat{W_{Shr}}+\widehat{W_{Litt}}\right)} = \frac{1}{1+\left(\widehat{W_{Litt}}/\widehat{W_{Shr}}\right)} = \\ = \frac{1}{1+\left(exp\left[b_{0_{Litt}}+b_{i_{Litt}} log(X_i)\right]/exp\left[b_{0_{Shr}}+b_{i_{Shr}} log(X_i)\right]\right)}$$

and solving by $\widehat{W_{Shr}}$ Equation (1) was disaggregated in two equations, the first one to estimate the total shrub fuel load:

$$\widehat{W_{Shr}} = \widehat{W_{Shr+Litt}} \cdot \frac{1}{1 + exp[b_0 + b_i \cdot log(X_i)]} \quad (2)$$

where $b_0 = b_{0Litt} - b_{0Shr}$; $b_i = b_{iLitt} - b_{iShr}$, and the second one to estimate the litter fuel load:

$$\widehat{W_{Litt}} = \widehat{W_{Shr+Litt}} - \widehat{W_{Shr}} = \widehat{W_{Shr+Litt}} \cdot \left[1 - \frac{1}{1 + exp[b_0 + b_i \cdot log(X_i)]}\right] \quad (3)$$

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

3. Two allometric equations to estimate coarse shrub load ($\widehat{W_{Shr_G23}}$) and fine shrub load ($\widehat{W_{Shr_G1}}$): $\widehat{W_{Shr_G23}} = exp\left[c_{0_{g23}} + c_{i_{g23}} log(X_i)\right]$ and $\widehat{W_{Shr_G1}} = exp\left[c_{0_{g1}} + c_{i_{g1}} log(X_i)\right]$; therefore, developing the ratio between $\widehat{W_{Shr_G23}}$ and $\widehat{W_{Shr}}$ in a similar way to step 2

$$\frac{\widehat{W_{Shr_G23}}}{\widehat{W_{Shr}}} = \frac{\widehat{W_{Shr_G23}}}{\left(\widehat{W_{Shr_G23}} + \widehat{W_{Shr_G1}}\right)} = \frac{1}{1 + \left(\widehat{W_{Shr_G1}} / \widehat{W_{Shr_G23}}\right)}$$

Equation (2) is disaggregated in two equations, one for estimating the coarse dead fuel loads:

$$\widehat{W_{Shr_G23}} = \widehat{W_{Shr}} \cdot \frac{1}{1 + exp[c_0 + c_i \cdot log(X_i)]} \quad (4)$$

where $c_0 = c_{0g1} - c_{0g23}$; $c_i = c_{ig1} - c_{ig23}$, and a second one for estimating fine shrub fuel load:

$$\widehat{W_{Shr_G1}} = \widehat{W_{Shr}} - \widehat{W_{Shr_G23}} = \widehat{W_{Shr}} \cdot \left[1 - \frac{1}{1 + exp[c_0 + c_i \cdot log(X_i)]}\right] \quad (5)$$

4. Finally, disaggregation of Equation (5) in a similar way produced two allometric equations for discriminating between dead fine ($\widehat{W_{Shr_G1_dead}}$) and live fine fuel loads ($\widehat{W_{Shr_G1_live}}$):

$$\widehat{W_{Shr_G1_dead}} = exp\left[d_{0_{g1_dead}} + d_{i_{g1_dead}} log(X_i)\right]$$
$$\widehat{W_{Shr_G1_live}} = exp\left[d_{0_{g1_live}} + d_{i_{g1_live}} log(X_i)\right]$$
$$\frac{\widehat{W_{Shr_G1_dead}}}{\widehat{W_{Shr_G1}}} = \frac{\widehat{W_{Shr_G1_dead}}}{\left(\widehat{W_{Shr_G1_dead}} + \widehat{W_{Shr_G1_live}}\right)} = \frac{1}{1 + \left(\widehat{W_{Shr_G1_live}} / \widehat{W_{Shr_G1_dead}}\right)}$$

The equation for estimating the fine dead fuel loads was then as follows:

$$\widehat{W_{Shr_G1_dead}} = \widehat{W_{Shr_G1}} \cdot \frac{1}{1 + exp[d_0 + d_i \cdot log(X_i)]} \quad (6)$$

where $d_0 = d_{0g1_live} - d_{0g1_dead}$; $d_i = d_{ig1_live} - d_{ig1_dead}$, and the equation for estimating the live fine fuel load was as follows:

$$\widehat{W_{Shr_G1_live}} = \widehat{W_{Shr_G1}} - \widehat{W_{Shr_{G1_{dead}}}} = \widehat{W_{Shr_G1}} \cdot \left[1 - \frac{1}{1 + exp[d_0 + d_i \cdot log(X_i)]}\right] \quad (7)$$

The condition number was used to evaluate the presence of multicollinearity among variables in the fitted equations. According to Myers [77], condition numbers higher than $\sqrt{1000}$ indicate problems associated with multicollinearity.

The presence of heteroscedasticity was checked using the White test [78] and by visual inspection of studentized residuals plotted against fitted values. When heteroscedasticity was detected, each observation was weighted by the inverse of its estimated variance ($\widehat{\sigma_i^2}$), under the assumption that this variance can be modelled as a power function of the independent variables [79], i.e., $\widehat{\sigma_i^2} = (X_i)^k$. The value of the exponential term k was optimized to provide the most homogeneous studentized residual plot by using the method proposed by Harvey [80].

The systems were fitted using the nonlinear seemingly unrelated regression (NLSUR) method, which takes the cross-equation correlations into account. The cross-equation error covariance matrix obtained by ordinary least squares was used to initiate the iterative procedure. When necessary, the weighting factor for heteroscedasticity was programmed in the MODEL procedure of SAS/ETS® [81].

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Two goodness-of-fit statistics were used to check the accuracy of estimates: the coefficient of determination (R^2) and the root mean square error (*RMSE*).

$$R^2 = 1 - \frac{\sum_{i=1}^{n}\left(Y_i - \widehat{Y}_i\right)^2}{\sum_{i=1}^{n}\left(Y_i - \overline{Y}\right)^2} \quad (8)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n}\left(Y_i - \widehat{Y}_i\right)^2}{n-1}} \quad (9)$$

where Y_i, $\widehat{Y}_i$, and $\overline{Y}$ are the observed, predicted and mean values of the dependent variable, and n is the total number of observations used to fit the equation.

As the number of sample plots per shrub community is low for fitting the systems for each, the complete database was used to compare the IE and DE approaches. However, differences between shrub communities were evaluated by expanding the parameters a_0, b_0, c_0, and d_0 with a linear relationship including associated parameters with dummy variables to differentiate the four communities:

$$\alpha_0 = \alpha_{00} + \alpha_{01} I_{Ea} + \alpha_{02} I_{Ug} + \alpha_{03} I_{Pt} \quad (10)$$

where α_0 is the expanded parameter (a_0, b_0, c_0 or d_0); α_{00} is a common parameter for all communities; α_{0i} ($i = 1, \ldots, 3$) is an associated parameter, and I_j (j = Ea, Ug, Pt) is a dummy variable whose value is equal to 1 for the specific community and 0 for the other shrub communities. If the result of the t-test of one specific associated parameter is significant (5%), this indicates differences between communities on the specific equation affected by the associated parameter.

Finally, the results of DE and IE approaches will be compared by calculating the R^2, the RMSE, the bias (mean error $\bar{e}$), the absolute bias (mean error in absolute value $\overline{|e|}$), and the percent RMSE (the percentage of RMSE over the mean value of the dependent variable RMSE%) from the observed and estimated fuel loads in the sample plots for each approach.

3. Results and Discussion

3.1. The Direct Estimation (DE) Approach

The final expressions of the system of equations fitted (Equations (1)–(7)) to the complete database of four shrub communities, including the best set of independent variables, the values of the parameter estimates, the asymptotic standard errors and the goodness-of-fit statistics, are shown in Table 4. The results of the White test and the values of the condition number did not indicate any problems of heteroscedasticity or multicollinearity for any fuel fraction.

The values and signs of all the parameters were biologically consistent and the graphical inspection of studentized residuals showed random patterns of residuals around zero, with homogeneous variance and no discernible trends. Plots of observed versus predicted values are shown in Figure 3.

All fitted equations, with the exception of the equation estimating W_{Litt}, explained more than 80% of the observed variability, with values ranging from 80.33% to 93.92%, even exceeding 90% in the equations estimating W_{Shr} (90.18%) and W_{Shr_G1} (93.92%). Differences between shrub communities were observed for most of the fuel fractions, except W_{Litt} and W_{Shr}. These results are similar to those obtained by other authors. Thus, for example, the linear equations proposed by Ku et al. [82] for estimating *Prosopis glandulosa* biomass in rangelands in the southwestern USA yielded R^2 values of 0.77–0.81 for respectively TLS-derived height bins and percentile heights as predictors; the models proposed by Olsoy et al. [43] for estimating total biomass and green biomass of individual plants of *Artemisia tridentata* in the sagebrush–steppe ecosystem in the western USA explained respectively 92 and 83% of the observed variability; for the same species and study area as in the aforementioned study, Li et al. [47] proposed a model that explained 87% of the observed variability; Greaves et al. [32]

fitted models to estimate aboveground total biomass of low-stature (<1.5 m) Arctic shrub species in the northern Alaskan tundra, obtaining R^2 values ranging from 0.91 to 0.94 depending on the scanning conditions (2 m close-range or <50 m variable-range); the linear models developed by Owers et al. [45] for estimating biomass in coastal wetland vegetation in southeast Australia explained between 42 and 99% of the observed variability, depending on the volumetric model used.

Although there are slight differences in the fitted equations, depending on the shrub community considered, the proposed system can be considered general. Because of structural and functional differences in the four communities analysed [11], improvement of the goodness-of-fit statistics is expected when a larger sample of plots to fit community-specific systems is available, especially for coarse shrub fuel load (W_{Shr_G23}), in which the inter-species variability is greater.

As previously explained, the shrub fuel loads of each fraction and community were not destructively sampled, but estimated from previously fitted equations, with Cov_{Shr}, $\overline{h_{Shr}}$ and $\overline{d_{Litt}}$ as independent variables. Therefore, as expected, the independent variables required as inputs to initiate the disaggregation system fitted ($\widehat{W_{Shr+Litt}}$ equation) are TLS-based metrics related to shrub height and cover (h_{95} and $TLSvCov_{Shr}$). Three other metrics are involved in the disaggregation process: one related to the shrub height (h_{70}) and another two related to the vertical distribution of the fuel (W_{scale} and IQR). The latter two variables are the only ones that discriminate between coarse and fine fuel (W_{Shr_G23} and W_{Shr_G1}) and the categories of live and dead fine fuels ($W_{Shr_G1_live}$ and $W_{Shr_G1_dead}$), highlighting the importance of the vertical distribution of fuels in the biomass loads of these fractions. Rowell et al. [44] already highlighted the importance of vertical distribution of fuels in their total load and the potential of metrics derived from the vertical height distribution of the TLS laser returns cloud for that purpose. Furthermore, the equations fitted for these fractions were also those most affected by structural differences between the four shrub communities analysed, resulting in significant community specific-parameters.

3.2. The Indirect Estimation (IE) Approach

The values of the parameter estimates, the asymptotic standard errors and the goodness-of-fit statistics for the three equations relating Cov_{Shr}, $\overline{h_{Shr}}$ and $\overline{d_{Litt}}$ to TLS-based metrics and variables are shown in Table 5. No problems of multicollinearity were detected for any of the three equations fitted. As expected, the best results of the goodness-of-fit statistics were obtained for $\overline{h_{Shr}}$, with a model explaining more than 91% of the observed variability; 66.26% for Cov_{Shr} and the poorest results for $\overline{d_{Litt}}$ with a model explaining a 39.07% of the observed variability. Similar results were obtained in studies characterizing shrub and using TLS. Thus, e.g., Vierling et al. [37] reported values of explained variability in height and shrub cover of respectively 94 and 51%, in *Artemisia tridentata* dominated ecosystems in eastern Washington, USA. Anderson et al. [83] fitted models to estimate the cover fraction of shrubs ($R^2 = 0.77$), annual grasses ($R^2 = 0.70$), perennial grasses ($R^2 = 0.36$), and forbs ($R^2 = 0.52$) using the random forest algorithm in desert grasslands and big sagebrush shrublands in southwest Idaho, USA. In a study in the agro-pastoral ecotone of northern China, Xu et al. [84] proposed a model for estimating grass height and canopy cover from TLS data, which explained 70 and 72% of the observed variability respectively. Better results were obtained by Chen et al. [85], who, in a study in South-East Australia, established models for estimating the litter depth and percentage cover of the different vertical layers of the understory from TLS metrics, with R^2 values of 0.9 and of 0.8–0.9, respectively.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Table 4. Final expression of the system of equations fitted simultaneously to estimate fuel loads of each fraction, including the best set of independent variables, the parameter estimates, the approximate standard errors and the goodness-of-fit statistics. $W_{Shr+Litt}$ = shrub and litter fuel load, W_{Shr} = total shrub fuel load, W_{Litt} = litter fuel load, W_{Shr_G23} = coarse shrub fuel load, W_{Shr_G1} = fine shrub fuel load, $W_{Shr_G1_dead}$ = dead fine shrub fuel load, and $W_{Shr_G1_live}$ = live fine shrub fuel load.

Equation	Expression	Par.	Estimate	Approx. Std. Error	RMSE (kg m^{-2})	R^2
No. 1	$\widehat{W_{Shr+Litt}} = (a_{00} + a_{01}I_{Ea}) \cdot h_{95}^{a_1} \cdot TLSvCov_{Shr}^{a_2}$	a_{00}	0.2954	0.0447	0.5796	0.8033
		a_{01}	−0.0860	0.0138		
		a_1	0.6416	0.0351		
		a_2	0.1397	0.0506		
No. 2	$\widehat{W_{Shr}} = \widehat{W_{Shr+Litt}} \cdot \frac{1}{1+exp[b_1 \cdot log(IQR)+b_2 \cdot log(h_{70})]}$	b_1	0.7205	0.1964	0.2630	0.9018
No. 3	$\widehat{W_{Litt}} = \widehat{W_{Shr+Litt}} \cdot \left[1 - \frac{1}{1+exp[b_1 \cdot log(IQR)+b_2 \cdot log(h_{70})]}\right]$	b_2	−0.8301	0.1860	0.4584	0.4080
No. 4	$\widehat{W_{Shr_G23}} = \widehat{W_{Shr}} \cdot \frac{1}{1+exp[c_{00}+c_{01}I_{Ea-Pt}+c_{02}I_{Ug}+c_1 \cdot log(W_{scale})]}$	c_{00}	4.6139	0.5061	0.1957	0.8263
		c_{01}	0.3103	0.0479		
No. 5	$\widehat{W_{Shr_G1}} = \widehat{W_{Shr}} \cdot \left[1 - \frac{1}{1+exp[c_{00}+c_{01}I_{Ea-Pt}+c_{02}I_{Ug}+c_1 \cdot log(W_{scale})]}\right]$	c_{02}	0.7254	0.0807	0.1154	0.9392
		c_1	−0.9864	0.1255		
No. 6	$\widehat{W_{Shr_G1_dead}} = \widehat{W_{Shr_G1}} \cdot \frac{1}{1+exp[d_{00}+d_{01}I_{Ea-Ug}+d_1 \cdot log(IQR)]}$	d_{00}	0.9106	0.1777	0.0820	0.8848
		d_{01}	0.2900	0.0347		
No. 7	$\widehat{W_{Shr_G1_live}} = \widehat{W_{Shr_G1}} \cdot \left[1 - \frac{1}{1+exp[d_{00}+d_{01}I_{Ea-Ug}+d_1 \cdot log(IQR)]}\right]$	d_1	−0.1084	0.0451	0.0860	0.8794

I_j (j = Ea, Ug, Pt) = dummy variable whose value is equal to 1 for the specific community and 0 for the other shrub communities. Ea = *Erica australis*, Ug = *Ulex gallii*/*Ulex minor*, Pt = *Pterospartum tridentatum*. h_{95} = 95th percentile height of laser returns (cm); $TLSvCov_{Shr}$ = ratio between the observed number of laser returns and lr_{max_ver}; IQR = Interquartile range (h_{75}−h_{25}) (cm); h_{70} = 70th percentile height of laser returns (cm); W_{scale} = scale parameter of the Weibull pdf.

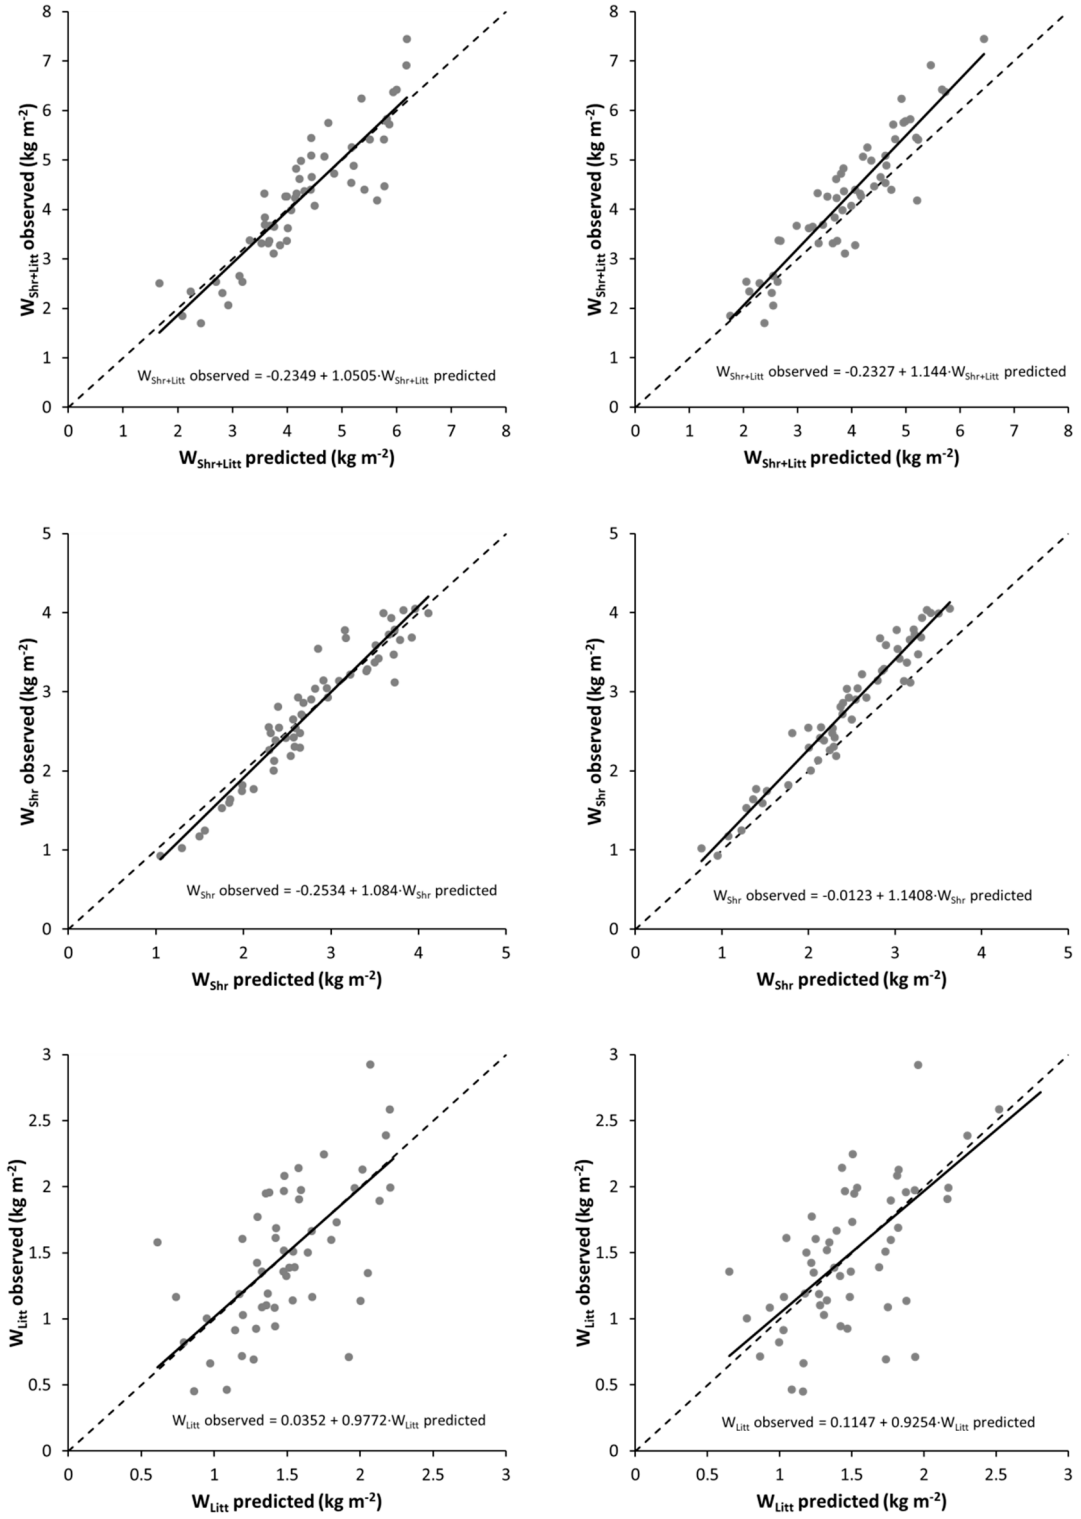

Figure 3. *Cont.*

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

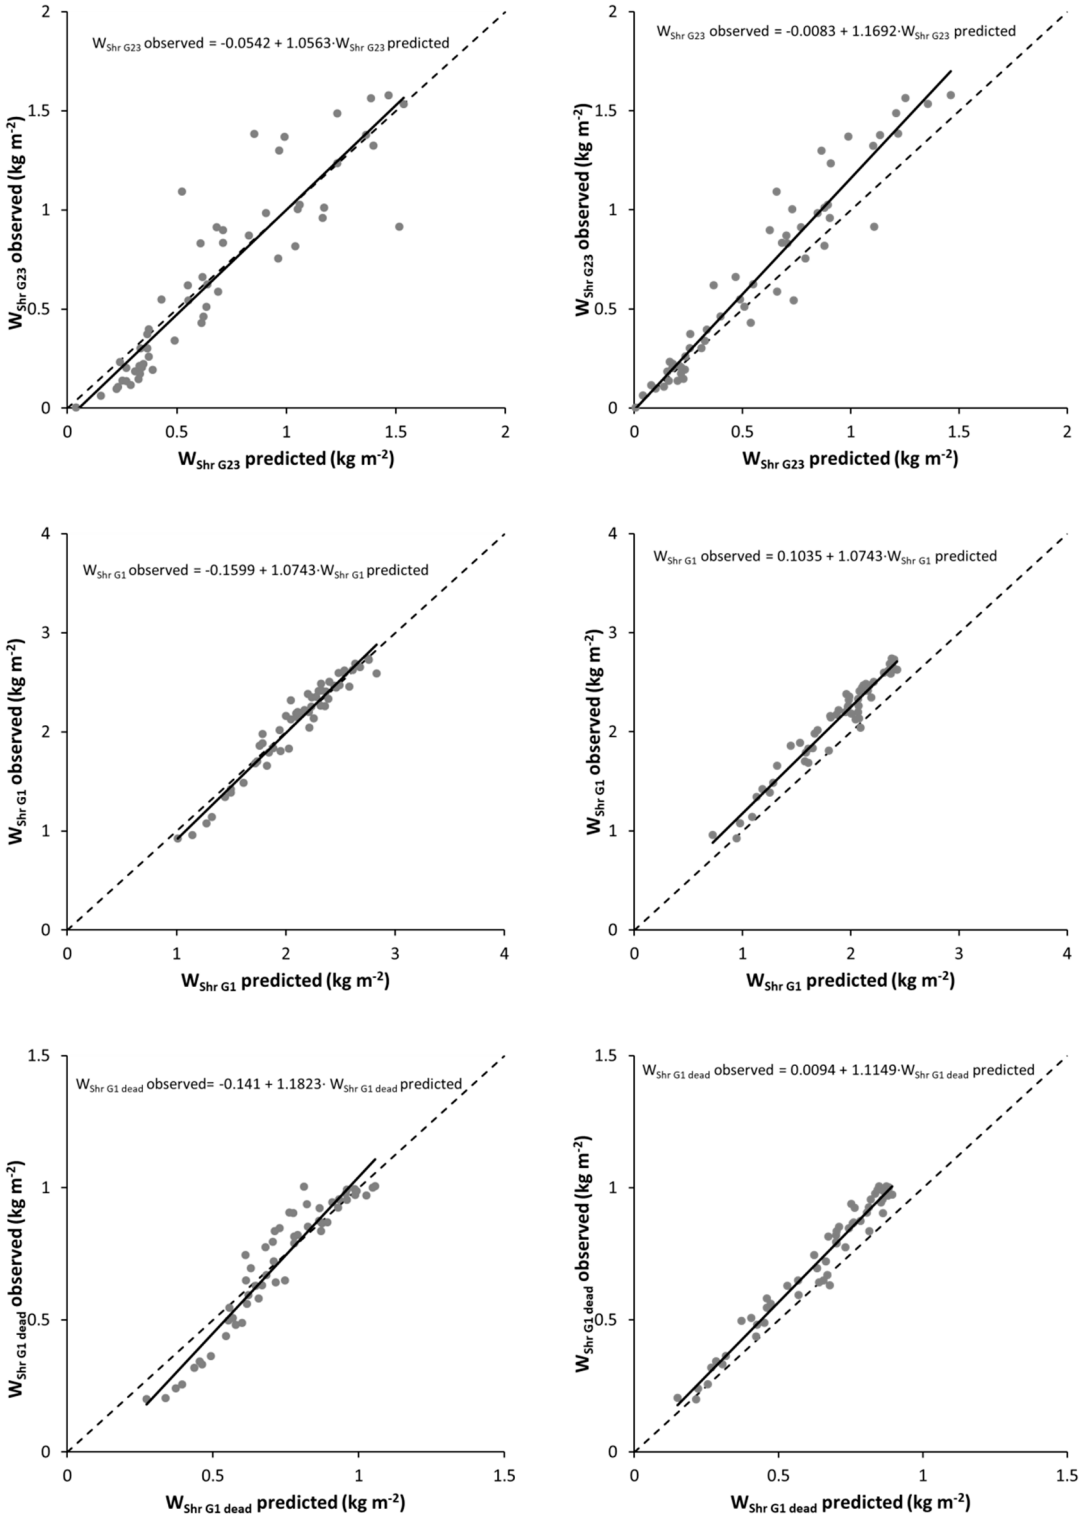

Figure 3. *Cont.*

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

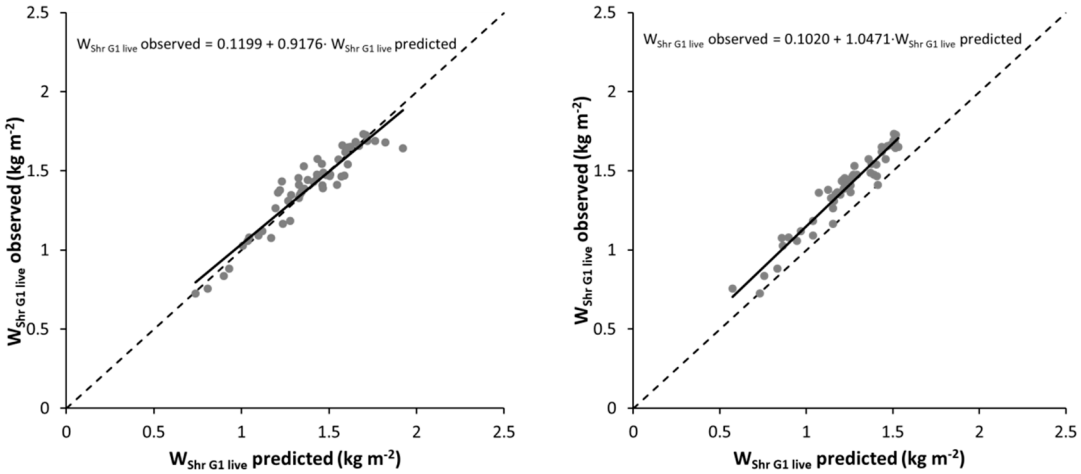

Figure 3. Plots of observed versus predicted values of shrub and litter fuel load ($W_{Shr+Litt}$), total shrub fuel load (W_{Shr}), litter fuel load (W_{Litt}), coarse shrub fuel load (W_{Shr_G23}), fine shrub fuel load (W_{Shr_G1}), dead fine shrub fuel load ($W_{Shr_G1_dead}$), and live fine shrub fuel load ($W_{Shr_G1_live}$) for DE (left) and IE (right) approaches.

Table 5. Final expression of the equations fitted to estimate the inputs of the biomass equations developed for the shrub communities in Galicia [69] from usual field measurements, with TLS-based metrics, the parameter estimates, the approximate standard errors and the goodness-of-fit statistics. Cov_{Shr} = shrub cover (%), $\overline{h_{Shr}}$ = mean shrub height and $\overline{d_{Litt}}$ = mean litter depth.

Variable	Expression	Par.	Estimate	Approx. Std. Error	RMSE	R^2
Cov_{Shr} (%)	$\widehat{Cov_{Shr}} = \frac{100}{1+exp(a_0+a_1 \cdot h_{95})}$	a_0 a_1	−0.4742 −0.0967	0.1707 0.0145	1.1226%	0.6626
$\overline{h_{Shr}}$ (cm)	$\overline{h_{Shr}} = b_0 + b_1 \cdot h_{max} + b_2 \cdot h_{10}$	b_0 b_1 b_2	−9.8958 0.8080 2.5762	4.2458 0.0430 0.5859	9.2027 cm	0.9175
$\overline{d_{Litt}}$ (cm)	$\overline{d_{Litt}} = c_0 + c_1 \cdot h_{kurt} + +c_2 \cdot TLSvCov_{Shr} + c_3 \cdot IQR$	c_0 c_1 c_2 c_3	−2.8156 1.9338 7.9632 0.1061	1.2422 0.9432 2.0776 0.0204	1.5190 cm	0.3907

h_{95} = 95th percentile height of laser returns (cm); h_{max} = maximum height of laser returns (cm); h_{10} = 10th percentile height of laser returns (cm); h_{kurt} = height of laser returns corresponding to kurtosis; $TLSvCov_{Shr}$ = ratio between the observed number of laser returns and lr_{max_ver}; IQR = Interquartile range ($h_{75}-h_{25}$) (cm).

The low accuracy of the estimates of the litter layer depth equation is consistent with the low accuracy of the estimates of the litter fuel load equation fitted in the DE approach (R^2 = 0.4080). These results were expected due to the strong relationship between the litter layer depth and the accumulated load per unit area and the difficulty in characterizing this depth from the TLS point clouds because of limited visibility in high-density shrub communities [49]. Therefore, because of the importance of this fraction in both the flame and the smouldering phases, in situations in which this fraction could contribute substantially to energy flux and emissions from surface fires, destructive sampling is required to complement TLS scans.

The estimates of Cov_{Shr}, $\overline{h_{Shr}}$ and $\overline{d_{Litt}}$ obtained with the three models were used as inputs of the biomass equations developed for the studied communities in Galicia [69] to estimate the fuel load of $W_{Shr+Litt}$, W_{Shr}, W_{Litt}, W_{Shr_G23}, W_{Shr_G1}, $W_{Shr_G1_dead}$, and $W_{Shr_G1_live}$. Plots of observed versus predicted values of these seven fuel loads are shown in Figure 3 for comparison with the same plots obtained using the DE approach.

Table 6 compares the values of R^2, RMSE, bias (mean error $\bar{e}$), absolute bias (mean error in absolute value $\overline{|e|}$), and the percent RMSE (the percentage of RMSE over the mean value of the dependent variable RMSE%) from the observed and estimated fuel loads in the sample plots for each approach.

Table 6. Goodness-of-fit statistics obtained with the direct estimation (DE) and indirect estimation (IE) approaches for each fuel fraction.

Variable	Direct Estimation (DE) Approach					Indirect Estimation (IE) Approach				
	R^2	RMSE (kg m^{-2})	$\bar{e}$	$\overline{\lvert e \rvert}$	RMSE (%)	R^2	RMSE (kg m^{-2})	$\bar{e}$	$\overline{\lvert e \rvert}$	RMSE (%)
$W_{Shr+Litt}$	0.8033	0.5796	−0.0183	0.4489	13.58	0.7642	0.6347	0.3339	0.5242	14.87
W_{Shr}	0.9018	0.2630	−0.0193	0.2121	9.50	0.7666	0.4056	0.3308	0.3393	14.65
W_{Litt}	0.4080	0.4584	0.0010	0.3572	30.55	0.4378	0.4467	0.0031	0.3482	29.78
W_{Shr_G23}	0.8263	0.1957	−0.0160	0.1440	29.51	0.8710	0.1687	0.0888	0.1235	25.44
W_{Shr_G1}	0.9392	0.1154	−0.0032	0.0958	5.48	0.6732	0.2676	0.2420	0.2444	12.71
$W_{Shr_G1_dead}$	0.8848	0.0820	−0.0090	0.0654	11.47	0.8371	0.0975	0.0821	0.0844	13.63
$W_{Shr_G1_live}$	0.8794	0.0860	0.0058	0.0640	6.19	0.5103	0.1734	0.1599	0.1602	12.47

Overall, the best results, in terms of goodness-of-fit statistics, were obtained with the DE approach, although for W_{Litt} and W_{Shr_G23} the IE approach explained more of the observed variability, with a reduction in RMSE of, respectively, 2.6 and 13.8%, relative to the DE approach. However, the plots of observed versus predicted values showed a slight bias in all the estimates in the IE approach, with a slight tendency to underestimate the values, whereas this trend was not appreciable in the plots of the estimates of the DE approach (Figure 3).

The system of compatible equations developed with the DE approach is proposed for estimating the fuel loads of the shrub communities analyzed, with the equations fitted for the IE approach used to estimate three other important variables for complete characterization of fuelbeds (Cov_{Shr}, $\overline{h_{Shr}}$ and $\overline{d_{Litt}}$).

Apart from the important improvement regarding the provision of a compatible system of equations that guarantees additivity, the proposed methodology does not add any apparent advantages in field sampling relative to the equations based on variables obtained from non-destructive sampling, such as those already existing for the species analyzed in the study area [69]. However, as Newnham et al. [86] pointed out, TLS should not be considered just as an extension or automation of traditional field data sampling, but rather as a completely different methodology to characterize the spatial structure at the plot scale with an unprecedented level of detail. TLS point clouds can easily be processed with simple algorithms, such as those used in this study, to provide useful additional information for characterizing fuelbeds that would otherwise be difficult, impractical, or impossible to obtain with non-destructive field sampling. For example, TLS can characterize the vertical distribution of fuel loads with greater precision and at a finer scale than afforded by traditional methods (see Figure 4). Moreover, the differences in water content between green and woody biomass produce differences in reflectivity of the laser energy [87,88] enabling the TLS point cloud to be divided into green and non-green fractions [43]. In addition, previous studies have shown that TLS allows for very accurate estimates of other fundamental variables describing structural characteristics of fuelbeds, such as bulk density [49,89] or packing ratio [55]; both of which strongly influences the flammability and combustibility of a given fuelbed. For these reasons, TLS could provide improved estimates of fuelbed properties driving fire behavior, thereby enhancing the accuracy of fire behavior prediction simulators [64,65].

Several authors have highlighted the usefulness that could have the use of estimation models derived from TLS data as a stepping stone to train remote sensor databases applicable at large scale [47,48,83,90]. Therefore, the development of accurate estimation methodologies, such as those presented in this paper, based on a single TLS scan, with the consequent reduction in costs and time, constitute the basis for the application of TLS in the forest inventory, combining it with inference methods such as model-based or model-assisted approaches.

Finally, the equations proposed in this study could be useful for characterizing shrub communities from the point of view of fire behavior and fire hazard assessment, as well as for designing prescribed burns, for simulation of erosion processes, for estimating carbon stocks or biomass potential as energy source and for characterizing and delimiting wildlife habitats. Although the approach proposed is transferrable to point clouds derived from other shrub communities, new models should be fitted based

on destructive sampling taking into account the specific ecosystem conditions, and considerations of timing due to phenology.

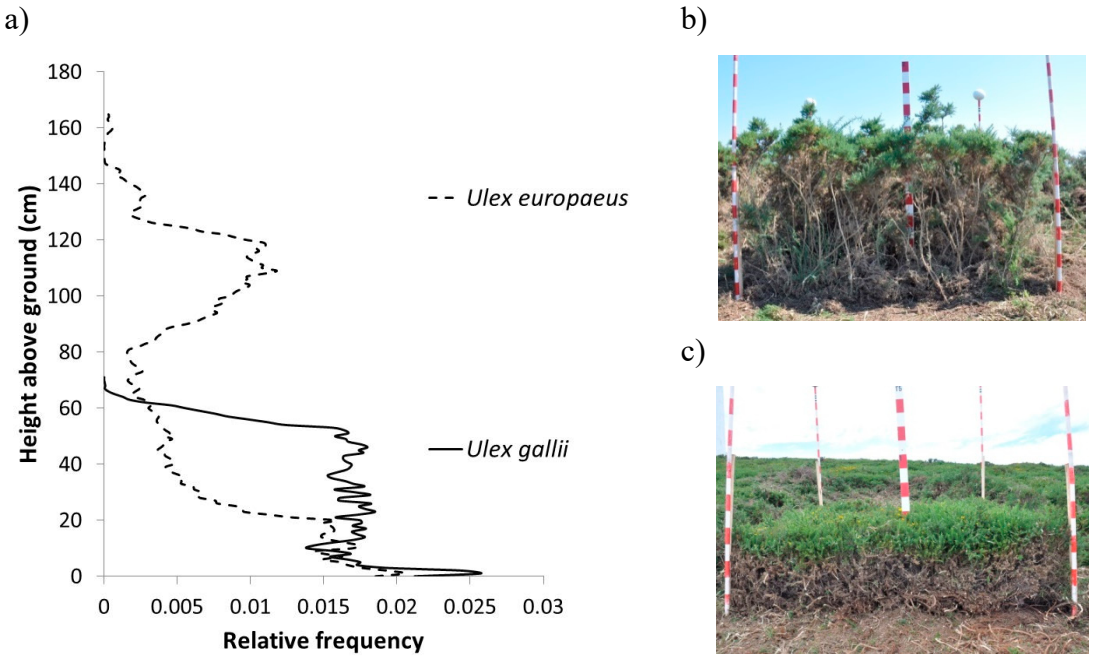

Figure 4. Vertical distribution of the relative frequency of TLS returns (**a**) in two fuel plots with different vertical structure (**b**) *Ulex europaeus* and (**c**) *Ulex gallii*.

4. Conclusions

Forest managers require accurate models for estimating shrub fuel loads, especially in fire-prone areas such as Galicia, where about 2% of the forest land area is burned annually (period 1978–2019) and some two-thirds of which correspond to shrub vegetation. In this study, two alternative approaches were compared for estimating size-disaggregated shrub and litter fuel loads and live/dead fractions from TLS derived metrics, for four of the main treeless shrub communities in Galicia. The results obtained suggest that the use of metrics derived from a single TLS scan as independent variables produces accurate estimates of shrub fuel loads, mainly by using the proposed systems of equations of the DE approach.

TLS research on surface fuels is limited, and previous studies have focused on the application of physical-based fire models requiring spatially explicit three-dimensional data [49,55,63]. In addition, most of these studies have analyzed the total biomass, at best distinguishing between green and non-green fuels [43]. The proposed method therefore represents an important improvement in relation to characterization of shrub community fuel loads.

In northwest Spain, the abandonment of agricultural land, among other factors, has generated a large increase in the wildland–urban interface, creating complex mosaics in which the fire-prone shrub communities analyzed in this study predominate. Efficient management of these ecosystems increasingly demands more accurate and detailed fuel maps for comparing and prioritizing different fuel reduction strategies and ecosystem restoration. This task will require assembling and combining databases of estimates obtained from both traditional sampling and the use of remote sensors. The study findings suggest that TLS may be valuable for achieving this aim.

Our purpose is to advance towards developing a methodology that ultimately enables characterization of the spatial and vertical distribution of shrub fuels, distinguishing between size and live/dead fractions. The present research is an initial exploratory study of potentially suitable approaches to achieving these objectives. Further sampling that covers all combinations of development stages and site qualities of each

shrub community, also including destructive sampling, is required to establish TLS as a robust technology for estimating the main characteristics related to fire behavior and for providing the basis for scaling up from plot to landscape.

Author Contributions: Conceptualization, C.A.-R., R.A.D.-V., and A.D.R.-G.; methodology, C.A.-R., S.A.-P., J.G.Á.-G., R.A.D.-V. and A.D.R.-G.; software, C.C., C.O. and J.G.Á.-G.; formal analysis, C.A.-R. and J.G.Á.-G.; investigation, C.A.-R., S.A.-P., J.G.Á.-G., R.A.D.-V. and A.D.R.-G.; resources, C.A.-R., S.A.-P., J.G.Á.-G., R.A.D.-V. and A.D.R.-G.; data curation, C.A.-R. and S.A.-P.; writing—original draft preparation, C.A.-R., S.A.-P., C.C., C.O., J.G.Á.-G., R.A.D.-V. and A.D.R.-G.; writing—review and editing, C.A.-R., S.A.-P., C.C., C.O., J.G.Á.-G., R.A.D.-V. and A.D.R.-G.; supervision, R.A.D.-V. and A.D.R.-G.; project administration, A.D.R.-G.; funding acquisition, A.D.R.-G. All authors have read and agreed to the published version of the manuscript.

Funding: This research was funded by the projects GEPRIF (RTA2014-00011-c06-04) and VIS4FIRE (RTA 2017-0042-C05-05) of the Spanish Ministry of Economy, Industry, and Competitiveness.

Acknowledgments: We are grateful to Mario López Fernández for his inestimable technical support in conducting all the field sampling tasks in the plot network. This work was supported by a pre-doctoral grant of the first author funded by the 'Consejería de Educación, Universidad y Formación Profesional" and the "Consejería de Economía, Empleo e Industria" of Galician Government and the EU operational program "FSE Galicia 2014–2020".

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Keane, R.E. Describing wildland surface fuel loading for fire management: A review of approaches, methods and systems. *Int. J. Wildland Fire* **2013**, *22*, 51–62. [CrossRef]
2. Keane, R.E. *Wildland Fuel Fundamentals and Applications*; Springer International Publishing: Cham, Switzerland, 2015.
3. Chandler, C.; Cheney, P.; Thomas, P.; Trabaud, L.; Williams, D. *Fire in Forestry, Volume 1: Forest Fire Behavior and Effects*; John Wiley and Sons Inc.: Hoboken, NJ, USA, 1983.
4. Pyne, S.J.; Andrews, P.L.; Laven, R.D. *Introduction to Widland Fire*, 2nd ed.; John Wiley and Sons Inc.: Hoboken, NJ, USA, 1996.
5. Finney, M.A.; Seli, R.C.; McHugh, C.W.; Ager, A.A.; Bahro, B.; Agee, J. Simulation of long-term landscape-level fuel treatment effects on large wildfires. *Int. J. Wildland Fire* **2007**, *16*, 712–727. [CrossRef]
6. Ager, A.A.; Vaillant, N.M.; Finney, M.A. Integrating Fire Behavior Models and Geospatial Analysis for Wildland Fire Risk Assessment and Fuel Management Planning. *J. Combust.* **2011**, *2011*, 572452. [CrossRef]
7. Jiménez, E.; Vega, J.A.; Ruiz-González, A.D.; Guijarro, M.; Alvarez-González, J.G.; Madrigal, J.; Cuiñas, P.; Hernando, C.; Fernández-Alonso, J.M. Carbon emissions and vertical pattern of canopy fuel consumption in three *Pinus pinaster* Ait. active crown fires in Galicia (NW Spain). *Ecol. Eng.* **2013**, *54*, 202–209. [CrossRef]
8. Lasslop, G.; Kloster, S. Impact of fuel variability on wildfire emission estimates. *Atmos. Environ.* **2015**, *121*, 93–102. [CrossRef]
9. Possell, M.; Jenkins, M.; Bell, T.L.; Adams, M.A. Emissions from prescribed fires in temperate forest in south-east Australia: Implications for carbon accounting. *Biogeosciences* **2015**, *12*, 257–268. [CrossRef]
10. Restaino, J. Fuel Loading. In *Encyclopedia of Wildfires and Wildland-Urban Interface (WUI) Fires*; Manzello, S., Ed.; Springer: Cham, Switzerland, 2019.
11. Arellano, S.; Vega, J.A.; Ruiz-González, A.D.; Arellano, A.; Álvarez-González, J.G.; Vega-Nieva, D.; Pérez, E. *Foto-guía de Combustibles Forestales de Galicia y Comportamiento del Fuego Asociado*; Andavira: Santiago de Compostela, Spain, 2017.
12. Koutsias, N.; Allgöwer, B.; Kalabokidis, K.; Mallinis, G.; Balatsos, P.; Goldammer, J.G. Fire occurrence zoning from local to global scale in the European Mediterranean basin: Implications for multi-scale fire management and policy. *iForest-Biogeosci. For.* **2015**, *9*, 195–204. [CrossRef]
13. San Miguel-Ayanz, J.; Durrant, T.; Boca, R.; Libertà, G.; Branco, A.; de Rigo, D.; Ferrari, D.; Maianti, P.; Artés Vivancos, T.; Oom, D.; et al. *Forest Fires in Europe, Middle East and North Africa 2018*; JRC Technical Report EUR 29856 EN: Ispra, Italy, 2019.
14. Jiménez-Ruano, A.; Rodrigues Mimbrero, M.; de la Riva Fernández, J. Exploring spatial–temporal dynamics of fire regime features in mainland Spain. *Nat. Hazards Earth Syst. Sci.* **2017**, *17*, 1697–1711. [CrossRef]
15. Rodrigues, M.; González-Hidalgo, J.C.; Peña-Angulo, D.; Jiménez-Ruano, A. Identifying wildfire-prone atmospheric circulation weather types on mainland Spain. *Agric. For. Meteorol.* **2019**, *264*, 92–103. [CrossRef]

16. Rodrigues, M.; Trigo, R.M.; Vega-García, C.; Cardil, A. Identifying large fire weather typologies in the Iberian Peninsula. *Agric. For. Meteorol.* **2020**, *280*, 107789. [CrossRef]
17. Xunta de Galicia. *Plan de Prevención y Defensa Contra los Incendios Forestales de Galicia–PLADIGA*; Consellería do Medio Rural: Santiago de Compostela, Spain, 2019.
18. MARM. *Cuarto Inventario Forestal Nacional. Galicia*; Ministerio de Medio Ambiente y Medio Rural y Marino: Madrid, Spain, 2011.
19. Catchpole, W.R.; Wheeler, C.J. Estimating plant biomass: A review of techniques. *Aust. J. Ecol.* **1992**, *17*, 121–131. [CrossRef]
20. Bonham, C.D. *Measurements for Terrestrial Vegetation*, 2nd ed.; Wiley-Blackwell: Oxford, UK, 2013.
21. Pearce, H.G.; Anderson, W.R.; Fogarty, L.G.; Todoroki, C.L.; Anderson, S.A.J. Linear mixed-effects models for estimating biomass and fuel loads in shrublands. *Can. J. For. Res.* **2010**, *40*, 2015–2026. [CrossRef]
22. Pasalodos-Tato, M.; Ruiz-Peinado, R.; del Río, M.; Montero, G. Shrub biomass accumulation and growth rate models to quantify carbon stocks and fluxes for the Mediterranean region. *Eur. J. For. Res.* **2015**, *134*, 537–553. [CrossRef]
23. De Cáceres, M.; Casals, P.; Gabriel, E.; Castro, X. Scaling-up individual-level allometric equations to predict stand-level fuel loading in Mediterranean shrublands. *Ann. For. Sci.* **2019**, *76*, 87. [CrossRef]
24. Keane, R.E.; Burgan, R.; Van Wagtendonk, J. Mapping wildland fuels for fire management across multiple scales: Integrating remote sensing, GIS, and biophysical modeling. *Int. J. Wildland Fire* **2001**, *10*, 301–319. [CrossRef]
25. Riaño, D.; Chuvieco, E.; Salas, J.; Palacios-Orueta, A.; Bastarrika, A. Generation of fuel type maps from Landsat TM images and ancillary data in Mediterranean ecosystems. *Can. J. For. Res.* **2002**, *32*, 1301–1315. [CrossRef]
26. Reich, R.M.; Lundquist, J.E.; Bravo, V.A. Spatial models for estimating fuel loads in the Black Hills, South Dakota, USA. *Int. J. Wildland Fire* **2004**, *13*, 119–129. [CrossRef]
27. Mutlu, M.; Popescu, S.C.; Stripling, C.; Spencer, T. Mapping surface fuel models using lidar and multispectral data fusion for fire behavior. *Remote Sens. Environ.* **2008**, *112*, 274–285. [CrossRef]
28. Viana, H.; Aranha, J.; Lopes, D.; Cohen, W.B. Estimation of crown biomass of *Pinus pinaster* stands and shrubland above-ground biomass using forest inventory data, remotely sensed imagery and spatial prediction models. *Ecol. Model.* **2012**, *226*, 22–35. [CrossRef]
29. Riaño, D.; Chuvieco, E.; Ustin, S.L.; Salas, J.; Rodríguez-Pérez, J.R.; Ribeiro, L.M.; Viegas, D.X.; Moreno, J.M.; Fernández, H. Estimation of shrub height for fuel-type mapping combining airborne LiDAR and simultaneous color infrared ortho imaging. *Int. J. Wildland Fire* **2007**, *16*, 341–348. [CrossRef]
30. Estornell, J.; Ruiz, L.A.; Velázquez-Martí, B.; Fernández-Sarría, A. Estimation of shrub biomass by airborne LiDAR data in small forest stands. *For. Ecol. Manag.* **2011**, *262*, 1697–1703. [CrossRef]
31. Jakubowksi, M.K.; Guo, Q.; Collins, B.; Stephens, S.; Kelly, M. Predicting Surface Fuel Models and Fuel Metrics Using Lidar and CIR Imagery in a Dense, Mountainous Forest. *Photogramm. Eng. Remote Sens.* **2013**, *79*, 37–49. [CrossRef]
32. Greaves, H.E.; Vierling, L.A.; Eitel, J.U.H.; Boelman, N.T.; Magney, T.S.; Prager, C.M.; Griffin, K.L. High-resolution mapping of aboveground shrub biomass in Arctic tundra using airborne lidar and imagery. *Remote Sens. Environ.* **2016**, *184*, 361–373. [CrossRef]
33. Li, A.; Dhakal, S.; Glenn, N.F.; Spaete, L.P.; Shinneman, D.J.; Pilliod, D.S.; Arkle, R.S.; McIlroy, S.K. Lidar aboveground vegetation biomass estimates in shrublands: Prediction, uncertainties and application to coarser scales. *Remote Sens.* **2017**, *9*, 903. [CrossRef]
34. Estornell, J.; Ruiz, L.A.; Velázquez-Martí, B.; Hermosilla, T. Analysis of the factors affecting LiDAR DTM accuracy. *Int. J. Digit. Earth* **2011**, *4*, 521–538. [CrossRef]
35. Glenn, N.F.; Spaete, L.P.; Sankey, T.T.; Derryberry, D.R.; Hardegree, S.P.; Mitchell, J.J. Errors in LiDAR-derived shrub height and crown area on sloped terrain. *J. Arid Environ.* **2011**, *75*, 377–382. [CrossRef]
36. Mitchell, J.J.; Glenn, N.F.; Sankey, T.T.; Derryberry, D.R.; Anderson, M.O.; Hruska, R.C. Small-footprint LiDAR estimations of sagebrush canopy characteristics. *Photogramm. Eng. Remote Sens.* **2011**, *77*, 521–530. [CrossRef]
37. Vierling, L.A.; Xu, Y.; Eitel, J.U.H.; Oldow, J.S. Shrub characterization using terrestrial laser scanning and implications for airborne LiDAR assessment. *Can. J. Remote Sens.* **2013**, *38*, 709–722. [CrossRef]

38. Hopkinson, C.; Chasmer, L.; Young-Pow, C.; Treitz, P. Assessing forest metrics with a ground-based scanning lidar. *Can. J. For. Res.* **2004**, *34*, 573–583. [CrossRef]
39. Astrup, R.; Ducey, M.J.; Granhus, A.; Ritter, T.; von Lüpke, N. Approaches for estimating stand-level volume using terrestrial laser scanning in a single-scan mode. *Can. J. For. Res.* **2014**, *44*, 666–676. [CrossRef]
40. Abegg, M.; Kükenbrink, D.; Zell, J.; Schaepman, M.E.; Morsdorf, F. Terrestrial laser scanning for forest inventories—tree diameter distribution and scanner location impact on occlusion. *Forests* **2017**, *8*, 184. [CrossRef]
41. Chen, S.; Feng, Z.; Chen, P.; Khan, T.U.; Lian, Y. Nondestructive Estimation of the Above-Ground Biomass of Multiple Tree Species in Boreal Forests of China Using Terrestrial Laser Scanning. *Forests* **2019**, *10*, 936. [CrossRef]
42. Loudermilk, E.L.; Hiers, J.K.; O'Brien, J.J.; Mitchell, R.J.; Singhania, A.; Fernandez, J.C.; Slatton, K.C. Ground-based LIDAR: A novel approach to quantify fine-scale fuelbed characteristics. *Int. J. Wildland Fire* **2009**, *18*, 676–685. [CrossRef]
43. Olsoy, P.J.; Glenn, N.F.; Clark, P.E.; Derryberry, D.R. Aboveground total and green biomass of dryland shrub derived from terrestrial laser scanning. *ISPRS J. Photogramm. Remote Sens.* **2014**, *88*, 166–173. [CrossRef]
44. Rowell, E.M.; Seielstad, C.A.; Ottmar, R.D. Development and validation of fuel height models for terrestrial lidar—RxCADRE 2012. *Int. J. Wildland Fire* **2016**, *25*, 38–47. [CrossRef]
45. Owers, C.J.; Rogers, K.; Woodroffe, C.D. Terrestrial laser scanning to quantify above-ground biomass of structurally complex coastal wetland vegetation. *Estuar. Coast. Shelf Sci.* **2018**, *204*, 164–176. [CrossRef]
46. Lovell, J.L.; Jupp, D.L.B.; Culvenor, D.S.; Coops, N.C. Using airborne and ground-based ranging lidar to measure canopy structure in Australian forests. *Can. J. Remote Sens.* **2003**, *29*, 607–622. [CrossRef]
47. Li, A.; Glenn, N.F.; Olsoy, P.J.; Mitchell, J.J.; Shrestha, R. Aboveground biomass estimates of sagebrush using terrestrial and airborne LiDAR data in a dryland ecosystem. *Agric. For. Meteorol.* **2015**, *213*, 138–147. [CrossRef]
48. Liu, L.; Pang, Y.; Li, Z.; Si, L.; Liao, S. Combining airborne and terrestrial laser scanning technologies to measure forest understorey volume. *Forests* **2017**, *8*, 111. [CrossRef]
49. Hudak, A.T.; Kato, A.; Bright, B.C.; Loudermilk, E.L.; Hawley, C.; Restaino, J.C.; Ottmar, R.D.; Prata, G.A.; Cabo, C.; Prichard, S.J.; et al. Towards spatially explicit quantification of pre- and post-fire fuels and fuel consumption from traditional and point cloud measurements. *For. Sci.* **2020**, *66*, 428–442. [CrossRef]
50. Crespo-Peremarch, P.; Fournier, R.A.; Nguyen, V.T.; van Lier, O.R.; Ruiz, L.Á. A comparative assessment of the vertical distribution of forest components using full-waveform airborne, discrete airborne and discrete terrestrial laser scanning data. *For. Ecol. Manag.* **2020**, *473*, 118268. [CrossRef]
51. Aicardi, I.; Dabove, P.; Lingua, A.M.; Piras, M. Integration between TLS and UAV photogrammetry techniques for forestry applications. *iForest-Biogeosci. For.* **2017**, *10*, 41–47. [CrossRef]
52. Warfield, A.D.; Leon, J.X. Estimating Mangrove Forest Volume Using Terrestrial Laser Scanning and UAV-Derived Structure-from-Motion. *Drones* **2019**, *3*, 32. [CrossRef]
53. LaRue, E.A.; Atkins, J.W.; Dahlin, K.; Fahey, R.; Fei, S.; Gough, C.; Hardiman, B.S. Linking Landsat to terrestrial LiDAR: Vegetation metrics of forest greenness are correlated with canopy structural complexity. *Int. J. Appl. Earth Obs. Geoinf.* **2018**, *73*, 420–427. [CrossRef]
54. Greaves, H.E.; Vierling, L.A.; Eitel, J.U.H.; Boelman, N.T.; Troy, S.T.; Magney, T.; Prager, C.M.; Griffin, K.L. Estimating aboveground biomass and leaf area of low-stature Arctic shrubs with terrestrial LiDAR. *Remote Sens. Environ.* **2015**, *164*, 26–35. [CrossRef]
55. Rowell, E.; Loudermilk, E.L.; Hawley, C.; Pokswinski, S.; Seielstad, C.; Queen, L.L.; O'Brien, J.J.; Hudak, A.T.; Goodrick, S.; Hiers, J.K. Coupling terrestrial laser scanning with 3D fuel biomass sampling for advancing wildland fuels characterization. *For. Ecol. Manag.* **2020**, *462*, 117945. [CrossRef]
56. Hawley, C.M.; Loudermilk, E.L.; Rowell, E.M.; Pokswinski, S. A novel approach to fuel biomass sampling for 3D fuel characterization. *MethodsX* **2018**, *5*, 1597–1604. [CrossRef]
57. Mandel, J.; Beezley, J.D.; Kochanski, A.K. Coupled atmosphere–wildland fire modeling with WRF 3.3 and SFIRE 2011. *Geosci. Model Dev.* **2011**, *4*, 591–610. [CrossRef]
58. Mandel, J.; Amram, S.; Beezley, J.D.; Kelman, G.; Kochanski, A.K.; Kondratenko, V.Y.; Lynn, B.H.; Regev, B.; Vejmelka, M. Recent advances and applications of WRF-SFIRE. *Nat. Hazards Earth Syst. Sci.* **2014**, *14*, 2829–2845. [CrossRef]

59. Mell, W.; Jenkins, M.A.; Gould, J.; Cheney, P. A physics-based approach to modeling grassland fires. *Int. J. Wildland Fire* **2007**, *16*, 1–22. [CrossRef]
60. Mell, W.; Maranghides, A.; McDermott, R.; Manzello, S.L. Numerical simulation and experiments of burning Douglas-fir trees. *Combust. Flame* **2009**, *156*, 2023–2041. [CrossRef]
61. Linn, R.R.; Reisner, J.; Colmann, J.J.; Winterkamp, J. Studying wildfire behavior using FIRETEC. *Int. J. Wildland Fire* **2002**, *11*, 233–246. [CrossRef]
62. Linn, R.R.; Winterkamp, J.; Colman, J.J.; Edminster, C.; Bailey, J.D. Modeling interactions between fire and atmosphere in discrete element fuelbeds. *Int. J. Wildland Fire* **2005**, *14*, 37–48. [CrossRef]
63. Hudak, A.; Prichard, S.; Keane, R.; Loudermilk, L.; Parsons, R.; Seielstad, C.; Rowell, E.; Skowronski, N. *Hierarchical 3D Fuel and Consumption Maps to Support Physics-Based Fire Modeling*; Joint Fire Science Program Project 16-4-01-15 Final Report; Joint Fire Science Program: Moscow, ID, USA, 2017.
64. Finney, M.A. *FARSITE: Fire Area Simulator–Model Development and Evaluation*; Research Paper RMRS-RP-4 Revised; United States Department of Agriculture, Forest Service, Rocky Mountain Research Station: Ogden, UT, USA, 2004.
65. Finney, M.A. An overview of FlamMap fire modeling capabilities. In *Fuels Management—How to Measure Success, Proceedings of the Rocky Mountain Research Station, Portland, OR, USA, 28–30 March 2006*; United States Department of Agriculture, Forest Service, Rocky Mountain Research Station: Fort Collins, CO, USA, 2006.
66. MARM. *Mapa Forestal de España. Escala 1:25.000*; Ministerio de Agricultura, Pesca y Alimentación: Madrid, Spain, 2011.
67. MMA. *Mapa Forestal Nacional. Escala 1:50.000*; Ministerio de Agricultura, Pesca y Alimentación: Madrid, Spain, 2006.
68. Canfield, R.H. Application of the line interception method in sampling range vegetation. *J. For.* **1941**, *39*, 388–394.
69. Arellano-Pérez, S. Modelos de Combustibles Forestales de Galicia. Master's Thesis, Universidad de Santiago de Compostela, Lugo, Spain, 2011.
70. Bliss, C. The Transformation of Percentages for Use in the Analysis of Variance. *Ohio J. Sci.* **1938**, *38*, 9–12.
71. Cao, Q.V.; Burkhart, H.E.; Lemin, R.C. *Diameter Distributions and Yields of Thinned Loblolly Pine Plantations*; FWS 1-82; School of Forestry and Wildlife Resources, Virginia Polytechnic Institute and State University: Blacksburg, VA, USA, 1982.
72. R Core Team. *R: A Language and Environment for Statistical Computing*; R Foundation for Statistical Computing: Vienna, Austria, 2020; Available online: https://www.R-project.org/ (accessed on 16 March 2020).
73. Adler, D.; Murdoch, D.; Nenadic, O.; Urbanek, S.; Chen, M.; Gebhardt, A.; Bolker, B.; Csardi, G.; Strzelecki, A.; Senger, A. rgl: 3D Visualization Using OpenGL. R package version 0.100.54. Available online: https://CRAN.R-project.org/package=rgl (accessed on 16 March 2020).
74. Meyer, D.; Dimitriadou, E.; Hornik, K.; Weingessel, A.; Leisch, F. e1071: Misc Functions of the Department of Statistics, Probability Theory Group (Formerly: E1071). R package version 1.7-2. Available online: https://CRAN.R-project.org/package=e1071 (accessed on 16 March 2020).
75. Tang, S.; Li, Y.; Wang, Y. Simultaneous equations, error-invariable models, and model integration in systems ecology. *Ecol. Model.* **2001**, *142*, 285–294. [CrossRef]
76. Tang, S.; Wang, Y. A parameter estimation program for the error-in-variable model. *Ecol. Model.* **2002**, *156*, 225–236. [CrossRef]
77. Myers, R.H. *Classical and Modern Regression with Applications*, 2nd ed.; Duxbury Press: Pacific Grove, CA, USA, 1990.
78. White, H. A heteroskedasticity-consistent covariance matrix estimator and a direct test for heteroskedasticity. *Econometrica* **1980**, *48*, 817–838. [CrossRef]
79. Cailliez, F. *Estimación del Volumen Forestal y Predicción del Rendimiento*; FAO: Roma, Italy, 1980.
80. Harvey, A.C. Estimating regression models with multiplicative heteroscedasticity. *Econometrica* **1976**, *44*, 461–465. [CrossRef]
81. SAS Institute Inc. *SAS/ETS®9.1 User's Guide*; SAS Institute Inc.: Cary, NC, USA, 2004.
82. Ku, N.; Popescu, S.C.; Ansley, R.J.; Perotto-Baldivieso, H.L.; Filippi, A.M. Assessment of available rangeland woody plant biomass with a terrestrial lidar system. *Photogramm. Eng. Remote Sens.* **2012**, *78*, 349–361. [CrossRef]

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

83. Anderson, K.E.; Glenn, N.F.; Spaete, L.P.; Shinneman, D.J.; Pilliod, D.S.; Arkle, R.S.; McIlroy, S.K.; Derryberry, D.R. Estimating vegetation biomass and cover across large plots in shrub and grass dominated drylands using terrestrial lidar and machine learning. *Ecol. Indic.* **2018**, *84*, 793–802. [CrossRef]
84. Xu, K.; Su, Y.; Liu, J.; Hu, T.; Jin, S.; Ma, Q.; Zhai, Q.; Wang, R.; Zhang, J.; Li, Y.; et al. Estimation of degraded grassland aboveground biomass using machine learning methods from terrestrial laser scanning data. *Ecol. Indic.* **2020**, *108*, 105747. [CrossRef]
85. Chen, Y.; Zhu, X.; Yebra, M.; Harris, S.; Tapper, N. Strata-based forest fuel classification for wildfire hazard assessment using terrestrial LiDAR. *J. Appl. Remote Sens.* **2016**, *10*, 046025. [CrossRef]
86. Newnham, G.J.; Armston, J.D.; Calders, K.; Disney, M.I.; Lovell, J.L.; Schaaf, C.B.; Strahler, A.H.; Danson, F.M. Terrestrial laser scanning for plot-scale forest measurement. *Curr. For. Rep.* **2015**, *1*, 239–251. [CrossRef]
87. Gao, B. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sens. Environ.* **1996**, *58*, 257–266. [CrossRef]
88. Sims, D.A.; Gamon, J.A. Estimation of vegetation water content and photosynthetic tissue area from spectral reflectance: A comparison of indices based on liquid water and chlorophyll absorption features. *Remote Sens. Environ.* **2003**, *84*, 526–537. [CrossRef]
89. Pimont, F.; Dupuy, J.L.; Rigolot, E.; Prat, V.; Piboule, A. Estimating Leaf Bulk Density Distribution in a Tree Canopy Using Terrestrial LiDAR and a Straightforward Calibration Procedure. *Remote Sens.* **2015**, *7*, 7995–8018. [CrossRef]
90. Greaves, H.E.; Vierling, L.E.; Eitel, J.U.H.; Boelman, N.T.; Magney, T.S.; Prager, C.M.; Griffin, K.L. Applying terrestrial lidar for evaluation and calibration of airborne lidar-derived shrub biomass estimates in Arctic tundra. *Remote Sens. Lett.* **2017**, *8*, 175–184. [CrossRef]

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.

© 2020 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (http://creativecommons.org/licenses/by/4.0/).

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

ANEXO B

Estimaciones de carga y estructura vertical de formaciones de matorral a partir de mediciones de obstrucción visual en campo

(Comunicación 8ºCFE)

Stéfano Arellano-Pérez

Cecilia Alonso-Rego

Mario López Fernández

Juan Gabriel Álvarez-Fernández

José Antonio Vega Hidalgo

Ana Daría Ruíz-González

Sociedad Española de Ciencias Forestales, Lleida, 27/06 al 01/07/2022.

ISBN 978-84-941695-6-4

USC
UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

Mercedes GUIJARRO GUZMÁN, Presidenta de la Sociedad Española de Ciencias Forestales, Sociedad organizadora del 8º Congreso Forestal Español, celebrado del 27 de junio al 1 de julio de 2022, en Lleida,

AUTORIZA:

la inclusión en la tesis doctoral de **Cecilia Alonso Rego** de la comunicación presentada a este Congreso "***Estimaciones de carga y estructura vertical de formaciones de matorral a partir de mediciones de obstrucción visual en campo***" (Referencia 8CFE-211), de la que Cecilia Alonso Rego es coautora.

Madrid, 18 de junio de 2023

GUIJARRO GUZMAN MERCEDES - DNI 01817730V

Firmado digitalmente por GUIJARRO GUZMAN MERCEDES - DNI 01817730V
Fecha: 2023.06.18 17:46:39 +02'00'

Fdo.: Mercedes Guijarro Guzmán
Presidenta de la Sociedad Española de Ciencias Forestales

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

8º CONGRESO FORESTAL ESPAÑOL

La **Ciencia forestal** y su contribución a los **Objetivos de Desarrollo Sostenible**

8CFE - 211

Edita: Sociedad Española de Ciencias Forestales
Cataluña | Catalunya · 27 junio | juny - 1 julio | juliol 2022
ISBN 978-84-941695-6-4
© Sociedad Española de Ciencias Forestales

Organiza

Estimaciones de carga y estructura vertical de formaciones de matorral a partir de mediciones de obstrucción visual en campo

ARELLANO-PÉREZ, S.[1], ALONSO-REGO, C.[1], LÓPEZ-FERNÁNDEZ, M.[1], ÁLVAREZ-GONZÁLEZ, J.G.[1], VEGA, J.A.[2] y RUIZ-GONZÁLEZ, A.D.[1]

[1] Unidad de Gestión Ambiental y Forestal Sostenible (UXAFORES), Departamento de Ingeniería Agroforestal, Escuela Politécnica Superior de Ingeniería, Universidade de Santiago de Compostela, Benigno Ledo s/n, 27002 Lugo, España.
[2] Centro de Investigación Forestal de Lourizán, PO Box 127. 36080, Pontevedra, España.

Resumen

La estructura de las formaciones de matorral propensas al fuego, definida por factores como su altura, distribución de cargas por estado vegetativo (vivo-muerto) y fracciones de tamaño, o la densidad aparente, desempeña un papel fundamental en el comportamiento del fuego, afectando a variables como la velocidad de propagación o la intensidad lineal. Las metodologías habituales de estimación de la estructura vertical de complejos de combustible se basan en muestreos destructivos o sensores remotos como el láser escáner terrestre, siendo laboriosas y/o costosas y, por ello, de difícil implementación a gran escala. En este trabajo se describe una técnica de campo robusta y no destructiva para estimar la estructura del complejo de combustible basada en la obstrucción visual de una banda graduada colocada verticalmente en el mismo. La metodología se aplica a 55 parcelas en formaciones *de Ulex europaeus*, *Ulex gallii, Erica australis* y *Pterospartum tridentatum*. A partir de observaciones sencillas se obtuvieron métricas usadas posteriormente como variables independientes para ajustar un sistema de ecuaciones de estimación de cargas por fracciones y estado vegetativo. Esta metodología puede utilizarse también para evaluar la biomasa, el stock de carbono o la densidad y estructura del matorral como hábitat de fauna.

Palabras clave

Ajuste simultáneo, combustible forestal, inventario no destructivo, noroeste de España.

1. Introducción

La carga de combustible, definida como la cantidad de biomasa expresada en peso de materia seca por unidad de superficie, es una característica fundamental del combustible forestal ya que, junto con otras características estructurales, afecta en gran medida al comportamiento del fuego, regulando la velocidad de propagación, la intensidad lineal o la longitud de la llama (Chandler et al., 1983; Pyne et al., 1996). La adecuada caracterización de los combustibles, incluyendo la carga de combustible desagregada por clases de tamaño y estado vegetativo (fracciones vivas y muertas), es esencial para obtener estimaciones fiables de los simuladores de comportamiento del fuego que puedan ser utilizadas en los procesos de toma de decisiones en la gestión del combustible y la predicción del riesgo de incendios (Finney et al., 2007; Ager et al., 2011). Además, la carga de combustible es también un componente esencial en la evaluación del ciclo del carbono y de las emisiones de gases de efecto invernadero en los incendios forestales (ver, por ejemplo, Jiménez et al., 2013; Lasslop & Kloster, 2015).

En Galicia, el rápido crecimiento de la vegetación como consecuencia de las suaves temperaturas anuales y a las elevadas precipitaciones genera grandes acumulaciones de combustible, tanto superficial como arbóreo, que favorecen los incendios forestales de alta intensidad (Arellano et al., 2017), siendo una de las zonas más afectadas por los incendios en Europa (Koutsias et al., 2015; San Miguel-Ayanz et al., 2019). Esto es especialmente notorio en las formaciones de matorrales, ya que el 63% de la superficie total quemada en esta región en los últimos 20 años ha afectado a comunidades arbustivas no arbóreas (Xunta de Galicia, 2019), a pesar

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

de que estas comunidades representan sólo un 30% de la superficie forestal total y un 20% de la superficie total de la región (MARM, 2011a).

La carga de combustible de las comunidades de matorral, incluyendo tanto la capa arbustiva como la de hojarasca, puede cuantificarse tanto mediante muestreo destructivo como no destructivo (Catchpole & Wheeler, 1992). El muestreo destructivo es el método más preciso para determinar la carga de combustible, pero también el más complejo y costoso en tiempo y dinero, por lo que es difícil de aplicar a grandes áreas (Bonham, 2013). El muestreo no destructivo permite la estimación indirecta de la carga de combustible, normalmente mediante el uso de relaciones alométricas entre dichas cargas y variables del combustible que se miden fácilmente en el campo (De Cáceres et al., 2019; Montero et al., 2020).

En las dos últimas décadas se han desarrollado nuevos modelos que relacionan las principales características de los combustibles con datos de teledetección provenientes tanto de imágenes de satélite (Riaño et al., 2002, Viana et al., 2012) como de escáner láser aerotransportado (ALS) (Estornell et al., 2011a; Li et al., 2017). Esto ha permitido la construcción de mapas temáticos de combustible para la simulación del comportamiento del fuego y para la evaluación del riesgo de incendios. Sin embargo, la precisión de tales estimaciones depende en gran medida de la exactitud del modelo digital del terreno (MDT) generado previamente que, a su vez, se ve afectado por la densidad de la vegetación y la orografía del terreno (Estornell et al., 2011b). Así, en zonas de matorrales muy densos y terrenos escarpados, típicos del territorio gallego, la altura y el volumen de los arbustos tienden a ser subestimados (Glenn et al., 2011).

Por otro lado, también el escáner láser terrestre (TLS) ha mostrado un gran potencial para su uso en la evaluación de la biomasa y otras características de las formaciones de matorral, fundamentalmente a partir de la reconstrucción de la forma de los arbustos a partir de la nube de puntos, ya sea por aproximación a trozos del volumen o por voxelización (Alonso-Rego et al., 2020). En general, estos estudios con el TLS requieren varios escaneos desde diferentes posiciones, a menudo al menos de 5 a 9 escaneos, lo que implica la realización de un inventario de campo muy costoso en tiempo al margen de la importante inversión que supone contar con un equipo de estas características. Por otro lado, otras alternativas de estimación más rápidas y sencillas de aplicar, como puede ser el uso de foto-guías de combustible, no siempre aportan el nivel de detalle requerido.

Por todo ello, es necesario emplear metodologías basadas en mediciones sencillas en campo que permitan una estimación robusta de la carga de combustible, distinguiendo entre fracciones y estado vegetativo del matorral. Una posible opción es el uso del método FuelRule propuesto por Davies et al. (2004) y que se basa en la relación existente entre las principales variables de interés de los combustibles relacionadas con los incendios, su estructura espacial y la obstrucción visual que dicha estructura espacial provoca al visualizar un objeto situado en el interior de dicha estructura.

2. Objetivos

El objetivo de este estudio es probar el uso potencial de las técnicas de obstrucción visual en la toma de datos en campo para la obtención de métricas que puedan ser utilizadas como variables independientes en modelos de estimación de carga de combustible de matorral diferenciando por fracciones de tamaño y estado vegetativo (vivos/muertos) para cuatro de las principales comunidades de matorral no arbolado en Galicia.

3. Metodología

3.1. Selección de las parcelas

Las formaciones de matorral predominantes en el área de estudio están dominadas por especies de los géneros *Ulex*, *Erica*, *Pterospartum*, *Cytisus*, *Genista* y *Retama*. En este trabajo se seleccionaron 4 formaciones de matorral ampliamente representadas en Galicia (MARM, 2011b) y que figuran entre las más frecuentemente afectadas por incendios forestales. En la Tabla 1 se muestran las principales características en cuanto a especies dominantes y secundarias de estas cuatro formaciones.

Tabla 1. Principales especies presentes en las comunidades de matorral seleccionadas para este estudio.

Comunidad	Parcelas	Código	Especie principal	Especies secundarias
Brezos de gran porte	15	*Ea*	*Erica australis* L.	*Pterospartum tridentatum, Halimium alyssoides* (Lam.) Greuter*, Erica arborea* L.*, Ulex europaeus*
Carqueixales	10	*Pt*	*Pterospartum tridentatum* (L) Willk.	*Erica umbellata* Loefle ex L.*, Halimium alyssoides, Erica australis* L.*, Ulex gallii, Ulex europaeus, Pteridium aquilinum* (L.) Kuhn
Tojos de gran porte	15	*Ue*	*Ulex europaeus* L.	*Ulex gallii, Erica umbellata, Pteridium aquilinum Pterospartum tridentatum,*
Tojos de porte bajo	15	*Ug*	*Ulex gallii* Planch./ *Ulex minor* Roth.	*Ulex europaeus, Erica umbellata, Daboecia cantábrica* (Huds.) K.Koch*, Pterospartum tridentatum, Pteridium aquilinum*

Un total de 55 parcelas de las cuatro comunidades fueron seleccionadas en la zona de distribución de cada una de ellas, de modo que la muestra fuera representativa de la dispersión observada en cuanto a composición de especies y altura media del matorral y que la cobertura fuera mayor del 80%. En la Figura 1 se muestra la distribución espacial de la muestra empleada.

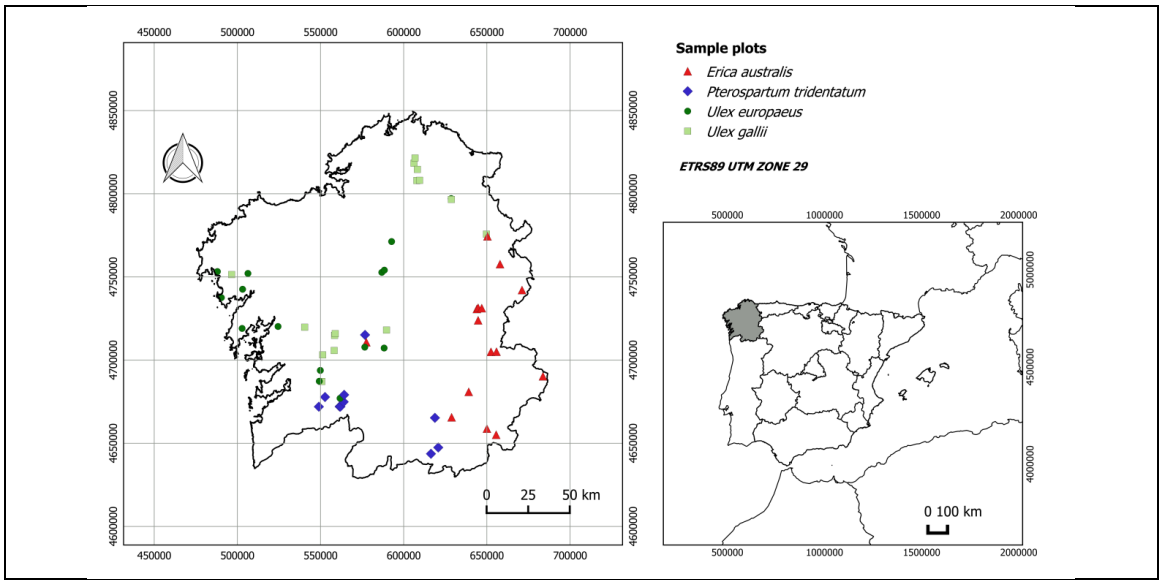

Figura 1. Localización geográfica de las parcelas empleadas en este estudio.

3.2. Medición de variables estructurales y estimación de cargas

En cada parcela se marcó sobre el terreno de forma aleatoria un cuadrado de 2x2 metros con los lados paralelos a la línea de máxima pendiente y a la curva de nivel. Cada cuadrado fue delimitado con jalones de madera y toda la vegetación exterior en una franja de 0.5 metros fue eliminada para facilitar las mediciones en el área delimitada. Se estableció un transecto formado por el perímetro completo del cuadrado más una diagonal interior que se utilizó como referencia para medir la longitud horizontal sobre el transecto de cada especie de matorral presente (cm), información que se utilizó para estimar la cobertura linear (Cov_m) siguiendo la metodología propuesta por Canfield (1941). También, cada 50 cm, se midió la altura total de cada especie interceptada por el transecto, la altura de la base de combustible de matorral vivo y muerto y la profundidad de la capa de mantillo, incluyendo en ella la hojarasca dado que la separación entre ambas capas no era siempre evidente. A partir de las mediciones de altura del matorral y de profundidad del mantillo se obtuvieron los valores medios por parcela ($\overline{h_m}$ y $\overline{h_{mant}}$, respectivamente).

Para cada comunidad las cargas de los combustibles se estimaron usando los sistemas de ecuaciones de estimación por especie desarrolladas para las comunidades de matorral en Galicia (Arellano-Pérez, 2011), y que emplean Cov_m, $\overline{h_m}$ y $\overline{h_{mant}}$ como variables de entrada. Esos sistemas incluyen ecuaciones para las siguientes 7 fracciones: combustible matorral fino muerto (diámetro<0.6 cm; $W_{m_G1_m}$); combustible matorral fino vivo (diámetro<0.6 cm; $W_{m_G1_v}$); combustible matorral fino (diámetro<0.6 cm; W_{m_G1}, muerto+vivo); combustible matorral grueso (diámetro≥0.6 cm; W_{m_G23}); combustible matorral total (W_m, fino+grueso); combustible mantillo (W_{mant}) y combustible total (W_{m+mant}). La Tabla 2 muestra los valores descriptivos de las variables estructurales por comunidad.

Tabla 2. Descripción de las principales características de los combustibles. Ea=Erica australis, Pt=Pterospartium tridentatum, Ue=Ulex europaeus y Ug=Ulex gallii/ Ulex minor. d.e.= desviación estándar, n= número de parcelas, $\overline{h_m}$ = altura media del matorral, Cov_m = cobertura, $\overline{h_{mant}}$ = profundidad media del mantillo, $W_{m_G1_m}$ = carga del combustible fino muerto, $W_{m_G1_v}$ = carga del combustible fino vivo, W_{m_G1} = carga del combustible fino, W_{m_G23} = carga del combustible grueso, W_m = carga total del matorral, W_{mant} = carga del mantillo y W_{m+mant} = carga total incluyendo matorral y mantillo.

Var.	Estadístico	*Ea* (n=15)	*Pt* (n=10)	*Ue* (n=15)	*Ug* (n=15)
$\overline{h_m}$ (cm)	Media (d.e.)	84.91 (31.48)	90.37 (33.94)	108.18 (19.95)	65.43 (21.77)
	Rango	38.24-150.76	42.86-151.05	59.71-113.10	13.90-109.33
Cov_m (%)	Media (d.e.)	99.80 (0.52)	99.34 (1.20)	99.64 (0.77)	98.32 (3.17)
	Rango	98.15-100	96.3-100	97.69-100	87.5-100
$\overline{h_{mant}}$ (cm)	Media (d.e.)	2.38 (1.17)	4.03 (1.19)	5.49 (2.11)	4.56 (0.98)
	Rango	0.78-5.60	2.02-5.86	3.08-10.55	2.40-5.81
$W_{m_G1_m}$ (kg m^{-2})	Media (d.e.)	0.41 (0.12)	0.84 (0.17)	0.89 (0.09)	0.75 (0.18)
	Rango	0.20-0.63	0.58-1.01	0.65-1.00	0.20-1.00
$W_{m_G1_v}$ (kg m^{-2})	Media (d.e.)	1.19 (0.23)	1.47 (0.25)	1.40 (0.07)	1.53 (0.23)
	Rango	0.76-1.53	1.08-1.73	1.18-1.48	0.72-1.69
W_{m_G1} (kg m^{-2})	Media (d.e.)	1.60 (0.36)	2.31 (0.42)	2.29 (0.16)	2.28 (0.41)
	Rango	0.96-2.16	1.66-2.74	1.83-2.47	0.92-2.69
W_{m_G23} (kg m^{-2})	Media (d.e.)	0.48 (0.36)	0.62 (0.40)	1.17 (0.31)	0.37 (0.28)
	Rango	0.06-1.38	0.12-1.37	0.46-1.58	0-1.09
W_m (kg m^{-2})	Media (d.e.)	2.08 (0.71)	2.93 (0.80)	3.47 (0.47)	2.65 (0.63)
	Rango	1.02-3.54	1.77-3.99	2.29-4.05	0.93-3.78
W_{mant} (kg m^{-2})	Media (d.e.)	1.00 (0.36)	1.38 (0.49)	1.89 (0.64)	1.70 (0.35)
	Rango	0.45-1.91	0.71-2.25	1.14-3.40	0.93-2.14
W_{m+mant} (kg m^{-2})	Media (d.e.)	3.08 (0.99)	4.31 (1.11)	5.35 (1.02)	4.35 (0.84)
	Rango	1.70-5.45	2.54-6.24	3.98-7.45	2.51-5.75

3.3. Mediciones de obstrucción visual con la banda y estimación de variables relacionadas

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

En cada una de las parcelas se realizaron las mediciones de obstrucción visual por parte del matorral de una barra de 2 metros de longitud y 5 cm de anchura dividida en bandas de 10 cm siguiendo la metodología de Davies et al. (2008). Para ello la barra se situó en posición vertical en el interior del cuadrado de 2x2 metros, a una distancia del 50 cm del centro del lado del cuadrado situado en curva de nivel en la parte inferior de la ladera. La barra se introdujo hasta llegar a la superficie del suelo mineral cubriendo, por tanto, la totalidad de la capa de hojarasca y mantillo. En cada banda de 10 cm se ha estimado visualmente la cobertura del matorral o de la capa de hojarasca y mantillo en porcentaje, distinguiendo entre especies y estado vegetativo (vivo o muerto). No se han considerado aquellas especies que no fueran leñosas. Además se ha estimado la altura de la capa de hojarasca y mantillo (h_{bmant}) y la altura total del matorral (h_{bm}), tomando como referencia para esta última la superficie de la capa de hojarasca y mantillo y las alturas de cada especie (Davies et al., 2008).

Con estos datos de cobertura de la banda de cada parcela se ha ajustado un modelo logístico:

$$p_i = \frac{e^{a+b*h_i}}{1+e^{a+b*h_i}} \quad [1]$$

donde p_i es el tanto por uno de cobertura de la banda *i* (*i* = 1 a 20) e h_i es la altura a la que está el punto medio de la banda *i* cuando el matorral sobrepasa la banda en altura y, en el caso de que la altura del matorral no llegue a sobrepasar la banda (última banda parcialmente ocupada), entonces h_i es la altura del punto medio de la longitud obstruida de dicha banda. Por ejemplo, si el matorral llega hasta 67 cm de altura, la última banda con matorral obstruyendo su visión va de 60 a 70 cm y el valor de h_i para esta banda sería de 63.5 cm.

Una vez estimados los parámetros del modelo logístico de perfil de combustible de cada parcela se obtuvieron los valores de una serie de métricas (Davies et al., 2008) para cada una de ellas: 1) Canopy Density Index (*CDI*), que se corresponde con el valor del parámetro *b* que define la pendiente de la recta de la linealización de la ecuación [1] $log(p_i/(1-p_i)) = a + b * h_i$; 2) Biomass Measure (*BM*), que se corresponde con el área bajo la curva del perfil obtenido por integración del modelo logístico entre 0 y la altura máxima del matorral; 3) la suma de los tantos por uno de obstrucción de matorral en cada banda para el total de la barra (obs_{acum}) y 4) el ratio entre la altura del mantillo y la altura total (r_{mant}).

3.4. Sistema de ecuaciones ajustado

Una vez estimadas para cada parcela tanto las cargas de las 7 fracciones de combustible como las métricas derivadas de las mediciones con la barra se procedió a ajustar un sistema de ecuaciones que permitan estimar dichas cargas de cada fracción usando como variables independientes las métricas derivadas de las mediciones con la barra.

Se decidió utilizar modelos alométricos ($Y = \beta_0 \cdot X_i^{\beta_i}$) y, en un primer paso, se procedió a ajustar la ecuación de cada fracción por separado. Para ello el modelo alométrico se linealizó empleando logaritmos y se seleccionó en cada caso el mejor conjunto de variables independientes (X_i) empleando el método stepwise. Una vez realizado ese paso se procedió a ajustar el sistema completo de siete ecuaciones no lineales simultáneamente para garantizar el principio de aditividad, es decir, que las estimaciones de una ecuación de carga que englobe varias fracciones coincida con la suma de las estimaciones de carga de cada una de las fracciones que la constituyen. El procedimiento empleado para garantizar la aditividad fue partir de la ecuación de carga total e ir desagregándola en cada uno de las fracciones que la constituyen siguiendo la metodología propuesta por Tang et al. (2001). De este modo, la expresión general de cada una de las siete ecuaciones se derivó de la siguiente manera:

1) En primer lugar se emplea una ecuación alométrica para estimar la carga total de combustible (matorral y mantillo) $\widehat{W_{m+mant}}$ conjuntamente.

$$\widehat{W_{m+mant}} = a_0 \cdot X_i^{a_i} \quad [2]$$

2) Se definen otras dos ecuaciones alométricas para discriminar entre la carga del combustible de matorral (W_m) y la del mantillo (W_{mant}) por desagregación de la ecuación [2]:

$\widehat{W_m} = exp\left[b_{0_m} + b_{i_m} log(X_i)\right]$ y $\widehat{W_{mant}} = exp\left[b_{0_{mant}} + b_{i_{mant}} log(X_i)\right]$; por lo tanto:

$$\frac{\widehat{W_m}}{\widehat{W_{m+mant}}} = \frac{\widehat{W_m}}{\left(\widehat{W_m} + \widehat{W_{mant}}\right)} = \frac{1}{1 + \left(\widehat{W_{mant}}/\widehat{W_m}\right)}$$

De este modo, la ecuación para estimar la carga de combustible de matorral fue:

$$\widehat{W_m} = \widehat{W_{m+mant}} \cdot \frac{1}{1 + exp[b_0 + b_i \cdot log(X_i)]} \quad [3]$$

siendo $b_0 = b_{0mant} - b_{0m}$ y $b_i = b_{imant} - b_{im}$; y la ecuación para la carga del mantillo fue:

$$\widehat{W_{mant}} = \widehat{W_{m+mant}} - \widehat{W_m} = \widehat{W_{m+mant}} \cdot \left[1 - \frac{1}{1 + exp[b_0 + b_i \cdot log(X_i)]}\right] \quad [4]$$

3) A continuación se desagrega la ecuación [3] para obtener dos ecuaciones que discriminen entre la carga de combustible de matorral grueso (W_{m_G23}) y fino (W_{m_G1}):

$\widehat{W_{m_G23}} = exp\left[c_{0_{g23}} + c_{i_{g23}} log(X_i)\right]$, y $\widehat{W_{m_G1}} = exp\left[c_{0_{g1}} + c_{i_{g1}} log(X_i)\right]$

$$\frac{\widehat{W_{m_G23}}}{\widehat{W_m}} = \frac{\widehat{W_{m_G23}}}{\left(\widehat{W_{m_G23}} + \widehat{W_{m_G1}}\right)} = \frac{1}{1 + \left(\widehat{W_{m_G1}}/\widehat{W_{m_G23}}\right)}$$

De este modo la ecuación de estimación de la carga de combustible grueso fue:

$$\widehat{W_{m_G23}} = \widehat{W_m} \cdot \frac{1}{1 + exp[c_0 + c_i \cdot log(X_i)]} \quad [5]$$

siendo $c_0 = c_{0g1} - c_{0g23}$ y $c_i = c_{ig1} - c_{ig23}$ y la de la carga de combustible fino fue:

$$\widehat{W_{m_G1}} = \widehat{W_m} - \widehat{W_{m_G23}} = \widehat{W_m} \cdot \left[1 - \frac{1}{1 + exp[c_0 + c_i \cdot log(X_i)]}\right] \quad [6]$$

4) Finalmente, la desagregación de la ecuación [6] da lugar a dos ecuaciones que permiten discriminar entre la carga de combustible de matorral fino muerto ($W_{m_G1_m}$) y vivo ($W_{m_G1_v}$):

$\widehat{W_{m_G1_m}} = exp\left[d_{0_{g1_m}} + d_{i_{g1_m}} log(X_i)\right]$ y $\widehat{W_{m_G1_v}} = exp\left[d_{0_{g1_v}} + d_{i_{g1_v}} log(X_i)\right]$

$$\frac{\widehat{W_{m_G1_m}}}{\widehat{W_{m_G1}}} = \frac{\widehat{W_{m_G1_m}}}{\left(\widehat{W_{m_G1_m}} + \widehat{W_{m_G1_v}}\right)} = \frac{1}{1 + \left(\widehat{W_{m_G1_v}}/\widehat{W_{m_G1_m}}\right)}$$

Por tanto, la ecuación de estimación de la carga de combustible fino muerto fue:

$$\widehat{W_{m_G1_m}} = \widehat{W_{m_G1}} \cdot \frac{1}{1 + exp[d_0 + d_i \cdot log(X_i)]} \quad [7]$$

siendo $d_0 = d_{0g1_v} - d_{0g1_m}$ y $d_i = d_{ig1_v} - d_{ig1_m}$; y la ecuación de la carga de combustible fino vivo fue:

$$\widehat{W_{m_G1_v}} = \widehat{W_{m_G1}} - \widehat{W_{m_G1_m}} = \widehat{W_{m_G1}} \cdot \left[1 - \frac{1}{1 + exp[d_0 + d_i \cdot log(X_i)]}\right] \quad [8]$$

Como el número de parcelas de cada comunidad es limitado para poder ajustar el sistema a cada una de dichas comunidades por separado, se empleó la base de datos completa para ajustar el sistema. Sin embargo, para evaluar las diferencias entre comunidades, los parámetros del modelo se expandieron usando una relación lineal que incluye parámetros asociados con variables dummy para diferenciar entre comunidades:

$$\alpha_0 = \alpha_{00} + \alpha_{01} I_{Ea} + \alpha_{02} I_{Ug} + \alpha_{03} I_{Pt} \quad [9]$$

donde α_0 es el parámetro que se expande; α_{00} es un parámetro común para las cuatro comunidades; α_{0i} (i = 1,...,3) es un parámetro asociado, e l_j (j = *Ea*, *Ug*, *Pt*) es una variable dummy cuyo valor es igual a 1 para la comunidad específica y 0 para el resto. Si el parámetro asociado resulta significativo en el ajuste (α=0.05), entonces existen diferencias entre las comunidades asociadas a dicho parámetro.

Para evaluar problemas de multicolinealidad en los modelos se calculó el valor del número de condición y, de acuerdo con Myers (1990), valores mayores de $\sqrt{1000}$ indican problemas asociados con la multicolinealidad que requieren prescindir de variables independientes fuertemente correlacionadas. Por otro lado, para evitar problemas de heteroscedasticidad se determinó el valor del test de White (1980) y se realizó una inspección visual de los gráficos de residuos studentizados frente a valores predichos de las cargas. En el caso de detectar problemas de heteroscedasticidad se procederá a ponderar el ajuste empleando como pesos de cada observación la inversa de su varianza estimada, siguiendo la metodología propuesta por Harvey (1976).

El Sistema de siete ecuaciones (ecuaciones [2] a [8]) fue ajustado simultáneamente empleando la metodología NLSUR (Nonnlinear Seemingly Unrelated Regression) para tener en cuenta las posibles correlaciones cruzadas entre los residuos de las diferentes fracciones de carga. El ajuste se realizó con el programa SAS/ETS® (2004). Para analizar la bondad del ajuste se estimaron dos estadísticos: el coeficiente de determinación (R^2) y la raíz del error medio cuadrático (*REMC*).

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y})^2} \quad [10]$$

$$REMC = \sqrt{\frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{n-1}} \quad [11]$$

donde y_i, $\hat{y}_i$ e $\bar{y}$ son los valores observado, predicho y medio de la variable dependiente y n es el número de datos empleados en el ajuste.

4. Resultados y discusión

La Tabla 3 muestra las ecuaciones obtenidas una vez realizado el ajuste simultáneo del sistema para la base de datos completa. En ningún caso se observaron problemas de multicolinealidad ni de heteroscedasticidad y todos los parámetros fueron significativos (α=0.05).

Las variables independientes que forma parte del sistema de ecuaciones son las alturas estimadas sobre la barra del matorral (h_{bm}) y de la capa de hojarasca y mantillo (h_{bmant}) y el valor de *Biomass Mesure* (*BM*), una métrica derivada del modelo logístico ajustado a las observaciones de obturación y que se corresponde con el área bajo la curva de dicho modelo. Aunque debido al tamaño de la muestra no fue posible ajustar el sistema de ecuaciones a cada una de las cuatro formaciones de matorral estudiadas, la inclusión de variables dummy para analizar diferencias entre ellas mostró diferencias significativas en los valores de dos o más parámetros en todas las ecuaciones ajustadas, lo que indica que sería necesario contar con una muestra de parcelas mayor para cada comunidad que permita ajustar el sistema de ecuaciones para cada una de ellas, lo que permitiría mejorar la exactitud de las estimaciones.

En la Figura 2 se muestran las gráficas de valores observados frente a valores predichos para cada una de las 7 fracciones a las que se ha ajustado una ecuación. Sobre dichas gráficas se han representado la diagonal (línea que correspondería con un ajuste perfecto) y la recta ajustada relacionando los valores observados con los predichos, mostrando también la expresión de dicha relación así como el valor del coeficiente de determinación (R^2) y de la raíz del error medio cuadrático del ajuste (*REMC*).

Tabla 3. Expresión final del sistema de ecuaciones ajustado simultáneamente para estimar la carga de cada fracción de combustible. $W_{m+mant.}$ = carga total de combustible (maorral + mantillo), W_m = carga total de combustible de matorral, $W_{mant.}$ = carga de mantillo, W_{m_G23} = carga de combustible grueso de matorral, W_{m_G1} = carga total de combustible fino de matorral total, $W_{m_G1_m}$ = carga de combustible fino muerto de matorral y $W_{m_G1_v}$ = carga de combustible fino vivo de matorral. I_j (j = Ea, Pt, Ue, Ug) = variable dummy cuyo valor es 1 para la comunidad específica a la que se refiere y 0 para el resto. Ea = Erica australis, Pt = Pterospartum tridentatum, Ue = Ulex europaeus y Ug = Ulex gallii/ Ulex minor. BM = Biomass Measure o área bajo la curva del modelo logístico ajustado y h_{bmant} y h_{bm} son las alturas estimadas con la barra para la capa de mantillo y para el matorral, respectivamente.

Expresión	Par.	Estimador
$\widehat{W_{m+mant}} = a_0 \cdot BM^{a_1 I_{Ea+Pt}} \cdot h_{bmant}^{a_2} \cdot h_{bm}^{a_3 I_{Ug+Ue}}$	a_0	0.2251
	a_1	0.2748
	a_2	0.2468
	a_3	0.5855
$\widehat{W_m} = \widehat{W_{m+mant}} \frac{1}{1+exp\left[b_{00}+b_{01}I_{Ea+Pt+Ug}+b_1 log(h_{bm})I_{Ea+Pt+Ug}+b_2 \cdot log(h_{bmant})\right]}$	b_{00}	-1.4335
	b_{01}	2.9891
$\widehat{W_{mant}} = \widehat{W_{m+mant}}\left[1-\frac{1}{1+exp\left[b_{00}+b_{01}I_{Ea+Pt+Ug}+b_1 log(h_{bm})I_{Ea+Pt+Ug}+b_2 \cdot log(h_{bmant})\right]}\right]$	b_1	-0.6361
	b_2	0.4501
$\widehat{W_{m_G23}} = \widehat{W_m} \frac{1}{1+exp\left[c_{00}+c_{01}I_{Ea+Pt}+c_{02}I_{Ug}+c_{10}log(h_{bm})I_{Ea+Pt+Ue}+c_{11}log(h_{bm})I_{Ug}\right]}$	c_{00}	5.5094
	c_{01}	0.4673
	c_{02}	6.9077
$\widehat{W_{m_G1}} = \widehat{W_m}\left[1-\frac{1}{1+exp\left[c_{00}+c_{01}I_{Ea+Pt}+c_{02}I_{Ug}+c_{10}log(h_{bm})I_{Ea+Pt+Ue}+c_{11}log(h_{bm})I_{Ug}\right]}\right]$	c_{10}	-1.0216
	c_{11}	-2.4011
$\widehat{W_{m_G1_m}} = \widehat{W_{m_G1}} \frac{1}{1+exp\left[d_{00}+d_{01}I_{Pt}+d_{02}I_{Ue}+d_{10}log(h_{bm})+d_{11}log(h_{bm})I_{Pt}+d_{12}log(h_{bm})I_{Ug}\right]}$	d_{00}	2.0462
	d_{01}	-1.2293
	d_{02}	-0.5330
$\widehat{W_{m_G1_v}} = \widehat{W_{m_G1}}\left[1-\frac{1}{1+exp\left[d_{00}+d_{01}I_{Pt}+d_{02}I_{Ue}+d_{10}log(h_{bm})+d_{11}log(h_{bm})I_{Pt}+d_{12}log(h_{bm})I_{Ug}\right]}\right]$	d_{10}	-0.2233
	d_{11}	0.1568
	d_{12}	-0.0905

Como se aprecia en las gráficas, las ecuaciones ajustadas explican una parte importante de la variabilidad observada, en la mayoría de los casos por encima del 70%, con valores que van desde el 46%, en el caso de la ecuación de estimación de la carga de combustible fino vivo de matorral, hasta casi el 88% de la ecuación de estimación de la carga de combustible grueso de matorral. En general, los modelos no presentan sesgo en sus estimaciones, salvo una ligera tendencia a subestimar para cargas bajas y sobreestimar para cargas altas en la ecuación de estimación de la carga de combustible fino vivo de matorral y a la inversa en la ecuación de estimación de la carga de combustible fino muerto de matorral.

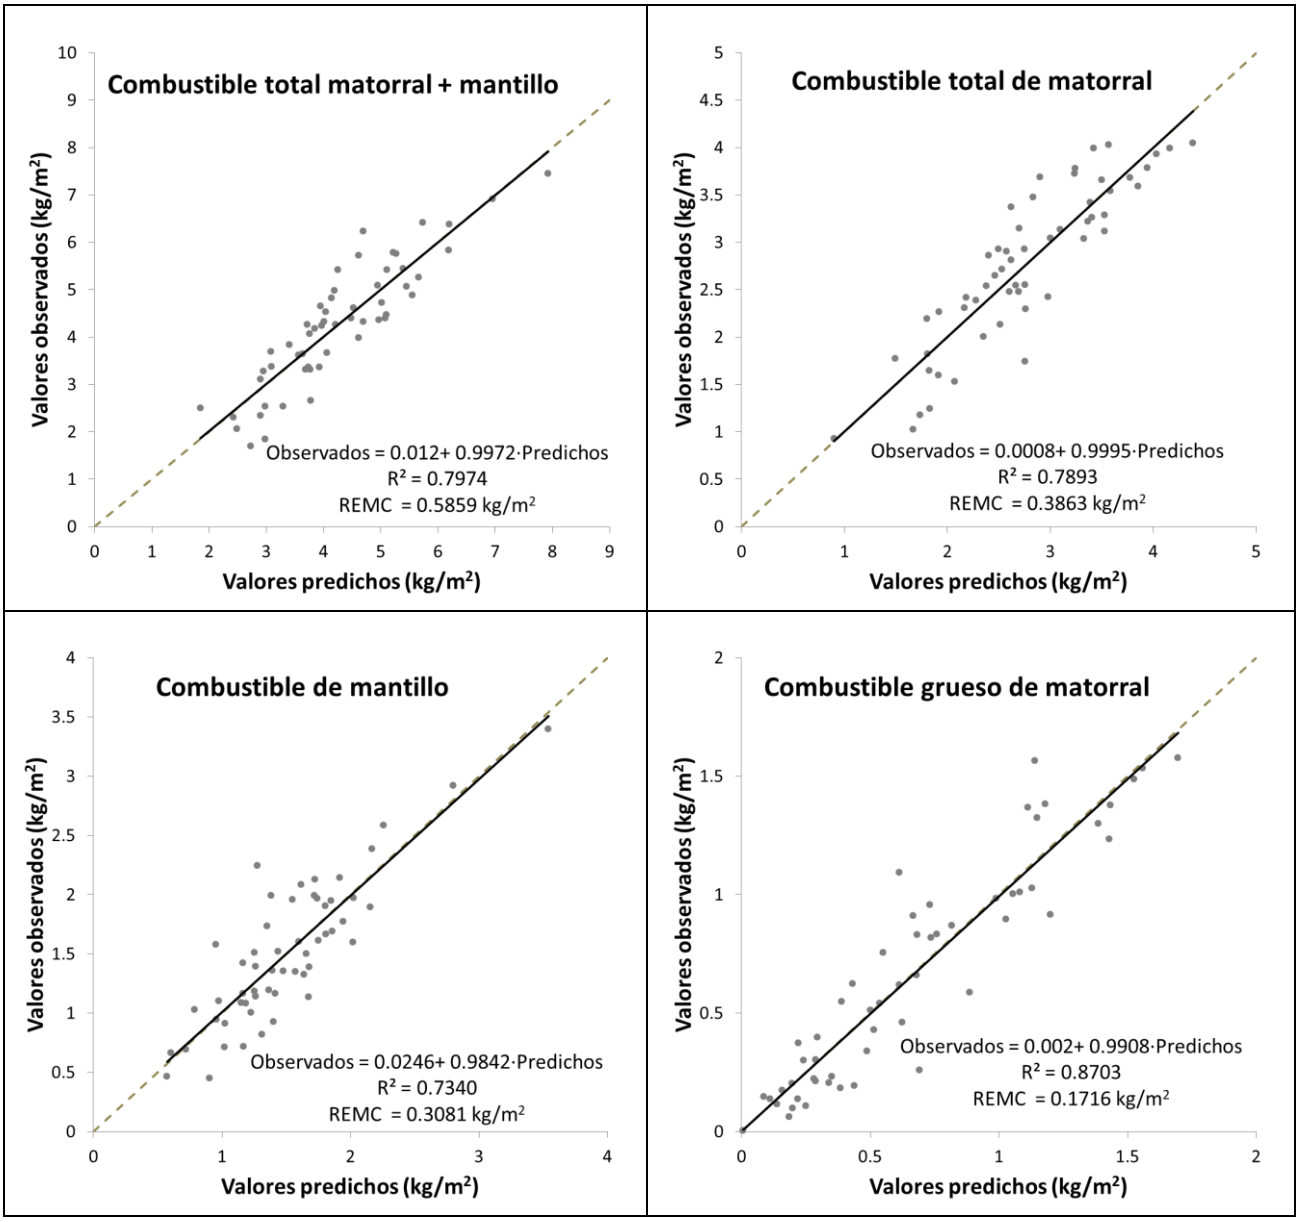

Figura 2. Valores observados frente a valores predichos de las cargas de las fracciones de combustibles ajustadas para el total de las parcelas analizadas. La línea punteada es la diagonal y la línea continua es la recta ajustada a los datos. R^2 es el coeficiente de determinación del ajuste de la recta de la figura y REMC es la raíz del error medio cuadrático.

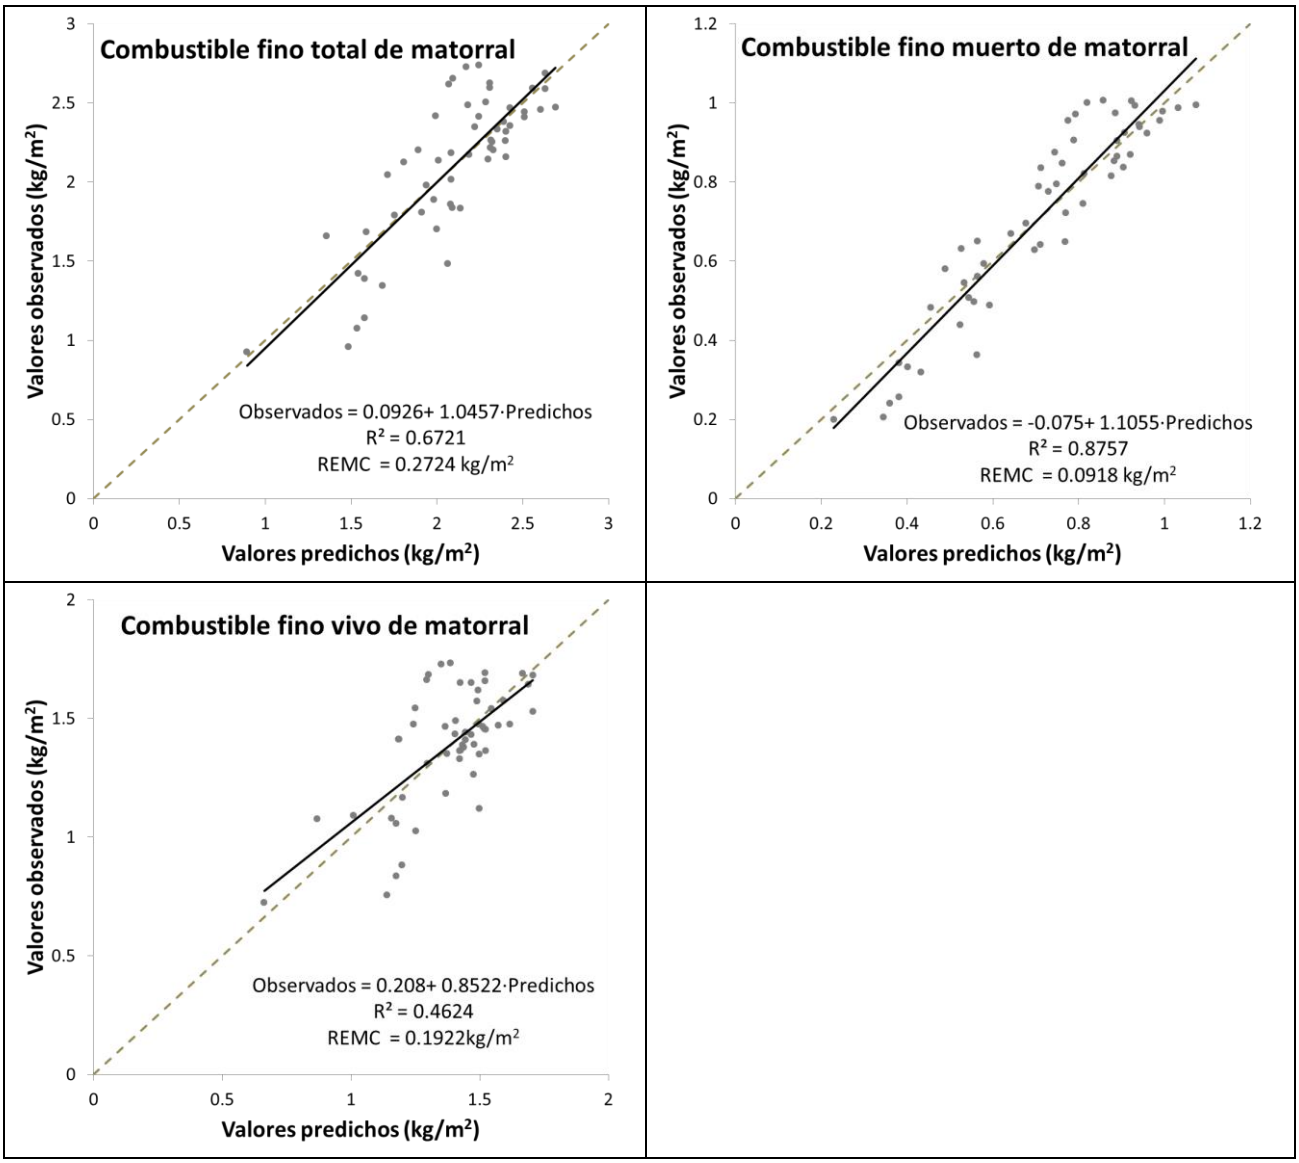

Figura 3. (continuación). Valores observados frente a valores predichos de las cargas de las fracciones de combustibles ajustadas para el total de las parcelas analizadas. La línea punteada es la diagonal y la línea continua es la recta ajustada a los datos. R^2 es el coeficiente de determinación del ajuste de la recta de la figura y REMC es la raíz del error medio cuadrático.

En general, los estadísticos de bondad del ajuste obtenidos son ligeramente inferiores a los obtenidos por Alonso-Rego et al. (2020), empleando la misma base de datos, al ajustar ecuaciones de estimación de estas mismas fracciones utilizando como variables independientes métricas derivadas de un único escaneo con láser terrestre (TLS). La única excepción es la ecuación de estimación de la carga de combustible de hojarasca y mantillo, que en este caso explica algo más del 73% de la variabilidad observada mientras que en el caso del modelo derivado de métricas del TLS únicamente explicó un 44% de la variabilidad observada. Una posible explicación de esta notable diferencia en la bondad de los ajustes para esta fracción es la fuerte correlación que existe entre la carga de mantillo y la profundidad de la capa de este combustible (Vega et al., 2022) y, mientras que la medición de dicha profundidad con la barra es sencilla y precisa, las nubes de puntos obtenidas del TLS no son de utilidad para caracterizar esta variable con exactitud (Alonso-Rego et al., 2020; Hudak et al., 2020).

5. Conclusiones

En Galicia, el abandono del terreno agrícola y la despoblación rural, entre otros factores, está provocando un fuerte incremento de la interfaz urbano-forestal, creando complejos mosaicos en los que predominan las formaciones de matorral propensas al fuego como las analizadas en este trabajo. La gestión eficaz de estos ecosistemas requiere cada vez más de cartografía detallada y precisa de combustibles que permitan comparar y priorizar diferentes estrategias de actuación preventiva y de restauración posterior. Para poder cumplir con estos requerimientos es necesario combinar información procedente tanto de inventarios de campo como de sensores remotos y los resultados obtenidos en este trabajo sugieren que el uso de la metodología basada en la oclusión visual puede ser de gran utilidad como alternativa al inventario tradicional para inventariar estas comunidades con fiabilidad.

En todo caso hay que tener en cuenta que este es un estudio preliminar y que las cargas de combustibles han sido estimadas y no cuantificadas, por lo que es necesario obtener una muestra más completa que cubra todas las combinaciones de desarrollo vegetativo y calidad de estación de las comunidades analizadas y que incorpore también muestreo destructivo para, de este modo, poder obtener ecuaciones fiables para cada fracción de combustible por comunidad.

6. Bibliografía

AGER, A.A.; VAILLANT, N.M.; FINNEY, M.A. 2011. Integrating Fire Behavior Models and Geospatial Analysis for Wildland Fire Risk Assessment and Fuel Management Planning. *J. Combustion* art. 572452.

ALONSO-REGO, C.; ARELLANO-PÉREZ, S.; CABO, C.; ORDOÑEZ, C.; ÁLVAREZ-GONZÁLEZ, J.G.; DÍAZ-VARELA, R.A.; RUIZ-GONZÁLEZ, A.D. 2020. Estimating Fuel Loads and Structural Characteristics of Shrub Communities by Using Terrestrial Laser Scanning. *Remote Sens.* 12, 3704.

ARELLANO-PÉREZ, S. 2011. Modelos de combustibles forestales de Galicia. Trabajo Fin de Máster, Universidad de Santiago de Compostela, Lugo, España.

ARELLANO, S., VEGA, J.A., RUIZ-GONZÁLEZ, A.D., ARELLANO, A., ÁLVAREZ-GONZÁLEZ, J.G., VEGA-NIEVA, D., PÉREZ, E. 2017. Foto-guía de combustibles forestales de Galicia y comportamiento del fuego asociado; Andavira. Santiago de Compostela. España.

BONHAM, C.D. 2013. Measurements for terrestrial vegetation, 2ª Edición. Wiley-Blackwell. Oxford, United Kingdom.

CANFIELD, R.H. 1941. Application of the line interception method in sampling range vegetation. *J. For.* 39, 388–394.

CATCHPOLE, W.R.; WHEELER, C.J. 1992. Estimating plant biomass: A review of techniques. *Aust. J. Ecol.* 17(2), 121–131.

CHANDLER, C.; CHENEY, P.; THOMAS, P.; TRABAUD, L.; WILLIAMS, D. 1983. Fire in Forestry. Volume 1. Forest Fire Behavior and Effects. John Wiley and Sons Inc. USA.

DAVIES, G.M.; HAMILTON, A.; SMITH, A.; LEGG, C.J. 2008. Using visual obstruction to estimate heathland fuel load and structure. *Int. J. Wildland Fire* 17(3), 380-389.

DE CÁCERES, M.; CASALS, P.; GABRIEL, E.; CASTRO, X. 2019. Scaling-up individual-level allometric equations to predict stand-level fuel loading in Mediterranean shrublands. *Ann. For. Sci.* 76, 87.

ESTORNELL, J.; RUIZ, L.A.; VELÁZQUEZ-MARTÍ, B.; FERNÁNDEZ-SARRÍA, A. 2011a. Estimation of shrub biomass by airborne LiDAR data in small forest stands. *For. Ecol. Manage*. 262, 1697–1703.

ESTORNELL, J.; RUIZ, L.A..; VELÁZQUEZ-MARTÍ, B.; HERMOSILLA, T. 2011b. Analysis of the factors affecting LiDAR DTM accuracy. *Int. J. Digit. Earth* 4(6), 521-538.

FINNEY, M.A.; SELI, R.C.; MCHUGH, CH.W.; AGER, A.A.; BAHRO, B.; AGEE, J. 2007. Simulation of long-term landscape-level fuel treatment effects on large wildfires. *Int. J. Wildland Fire* 16, 712-727.

GLENN, N.F.; SPAETE, L.P.; SANKEY, T.T.; DERRYBERRY, D.R.; HARDEGREE, S.P.; MITCHELL, J.J. 2011. Errors in LiDAR-derived shrub height and crown area on sloped terrain. *J. Arid Environ.* 75(4), 377–382.

HARVEY, A.C. 1976. Estimating regression models with multiplicative heteroscedasticity. *Econometrica* 44, 461-465.

HUDAK, A.T.; KATO, A.; BRIGHT, B.C.; LOUDERMILK, E.L.; HAWLEY, C.; RESTAINO, J.C.; OTTMAR, R.D.; PRATA, G.A.; CABO, C.; PRICHARD, S.J.; ROWELL, E.M.; WEISE, D.R. 2020. Towards spatially explicit quantification of pre- and post-fire fuels and fuel consumption from traditional and point cloud measurements. *For. Sci.* 66, 428–442.

JIMÉNEZ, E.; VEGA, J.A.; RUIZ-GONZÁLEZ, A.D.; GUIJARRO, M.; ALVAREZ-GONZÁLEZ, J.G.; MADRIGAL, J.; CUIÑAS, P.; HERNANDO, C.; FERNÁNDEZ-ALONSO, J.M. 2013. Carbon emissions and vertical pattern of canopy fuel consumption in three *Pinus pinaster* Ait. active crown fires in Galicia (NW Spain). *Ecol. Eng.* 54, 202-209.

KOUTSIAS, N.; ALLGÖWER, B.; KALABOKIDIS, K.; MALLINIS, G.; BALATSOS, P.; GOLDAMMER, J.G. 2015. Fire occurrence zoning from local to global scale in the European Mediterranean basin: implications for multi-scale fire management and policy. *iForest* 9, 195-204.

LASSLOP, G.; KLOSTER, S. 2015. Impact of fuel variability on wildfire emission estimates. *Atmos. Environ.* 121, 93-102.

LI, A.; DHAKAL, S.; GLENN, N.F.; SPAETE, L.P.; SHINNEMAN, D.J.; PILLIOD, D.S.; ARKLE, R.S.; MCILROY, S.K. 2017. Lidar aboveground vegetation biomass estimates in shrublands: Prediction, uncertainties and application to coarser scales. *Remote Sens.* 9(9), 903.

MARM. 2011a. Cuarto Inventario Forestal Nacional. Galicia; Ministerio de Medio Ambiente y Medio Rural y Marino. Madrid. España.

MARM. 2011b. Mapa Forestal de España. Escala 1:25.000. Ministerio de Agricultura, Pesca y Alimentación: Madrid, España.

MONTERO, G.; LÓPEZ-LEIVA, C.; RUIZ-PEINADO, R.; LÓPEZ-SENESPLEDA, E.; ONRUBIA, R.; PASALODOS, M. 2020. Producción de biomasa y fijación de carbono por los matorrales españoles y por el horizonte orgánico superficial de los suelos forestales. Ministerio de Agricultura, Pesca y Alimentación. Madrid. España.

MYERS, R.H. 1990. Classical and modern regression with applications, 2nd edition; Duxbury Press: California, USA.

PYNE, S.J.; ANDREWS, P.L.; LAVEN, R.D. 1996. Introduction to widland fire, 2nd Edition. John Wiley and Sons Inc. USA.

RIAÑO, D.; CHUVIECO, E.; SALAS, J.; PALACIOS-ORUETA, A.; BASTARRIKA, A. 2002. Generation of fuel type maps from Landsat TM images and ancillary data in Mediterranean ecosystems. *Can. J. For. Res.* 32, 1301–1315.

SAN MIGUEL-AYANZ, J.; DURRANT, T.; BOCA, R.; LIBERTÀ, G.; BRANCO, A.; DE RIGO, D.; FERRARI, D.; MAIANTI, P.; ARTÉS VIVANCOS, T.; OOM, D.; PFEIFFER, H.; NUIJTEN, D.; LERAY, T. 2019. Forest Fires in Europe, Middle East and North Africa 2018. JRC Technical Report EUR 29856 EN.

SAS INSTITUTE INC. 2004. SAS/ETS® 9.1 User's Guide; SAS Institute Inc: Cary, NC, USA.

TANG, S.; LI, Y.; WANG, Y. 2001. Simultaneous equations, error-invariable models, and model integration in systems ecology. *Ecol. Model.* 142, 285–294.

VEGA, A.; ARELLANO-PÉREZ, s.; ÁLVAREZ-GONZÁLEZ, J.G.; FERNÁNDEZ, C.; JIMÉNEZ, E.; FERNÁNDEZ-ALONSO, J.M.; VEGA-NIEVA, D.J.; BRIONES-HERRERA, C.; ALONSO-REGO, C., FONTÚRBEL, T., RUIZ-GONZÁLEZ, A.D. 2022. Modelling aboveground biomass and fuel load components at stand level in shrub communities in NW Spain. *For. Ecol. Manage.* 505, 119926.

VIANA, H.; ARANHA, J.; LOPES, D.; COHEN, W.B. 2012. Estimation of crown biomass of *Pinus pinaster* stands and shrubland above-ground biomass using forest inventory data, remotely sensed imagery and spatial prediction models. *Ecol. Model*. 226, 22-35.

WHITE, H. 1980. A heteroskedasticity-consistent covariance matrix estimator and a direct test for heteroskedasticity. *Econometrica* 48(4), 817-838.

XUNTA DE GALICIA. 2019. Plan de prevención y defensa contra los incendios forestales de Galicia –PLADIGA-. Consellería do Medio Rural. Santiago de Compostela. España.

ANEXO C

Estimating Stand and Fire-Related Surface and Canopy Fuel Variables in Pine Stands Using Low-Density Airborne and Single-Scan Terrestrial Laser Scanning Data

(Artículo 2)

Cecilia Alonso-Rego

Stéfano Arellano-Pérez

Juan Guerra-Hernández

Juan Alberto Molina-Varela

Adela Martínez-Calvo

César Pérez-Cruzado

Fernando Castedo-Dorado

Eduardo González-Ferreiro

Juan Gabriel Álvarez-González

Ana Daría Ruíz-González

Remote Sensing, 2021, 13, 5170

https://doi.org/10.3390/rs13245170

La revista *Remote Sensing* pertenece a la editorial MPDI, que permite la reutilización del artículo por la autora como parte de su tesis doctoral: https://www.mdpi.com/authors/rights

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

remote sensing

MDPI

Article

Estimating Stand and Fire-Related Surface and Canopy Fuel Variables in Pine Stands Using Low-Density Airborne and Single-Scan Terrestrial Laser Scanning Data

Cecilia Alonso-Rego [1], Stéfano Arellano-Pérez [1], Juan Guerra-Hernández [2], Juan Alberto Molina-Valero [1], Adela Martínez-Calvo [1], César Pérez-Cruzado [3], Fernando Castedo-Dorado [4], Eduardo González-Ferreiro [5], Juan Gabriel Álvarez-González [1] and Ana Daría Ruiz-González [1,*]

[1] Unidad de Gestión Ambiental y Forestal Sostenible (UXAFORES), Departamento de Ingeniería Agroforestal, Escuela Politécnica Superior de Ingeniería, Universidad de Santiago de Compostela, Benigno Ledo s/n, Campus Terra, 27002 Lugo, Spain; c.alonso.rego@usc.es (C.A.-R.); stefano.arellano@usc.es (S.A.-P.); juanalberto.molina.valero@usc.es (J.A.M.-V.); adela.martinez.calvo@usc.es (A.M.-C.); juangabriel.alvarez@usc.es (J.G.Á.-G.)

[2] Forest Research Centre, School of Agriculture, University of Lisbon, Instituto Superior de Agronomia (ISA), Tapada da Ajuda, 1349-017 Lisbon, Portugal; juanguerra@isa.ulisboa.pt

[3] Proyectos y Planificación (PROEPLA), Departamento de Producción Vegetal y Proyectos de Ingeniería, Escuela Politécnica Superior de Ingeniería, Universidad de Santiago de Compostela, Benigno Ledo s/n, Campus Terra, 27002 Lugo, Spain; cesar.cruzado@usc.es

[4] Departamento de Ingeniería y Ciencias Agrarias, Grupo de Investigación en Geomática e Ingeniería Cartográfica GI-202-GEOINCA, Universidad de León, Campus de Ponferrada, 24401 Ponferrada, Spain; fcasd@unileon.es

[5] Departamento de Tecnología Minera, Topografía y de Estructuras, Grupo de Investigación en Geomática e Ingeniería Cartográfica GI-202-GEOINCA, Escuela Superior y Técnica de Ingenieros de Minas y Escuela de Ingeniería Agraria y Forestal, Universidad de León, Av. de Astorga s/n, Campus de Ponferrada, 24401 Ponferrada, Spain; egonf@unileon.es

* Correspondence: anadaria.ruiz@usc.es

Citation: Alonso-Rego, C.; Arellano-Pérez, S.; Guerra-Hernández, J.; Molina-Valero, J.A.; Martínez-Calvo, A.; Pérez-Cruzado, C.; Castedo-Dorado, F.; González-Ferreiro, E.; Álvarez-González, J.G.; Ruiz-González, A.D. Estimating Stand and Fire-Related Surface and Canopy Fuel Variables in Pine Stands Using Low-Density Airborne and Single-Scan Terrestrial Laser Scanning Data. *Remote Sens.* **2021**, *13*, 5170. https://doi.org/10.3390/rs13245170

Academic Editor: Lin Cao

Received: 19 November 2021
Accepted: 18 December 2021
Published: 20 December 2021

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.

Copyright: © 2021 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (https://creativecommons.org/licenses/by/4.0/).

Abstract: In this study, we used data from a thinning trial conducted on 34 different sites and 102 sample plots established in pure and even-aged *Pinus radiata* and *Pinus pinaster* stands, to test the potential use of low-density airborne laser scanning (ALS) metrics and terrestrial laser scanning (TLS) metrics to provide accurate estimates of variables related to surface and canopy fires. An exhaustive field inventory was carried out in each plot to estimate the main stand variables and the main variables related to fire hazard: surface fuel loads by layers, fuel strata gap, surface fuel height, stand mean height, canopy base height, canopy fuel load and canopy bulk density. In addition, the point clouds from low-density ALS and single-scan TLS of each sample plot were used to calculate metrics related to the vertical and horizontal distribution of forest fuels. The comparative performance of the following three non-parametric machine learning techniques used to estimate the main stand- and fire-related variables from those metrics was evaluated: (i) multivariate adaptive regression splines (MARS), (ii) support vector machine (SVM), and (iii) random forest (RF). The selection of the best modeling approach was based on a comparison of the root mean square error (RMSE), obtained by optimizing the parameters of each technique and performing cross-validation. Overall, the best results were obtained with the MARS techniques for data from both sensors. The TLS data provided the best results for variables associated with the internal characteristics of canopy structure and understory fuel but were less reliable for estimating variables associated with the upper canopy, due to occlusion by mid-canopy foliage. The combination of ALS and TLS metrics improved the accuracy of estimates for all variables analyzed, except the height and the biomass of the understory shrubs. The variability demonstrated by the combined use of both types of metrics ranged from 43.11% for the biomass of duff litter layers to 94.25% for dominant height. The results suggest that the combination of machine learning techniques and metrics derived from low-density ALS data, drawn from a single-scan TLS or a

combination of both metrics, may represent a promising alternative to traditional field inventories for obtaining valuable information about surface and canopy fuel variables at large scales.

Keywords: forest fuel modeling; ALS/TLS; canopy fuel characterization; understory fuel characterization

1. Introduction

The use of accurate data obtained in forest inventories, including data on the canopy, understory, woody debris and litter fuel, is crucial for fire and forest management. Complete spatial and physical descriptions of the forest fuel layer (i.e., loads, horizontal coverage, spatial continuity, etc.) are needed as input variables in most fire behavior simulators [1–3]. Despite the essential role of forest fuel characterization in forest fire management and fire behavior, it remains challenging due to high spatial and temporal variability [4]. Traditional field measurements constitute the most accurate method of quantifying these variables, but field-based methods are often expensive and time-consuming and do not capture the range of variation across the landscape; also, in some cases, the data collection methods cannot feasibly capture three-dimensional (3D) forest characteristics [5].

Remote-sensing LiDAR (airborne light detection and ranging) technology with ALS (airborne laser scanning) and TLS (terrestrial laser scanning) sensors has been used as a cost-efficient method for monitoring a variety of forest inventory and forest fuel variables [6–9]. LiDAR scanning, with discrete or full-waveform technology, has been widely employed to characterize forest inventory variables and canopy fuel characteristics at a landscape scale using an area-based approach (ABA) in the last two decades [10–18]. However, fewer studies have examined the potential of ALS remote sensing for characterizing the lower canopy structure, the understory, and near-ground fuels, owing to the persistent difficulties associated with the presence of taller elements that occlude the underlying elements [19–24]. Although full-waveform ALS provides information about the interaction between the signal and the environment it travels through, as opposed to discrete ALS, which provides greater detail about the vertical distribution of the forest components [25–27], less attention has been devoted to the former due to the greater complexity of the data and the limited availability of processing tools [27,28].

Terrestrial laser scanning (TLS) has been proven to have great potential for characterizing and quantifying fuel variables that are essential for determining fire risk and fire behavior [29–32]. Most fuel characterization studies that use TLS data have focused on analyzing shrub vegetation in ecosystems without tree cover, often with the aim of obtaining spatially explicit, three-dimensional data as inputs for physical-based fire-spread models [33–36]. Such detailed studies require multiple scans in order to reconstruct the vegetation structure via piecewise approximation of the volume or by voxelization [30,34,36,37], which are time-consuming processes in terms of both field acquisition and the post-processing of data. However, single-scan TLS surveys have rarely been used to characterize forest fuels.

As a complement to ALS measurements, the increasingly accessible TLS technology, which scans the canopy structure from below (i.e., upwards), may enable accurate fine-scale assessment of fire fuel [20,38]. Although TLS-derived data are less suited for characterizing the complete forest structure over large areas, accurate information on the below-canopy structure can be a valuable addition to ALS observations, providing a better understanding of the relationship between canopy structure and the spatial distribution of understory and near-surface fuels. Therefore, TLS should be viewed as a completely different approach for characterizing forest structure at the plot scale, offering a high level of detail [39] that can complement the development of estimation models supported by

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

remote sensing data to the required spatial extent, such as those obtained from ALS surveys [20].

Over the past decade, comparison between ALS and TLS data for characterizing forest environments has been explored in different fields; for example, to characterize tree variables [40–43]; to estimate LAI and vertical foliage profiles [27,44–47]; to predict aboveground shrub biomass and characterize forest understory structure [48–50]; to estimate canopy fuel loads [51,52]; and to quantify the structural diversity of the forest [53]. However, few studies have considered the benefits of combining ALS and TLS data [19,54–58]. In addition, these studies are based on the fusion of ALS and TLS multi-angle scan point clouds to produce complex 3D geometric information at a very detailed scale that exceeds the requirements of most operational fire simulators, such as Farsite and FlamMap [2,3]. Furthermore, such fusions require complex and time-consuming georeferencing, data matching and post-processing protocols [56,59].

Accordingly, the aim of this study was to test the potential use of low-density ALS-derived metrics, TLS-derived metrics and a combination of both metrics to provide accurate estimates of surface and canopy fire-related variables to characterize Atlantic pine forest ecosystems at the stand level, comparing three non-parametric machine learning techniques: (i) multivariate adaptive regression splines (MARS), (ii) support vector machines (SVM) and (iii) random forest (RF).

2. Materials and Methods

2.1. Data

2.1.1. Study Area and Sample Plots

The study area is located in NW Spain (Figure 1). The data set corresponds to 34 thinning trials established in pure, even-aged stands of maritime pine (*Pinus pinaster* Ait.) (20 locations) and radiata pine (*Pinus radiata* D. Don) (14 locations). The thinning trials were carried out in 2009–2010, when the stand age ranged from 12 to 32 years (mean age 17.6 years) for maritime pine and from 12 to 22 years (mean age 16.3 years) for radiata pine. The average slope was 23.8%, with values ranging from 3.9 to 35.2%. Three rectangular plots (25 × 40 m) were established in each location, and a different treatment was randomly applied to each of the three plots: control (C, unthinned), moderate thinning (LT, 20% of the basal area removed) or heavy thinning (HT, 40% of the basal area removed). The same treatment that was applied in the plot was also applied in a 5-m buffer area around each plot. The corners of the sample plots were georeferenced using a Trimble Geo7X GPS (Geospatial, USA) with subsequent post-processing of the information to obtain sub-centimeter accuracies of the coordinates. All the trees within the plots were measured before and after thinning and were re-measured in 2011–2012, 2013–2014 and 2015–2016. However, surface fuels were only inventoried in 2015–2016 and, due to the complexity of the approach used to estimate these fuel loads, the moderately thinned plots were not considered. Therefore, only the control treatment and heavy thinning were analyzed for surface fire-related variables (68 sample plots), and the complete trials were used to analyze the canopy fire-related variables (102 sample plots). The thinning trials are described in further detail by Arellano-Pérez et al. [60].

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

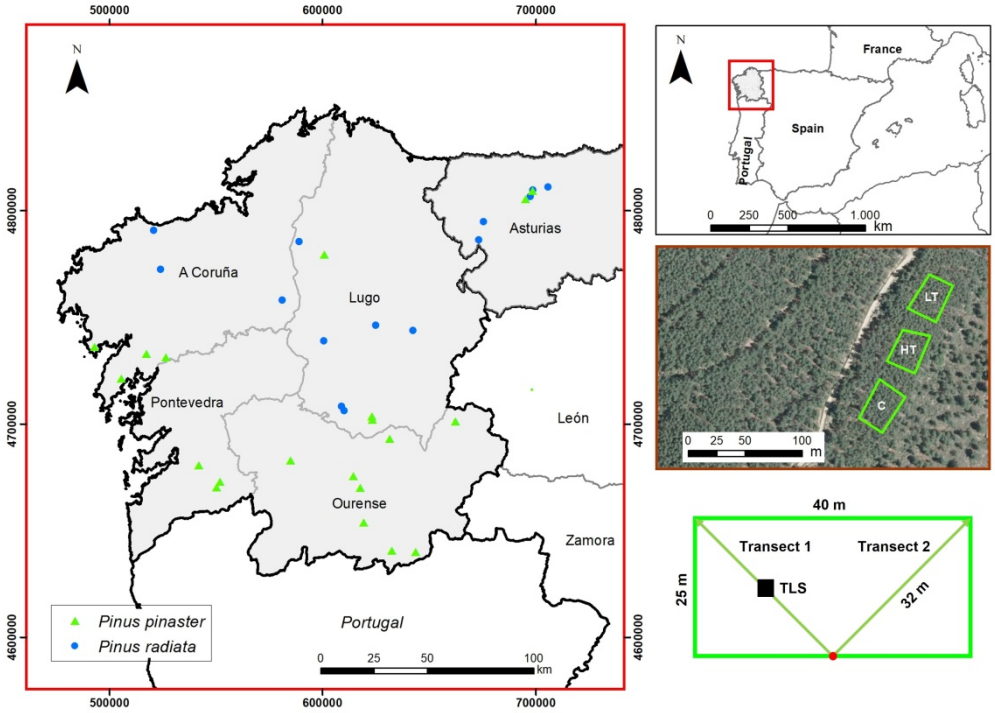

Figure 1. Geographical location of the 34 thinning trials in the study area (**left**). Example of three sample plots (green polygons) in one of the trial locations (**middle right**). Arrangement of surface fuel transects in each sample plot (**lower right**).

2.1.2. Tree and Stand Variables

The diameter at breast height (d) of all the trees was measured to the nearest 0.1 cm, at two perpendicular angles, with a graduated caliper. Total tree height (h) and height to the base of the live crown (h_{blc}, defined as the lower insertion point of live branches in a tree) were measured to the nearest 0.1 m with a digital hypsometer in a random sample of 30 trees and in an additional sample, including all dominant trees (the proportion of the 100-largest diameter trees per hectare). Generalized h–d models [61] and crown profile models [62,63] developed in the study area for *P. radiata* and *P. pinaster* were used to estimate h and h_{blc} for the remaining trees. For each tree, the total volume, the total aboveground biomass, and the fine biomass (consisting of the biomass of needles and fine twigs (particles of diameter < 0.6 cm)) were estimated using the individual tree-volume equations and the compatible biomass systems developed for maritime pine and radiata pine in Galicia [61]. The number of stems per hectare (N), stand basal area (G), mean stand height ($\bar{h}$), stand dominant height (H, defined as the mean height of the 100 thickest trees per ha), stand volume (V) and stand total aboveground biomass (W) were calculated from the tree variables for each plot and thinning treatment on a per-area basis (Table 1).

2.1.3. Canopy Fuel Variables

Three structural canopy fuel variables were estimated from tree measurements for each plot: canopy base height (CBH), canopy fuel load (CFL) and canopy bulk density (CBD). CBH was calculated as the height from the ground to the base of the live crown of trees, as an average per plot; CFL was calculated by dividing the fine biomass of all the trees of the sample plot by the plot area, and CBD was calculated by dividing CFL by the crown length, estimated as the difference between mean stand height ($\bar{h}$) and CBH. Mean and standard deviation values for the main stand characteristics and canopy fuel variables for each species and treatment are shown in Table 1.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Table 1. Statistics of main stand characteristics and canopy fuel variables. Std. dev. = standard deviation; N = stem density; G = stand basal area; $\bar{h}$ = mean stand height; H = stand dominant height; V = stand volume; W = stand total aboveground biomass; CFL = available canopy fuel load; CBH = canopy base height; CBD = canopy bulk density; C = control, LT= moderate thinning and HT = heavy thinning.

Variable	Statistic	*Pinus pinaster*			*Pinus radiata*		
		C	LT	HT	C	LT	HT
Stand Variables							
N	Mean	1312.57	945.53	697.70	1014.23	725.52	506.35
(stems ha^{-1})	Std. dev.	384.14	358.82	228.99	261.14	144.36	112.60
G	Mean	45.75	38.59	33.19	39.33	31.94	27.89
(m^2 ha^{-1})	Std. dev.	8.93	8.57	6.95	9.32	7.39	7.56
H	Mean	16.31	16.39	16.55	22.99	22.42	21.76
(m)	Std. dev.	2.49	2.85	2.51	2.97	2.63	2.94
V	Mean	297.51	256.28	223.39	349.20	282.46	245.22
(m^3 ha^{-1})	Std. dev.	90.41	88.14	70.34	95.83	84.04	86.85
W	Mean	160.06	138.55	121.31	172.47	138.89	119.40
(Mg ha^{-1})	Std. dev.	45.54	44.90	35.66	46.57	40.10	41.19
Canopy fire-related variables							
$\bar{h}$	Mean	14.79	15.18	15.53	19.16	19.58	20.01
(m)	Std. dev.	2.28	2.61	2.57	2.82	2.38	3.08
CFL	Mean	1.15	0.99	0.87	1.20	0.96	0.82
(kg m^{-2})	Std. dev.	0.26	0.26	0.20	0.28	0.21	0.21
CBH	Mean	9.10	8.88	8.89	10.50	9.72	9.23
(m)	Std. dev.	2.06	2.36	2.33	2.66	1.89	2.83
CBD	Mean	0.21	0.16	0.13	0.14	0.10	0.08
(kg m^{-3})	Std. dev.	0.05	0.04	0.03	0.03	0.02	0.03

2.1.4. Understory Fuel Variables

For each sample plot, two transects of 32 m were established from the middle of one of the 40 m sides of the plot to the vertices of the opposite side (see Figure 1). The linear shrub cover, differentiated by species, was recorded along each transect, and the depth of the litter and duff layers and the height of each shrub species were measured at 4 m intervals. The mean understory cover (COVshrub) and depth of the litter and duff layers ($\overline{d_{LFH}}$) of the sample plot were estimated from these measurements. The mean shrub height ($\overline{h_{shrub}}$) was calculated by weighting the heights of understory species according to the respective cover, and the fuel strata gap (FSG) was calculated as the difference between CBH and $\overline{h_{shrub}}$. The total understory load (Wshrub) and litter and duff layer fuel load (WLFH) were calculated using the equations proposed by Arellano-Pérez et al. [60] for these types of fuels in pine stands in Galicia. Finally, the downed woody debris load (Wdebris) was estimated by the planar transect method [64,65]. Mean and standard deviation values for the main surface fuel variables are shown in Table 2 for each species and thinning treatment.

Table 2. Summary statistics of the main surface fuel variables. Std. dev. = standard deviation; C = control; HT = heavy thinning; $\overline{h_{shrub}}$ = understory fuel depth, weighted by species cover; COV_{shrub} = understory cover; FSG = fuel strata gap; W_{debris} = downed woody debris load; W_{LFH} = litter and duff layers load and W_{shrub} = understory fuel load.

Variable	Statistic	*Pinus pinaster*		*Pinus radiata*	
		C	HT	C	HT
$\overline{h_{shrub}}$	Mean	30.39	37.57	46.19	56.96
(cm)	Std. dev.	21.44	25.99	24.97	24.57
COV_{shrub}	Mean	28.16	44.55	51.45	55.08
(%)	Std. dev.	26.13	27.70	32.61	32.41
FSG	Mean	8.79	8.52	10.04	8.66

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

(m)	Std. dev.	2.06	2.35	2.67	2.84
W_{debris}	Mean	5.78	11.89	7.22	27.66
(Mg ha^{-1})	Std. dev.	3.49	9.99	5.96	25.01
W_{LFH}	Mean	31.34	30.47	31.20	31.41
(Mg ha^{-1})	Std. dev.	5.23	4.69	3.93	4.59
W_{shrub}	Mean	4.60	6.11	7.06	8.57
(Mg ha^{-1})	Std. dev.	3.08	3.08	3.67	3.40

2.1.5. TLS Data

Each sample plot was scanned once by positioning the TLS equipment in the middle of the left transect coinciding with the field measurements. This position was also georeferenced with a Trimble Geo7X GPS with subsequent post-processing of the information to obtain sub-centimeter accuracies. Three-dimensional point clouds with a density of ~7.67 mm point spacing (~130 points/m) at 10 m were collected using the FARO Laser Scanner Focus 3D × 130 (Faro, USA). The TLS is a class-I laser (wavelength = 1550 nm) with a range of 0.6 to 130 m, for objects with 90% reflectivity, and an accuracy of ± 2 mm at 10 m range.

The point clouds from the single scan on each sample plot were cropped considering a 10-m radius to prevent incorporating any information from outside the plot. The height above the terrain of each point was calculated from digital elevation models (DEMs) created from each scan, using the "normalize" function in the FORTLS package [66] in R [67]. In the first step, ground points were segmented using the cloth simulation filter algorithm [68], and a DEM was generated via spatial interpolation of the z-value for these points, using a k-nearest-neighbor approach with inverse-distance weighting (KNN-IDW). Normalized heights were then calculated by subtracting the smoothed DEM from the z-values. These values were used to calculate 43 TLS metrics related to the vertical distribution of the point clouds. The metrics and the corresponding descriptions are summarized in Table 3.

Table 3. Variables related to the height distribution of the normalized TLS point cloud.

Metric	Description
TLShmax (cm)	maximum
TLShmean (cm)	mean
TLShmode (cm)	mode
TLShmedian (cm)	median
TLShSD (cm)	standard deviation
TLShvar (cm)	variance
TLShCV (cm)	coefficient of variation (ratio)
TLShskw, TLShkurt	skewness and kurtosis
TLShID (cm)	interquartile distance
TLSh01, TLSh05, TLSh10, …, TLSh90, TLSh95, TLSh99 (cm)	percentiles
TLSh25 and TLSh75 (cm)	first and third quartiles
TLShL1, TLShL2, TLShL3, TLShL4	L-moments of order i (i = 1,…,4)
TLShL-CV	Ratio of L1 and L2 moments
TLShMAD-median	median of the absolute deviations from the overall median
TLShMAD-mode	mode of the absolute deviations from the overall mode
TLSPA2m	% of laser returns above 2 m
TLSPAhmean	% of laser returns above hmean
TLSPAhmode	% of laser returns above hmode
TLSCRR	canopy relief ratio (TLShmean/TLShmax)

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

In addition, three other metrics were derived from the point cloud: (i) the ratio of the number of observed laser returns and the maximum number of laser returns (TLSPmax);

(ii) the ratio of the number of observed laser returns above 2 m in height and the maximum number of laser returns above 2 m in height (TLSPA2m_max); and (iii) the ratio of the number of observed laser returns below 2 m in height and the maximum number of laser returns below 2 m in height (TLSPB2m_max). The maximum number of laser returns was estimated as the number of returns that would be obtained, taking into account the laser scanning density on the surface of a cylinder of 10 m radius, with a base on the ground and height equal to the maximum height of the trees in the plot or in the height interval 0–2 m or 2 m–maximum height. We hypothesize that these metrics should be related to the bulk density of the total vegetation and shrubs in the plot, respectively.

Finally, the vertical point distribution was modeled using the two-parameter Weibull probability density function (pdf). For this purpose, the relative frequency of the number of laser returns in each cylindrical layer of height by 1 cm and radius 10 m was calculated by dividing the number of returns in this layer by the total number of laser returns. The scale (Wscale) and shape (Wshape) parameters of the Weibull pdf were then estimated using the first and the second moments of the relative distribution of vertical laser returns [69].

A total of 48 variables (the 43 metrics related to the vertical distribution of the point clouds summarized in Table 3—the three ratios characterizing the bulk density of vegetation and shrubs and the two Weibull pdf parameters) were finally considered as potential independent variables for the modeling of fuel loads.

2.1.6. ALS Data

ALS data set used in this study was obtained in the second round of the Spanish countrywide ALS measurements, which are publicly available in Spain through the National Plan for Aerial Orography (hereafter referred to as the PNOA). Square ALS blocks of 2 km on each side, covering the whole region of Galicia, were obtained from the CNIG (Centro Nacional de Información Geográfica) computer server (http://centrodedescargas.cnig.es/CentroDescargas/index.jsp (accessed on 7 June 2018)). The ALS data were collected in July–September 2015 (West Galicia), August–December 2016 and February 2017 (East Galicia), roughly coinciding with the timing of the field inventories. The scanning sensors used to collect the ALS data in the study area were a LEICA ALS50 (Leica Geosystems AG, Germany) (West Galicia) and a LEICA ALS80 (Leica Geosystems AG, Germany) (East Galicia). The standard laser pulse density was 0.5 first returns m^{-2}; the vertical accuracy of the scanning survey varied between 0.15 and 0.2 m and the horizontal accuracy varied between 0.3 and 0.4 m. The ALS datasets were processed using Fusion/LDV software [70]. The software parametrization and the workflow for processing the ALS point cloud are described in detail by González-Ferreiro et al. [12]. Briefly, all ALS echoes classified as "ground" were used to create a digital elevation model (DEM) with a spatial resolution of 2 m. Normalized heights were then calculated by subtracting the smoothed DEM from the z-values. These heights were used to calculate metrics related to the vertical distribution of the point clouds, similar to those obtained for the TLS data (Table 3), and to distinguish tree canopies (echoes above 2 m) and the shrub layer (echoes below 2 m) when computing the ALS height metrics.

2.2. Model Development

In a first step, models were developed separately for estimating the main fire-related variables and other stand variables from TLS- and ALS-derived metrics by using three different modeling approaches: multivariate adaptive regression splines (MARS), random forest (RF) and support vector machines (SVM). After selection of the best approach, the models were then refitted by combining ALS and TLS metrics as independent variables to examine the effect on the estimates and the goodness-of-fit statistics. In addition to using the TLS- and ALS-based metrics, a logical variable (I_{sp}) was also included to discriminate between overstory tree species, with a value of 1 for *P. radiata* and 0 for *P. pinaster*.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

MARS is a nonparametric technique that was proposed by Friedman [71]. This method constructs a non-linear regression model by fitting piecewise linear regressions in distinct intervals of the independent variable space. The general form of the non-parametric regression model is as follows:

$$y = \beta_0 + \sum_{i=1}^{M} \beta_i B_i(X) + \varepsilon \quad (1)$$

where β_0 is the intercept of the model, $B_i(X)$ are piecewise linear basis functions with X a vector of independent variables, β_i is the coefficient of the ith base, M is the number of basis functions and ε is the error. Each piecewise linear basis function takes on the following two forms: (1) a hinge function with the form $max(0, x\text{-}cte)$ with $x\text{-}cte > 0$ or $max(0, cte\text{-}x)$ with $cte\text{-}x > 0$ where x is an independent variable and cte is a constant value called "knot"; or (2) a product of two or three hinge functions, which can therefore model the interaction between two or three independent variables (x) defining the model degree (k = 1, 2 or 3).

The number of basis functions (M) and the model degree (k) were optimized by performing jack-knife cross-validation so that the training data set consists of all sample plots except one (test data set) and the model is fitted as many times as there are sample plots. The optimal model will be that yielding the lowest root mean square error (RMSE):

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

where y_i and $\hat{y}_i$ are the observed and predicted values of the dependent variable, respectively, and n is the number of observations. The predicted values used were those obtained in cross-validation for the out-of-bag samples (test data set). The "earth" package [72] in R software [67] was used to fit the MARS models.

RF is a widely used non-parametric classification and regression technique proposed by Breiman [73], consisting of an ensemble of decision trees. Bagging is used to create different training subsets and then fit a tree for each one, providing an estimate for those samples not included in the training subset. The final estimate in regression for each sample is obtained as a weighted mean of the estimates of a large number of individual trees [74].

RF also provides a measure of the importance of input features through random permutation, which can be used for feature-ranking or selection [75]. An RF model requires the number of trees to be grown and the number of randomized independent variables selected in each split to be established. In this study, the "randomForest" package [76] in R software [67] was used to fit the RF models by establishing the number of trees as 500 and the number of independent variables selected in each split as the square root of the total number of independent variables. The optimal RF model was again obtained using a cross-validation procedure by minimizing the RMSE obtained, using the residuals of the weighted estimates of the out-of-bag samples.

SVMs have been developed from artificial neural networks [77], and the models are developed by a set of vectors (or hyperplanes, if a higher dimension is requested) that minimize the mean error using kernel functions. The type of kernel used is a parameter that must be correctly established. Kernels also require their own parameterization, which can make employing this type of technique unsuitable for users with limited experience. Three different kernel functions were used in this study: linear (SVM-L), radial (SVM-R) and polynomial (SVM-P). The values of the hyperparameters associated with each of the kernel functions were optimized to minimize the RMSE obtained by jack-knife cross-validation. The "e1071" package [78] of R software [67] was used to fit the SVM models.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Two goodness-of-fit statistics were used to compare the results of the three modeling approaches: the RMSE(%), calculated as the percentage of RMSE over the mean value of

the dependent variable, and the R^2, defined as the square of the Pearson's correlation coefficient between observed and estimated values of the dependent variable ($r^2_{y_i\hat{y}_i}$).

3. Results and Discussion

3.1. Models Based on TLS-Derived Metrics

The goodness-of-fit statistics for the best models obtained with the three different approaches are shown in Table 4. Overall, models with the highest percentage of variability were explained (R^2) and the lowest RMSE were obtained using the MARS approach, whereas the least accurate estimates corresponded to the models obtained by the RF approach. The SVM models produced very similar overall results to MARS models but only when the kernel with the best goodness-of-fit statistics was selected for each dependent variable. The results suggest that parametrization of the radial kernel produces more accurate estimates of variables related to biomass or volume accumulation (W_{debris}, W_{LFH}, W_{shrub}, CFL, W and V), while for height-related variables ($\bar{h}_{shrub}$, FSG, $\bar{h}$, CBH and H), a simpler linear kernel is accurate enough. The use of the polynomial kernel, which is more complex to parameterize, did not improve the accuracy of the estimates, except with the model used to estimate W_{LFH}.

Table 4. Goodness-of-fit statistics of the models fitted using the three different approaches, considering TLS-derived metrics as independent variables. MARS = multivariate adaptive regression splines; SVM = support vector machine with linear (SVM-L), radial (SVM-R) or polynomial (SVM-P) kernels; and RF = random forest. The best results for each dependent variable are highlighted in bold.

Surface Fire-Related Variables						
Variable	**Statistic**	**MARS**	**SVM-L**	**SVM-R**	**SVM-P**	**RF**
$\bar{h}_{shrub}$ (cm)	R^2	**0.5308**	0.4605	0.3816	0.4679	0.4305
	RMSE(%)	**42.55**	45.63	48.85	45.32	46.88
FSG (m)	R^2	**0.7662**	0.6959	0.6254	0.6968	0.6556
	RMSE(%)	**13.30**	15.17	16.84	15.15	16.14
W_{debris} (Mg ha^{-1})	R^2	**0.3653**	0.2395	0.2507	0.0737	---
	RMSE(%)	**97.07**	106.26	105.47	117.27	---
W_{LFH} (Mg ha^{-1})	R^2	0.3496	0.3035	0.3346	**0.4225**	0.2987
	RMSE(%)	11.96	12.38	12.10	**11.27**	12.42
W_{shrub} (Mg ha^{-1})	R^2	**0.3462**	0.3270	0.3178	0.3106	0.3180
	RMSE(%)	**44.51**	45.16	45.46	45.70	45.46
Canopy fire-related variables						
Variable	Statistic	MARS	SVM-L	SVM-R	SVM-P	RF
$\bar{h}$ (m)	R^2	0.9250	0.9357	**0.9395**	0.9318	0.8766
	RMSE(%)	5.43	5.03	**4.88**	5.18	6.97
CBH (m)	R^2	**0.7715**	0.7273	0.7417	0.7115	0.6670
	RMSE(%)	**11.92**	13.02	12.67	13.39	14.39
CFL (kg m^{-2})	R^2	**0.4235**	0.3498	0.3783	0.3498	0.2978
	RMSE(%)	**20.42**	21.69	21.21	21.69	22.54
CBD (kg m^{-3})	R^2	**0.5135**	0.4510	0.3604	0.3265	0.2660
	RMSE(%)	**26.54**	28.16	30.43	31.21	32.62
Stand variables						
Variable	Statistic	MARS	SVM-L	SVM-R	SVM-P	RF
H (m)	R^2	**0.9324**	0.9200	0.9316	0.9190	0.9066
	RMSE(%)	**5.39**	5.86	5.42	5.90	6.34
G (m^2 ha^{-1})	R^2	**0.5187**	0.2945	0.5125	0.2937	0.3334
	RMSE(%)	**18.70**	22.64	18.82	22.66	22.01
V (m^3 ha^{-1})	R^2	0.5865	0.4976	**0.5924**	0.5236	0.4475
	RMSE(%)	21.84	24.07	**21.68**	23.44	25.24
W	R^2	0.5607	0.4600	**0.6120**	0.4831	0.4603

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

(Mg ha^{-1})	RMSE(%)	21.29	23.61	**20.01**	23.10	23.60

The explanatory ability of the models obtained with MARS depended on the characteristics of the dependent variable analyzed. For variables related to shrub or tree height, the variability explained by the models ranged from 53.1% for $\bar{h}_{shrub}$ (RMSE % = 42.55) to values of around 93% for mean ($\bar{h}$) and dominant (H) canopy heights (RMSE % = 5.43 and 5.39, respectively), with values of around 77% for FSG and CBH (RMSE % = 13.30 and 11.92, respectively). The shrub height is not an arithmetic mean but a value weighted by the coverage of the different shrub species present, so that estimation from TLS metrics not only depended on the vertical distribution of the point cloud but also on the horizontal distribution. This may explain why a smaller amount of variability was explained than for the other height variables that can be more easily estimated from the metrics of the vertical distribution of the point cloud.

The values of the goodness-of-fit statistics obtained for mean and dominant heights are within the upper range of values reported in the relevant literature: Huang et al. [79] reported explained variability values of 90.25%, with an RMSE% of 6.91, for the estimation of individual tree heights in mixed hardwood stands in Culai Mountain National Forest in China; Liang and Hyyppa [80] obtained RMSE% values ranging from 6.9 to 21.3% in single scans for tree-height estimation in a study including mixed stands of *P. sylvestris*, *Picea abies,* and *Betula* sp. And pine- and spruce-dominated stands in Finland; Srinivasan et al. [81] explained 92% of the observed variability in the height estimation of individual *P. taeda* trees; and, in a comprehensive study of different TLS algorithms for processing TLS datasets, Liang et al. [8] used 24 sample plots selected from varying forest-stand conditions in boreal forests and obtained RMSE% values for a single scan that ranged from 12 to 23% in "Easy" plots (clear visibility with minimal understory vegetation and low stem density ~600 trees/ha), from 18 to 41% in "Medium" plots (moderate stem densities ~1000 trees/ha and sparse understory vegetation), and from 28 to 57% in "Difficult" plots (plots with high stem densities of ~2000 trees/ha and dense understory vegetation). Nonetheless, these comparisons are inconclusive as, in all these studies, the goodness-of-fit statistics refer to estimates of individual tree heights and not to stand values. On the other hand, Torralba et al. [82] fitted a model for estimating H from TLS-derived metrics with a single scan that explained 73% of the observed variability, with an RMSE% value of 8% in mixed stands of Mediterranean forest.

Very few studies have characterized the vertical structure of forest fuels using TLS data [83,84]. García et al. [83] fitted CBH and FSG estimation models in Scots pine and larch, as well as mixed stands of oak and birch forests in Cheshire (UK) from a single TLS scan, with RMSE% values of 46.54 and 49.68%, respectively, which are much higher than those obtained in this study (8.29 and 8.57%).

Regarding the variables related to overstory biomass or volume (G, W, V, CFL and CBD), the variability explained by the MARS models ranged from 42.35% for CFL (RMSE% = 20.42) to 58.65% for V (21.84%), with values slightly above 51% for G and CBD (RMSE% = 18.70 and 26.54, respectively), and around 56% for W (RMSE% = 21.29). The RMSE% values are within the lower range of values reported in previous studies, especially for V and W, although, in most of these studies, the stand variables were calculated by aggregating tree values derived from allometric models including tree diameter and height estimates that were mainly obtained from several scans and not directly estimated, as in the present study [85,86]. However, the accuracy of this individual tree-modeling approach is strongly dependent on stem detection, which is affected by occlusion effects, low point density and a high amount of noise at certain locations in the plot, even when the multi-scan mode is used [7,87]. In single scans, stem detection rates vary between 20 and 100%, with values around 73% in forests with densities of between 400 and 1400 stems/ha [80,88–90].

Strahler et al. [91] obtained an error of 15.49% in the estimation of basal area in a *P. ponderosa* stand in New South Wales (Australia) with a single scan; in a study with 30 scan

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

plots installed in six New England hardwood and conifer forest stands, Yao et al. [92] explained 66% of the observed variability in G, with an RMSE% value of 15.24% and 85% of the variability observed in W, with an RMSE% of 10.69%; Skowronski et al. [51] reported RMSE% values for CBD and CFL estimates of 18.48% and 15.68%, respectively, in wildfire-prone stands in the New Jersey Pinelands; Torralba et al. [82] explained 70% of the observed variability in W with an RMSE% of 21% in Mediterranean forests using TLS-metrics obtained with a single scan similar to those used in this study; in a study of 40 plots in mature *P. sylvestris* forests in Spain, Molina-Valero et al. [93] estimated G from a single scan with an RMSE% of 21.84%, and explained 75% of the observed variability.

Regarding the MARS models for estimating surface fuel loads (W_{LFH}, W_{debris} and W_{shrub}), the explained variability is very similar, varying between 34.62% for W_{shrub} and 36.53% for W_{debris}, although the RMSE% values are very different (11.96% for W_{LFH}; 97.07% for W_{debris} and 44.51% for W_{shrub}), as a consequence of the large variability observed in the W_{debris} load, especially in the heavily thinned plots.

Most studies estimating shrub biomass using TLS data have focused on reconstructing the shrub shape from the point cloud, either by piecewise approximation of the volume or by voxelization [30,34,36,37]. Studies that use TLS to predict the biomass distribution of shrub and other fuel layers without reconstructing shapes from the returns are scarce. For example, Chen et al. [21] developed a predictive model to estimate surface fuel loads in south-eastern Australian *Eucalyptus* forests, including the topography and previous fire disturbance as possible independent variables. The best model explained 89% of the observed variability, with litter depth obtained via TLS data, the number of years since the last fire, canopy density obtained with ALS data, and plot elevation as independent variables; when ALS and topographic variables were not considered, the amount of observed variability explained was reduced to 69%. Wallace et al. [94] explained 74% (RMSE% = 16.3%) of the observed variability in aboveground surface biomass in eucalypt-dominated lowland forests and 50% (RMSE% = 41.2%) in floodplain riparian forests in Victoria (Australia) using TLS data. Alonso-Rego et al. [32] developed an equation system for estimating size-disaggregated shrub and litter fuel loads for four treeless shrub communities in Galicia (NW Spain), using metrics derived from a single TLS scan with an RMSE% of 30.55% for W_{LFH} and 9.50% for W_{shrub}. Li et al. [95] obtained a model that explained 69% of the shrub layer biomass in temperate mixed broadleaf–conifer forest in Jilin Province (China), using TLS-derived shrub volume.

3.2. Models Based on ALS-Derived metrics

The goodness-of-fit statistics of the best models obtained with the three different modeling approaches are shown in Table 5. Similar to the models based on TLS metrics, MARS and SVS approaches outperformed the RF approach. Taking these results into account, and to facilitate comparison between those models with different metrics (TLS vs. ALS), the discussion below only considers the MARS model statistics.

Table 5. Goodness-of-fit statistics of the models fitted using the three different approaches, considering ALS-derived metrics as independent variables. MARS = multivariate adaptive regression splines; SVM = support vector machine with linear (SVM-L), radial (SVM-R) or polynomial (SVM-P) kernels; and RF = random forest. The best results for each dependent variable are highlighted in bold.

		Surface Fire-Related Variables				
Variable	**Statistic**	**MARS**	**SVM-L**	**SVM-R**	**SVM-P**	**RF**
$\bar{h}_{shrub}$ (cm)	R^2	0.3201	0.3144	**0.4246**	0.4185	0.2758
	RMSE(%)	51.22	51.44	**47.12**	47.37	52.86
FSG (m)	R^2	0.8551	0.7924	0.7310	**0.8624**	0.7811
	RMSE(%)	10.47	12.53	14.27	**10.20**	12.87
W_{debris} (Mg ha^{-1})	R^2	**0.4069**	0.3794	0.3874	0.3244	0.3027
	RMSE(%)	**93.84**	95.99	95.37	100.15	101.75

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

W_{LFH}	R^2	0.1049	0.1556	0.1346	**0.1750**	---
(Mg ha^{-1})	RMSE(%)	14.03	13.63	13.80	**13.47**	---
W_{shrub}	R^2	**0.4796**	0.4020	0.4514	0.4333	0.4542
(Mg ha^{-1})	RMSE(%)	**39.71**	42.56	40.77	41.44	40.67
Canopy fire-related variables						
Variable	Statistic	MARS	SVM-L	SVM-R	SVM-P	RF
$\bar{h}$	R^2	**0.8916**	0.8457	0.8197	0.8455	0.8381
(m)	RMSE(%)	**6.53**	7.80	8.43	7.80	7.98
CBH	R^2	0.8457	0.8574	0.8381	**0.8625**	0.8141
(m)	RMSE(%)	9.79	9.41	10.03	**9.25**	10.75
CFL	R^2	**0.5203**	0.4167	0.3959	0.3985	0.3285
(kg m^{-2})	RMSE(%)	**18.63**	20.55	20.91	20.87	22.05
CBD	R^2	0.5587	0.4677	0.4412	**0.5727**	0.4590
(kg m^{-3})	RMSE(%)	25.26	27.74	28.45	**24.84**	27.95
Stand variables						
Variable	Statistic	MARS	SVM-L	SVM-R	SVM-P	RF
H	R^2	**0.9307**	0.9201	0.8560	0.9105	0.8849
(m)	RMSE(%)	**5.46**	5.86	7.87	6.20	7.03
G	R^2	0.4939	0.4867	0.4314	**0.5027**	0.3849
(m^2 ha^{-1})	RMSE(%)	19.18	19.32	20.33	**19.01**	21.14
V	R^2	**0.6599**	0.5749	0.5521	0.6137	0.5638
(m^3 ha^{-1})	RMSE(%)	**19.80**	22.14	22.73	21.11	22.43
W	R^2	**0.6452**	0.5199	0.5620	0.5949	0.5624
(Mg ha^{-1})	RMSE(%)	**19.14**	22.26	21.26	20.45	21.25

As with models based on TLS metrics, the accuracy of estimates from models based on ALS metrics varied greatly, depending on the dependent variable analyzed. For variables related to tree or shrub height, the explained variability was very similar to that obtained with the TLS models for $\bar{h}$ (89.16%; RMSE% = 6.53%), and H (93.07%; RMSE% = 5.46%); it was much higher for CBH (84.57%; RMSE% = 9.79%) and FSG (85.51%; RMSE% = 10.47%) and much lower in the case of $\bar{h}_{shrub}$ (32.01%; RMSE% = 51.22%), probably due to the difficulty in adequately characterizing the understory in dense forests using low-density LiDAR data collected from an airborne platform [23,96]. Comparative studies show that ALS yields more accurate canopy-height estimations than TLS [41,97], while TLS yields a more accurate characterization of the understory vegetation [19,98].

Regarding the variables related to overstory volume or biomass, the models based on ALS metrics were similar to those based on TLS metrics for G (R^2 = 0.4939; RMSE% = 19.18%) and much better for the other variables (V -R^2 = 0.6599; RMSE% = 19.80%-; W -R^2 = 0.6452; RMSE% = 19.14%-; CFL -R^2 = 0.5203; RMSE% = 18.63%-; and CBD -R^2 = 0.5587; RMSE% = 25.26%). For surface fuel loads, model estimates based on ALS metrics were slightly more accurate for W_{debris} (R^2 = 0.4069; RMSE% = 93.84%) and W_{shrub} (R^2 = 0.4796; RMSE% = 39.71%) and much worse for W_{LFH} (R^2 = 0.1049; RMSE% = 14.03%). As with models based on TLS metrics, in the case of the latter variable, the RMSE% was low, despite the fact that a very low amount of the variability was explained by the model (≈10%) due to the low variability of litter fuel load in the 68 plots analyzed; by contrast, in the case of debris fuel load, the RMSE% was very high due to the high variability observed in the plots, especially in the heavily thinned plots.

All these goodness-of-fit values are within the range previously reported for low-density LiDAR data and forests of similar characteristics. For example, for pure *P. radiata* forests, the V models developed by González-Ferreiro et al. [10] yielded an RMSE% of 30.4% for LIDAR data, with a density of 0.5 first-returns/m^2 and 24.98% for 8 first-returns/m^2; the AGB models used by the same authors yielded RMSE% values of 26.77% for 0.5 first-returns/m^2 and 23.73% for 8 first-returns/m^2. Using the same data and applying a hybrid approach based on the combined use of multiple linear regression

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

(MLR) and a genetic algorithm to select the best set of independent variables, García-Gutiérrez et al. [99] reported RMSE% values of 23.03% and 21.29% for G models, using LiDAR data with densities of 0.5 and 8 first-returns/m², respectively; 27.24% and 24.63% for V models fitted to LiDAR data sets of 0.5 and 8 first-returns/m², respectively; and for W models, RMSE% values of 26.77% for 0.5 first-returns/m² and 24.04% for a laser pulse density of 8 first-returns/m². In a study in *P. radiata* forest in Galicia, González-Ferreiro et al. [11] obtained RMSE% values of 6.94% for $\bar{h}$; 7.13% for CBH; 12.40% for CFL; and 21.85% for CBD with LiDAR data with a density of 0.5 first-returns/m². In a study of a network of thinning trials in 4 pure and even-aged *P. pinaster* stands in Asturias (NW Spain), Hevia et al. [14] obtained RMSE% values for $\bar{h}$, H and CBH of the same order as those obtained in this study (5.22; 6.50 and 8.43%, respectively), although the results were much better for fuel load variables (8.09% for CFL and 9.78% for CBD); however, LiDAR data density was also much higher (8–16 first-returns/m²) than that used in this study. Jiménez et al. [100] developed models for estimating stand variables in *P. pinaster* and *P. radiata* forests in Galicia, using a combination of PNOA LiDAR data and LANDSAT-ETM data in plots of the Fourth Spanish National Forest Inventory (4-SNFI) obtaining RMSE% values for G of 41. 62% for *P. pinaster* and 27.64% for *P. radiata*; the H values were 6.31 and 11.76%, respectively, for the same species; for crown biomass, the values were 42.86 and 26%, respectively, and for stem biomass, 46.92 and 23.99%, respectively. When also using 4-SNFI data and PNOA LiDAR data, González-Ferreiro et al. [12] obtained RMSE% values for the estimation of CFL of 44.35% for *P. radiata* and 45.39% for *P. pinaster*. In a study of *P. pinaster* and *P. radiata* forests in north-western Spain using machine learning approaches, Novo-Fernández et al. [101] obtained RMSE% values for estimating V of 37.95 and 37.23%, respectively, and 38.51 and 38.27%, respectively, for estimating W from data of the 4-SNFI and the same PNOA LiDAR data used in this study.

3.3. MARS Models Combining TLS- and ALS-Derived Metrics

The mathematical expressions of MARS models obtained using TLS metrics, ALS metrics, and both, combined as independent variables for estimating surface fire-related variables, canopy fire-related variables and stand variables are shown in Tables A1, A2 and A3, respectively (see Appendix A). The combination of ALS and TLS metrics improved the predictive ability of models based on a unique metric type in all cases except for $\bar{h}_{shrub}$ and W_{shrub}, as shown by the values of the goodness-of-fit statistics (Table 6) for each set of metrics (TLS, ALS, and TLS + ALS). Improved accuracy of estimates is particularly important for those variables related to overstory volume or biomass, with RMSE reductions of 7.56% for CFL; 9.21% for V; 9.52% for CBD; and 10.72% for G.

These results were expected as these variables are strongly related to canopy size, and its vertical and horizontal distribution and the combination of ALS-derived metrics (considering zenith angle) and ground-based TLS-derived metrics provides much more complete information regarding spatial structure [102]. The models developed for estimating W_{LFH} and W_{debris} that were fitted using metrics from both sensors also showed RMSE reductions of 6.47 and 7.22%, respectively.

Table 6. Goodness-of-fit statistics of the models fitted, using the three different sets of metrics (TLS, ALS and TLS + ALS) as independent variables.

Surface Fire-Related Variables				
Variable	**Statistic**	**TLS-Data**	**ALS-Data**	**TLS + ALS-Data**
$\bar{h}_{shrub}$ (cm)	R^2	0.5308	0.3201	0.5308
	RMSE(%)	42.55	51.22	42.55
FSG (m)	R^2	0.7662	0.8551	0.8987
	RMSE(%)	13.30	10.47	8.75
Wdebris (Mg ha^{-1})	R^2	0.3653	0.4069	0.4894
	RMSE(%)	97.07	93.84	87.06

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

WLFH	R^2	0.3496	0.1049	0.4311
(Mg ha^{-1})	RMSE(%)	11.96	14.03	11.19
Wshrub	R^2	0.3462	0.4796	0.3462
(Mg ha^{-1})	RMSE(%)	44.51	39.71	44.51
Canopy fire-related variables				
Variable	Statistic	TLS-data	ALS-data	TLS+ALS-data
$\bar{h}$	R^2	0.9250	0.8916	0.9343
(m)	RMSE(%)	5.43	6.53	5.08
CBH	R^2	0.7715	0.8457	0.8683
(m)	RMSE(%)	11.92	9.79	9.05
CFL	R^2	0.4235	0.5203	0.5899
(kg m^{-2})	RMSE(%)	20.42	18.63	17.22
CBD	R^2	0.5135	0.5587	0.6383
(kg m^{-3})	RMSE(%)	26.54	25.26	22.86
Stand variables				
Variable	Statistic	TLS-data	ALS-data	TLS+ALS-data
H	R^2	0.9324	0.9307	0.9425
(m)	RMSE(%)	5.39	5.46	4.97
G	R^2	0.5187	0.4939	0.6163
(m^2 ha^{-1})	RMSE(%)	18.7	19.18	16.70
V	R^2	0.5865	0.6599	0.7197
(m^3 ha^{-1})	RMSE(%)	21.84	19.80	17.98
W	R^2	0.5607	0.6452	0.6512
(Mg ha^{-1})	RMSE(%)	21.29	19.14	18.97

The relative importance of each independent variable for the best-fit models is shown in Figure 2. The importance of each variable was estimated on the basis of the RMSE reduction that incorporation in the model implies, assuming that the other independent variables are already included in the model.

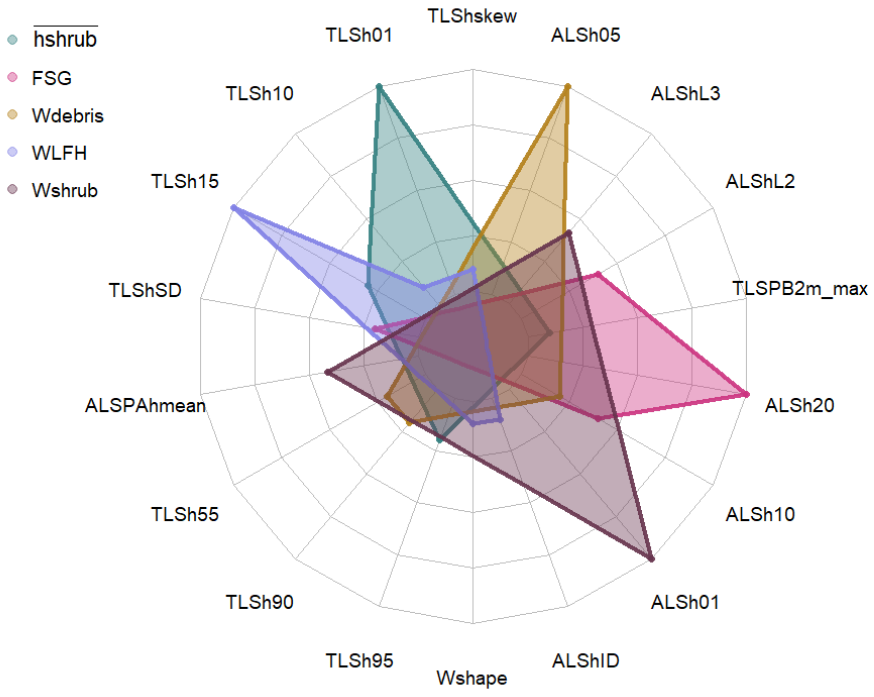

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

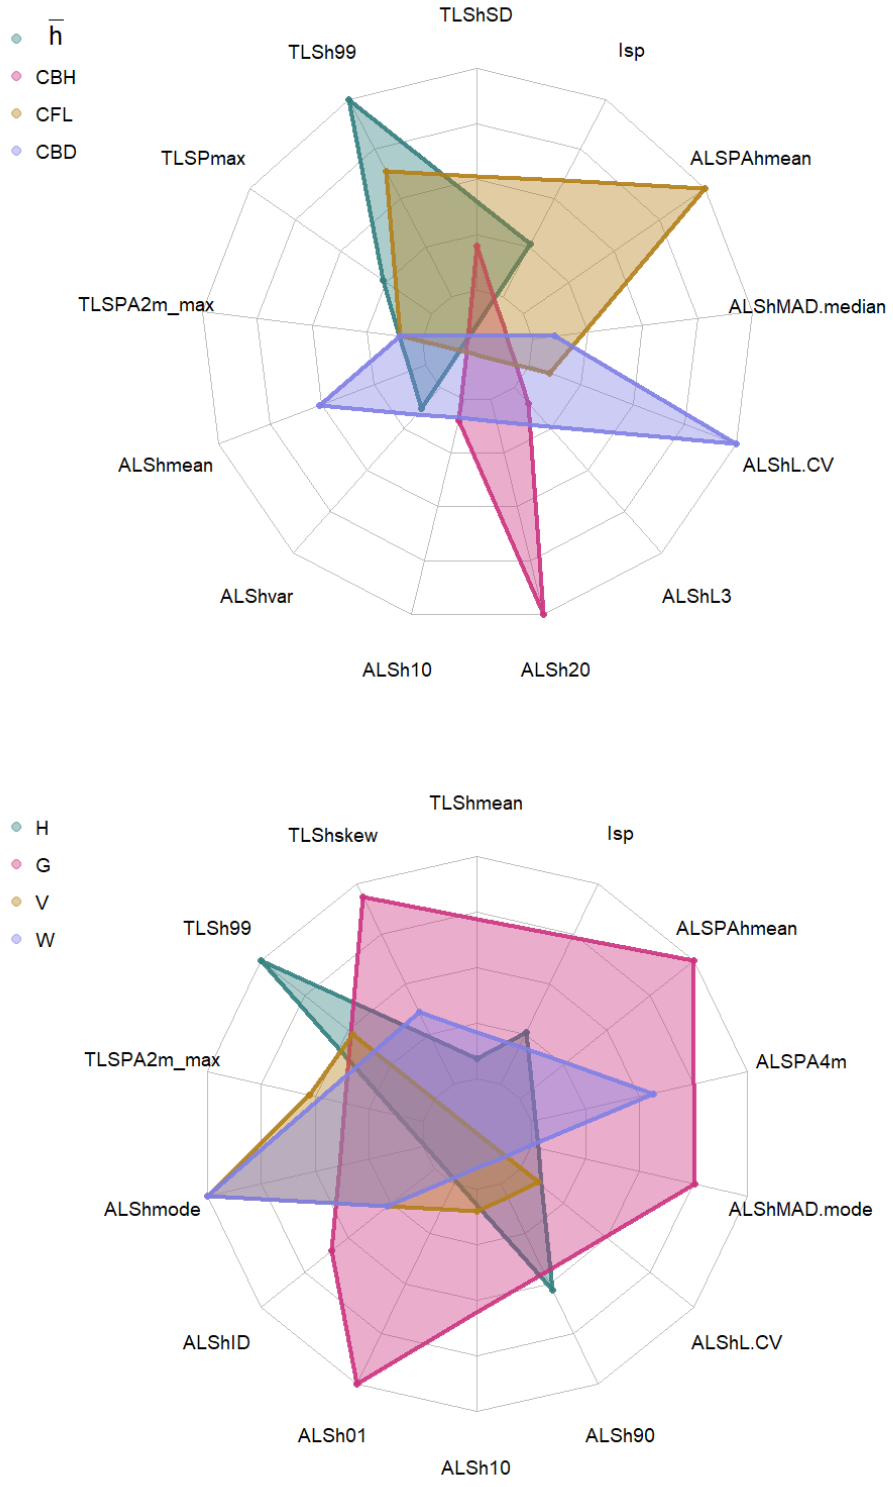

Figure 2. Relative importance of independent variables for the best-fit models for estimating surface fire-related variables (upper figure), canopy fire-related variables (middle figure) and stand variables (lower figure), respectively. The values were estimated from the RMSE reduction that the incorporation of each variable in the model implies, assuming that the other independent variables were already included in the model.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Overall, the percentile metrics of both ALS and TLS data sets were the variables that contribute most to the variability explained by the models, especially for those dependent variables related to height ($\bar{h}_{shrub}$, $\bar{h}$, FSG, CBH and H). However, as expected, in the case

of variables related to fuel loads, metrics related to profile shape (skewness, interquartile distance, L-moments, or the shape parameter of the Weibull distribution) or to the horizontal distribution of the point cloud ($TLSP_{A2m_max}$ or $TLSP_{B2m_max}$) contributed significantly to the reduction of RMSE values. These results were similar to those obtained in multiple studies that used metrics instead of reconstructing 3D structures, especially in the case of ALS point clouds [41,101,103–105].

For all models fitted using TLS-derived metrics, except those related to variables associated with surface fuels ($\bar{h}_{shrub}$, W_{debris}, W_{LFH} and W_{shrub}), the estimates were species-dependent, i.e., the species-related logical variable (I_{sp}) appeared as a significant independent variable alone and/or modulating the effect of other independent variables. However, this logical variable was not part of the adjusted models using ALS-derived metrics, except in the case of H. By combining both metrics, the species-related logical variable only affected the estimates of the dominant height model. These results were consistent with differences in the resolution and spatial coverage of each LiDAR platform, conditioned by point density and scan positions that affect occlusions, limiting their ability to characterize different canopy zones [49,53]. TLS measures the forest from below (i.e., upward), producing high-resolution data that provide a detailed characterization of the differences in the vertical structure of the stands of these two species, especially in the lower canopy. On the other hand, the low-density ALS used has much lower resolution, and the downward view of the forest leads to many more occlusions and hinders characterization of the lower canopy. Therefore, the greater variability in the TLS point cloud metrics is driven by the inclusion of a species-related factor in the models. In the case of the dominant height models, even the low-density ALS used allows the upper crown structure to be characterized in great detail, which, when combined with the remarkable differences in H between species in the dataset used (16.42 m and 22.39 m for *P. pinaster* and *P. radiata*, respectively), results in a great variability of the upper percentiles that is driven by the inclusion of the logical variable affecting the species. Despite the differences in point density of the sensors, models fitted for this variable yielded very similar goodness-of-fit statistics, explaining almost 93% of the observed variability. Similar results have already been reported in benchmarking studies [19,45,98]. The species-independent nature of the fitted models, based on ALS-derived metrics, enables the construction of estimation maps without pre-stratification according to pine species or the added use of classification models using remote sensing data, which could increase the uncertainty of the estimates.

Finally, Figure A1 (Appendix A) shows the scatter plots of observed versus predicted values, obtained with the best-fitting models for estimating surface and canopy fire-related and stand variables. These graphs do not show any evident trends indicating under- or over-estimation biases for any of the dependent variables analyzed. In addition, no anomalous trends were observed in the models fitted only with ALS- or TLS-derived metrics (graphs not included).

4. Conclusions

Rational decision-making related to the management of forest fuels to reduce fire risk and regarding the best alternatives to fight fires, based on predicted fire behavior, must be based on objective and reliable characterization of the variables related to the initiation and spread of forest fires, i.e., surface and, especially, crown fires.

The results obtained in this study indicated that the use of metrics obtained from both low-density ALS and single-scan TLS surveys shows promise for characterizing the main surface and canopy fuel variables related to fire risk. However, each platform has trade-offs, which, unsurprisingly, affect the models' estimations. ALS captures the vegetation structure from above, providing a higher level of detail in the upper canopy and declining accuracy in representing canopy characteristics with increasing canopy depth, especially for species with dense canopies, such as those analyzed here, and with the low-density ALS used in the study. Conversely, TLS captures the vegetation structure from below,

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

providing high-resolution data on the internal characteristics of canopy structural diversity and understory vegetation. However, TLS data are less reliable for estimating upper canopy variables due to occlusion by mid-canopy foliage.

Combining the advantages of both sensors by integrating both sets of metrics as predictor variables in the models yielded an overall improvement in the accuracy of the estimates, clearly indicating the potential of integrating ALS and TLS systems in forest inventories.

Models were developed in this study by integrating independently derived ALS and TLS metrics, without the need to combine both point clouds by complex post-processing methods; however, the combination of these metrics would enable permanent 3D characterization of the forest structure when required, enabling very accurate subsequent analyses and even characterizing variables not previously considered.

Author Contributions: Conceptualization, C.A.-R. and A.D.R.-G.; methodology, C.A.-R., S.A.-P., J.G.Á.-G. and A.D.R.-G.; software, J.G.-H., E.G.-F. and J.G.Á.-G.; formal analysis, C.A.-R. and J.G.Á.-G.; investigation, C.A.-R., S.A.-P. and A.D.R.-G.; resources, C.A.-R., S.A.-P., J.G.-H., J.A.M.-V., A.M.-C., C.P.-C., F.C.-D., E.G.-F., J.G.Á.-G. and A.D.R.-G.; data curation, C.A.-R. and S.A.-P.; writing—original draft preparation, C.A.-R., S.A.-P., J.G.-H., J.A.M.-V., A.M.-C., C.P.-C., F.C.-D., E.G.-F., J.G.Á.-G. and A.D.R.-G.; supervision, A.D.R.-G.; project administration, A.D.R.-G.; funding acquisition, A.D.R.-G. All authors have read and agreed to the published version of the manuscript.

Funding: This research was funded by the projects GEPRIF (RTA2014-00011-C06-04) and VIS4FIRE (RTA2017-00042-C05-05) of the Spanish Ministry of Economy, Industry, and Competitiveness and a pre-doctoral grant of the first author funded by the "Consejería de Educación, Universidad y Formación Profesional" and the "Consejería de Economía, Empleo e Industria" of the Galician Government and the EU operational program "FSE Galicia 2014–2020".

Institutional Review Board Statement: Not applicable.

Informed Consent Statement: Not applicable.

Data Availability Statement: The data presented in this study are available on request from the corresponding author. The data are not publicly available due to the restrictions of the research projects from which the study is derived.

Acknowledgments: We are grateful to Mario López Fernández for his inestimable technical support in conducting all the field sampling tasks in the plot network.

Conflicts of Interest: The authors declare no conflict of interest.

Appendix A

Table A1. Mathematical expression of the MARS models. fitted using the three different sets of metrics (TLS, ALS and TLS + ALS) as independent variables for estimating surface fire-related variables.

Surface Fire-Related Variables		
Variable	**Metrics**	**Model**
$\bar{h}_{shrub}$ (m)	TLS	$\bar{h}_{shrub} = 18.36 - 572.09 \cdot (0.11 - TLSh_{01}) + 38.87 \cdot (1.81 - TLSh_{15}) + 8.23 \cdot (TLSh_{95} - 15.39) + 0.11 \cdot (15.39 - TLSh_{95}) \cdot TLSP_{B2m_max}$
	ALS	$\bar{h}_{shrub} = 56.18 - 343.89 \cdot (0.29 - ALSh_{CV}) + 148.79 \cdot (ALS_{CRR} - 0.59)$
	TLS + ALS	The inclusion of ALS metrics does not improve the goodness-of-fit statistics of the model using only TLS metrics
FSG (m)	TLS	$FSG = 11.08 - 1.13 \cdot I_{sp} - 0.92 \cdot (15.39 - TLSh_{95}) + 2.11 \cdot (TLSh_{95} - 15.39) - 0.66 \cdot TLSh_{20} \cdot (TLSh_{95} - 15.39)$
	ALS	$FSG = 6.26 + 1.77 \cdot (ALSh_{MAD-mode} - 2.69) + 2.51 \cdot (ALSh_{L2} - 1.67) + 0.79 \cdot (ALSh_{40} - 9.46) - 0.053 \cdot ALSP_{Ahmean} \cdot (ALSh_{MAD-mode} - 1.77)$
	TLS + ALS	$FSG = 8.86 - 1.01 \cdot (5.11 - TLSh_{SD}) + 4.41 \cdot (ALSh_{L2} - 2.19) + 0.65 \cdot (ALSh_{10} - 8.77) - 0.93 \cdot (8.12 - ALSh_{20})$

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

W_{debris} (Mg ha^{-1})	TLS	$W_{debris} = 36.99 - 88.39 \cdot (TLSh_{01} - 0.18)$ $-43.42 \cdot (0.87 - TLSh_{05}) - 4.80 \cdot (TLSh_{70} - 8.75)$ $+7.01 \cdot (TLSh_{95} - 13.50) \cdot TLSh_{05}$
	ALS	$W_{debris} = 8.51 + 219.67 \cdot (ALSh_{L-CV} - 0.09)$ $+10.66 \cdot (3.99 - ALSh_{05}) - 19.18 \cdot (14.83 - ALSh_{30})$ $+17.30 \cdot (16.12 - ALSh_{50})$
	TLS+ALS	$W_{debris} = 11.40 - 6.14 \cdot (6.63 - TLSh_{55})$ $+15.18 \cdot (5.17 - ALSh_{05}) - 8.43 \cdot (6.70 - ALSh_{10})$ $+0.45 \cdot (42.15 - TLSP_{Ahmean}) \cdot TLSh_{90}$
W_{LFH} (Mg ha^{-1})	TLS	$W_{LFH} = 31.17 + 0.11 \cdot (TLSP_{B2m_max} - 12.32)$ $-16.41 \cdot (0.36 - TLSh_{skew}) + 1.56 \cdot (TLSh_{55} - 6.53)$
	ALS	$W_{LFH} = 31.68 - 8.10 \cdot (3.75 - ALSh_{var})$
	TLS + ALS	$W_{LFH} = 35.14 - 15.50 \cdot (0.34 - TLSh_{skew})$ $-12.46 \cdot (TLSh_{10} - 0.80) + 15.03 \cdot (TLSh_{15} - 1.63)$ $-3.26 \cdot (1.23 - W_{shape}) \cdot ALSh_{ID}$
W_{shrub} (Mg ha^{-1})	TLS	$W_{shrub} = 7.94 + 5.82 \cdot (TLSh_{kurt} - 0.68)$ $-39.62 \cdot (0.11 - TLSh_{01}) - 24.23 \cdot (TLSh_{01} - 0.11)$ $-14.49 \cdot (TLSh_{01} - 0.11) \cdot TLSh_{kurt}$
	ALS	$W_{shrub} = 5.86 + 32.17 \cdot (-0.18 - ALSh_{L3})$ $+1.08 \cdot (6.98 - ALSh_{01}) - 0.26 \cdot (ALSP_{Ahmean} - 29.97)$ $+4.43 \cdot (6.98 - ALSh_{01}) \cdot ALSh_{L3}$
	TLS + ALS	The inclusion of TLS metrics does not improve the goodness-of-fit statistics of the model using only ALS metrics

Table A2. Mathematical expression of the MARS models. fitted using the three different sets of metrics (TLS, ALS and TLS + ALS) as independent variables for estimating canopy fire-related variables.

Canopy Fire-Related Variables		
Variable	**Metrics**	**Model**
$\bar{h}$ (m)	TLS	$\bar{h} = 13.30 - 1.12 \cdot (12.31 - TLSh_{99})$ $+1.04 \cdot (TLSh_{99} - 12.31) + 0.04 \cdot (TLSh_{99} - 12.31)$ $\cdot (TLSP_{max} - 23.72) \cdot I_{sp}$
	ALS	$\bar{h} = 20.93 - 0.95 \cdot (22.77 - ALSh_{99})$ $+0.55 \cdot (ALSh_{99} - 22.77) - 24.51 \cdot (0.53 - ALS_{CRR})$ $+6.03 \cdot (22.77 - ALSh_{99}) \cdot (ALSh_{L-CV} - 0.11)$
	TLS + ALS	$\bar{h} = 13.46 - 1.23 \cdot (12.31 - TLSh_{99})$ $+0.96 \cdot (TLSh_{99} - 12.31) + 0.10 \cdot (ALSh_{var} - 15.23)$ $+0.04 \cdot (TLSh_{99} - 12.31) \cdot (TLSP_{max} - 24.56) \cdot I_{sp}$
CBH (m)	TLS	$CBH = 12.64 - 1.14 \cdot I_{sp} - 0.09 \cdot (32.86 - TLSP_{max})$ $-1.02 \cdot (15.83 - TLSh_{95}) + 0.97 \cdot (TLSh_{95} - 15.83)$
	ALS	$CBH = 9.64 - 0.34 \cdot (ALSh_{MAD-mode} - 1.76)$ $+6.15 \cdot (-0.19 - ALSh_{L3}) + 0.43 \cdot (ALSh_{10} - 7.96)$ $-0.44 \cdot (19.02 - ALSh_{90})$
	TLS + ALS	$CBH = 7.89 + 1.05 \cdot (TLSh_{SD} - 3.49)$ $+5.11 \cdot (-0.19 - ALSh_{L3}) + 0.45 \cdot (ALSh_{10} - 9.21)$ $-0.39 \cdot (11.10 - ALSh_{20})$
CFL (kg m^2)	TLS	$CFL = 1.39 - 0.39 \cdot (-0.58 - TLSh_{kurt})$ $-0.13 \cdot (13.37 - TLSh_{95}) - 0.02 \cdot (30.55 - TLSP_{A2m_max}) \cdot I_{sp}$ $-0.99 \cdot TLSh_{10} \cdot TLSh_{15} \cdot (4.39 - TLSh_{55})$
	ALS	$CFL = 0.77 + 0.02 \cdot (ALSP_{A4m} - 49.60)$ $+0.76 \cdot (ALSh_{mode} - 10.02) \cdot (0.24 - ALSh_{L4})$ $-0.03 \cdot (2.76 - ALSh_{SD}) \cdot (ALSP_{A4m} - 49.60)$ $+0.04 \cdot (1.40 - ALSh_{MAD-mode}) \cdot (ALSP_{A4m} - 49.60)$
	TLS + ALS	$CFL = 1.31 - 0.03 \cdot (30.55 - TLSP_{A2m_max})$ $-0.11 \cdot (16.55 - TLSh_{99}) - 3.75 \cdot (ALSh_{L-CV} - 0.17)$ $+0.01 \cdot (ALSP_{Ahmean} - 40.04)$
CBD (kg m^3)	TLS	$CBD = 0.21 - 0.061 \cdot I_{sp} - 0.0053 \cdot (30.55 - TLSP_{A2m_max})$ $-0.046 \cdot (10.48 - TLSh_{90}) + 0.008 \cdot (TLSh_{90} - 10.48)$
	ALS	$CBD = 0.13 - 0.47 \cdot (ALSh_{L-CV} - 0.11)$ $+0.025 \cdot (ALSP_{Ahmean} - 53.55) - 0.022 \cdot (0.11 - ALSh_{L-CV}) \cdot ALSP_{Ahmode} - 0.001$ $\cdot (ALSP_{Ahmean} - 53.55) \cdot ALSh_{99}$
	TLS + ALS	$CBD = 0.12 + 2.79 \cdot (0.11 - ALSh_{L-CV})$

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

	$+0.007 \cdot (ALSP_{Ahmean} - 53.55) - 0.017 \cdot (30.55 - TLSP_{A2m_max}) \cdot (1.58 - ALSh_{MAD-median}) - 0.001 \cdot (30.55 - TLSP_{A2m_max}) \cdot (ALSh_{MAD-median} - 1.58) \cdot TLSh_{20}$

Table A3 Mathematical expression of the MARS models. fitted using the three different sets of metrics (TLS, ALS and TLS + ALS) as independent variables for estimating stand variables.

Stand Variables		
Variable	**Metrics**	**Model**
H (m)	TLS	$H = 18.56 + 8.94 \cdot I_{sp} - 1.12 \cdot (15.96 - TLSh_{99}) - 0.15 \cdot TLSP_{Ahmean} \cdot I_{sp} + 0.03 \cdot TLSh_{max} \cdot (TLSh_{99} - 15.96)$
	ALS	$H = 14.88 - 0.61 \cdot (10.93 - ALSh_{25}) + 1.14 \cdot (ALSh_{90} - 13.74) + 1.15 \cdot (35.70 - ALSP_{Ahmean}) \cdot ALSh_{L-kurt} + 0.03 \cdot ALSP_{A4m} \cdot (12.28 - ALSh_{30}) \cdot I_{sp}$
	TLS + ALS	$H = 18.75 + 7.78 \cdot I_{sp} - 1.17 \cdot (15.96 - TLSh_{99}) + 0.75 \cdot (ALSh_{90} - 17.34) - 0.13 \cdot TLSP_{Ahmean} \cdot I_{sp}$
G (m^2 ha^{-1})	TLS	$G = 53.05 - 12.20 \cdot I_{sp} - 1.41 \cdot (28.37 - TLSP_{A2m_max}) - 12.03 \cdot (-0.35 - TLSh_{kurt}) - 8.35 \cdot (10.48 - TLSh_{90}) + 3.42 \cdot (TLSh_{90} - 10.48)$
	ALS	$G = 21.83 + 0.96 \cdot (ALSh_{mode} - 10.02) - 13.52 \cdot (2.24 - ALSh_{SD}) + 0.90 \cdot (15.23 - ALSh_{var}) + 0.46 \cdot (ALSP_{A4m} - 49.60)$
	TLS + ALS	$G = 24.90 - 15.55 \cdot (0.64 - TLSh_{skew}) - 8.94 \cdot (3.44 - ALSh_{ID}) + 10.47 \cdot (2.70 - ALSh_{MAD-mode}) + 1.33 \cdot (ALSh_{01} - 1.68) + 0.69 \cdot (ALSP_{Ahmean} - 40.04)$
V (m^3 ha^{-1})	TLS	$V = 347.82 - 65.26 \cdot I_{sp} - 11.61 \cdot (28.37 - TLSP_{A2m_max}) + 33.65 \cdot (TLSh_{99} - 14.19) - 46.29 \cdot (14.78 - TLSh_{99})$
	ALS	$V = 176.76 + 16.15 \cdot (ALSh_{mode} - 10.02) - 26.49 \cdot (3.76 - ALSh_{ID}) + 3.97 \cdot (ALSP_{A4m} - 53.21) + 1.47 \cdot (ALSP_{A4m} - 53.21) \cdot (48.77 - ALSP_{Ahmean})$
	TLS + ALS	$V = 385.23 - 10.92 \cdot (30.55 - TLSP_{A2m_max}) - 28.06 \cdot (18.63 - TLSh_{99}) + 22.62 \cdot (ALSh_{mode} - 10.02) - 575.74 \cdot (ALSh_{L-CV} - 0.08) \cdot (ALSh_{10} - 9.21)$
W (Mg ha^{-1})	TLS	$W = 216.79 - 43.98 \cdot I_{sp} - 5.86 \cdot (28.37 - TLSP_{A2m_max}) - 24.18 \cdot (15.96 - TLSh_{99}) + 15.53 \cdot (TLSh_{99} - 15.96)$
	ALS	$W = 92.24 + 4.69 \cdot (ALSh_{mode} - 10.02) + 2.58 \cdot (ALSP_{A4m} - 49.60) + 110.67 \cdot (ALSh_{mode} - 10.02) \cdot (0.20 - ALSh_{CV}) - 2.44 \cdot (ALSP_{A4m} - 49.60) \cdot (2.76 - ALSh_{SD})$
	TLS + ALS	$W = 105.02 - 49.55 \cdot (0.64 - TLSh_{skew}) + 8.73 \cdot (ALSh_{mode} - 10.02) - 12.03 \cdot (ALSh_{ID} - 3.76) + 1.61 \cdot (ALSP_{A4m} - 49.59)$

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

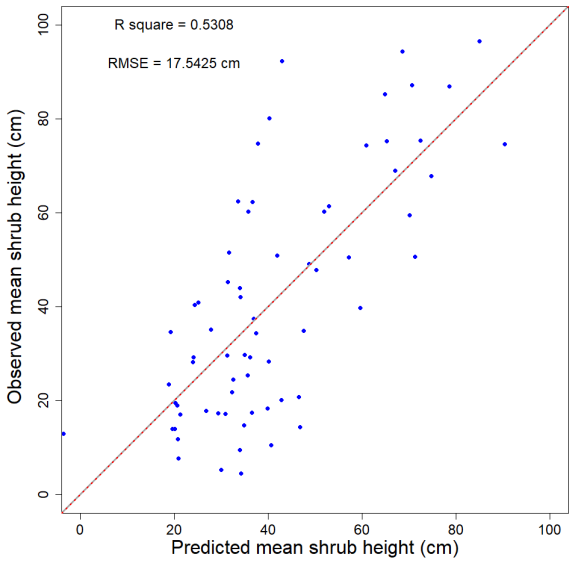

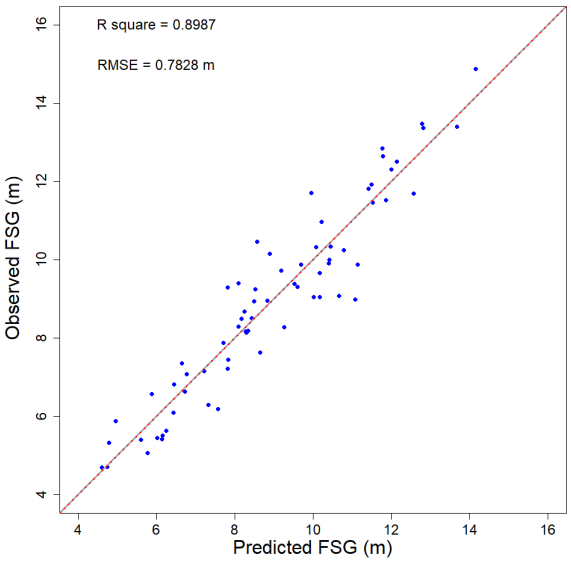

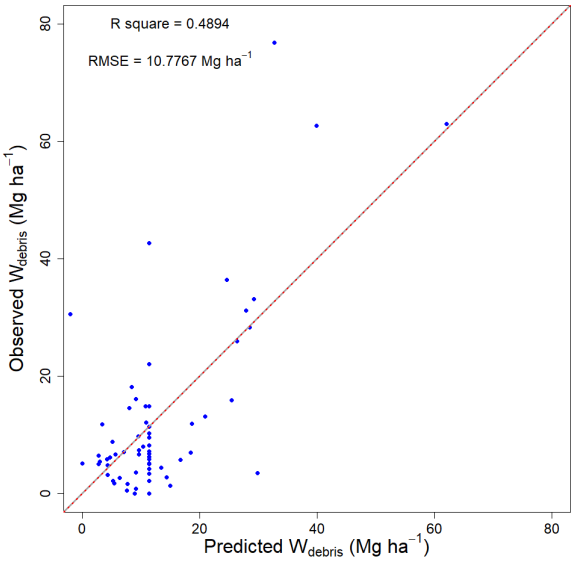

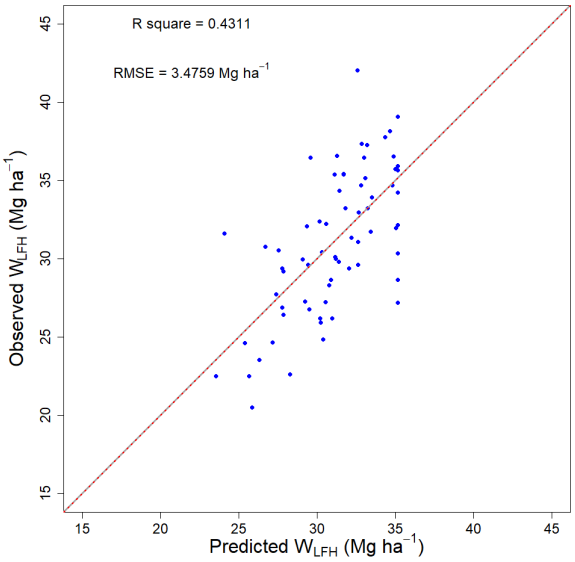

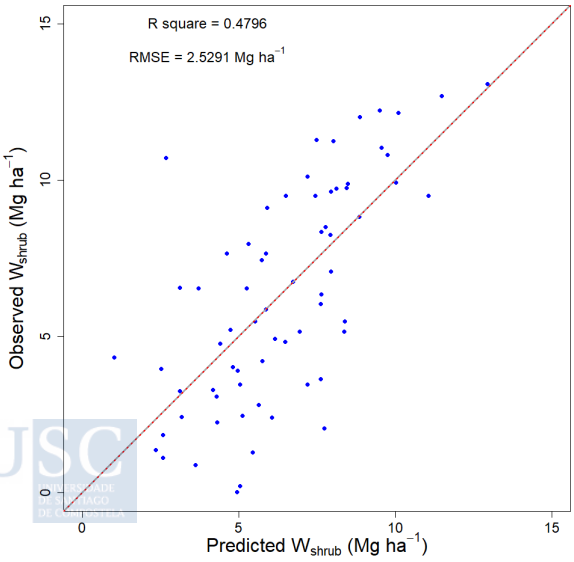

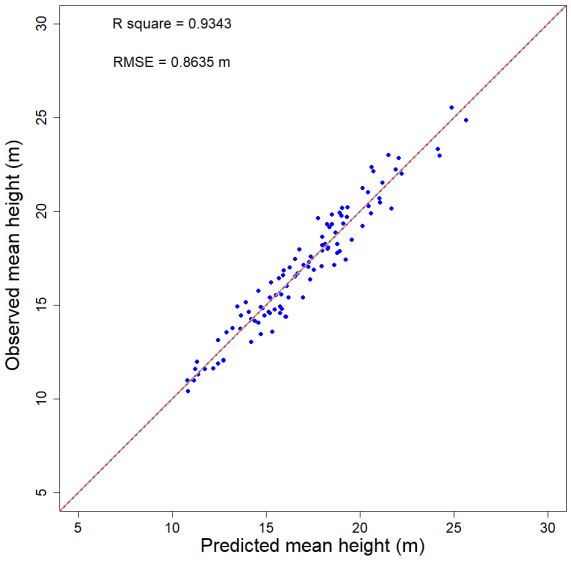

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

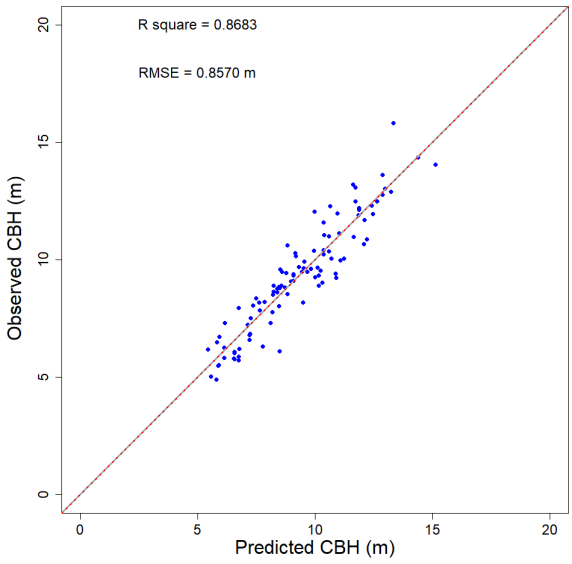
R square = 0.8683
RMSE = 0.8570 m
Observed CBH (m)
Predicted CBH (m)

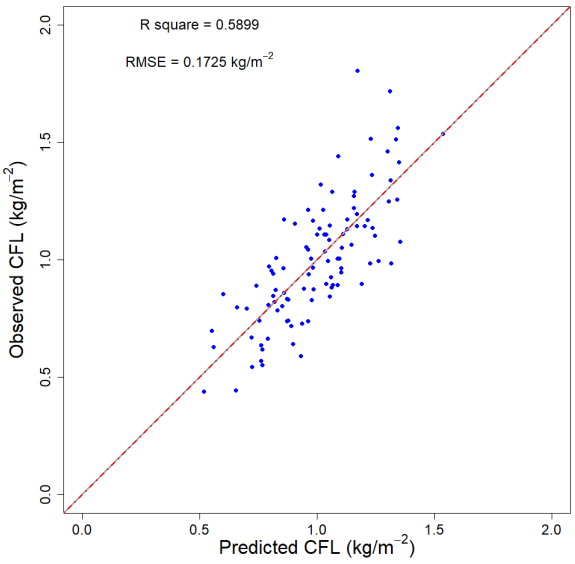
R square = 0.5899
RMSE = 0.1725 kg/m^{-2}
Observed CFL (kg/m^{-2})
Predicted CFL (kg/m^{-2})

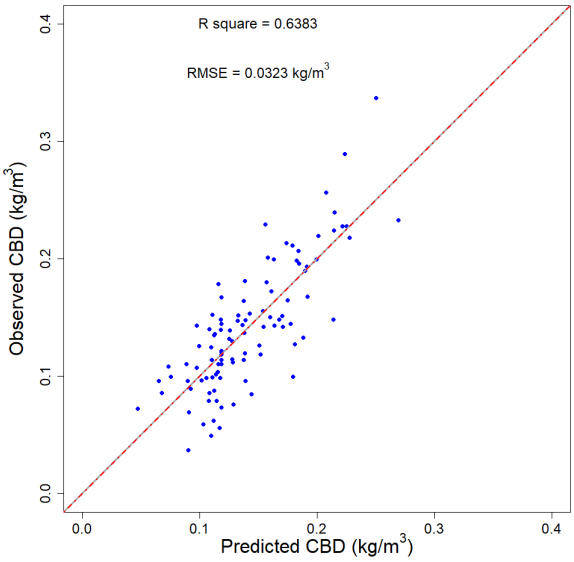
R square = 0.6383
RMSE = 0.0323 kg/m^3
Observed CBD (kg/m^3)
Predicted CBD (kg/m^3)

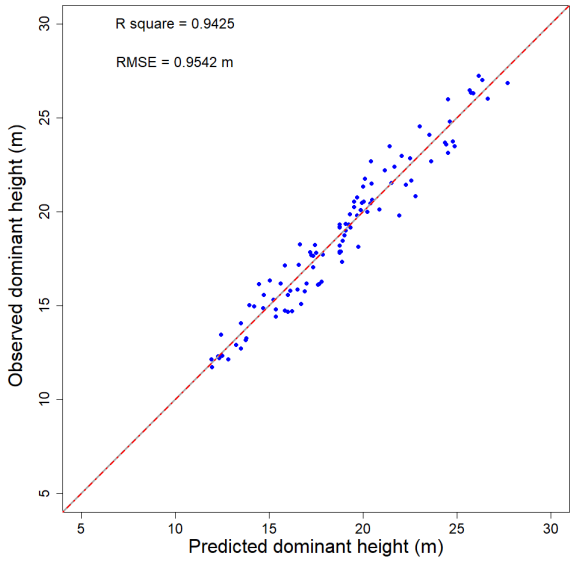
R square = 0.9425
RMSE = 0.9542 m
Observed dominant height (m)
Predicted dominant height (m)

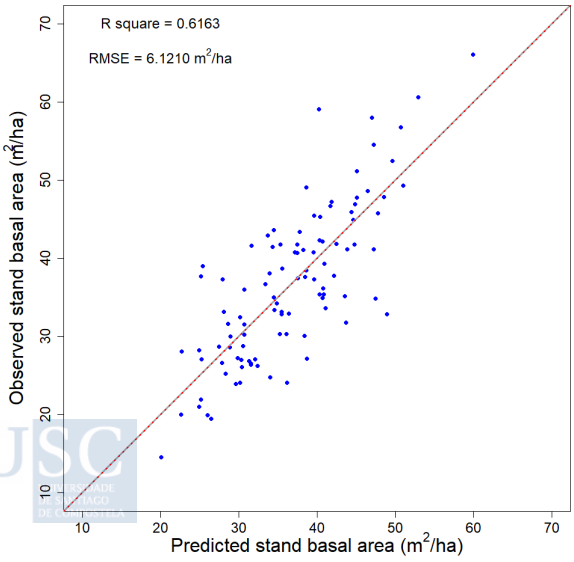
R square = 0.6163
RMSE = 6.1210 m^2/ha
Observed stand basal area (m^2/ha)
Predicted stand basal area (m^2/ha)

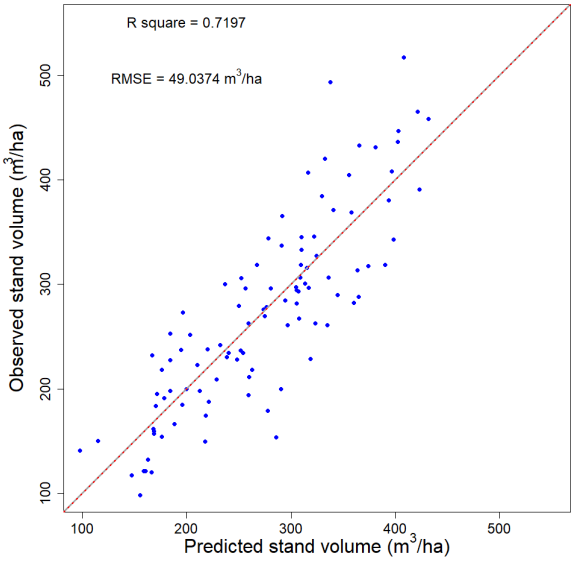
R square = 0.7197
RMSE = 49.0374 m^3/ha
Observed stand volume (m^3/ha)
Predicted stand volume (m^3/ha)

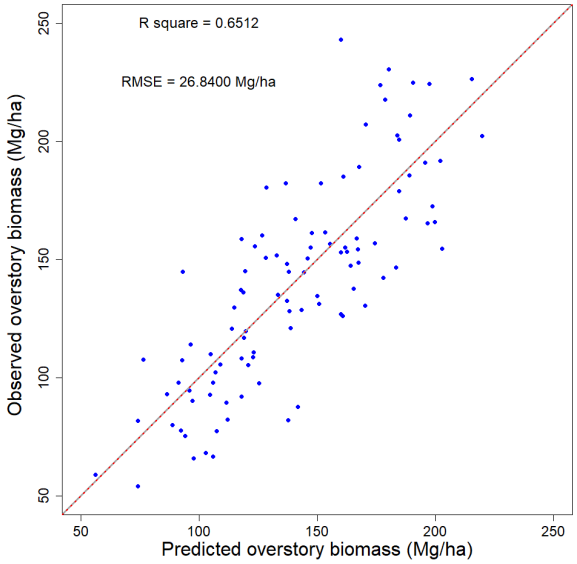

Figure A1. Plots of observed versus predicted values with the best-fitted models for estimating surface and canopy fire-related and stand variables. The red line represents the linear relationship between the two types of values.

References

1. Andrews, P.L. *BEHAVE: Fire Behavior Prediction and Fuel Modeling System: BURN Subsystem, Part 1*; US Department of Agriculture, Forest Service, Intermountain Research Station: Ogden, UT, USA, 1986.
2. Finney, M.A. *FARSITE: Fire Area Simulator-Model Development and Evaluation*; Res. Pap. RMRS-RP-4, Revised 2004; US Department of Agriculture, Forest Service, Rocky Mountain Research Station: Ogden, UT, USA, 1998; Volume 47, p. 4.
3. Finney, M.A. An overview of FlamMap fire modeling capabilities. In Proceedings of the Fuels Management-How to Measure Success: Conference Proceedings, Portland, OR, USA, 28–30 March 2006; Andrews, P.L., Butler, B.W., Eds.; Proceedings RMRS-P-41; US Department of Agriculture, Forest Service, Rocky Mountain Research Station: Fort Collins, CO, USA, 2006; pp. 213–220.
4. Arellano-Pérez, S.; Castedo-Dorado, F.; López-Sánchez, C.; González-Ferreiro, E.; Yang, Z.; Díaz-Varela, R.; Álvarez-González, J.; Vega, J.; Ruiz-González, A. Potential of Sentinel-2A Data to Model Surface and Canopy Fuel Characteristics in Relation to Crown Fire Hazard. *Remote Sens.* **2018**, *10*, 1645.
5. Hawbaker, T.J.; Keuler, N.S.; Lesak, A.A.; Gobakken, T.; Contrucci, K.; Radeloff, V.C. Improved estimates of forest vegetation structure and biomass with a LiDAR-optimized sampling design. *J. Geophys. Res. Biogeosciences* **2009**, *114*. https://doi.org/10.1029/2008JG000870.
6. Maltamo, M.; Næsset, E.; Vauhkonen, J. Forestry applications of airborne laser scanning. Concepts and case studies. *Manag. For. Ecosyst.* **2014**, *27*, 460.
7. Liang, X.; Kankare, V.; Hyyppä, J.; Wang, Y.; Kukko, A.; Haggrén, H.; Yu, X.; Kaartinen, H.; Jaakkola, A.; Guan, F. Terrestrial laser scanning in forest inventories. *ISPRS J. Photogramm. Remote Sens.* **2016**, *115*, 63–77.
8. Liang, X.; Hyyppä, J.; Kaartinen, H.; Lehtomäki, M.; Pyörälä, J.; Pfeifer, N.; Holopainen, M.; Brolly, G.; Francesco, P.; Hackenberg, J. International benchmarking of terrestrial laser scanning approaches for forest inventories. *ISPRS J. Photogramm. Remote Sens.* **2018**, *144*, 137–179.
9. Gale, M.G.; Cary, G.J.; Van Dijk, A.I.; Yebra, M. Forest fire fuel through the lens of remote sensing: Review of approaches, challenges and future directions in the remote sensing of biotic determinants of fire behaviour. *Remote Sens. Environ.* **2021**, *255*, 112282.
10. González-Ferreiro, E.; Diéguez-Aranda, U.; Miranda, D. Estimation of stand variables in *Pinus radiata* D. Don plantations using different LiDAR pulse densities. *Forestry* **2012**, *85*, 281–292.
11. González-Ferreiro, E.; Diéguez-Aranda, U.; Crecente-Campo, F.; Barreiro-Fernández, L.; Miranda, D.; Castedo-Dorado, F. Modelling canopy fuel variables for *Pinus radiata* D. Don in NW Spain with low-density LiDAR data. *Int. J. Wildland Fire* **2014**, *23*, 350–362.
12. González-Ferreiro, E.; Arellano-Pérez, S.; Castedo-Dorado, F.; Hevia, A.; Vega, J.A.; Vega-Nieva, D.; Álvarez-González, J.G.; Ruiz-González, A.D. Modelling the vertical distribution of canopy fuel load using national forest inventory and low-density airborne laser scanning data. *PLoS ONE* **2017**, *12*, e0176114.
13. Hermosilla, T.; Ruiz, L.A.; Kazakova, A.N.; Coops, N.C.; Moskal, L.M. Estimation of forest structure and canopy fuel parameters from small-footprint full-waveform LiDAR data. *Int. J. Wildland Fire* **2013**, *23*, 224–233.

14. Hevia-Cabal, A.; Álvarez-González, J.G.; Ruiz Fernández, E.; Prendes, C.; Ruiz González, A.D.; Majada, J.; González-Ferreiro, E. Modelling canopy fuel and forest stand variables and characterizing the influence of thinning in the stand structure using airborne LiDAR. *Rev. Teledetección* **2016**, *45*, 41–55.
15. Kelly, M.; Su, Y.; Di Tommaso, S.; Fry, D.L.; Collins, B.M.; Stephens, S.L.; Guo, Q. Impact of Error in Lidar-Derived Canopy Height and Canopy Base Height on Modeled Wildfire Behavior in the Sierra Nevada, California, USA. *Remote Sens.* **2018**, *10*, 10.
16. Botequim, B.; Fernandes, P.M.; Borges, J.G.; González-Ferreiro, E.; Guerra-Hernández, J. Improving silvicultural practices for Mediterranean forests through fire behaviour modelling using LiDAR-derived canopy fuel characteristics. *Int. J. Wildland Fire* **2019**, *28*, 823–839.
17. Ruiz, L.Á.; Crespo-Peremarch, P.; Torralba, J. Modelling canopy fuel properties and understory vegetation with full-waveform LiDAR. In Proceedings of the International Conference on Smart Geoinformatics Applications (ICSGA 2021), Prince of Songkla University, Phuket, Thailand, 24–25 February 2021.
18. Chamberlain, C.P.; Meador, A.J.S.; Thode, A.E. Airborne lidar provides reliable estimates of canopy base height and canopy bulk density in southwestern ponderosa pine forests. *For. Ecol. Manag.* **2021**, *481*, 118695.
19. Hilker, T.; van Leeuwen, M.; Coops, N.; Wulder, M.A.; Newnham, G.; Jupp, D.; Culvenor, D. Comparing canopy metrics derived from terrestrial and airborne laser scanning in a Douglas-fir dominated forest stand. *Trees* **2010**, *24*, 819–832.
20. White, J.C.; Coops, N.C.; Wulder, M.A.; Vastaranta, M.; Hilker, T.; Tompalski, P. Remote sensing technologies for enhancing forest inventories: A review. *Can. J. Remote Sens.* **2016**, *42*, 619–641.
21. Chen, Y.; Zhu, X.; Yebra, M.; Harris, S.; Tapper, N. Development of a predictive model for estimating forest surface fuel load in Australian eucalypt forests with LiDAR data. *Environ. Model. Softw.* **2017**, *97*, 61–71.
22. Bright, B.C.; Hudak, A.T.; Meddens, A.J.; Hawbaker, T.J.; Briggs, J.S.; Kennedy, R.E. Prediction of forest canopy and surface fuels from lidar and satellite time series data in a bark beetle-affected forest. *Forests* **2017**, *8*, 322.
23. Campbell, M.J.; Dennison, P.E.; Hudak, A.T.; Parham, L.M.; Butler, B.W. Quantifying understory vegetation density using small-footprint airborne lidar. *Remote Sens. Environ.* **2018**, *215*, 330–342.
24. Stefanidou, A.; ZGitas, I.; Korhonen, L.; Georgopoulos, N.; Stavrakoudis, D. Multispectral lidar-based estimation of surface fuel load in a dense coniferous forest. *Remote Sens.* **2020**, *12*, 3333.
25. Cao, L.; Coops, N.C.; Hermosilla, T.; Innes, J.; Dai, J.; She, G. Using small-footprint discrete and full-waveform airborne LiDAR metrics to estimate total biomass and biomass components in subtropical forests. *Remote Sens.* **2014**, *6*, 7110–7135.
26. Anderson, K.; Hancock, S.; Disney, M.; Gaston, K.J. Is waveform worth it? A comparison of LiDAR approaches for vegetation and landscape characterization. *Remote Sens. Ecol. Conserv*. **2016**, *2*, 5–15.
27. Crespo-Peremarch, P.; Fournier, R.A.; Nguyen, V.-T.; van Lier, O.R.; Ruiz, L.Á. A comparative assessment of the vertical distribution of forest components using full-waveform airborne, discrete airborne and discrete terrestrial laser scanning data. *For. Ecol. Manag.* **2020**, *473*, 118268.
28. Crespo-Peremarch, P.; Ruiz, L.Á.; Balaguer-Beser, Á.; Estornell, J. Analyzing the role of pulse density and voxelization parameters on full-waveform LiDAR-derived metrics. *ISPRS J. Photogramm. Remote Sens*. **2018**, *146*, 453–464.
29. Loudermilk, E.L.; Hiers, J.K.; O'Brien, J.J.; Mitchell, R.J.; Singhania, A.; Fernandez, J.C.; Slatton, K.C. Ground-based LIDAR: A novel approach to quantify fine-scale fuelbed characteristics. *Int. J. Wildland Fire* **2009**, *18*, 676–685.
30. Olsoy, P.J.; Glenn, N.F.; Clark, P.E.; Derryberry, D.R. Aboveground total and green biomass of dryland shrub derived from terrestrial laser scanning. ISPRS J. Photogramm. *Remote Sens*. **2014**, *88*, 166–173.
31. Owers, C.J.; Rogers, K.; Woodroffe, C.D. Terrestrial laser scanning to quantify above-ground biomass of structurally complex coastal wetland vegetation. Estuar. *Coast. Shelf Sci*. **2018**, *204*, 164–176.
32. Alonso-Rego, C.; Arellano-Pérez, S.; Cabo, C.; Ordoñez, C.; Álvarez-González, J.G.; Díaz-Varela, R.A.; Ruiz-González, A.D. Estimating fuel loads and structural characteristics of shrub communities by using terrestrial laser scanning. *Remote Sens.* **2020**, *12*, 3704.
33. Rowell, E.; Loudermilk, E.L.; Seielstad, C.; O'Brien, J.J. Using simulated 3D surface fuelbeds and terrestrial laser scan data to develop inputs to fire behavior models. *Can. J. Remote Sens.* **2016**, *42*, 443–459.
34. Rowell, E.; Loudermilk, E.L.; Hawley, C.; Pokswinski, S.; Seielstad, C.; Queen, L.L.; O'Brien, J.J.; Hudak, A.T.; Goodrick, S.; Hiers, J.K. Coupling terrestrial laser scanning with 3D fuel biomass sampling for advancing wildland fuels characterization. *For. Ecol. Manag*. **2020**, *462*, 117945.
35. Hudak, A.; Prichard, S.; Keane, R.; Loudermilk, L.; Parsons, R.; Seielstad, C.; Rowell, E.; Skowronski, N. *Hierarchical 3D Fuel and Consumption Maps to Support Physics-Based Fire Modeling*; Joint Fire Science Program Project 16-4-01-15 Final Report; US Forest Service, Rocky Mountain Research Station: Moscow, ID, USA, 2017; 38p.
36. Hudak, A.T.; Kato, A.; Bright, B.C.; Loudermilk, E.L.; Hawley, C.; Restaino, J.C.; Ottmar, R.D.; Prata, G.A.; Cabo, C.; Prichard, S.J.; et al. Towards spatially explicit quantification of pre- and post-fire fuels and fuel consumption from traditional and point cloud measurements. *For. Sci*. **2020**, *66*, 428–442.
37. Greaves, H.E.; Vierling, L.A.; Eitel, J.U.H.; Boelman, N.T.; Troy, S.T.; Magney, T.; Prager, C.M.; Grin, K.L. Estimating aboveground biomass and leaf area of low-stature Arctic shrubs with terrestrial LiDAR. *Remote Sens. Environ*. **2015**, *164*, 26–35.
38. Jupp, D.L.B.; Culvenor, D.S.; Lovell, J.L.; Newnham, G.J.; Strahler, A.H.; Woodcock, C.E. Estimating forest LAI profiles and structural parameters using a ground-based laser called 'Echidna'. *Tree Physiol.* **2009**, *29*, 171–181.

39. Newnham, G.J.; Armston, J.D.; Calders, K.; Disney, M.I.; Lovell, J.L.; Schaaf, C.B.; Strahler, A.H.; Danson, F.M. Terrestrial laser scanning for plot-scale forest measurement. *Curr. For. Rep.* **2015**, *1*, 239–251.
40. Wezyk, P. The integration of the Terrestrial and Airborne Laser Scanning technologies in the semi-automated process of retrieving selected trees and forest stand parameters. *Ambiencia* **2012**, *8*, 533–548.
41. Hilker, T.; Coops, N.C.; Newnham, G.J.; van Leeuwen, M.; Wulder, M.A.; Stewart, J.; Culvenor, D.S. Comparison of terrestrial and airborne LiDAR in describing stand structure of a thinned lodgepole pine forest. *J. For.* **2012**, *110*, 97–104.
42. Kankare, V.; Vauhkonen, J.; Tanhuanpaa, T.; Holopainen, M.; Vastaranta, M.; Joensuu, M.; Krooks, A.; Hyyppä, J.; Hyyppä, H.; Alho, P.; et al. Accuracy in estimation of timber assortments and stem distribution—a comparison of airborne and terrestrial laser scanning techniques. *ISPRS J. Photogramm. Remote Sens.* **2014**, *97*, 89–97.
43. Kankare, V.; Liang, X.; Vastaranta, M.; Yu, X.; Holopainen, M.; Hyyppä, J. Diameter distribution estimation with laser scanning based multisource single tree inventory. *ISPRS J. Photogramm. Remote Sens.* **2015**, *108*, 161–171.
44. Chasmer, L.; Hopkinson, C.; Treitz, P. Assessing the three dimensional frequency distribution of airborne and ground-based LiDAR data for red pine and mixed deciduous forest plots. Int. Arch. Photogramm. *Remote Sens. Spat. Inf. Sci*. **2004**, *36*, 8.
45. Jung, S.-E.; Kwak, D.-A.; Park, T.; Lee, W.-K.; Yoo, S. Estimating crown variables of individual trees using airborne and terrestrial laser scanners. *Remote Sens.* **2011**, *3*, 2346–2363.
46. Listopad, C.M.C.S.; Drake, J.B.; Masters, R.E.; Weishampel, J.F. Portable and Airborne Small Footprint LiDAR: Forest Canopy Structure Estimation of Fire Managed Plots. *Remote Sens*. **2011**, *3*, 1284–1307.
47. Zhao, F.; Yang, X.; Strahler, A.H.; Schaaf, C.L.; Yao, T.; Wang, Z.; Román, M.O.; Woodcock, C.E.; Ni-Meister, W.; Jupp, D.L.B.; et al. A comparison of foliage profiles in the Sierra National Forest obtained with a full-waveform under-canopy EVI lidar system with the foliage profiles obtained with an airborne full-waveform LVIS lidar system. *Remote Sens. Environ.* **2013**, *136*, 330–341.
48. Greaves, H.E.; Vierling, L.A.; Eitel, J.U.H.; Boelman, N.T.; Magney, T.S.; Prager, C.M.; Griffin, K.L. Applying terrestrial lidar for evaluation and calibration of airborne lidar-derived shrub biomass estimates in Arctic tundra. *Remote Sens. Lett.* **2017**, *8*, 175–184.
49. Liu, L.; Pang, Y.; Li, Z.; Si, L.; Liao, S. Combining Airborne and Terrestrial Laser Scanning Technologies to Measure Forest Understorey Volume. *Forests* **2017**, *8*, 111.
50. Torralba, J.; Crespo-Peremarch, P.; Ruiz, L.Á. Assessing the use of discrete, fullwaveform LiDAR and TLS to classify Mediterranean forest species composition. *Rev. Teledetección* **2018**, 27–40. https://doi.org/10.4995/raet.2018.11106.
51. Skowronski, N.S.; Clark, K.-L.; Duveneck, M.; Hom, J. Three-dimensional canopy fuel loading predicted using upward and downward sensing LiDAR systems. *Remote Sens. Environ.* **2011**, *115*, 703–714.
52. Lindberg, E.; Holmgren, J.; Olofsson, K.; Olsson, H. Estimation of stem attributes using a combination of terrestrial and airborne laser scanning. *Eur. J. For. Res.* **2012**, *131*, 1917–1931.
53. LaRue, E.A.; Wagner, F.W.; Fei, S.; Atkins, J.W.; Fahey, R.T.; Gough, C.M.; Hardiman, B.S. Compatibility of Aerial and Terrestrial LiDAR for Quantifying Forest Structural Diversity. *Remote Sens.* **2020**, *12*, 1407.
54. Hauglin, M.; Lien, V.; Næsset, E.; Gobakken, T. Geo-referencing forest field plots by co-registration of terrestrial and airborne laser scanning data. *Int. J. Remote Sens.* **2014**, *5*, 3135–3149.
55. Yang, B.; Zang, Y.; Dong, Z.; Huang, R. An automated method to register airborne and terrestrial laser scanning point clouds. *ISPRS J. Photogramm. Remote Sens.* **2015**, *109*, 62–76.
56. Paris, C.; Kelbe, D.; van Aardt, J.; Bruzzone, L. A Novel Automatic Method for the Fusion of ALS and TLS LiDAR Data for Robust Assessment of Tree Crown Structure Fellow. *IEEE Transcations Geosci. Remote Sens.* **2017**, *55*, 3679–3693.
57. Bazezew, M.N.; Hussin, Y.A.; Kloosterman, E.H. Integrating Airborne LiDAR and Terrestrial Laser Scanner forest parameters for accurate above-ground biomass/carbon estimation in Ayer Hitam tropical forest, Malaysia. *Int. J. Appl. Earth Obs. Geoinf.* **2018**, *73*, 638–652.
58. Giannetti, F.; Puletti, N.; Quatrini, V.; Travaglini, D.; Bottalico, F.; Corona, P.; Chirici, G. Integrating terrestrial and airborne laser scanning for the assessment of single-tree attributes in Mediterranean forest stands. *Eur. J. Remote Sens.* **2018**, *51*, 795-807.
59. Dai, W.; Yang, B.; Liang, X.; Dong, Z.; Huang, R.; Wang, Y.; Li, W. Automated fusion of forest airborne and terrestrial point clouds through canopy density analysis. *ISPRS J. Photogramm. Remote Sens.* **2019**, *156*, 94–107.
60. Arellano-Pérez, S.; Castedo-Dorado, F.; Álvarez-González, J.G.; Alonso-Rego, C.; Vega, J.A.; Ruiz-González, A.D. Mid-term effects of a thin-only treatment on fuel complex, potential fire behaviour and severity and post-fire soil erosion protection in fast-growing pine plantations. *For. Ecol. Manag.* **2020**, *460*, 117895.
61. Dieguez-Aranda, U.; Rojo-Alboreca, A.; Castedo-Dorado, F.; Álvarez-González, J.G.; Barrio-Anta, M.; Crecente-Campo, F.; González-González, J.M.; Pérez-Cruzado, C.; Rodriguez-Soalleiro, R.; López-Sánchez, C.A.; et al. *Herramientas Selvícolas Para la Gestión Forestal Sostenible en Galicia*; Xunta de Galicia: Santiago de Compostela, Spain, 2009.
62. Crecente-Campo, F.; Marshall, P.; LeMay, V.; Diéguez-Aranda, U. A crown profile model for *Pinus radiata* D. Don in northwestern Spain. *For. Ecol. Manag*. **2009**, *257*, 2370–2379.
63. Crecente-Campo, F.; Álvarez-González, J.G.; Castedo-Dorado, F.; Gómez-García, E.; Diéguez-Aranda, U. Development of crown profile models for *Pinus pinaster* Ait. and *Pinus sylvestris* L. in northwestern Spain. *Forestry* **2013**, *86*, 481–491.
64. Brown, J.K. A Planar Intersect Method for Sampling Fuel Volume and Surface Area. *For. Sci.* **1971**, *17*, 96–102.
65. Brown, J.K. *Handbook for Inventorying Downed Woody Material*; General Technical Report GTR-INT-16; USDA Forest Service, Intermountain Forest and Range Experiment Station: Ogden, UT, USA, 1974.

66. Molina-Valero, J.A.; Ginzo Villamayor, M.J.; Novo Pérez, A.M.; Martínez-Calvo, A.; Álvarez-González, J.G.; Montes, F.; Pérez-Cruzado, C. FORTLS: Automatic Processing of TLS Point Cloud Data for Forestry Purposes. R Package Version 1.0.3. 2021. Available online: https://CRAN.R-project.org/package=FORTLS (accessed on 4 December 2021).
67. R Core Team. *R: A Language and Environment for Statistical Computing*; R Foundation for Statistical Computing: Vienna, Austria, 2020. 2021. Available online: https://www.R-project.org/ (accessed on 4 November 2021).
68. Zhang, W.; Qi, J.; Wan, P.; Wang, H.; Xie, D.; Wang, X.; Yan, G. An easy-to-use airborne LiDAR data filtering method based on cloth simulation. *Remote Sens.* **2016**, *8*, 501.
69. Cao, Q.V.; Burkhart, H.E.; Lemin, R.C. *Diameter Distributions and Yields of Thinned Loblolly Pine Plantations*; FWS 1-82; School of Forestry and Wildlife Resources; Virginia Polytechnic Institute and State University: Blacksburg, VA, USA, 1982.
70. McGaughey, R.J. *FUSION/LDV: Software for LIDAR Data Analysis and Visualization*; US Department of Agriculture, Forest Service: Pacific Northwest Research Station: Seattle, WA, USA, 2021. Available online: http://forsys.sefs.uw.edu/fusion/fusion_overview.html (accessed on 4 December 2021).
71. Friedman, J.H. Multivariate adaptive regression splines (with discussion). *Ann. Stat*. **1991**, *19*, 79–141.
72. Milborrow, S. Derived from Mda: Mars by Hastie T and Tibshirani R. Uses Alan Miller's Fortran Utilities with Thomas Lumley's Leaps Wrapper. Earth: Multivariate Adaptive Regression Splines. R Package Version 4.5.1. Available online: https://cran.r-project.org/package=earth (accessed on 4 December 2021).
73. Breiman, L. Random forests. *Mach. Learn*. **2001**, *45*, 5–32.
74. Genuer, R.; Poggi, J.M.; Tuleau-Malot, C. Variable selection using random forests. *Pattern Recognit. Lett.* **2010**, *31*, 2225–2236.
75. Gislason, P.O.; Benediktsson, J.A.; Sveinsson, J.R. Random Forests for land cover classification. *Pattern Recognit. Lett.* **2006**, *27*, 294–300.
76. Liaw, A.; Wiener, M. Classification and Regression by randomForest. *R News* **2002**, *2*, 18–22.
77. Cortes, C.; Vapnik, V. Support-vector networks. *Mach. Learn.* **1995**, *20*, 273–297.
78. Meyer, D.; Dimitriadou, E.; Hornik, K.; Weingessel, A.; Leisch, F. e1071: Misc Functions of the Department of Statistics, Probability Theory Group (Formerly: E1071), TU Wien. R Package Version 1.7-2. Available online: https://CRAN.R-project.org/package=e1071 (accessed on 4 December 2021).
79. Huang, H.; Li, Z.; Gong, P.; Cheng, X.; Clinton, N.; Cao, C.; Ni, W.; Wang, L. Automated methods for measuring DBH and tree heights with a commercial scanning lidar. *Photogram. Eng. Remote Sens*. **2011**, *77*, 219–227.
80. Liang, X.; Hyyppa, J. Automatic Stem Mapping by Merging Several Terrestrial Laser Scans at the Feature and Decision Levels. *Sensors* **2013**, *13*, 1614–1634.
81. Srinivasan, S.; Popescu, S.; Eriksson, M.; Sheridan, R.D.; Ku, N.-W. Terrestrial Laser Scanning as an Effective Tool to Retrieve Tree Level Height, CrownWidth, and Stem Diameter. *Remote Sens.* **2015**, *7*, 1877–1896.
82. Torralba, J.; Ruiz, L.A.; Carbonell-Rivera, J.P.; Crespo-Peremarch, P. Análisis de posiciones y densidades TLS (Terrestrial Laser Scanning) para optimizar la estimación de parámetros forestales. In *Teledetección: Hacia una Visión Global del Cambio Climático*; Ruiz, L.A., Estornell, J., Calle, A., Antuña-Sánchez, J.C., Eds.; Universidad de Valladolid: Valladolid, Spain, 2019; pp. 443–446.
83. García, M.; Danson, F.M.; Riaño, D.; Chuvieco, E.; Ramirez, F.A.; Bandugula, V. Terrestrial laser scanning to estimate plot-level forest canopy fuel properties. *Int. J. Appl. Earth Obs. Geoinf.* **2011**, *13*, 636–645.
84. Wilson, N.; Bradstock, R.; Bedward, M. Detecting the effects of logging and wildfire on forest fuel structure using terrestrial laser scanning (TLS). *For. Ecol. Manag*. **2021**, *488*, 119037.
85. Astrup, R.; Ducey, M.J.; Granhus, A.; Ritter, T.; von Lüpke, N. Approaches for estimating stand-level volume using terrestrial laser scanning in a single-scan mode *Can. J. For. Res*. **2014**, *44*, 666–676.
86. Panagiotidis, D.; Abdollahnejad, A.; Slavík, M. Assessment of Stem Volume on Plots Using Terrestrial Laser Scanner: A Precision Forestry Application. *Sensors* **2021**, *21*, 301.
87. Watt, P.J.; Donoghue, D.N.M. Measuring forest structure with terrestrial laser scanning. *Int. J. Remote Sens.* **2005**, *26*, 1437–1446.
88. Brolly, G.; Kiraly, G. Algorithms for stem mapping by means of terrestrial laser scanning. *Acta Silv. Lignaria Hung.* **2009**, *5*, 119–130.
89. Liang, X.; Litkey, P.; Hyyppa, J.; Kaartinen, H.; Vastaranta, M.; Holopainen, M. Automatic stem mapping using single-scan terrestrial laser scanning. *IEEE Trans. Geosci. Remote Sens.* **2012**, *50*, 661–670.
90. Olofsson, K.; Holmgren, J.; Olsson, H. Tree stem and height measurements using terrestrial laser scanning and the RANSAC algorithm. *Remote Sens.* **2014**, *6*, 4323–4344.
91. Strahler, A.H.; Jupp, D.L.B.; Woodcock, C.E.; Schaaf, C.B.; Yao, T.; Zhao, F.; Yang, X.; Lovell, J.; Culvenor, D.; Newnham, G.; et al. Retrieval of forest structural parameters using a ground-based lidar instrument (Echidna®). *Can. J. Remote Sens.* **2008**, *34*, S426–S440.
92. Yao, T.; Yang, X.; Zhao, F.; Wang, Z.; Zhang, Q.; Jupp, D.; Lovell, J.; Culvenor, D.; Newnham, G.; Ni-Meister, W.; et al. Measuring forest structure and biomass in New England forest stands using Echidna ground-based lidar. *Remote Sens. Environ*. **2011**, *115*, 2965–2974.
93. Molina-Valero, J.A.; Ginzo-Villamayor, M.J.; Novo-Pérez, M.A.; Álvarez-González, J.G.; Pérez-Cruzado, C. Estimación del área basimétrica en masas maduras de Pinus sylvestris en base a una única medición del escáner láser terrestre (TLS). *Cuad. Soc. Española Cienc. For.* **2019**, *45*, 97–116.
94. Wallace, L.; Hillman, S.; Reinke, K.; Hally, B. Non-destructive estimation of above-ground surface and near-surface biomass using 3D terrestrial remote sensing techniques. *Methods Ecol. Evol.* **2017**, *8*, 1607–1616.

95. Li, S.; Wang, T.; Hou, Z.; Gong, Y.; Feng, L.; Ge, J. Harnessing terrestrial laser scanning to predict understory biomass in temperate mixed forests. *Ecol. Indic.* **2021**, *121*, 107011.
96. Keane, R.E.; Burgan, R.; van Wagtendonk, J. Mapping wildland fuels for fire management across multiple scales: Integrating remote sensing, GIS, and biophysical modeling. *Int. J. Wildland Fire* **2001**, *10*, 301–319.
97. Crespo-Peremarch, P.; Ruiz, L. Análisis comparativo del potencial del ALS y TLS en la caracterización estructural de la masa forestal basado en voxelización. In *Nuevas Plataformas y Sensores de Teledetección, Proceedings of the XVII Congreso de la Asociación Española de Teledetección, Murcia, Spain, 3–7 October 2017*; Ruiz, L.A., Estornell, J., Erena, M., Eds.; Universitat Politécnica de Valencia: Valencia, Spain, 2017; pp. 131–135.
98. Chasmer, L.; Hopkinson, C.; Treitz, P. Investigating laser pulse penetration through a conifer canopy by integrating airborne and terrestrial lidar. *Can. J. Remote Sens.* **2006**, *32*, 116–125.
99. García-Gutiérrez, J.; Gonzalez-Ferreiro, E.; Riquelme-Santos, J.C.; Miranda, D.; Dieguez-Aranda, U.; Navarro-Cerrillo, R.M. Evolutionary feature selection to estimate forest stand variables using LiDAR. *Int. J. Appl. Earth Obs. Geoinf.* **2014**, *26*, 119–131.
100. Jiménez, E.; Vega, J.A.; Fernández-Alonso, J.M.; Vega-Nieva, D.; Ortiz, L.; López-Serrano, P.M.; López-Sánchez, C.A. Estimation of aboveground forest biomass in Galicia (NW Spain) by the combined use of LiDAR, LANDSAT ETM+ and National Forest Inventory data. *Iforest-Biogeosci. For.* **2017**, *10*, 590–596.
101. Novo-Fernández, A.; Barrio-Anta, M.; Recondo, C.; Cámara-Obregón, A.; López-Sánchez, C.A. Integration of National Forest Inventory and Nationwide Airborne Laser Scanning Data to Improve Forest Yield Predictions in North-Western Spain. *Remote Sens.* **2019**, *11*, 1693.
102. Xu, D.; Wang, H.; Xu, W.; Luan, Z.; Xu, X. LiDAR Applications to Estimate Forest Biomass at Individual Tree Scale: Opportunities, Challenges and Future Perspectives. *Forests* **2021**, *12*, 550.
103. Bouvier, M.; Durrieu, S.; Fournier, R.A.; Renaud, J.P. Generalizing predictive models of forest inventory attributes using an area-based approach with airborne LiDAR data. *Remote Sens. Environ.* **2015**, *156*, 322–334.
104. Guerra-Hernández, J.; Bastos Görgens, E.; García-Gutiérrez, J.; Estraviz Rodriguez, L.C.; Tom, M.; González-Ferreiro, E. Comparison of ALS based models for estimating aboveground biomass in three types of Mediterranean forest. *Eur. J. Remote Sens.* **2016**, *49*, 185–204.
105. Mauro, F.; Hudak, A.T.; Fekety, P.A.; Frank, B.; Temesgen, H.; Bell, D.M.; Gregory, M.J.; McCarley, T.R. Regional Modeling of Forest Fuels and Structural Attributes Using Airborne Laser Scanning Data in Oregon. *Remote Sens.* **2021**, *13*, 261.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

ANEXO D

Individual-Tree and Stand-Level Models for Estimating Ladder Fuel Biomass Fractions in Unpruned *Pinus radiata* Plantations

(Artículo 3)

Cecilia Alonso-Rego

Paulo Fernandes

Juan Gabriel Álvarez-González

Stéfano Arellano-Pérez

Ana Daría Ruíz-González

Forest, 2022, 13, 1697

https://doi.org/10.3390/f13101697

La revista *Forest* pertenece a la editorial MPDI, que permite la reutilización del artículo por la autora como parte de su tesis doctoral: https://www.mdpi.com/authors/rights

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

forests

MDPI

Article

Individual-Tree and Stand-Level Models for Estimating Ladder Fuel Biomass Fractions in Unpruned *Pinus radiata* Plantations

Cecilia Alonso-Rego [1], Paulo Fernandes [2], Juan Gabriel Álvarez-González [1], Stefano Arellano-Pérez [1] and Ana Daría Ruiz-González [1,*]

[1] Unidad de Gestión Ambiental y Forestal Sostenible (UXAFORES), Departamento de Ingeniería Agroforestal, Escuela Politécnica Superior de Ingeniería, Universidad de Santiago de Compostela, Rua Beningno Ledo s/n, 27002 Lugo, Spain
[2] CITAB—Centro de Investigação e de Tecnologias Agro-Ambientais e Biológicas, Universidade de Trás-os-Montes e Alto Douro, 5001-801 Vila Real, Portugal
* Correspondence: anadaria.ruiz@usc.es; Tel.: +34-982-823220

Abstract: The mild climate and, in recent decades, the increased demand for timber have favoured the establishment of extensive plantations of fast-growing species such as *Pinus radiata* in Galicia (a fire-prone region in northwestern Spain). This species is characterised by very poor self-pruning; unmanaged pine stands have a worrying vertical continuity of fuels after crown closure because the dead lower branches accumulate large amounts of fine dead biomass including twigs and suspended needles. Despite the important contribution of these dead ladder fuels to the overall canopy biomass and to crown-fire hazards, equations for estimating these fuels have not yet been developed. In this study, two systems of equations for estimating dead ladder fuel according to size class and the vertical distribution in the first 6 m of the crown were fitted: a tree-level system based on individual tree and stand variables and a stand-level system based only on stand variables. The goodness-of-fit statistics for both model systems indicated that the estimates were robust and accurate. At the tree level, fuel biomass models explained between 35% and 59% of the observed variability, whereas cumulative fuel biomass models explained between 62% and 81% of the observed variability. On the other hand, at the stand level, fuel-load models explained between 88% and 98% of the observed variability, whereas cumulative fuel-load models explained more than 98% of the total observed variability. These systems will therefore allow managers to adequately quantify the dead ladder fuels in pure *Pinus radiata* stands and to identify the treatments required to reduce crown-fire hazard.

Keywords: canopy base height; canopy fuel load; canopy bulk density; crown-fire hazard; pure even-aged stands; forest management

check for updates

Citation: Alonso-Rego, C.; Fernandes, P.; Álvarez-González, J.G.; Arellano-Pérez, S.; Ruiz-González, A.D. Individual-Tree and Stand-Level Models for Estimating Ladder Fuel Biomass Fractions in Unpruned *Pinus radiata* Plantations. *Forests* **2022**, *13*, 1697. https://doi.org/10.3390/f13101697

Academic Editor: Palaiologos Palaiologou

Received: 9 September 2022
Accepted: 11 October 2022
Published: 15 October 2022

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.

Copyright: © 2022 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (https://creativecommons.org/licenses/by/4.0/).

1. Introduction

Fuel bed, the general term for the complex array of biomass types in a given area, is vertically stratified into three fuel layers: ground, surface, and canopy fuels [1]. Ground fuel comprises all of the burnable material below the litter including duff, plant roots, decaying wood, and peat. Ground fuel supports smouldering (flameless) combustion, which produces lower temperatures and lasts longer than the flaming combustion of surface fuels [2]. Canopy or aerial fuels comprise the biomass above the surface fuel layer; some of their structural characteristics such as canopy fuel load (*CFL*), canopy bulk density (*CBD*), and canopy base height (*CBH*) affect the initiation and spread of crown fires [3,4]. These variables must be quantified to predict fire behaviour characteristics and enable the selection of appropriate silvicultural treatments aimed at reducing susceptibility to crown fires in fire-prone stands such as pine forests [5]. *CFL* is defined as the mass of available canopy fuel per unit ground area, *CBD* indicates the amount of available fuel per volume unit in the aerial layer, and *CBH* is the lowest height above ground level at which there is sufficient canopy fuel to propagate fire vertically through the canopy [6,7]. For modelling

purposes, needles and fine twigs (diameter < 6 mm) are usually considered the available fuel because they are generally consumed within the flaming front of a crown fire [8].

Different approaches and methods have been used to estimate the canopy fuel variables related to crown fires; e.g., [3,6,9]. The most commonly used approach is the "load-over-depth method", which assumes that all canopy fine fuel is homogeneously distributed. This method is consistent with the semi-empirical based models used in the main fire behaviour simulators available [10]. The canopy fine fuel can be estimated at the individual tree level by using equations to predict crown fuel characteristics using regressor variables that are easy to measure in the field such as tree diameter or height; e.g., [11,12]; and at the stand level by using models that are less accurate but also less demanding in terms of sampling. Thus, for example, in the study area, i.e., the north-western Iberian Peninsula, these types of models have been developed for pine stands that are prone to crown fires using stand variables determined in field inventories [11–16] or by remote sensing technologies including airborne light detection and ranging (LiDAR) [17–20] and optical satellite imagery [21]. The latter two approaches are less accurate than those based on field inventory but facilitate landscape-level mapping and thus the use of map-based simulation systems such as FlamMap [22].

The surface fuel layer (including litter, shrubs, grasses, and woody biomass) also contributes to crown-fire hazards because its load (biomass per unit area) modulates the fireline intensity of the surface phase and its height affects the fuel strata gap (*FSG*), which is defined as the distance from the top of the surface fuel bed to the lower limit of the aerial fuel stratum comprising the ladder and live crown fuels that can support vertical fire propagation [23].

Surface fuels are characterised by similar methods to those described for canopy fuels. However, given the high coverage and complexity of shrub communities with or without an overlaying tree canopy in the study region, the stand-level approach is based on field inventory [24,25], terrestrial laser scanning [26] and remote sensing techniques such as LiDAR [27] and satellite imaging [21].

In Galicia (NW Spain), an area at the intersection between the Mediterranean and Atlantic climatic influences, a certain level of summer drought coexists with high forest productivity, resulting in very high fuel accumulation [28,29]. These favourable site conditions have allowed the proliferation of pure and even-aged pine stands, especially of *Pinus pinaster* L. and *Pinus radiata* D. Don. According to the IV National Forest Inventory (IVIFN [30]), these species cover 217,000 and 96,000 ha, respectively, accounting for 15 and 7% of the forest area in the region. The mild climate and, in recent decades, the increased demand for timber have favoured the establishment of extensive commercial forest plantations of both fast-growing species [30,31].

Different silvicultural or forest management strategies are used for these species in Galicia depending on site quality and the cost effectiveness of the final products [32]. These strategies include fuel treatments by thinning and pruning (to a maximum height of 6 m) to reduce canopy fuels and mastication to control surface fuels. These treatments enable a certain vertical and horizontal fuel discontinuity to be maintained by generating a gap between surface and canopy fuels; they are thus expected to decrease the likelihood of crown fire initiation and spread. However, a high proportion of adult pine stands are either not managed or are inadequately managed and display a worrying vertical continuity of fuels. This particularly applies to *Pinus radiata* stands, given the very poor self-pruning that characterises the species [33]. Thus, large amounts of dead biomass accumulate in the lower canopy after crown closure, including fine twigs and suspended needles, which represent the so-called ladder fuels.

Ladder fuels comprise live or dead vegetation or a combination of both that provides vertical and horizontal continuity and enables surface-to-crown fire transition, thus transforming comparatively low-intensity fires into severe canopy fires [34]. In addition, dense ladder fuels can make fire suppression more difficult and increase the exposure of firefighters to hazardous conditions, especially when fire behaviour shifts unexpectedly,

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

by inhibiting escape to safety zones [35,36]. Ladder fuels can also reduce habitat quality by decreasing accessibility and foraging efficiency for wildlife [37]. Ladder fuels can be any live or dead biomass, but usually occurs as tree and shrub foliage and small branches that extend to the surface fuel layer or up into the canopy layer [1]. Ladder fuels should therefore be considered when assessing the potential for crown fires in radiata pine stands to prevent the fire hazard being underestimated.

Existing *Pinus radiata CFL* estimation models in Galicia are robust, especially those based on stand variables [12], but can lead to underestimation of *CFL* in closed canopy and unpruned stands because they are based on the individual tree aerial biomass equations that only quantify the live fraction [38]. Furthermore, *CBH* according to the requirements of early crown fire initiation models [3]; i.e., solely based on the live crown component, might not be an adequate metric for the inception of crown fires in this type of stand where dead ladder fuels are well represented. Van Wagner [3] viewed ladder fuels, if abundant enough, as a component of surface fire behaviour that would increase fireline intensity and extend the flame into the live canopy. This implies an option for either the addition of ladder fuels to the surface fuel complex if fire behaviour modeling based on Van Wagner [3] is used or the usage of fire behaviour models and systems where *FSG* (dependent on the height to dead branches and foliage) is an input to assess the surface-to-crown fire transition [5,23,39]. The latter is preferred because the degree of involvement of ladder fuels in combustion will vary within the range of fire weather and stand structure conditions [40].

The process of fuel-management decision making, including the required fire behaviour simulations, should be informed by appropriate and thorough assessment of fuel variables. Therefore, the objective of this study was to develop tools to allow managers to correctly quantify dead ladder fuels in closed canopy and unpruned pure and even-aged *Pinus radiata* stands and thus select the treatments required to reduce crown-fire hazards by incorporating this highly flammable fuel in the estimates of the canopy fuel variables most closely related to fire hazards. With this aim, two systems of equations were fitted. One system was first fitted to estimate the dead biomass according to size class in the first 6 m of the crown of the individual tree and its vertical distribution. Another system was then fitted to estimate the stand-level load of the different size classes and their vertical distribution in a 6 m layer from the ground.

2. Materials and Methods

A total of 20 mature, pure even-aged, unmanaged stands of *Pinus radiata* (Figure 1) were subjectively selected to cover the observed variability in site quality and density in the area of distribution of the species in Galicia.

A temporary circular sample plot with a 10 m radius was established in each stand. The diameter at breast height (d) of all trees within the sample plot was measured to the nearest 0.1 cm at two perpendicular angles with a graduated caliper. The total tree height (h), height to the live crown base (h_{blc}), and height to the dead crown base (h_{bdc}), which were defined as the lower insertion point of respectively live branches and dead branches in a tree, were measured to the nearest 0.1 m with a digital hypsometer in a random subsample of one-third of the total trees in the sample plot (237 trees). The number of stems per hectare (N), stand basal area (G), mean diameter ($\overline{d}$), quadratic mean diameter (dg), mean stand height ($\overline{h}$), and a modification of the relative spacing index (RS), defined as $100/(\sqrt{N}\cdot\overline{h})$, were calculated for each sample plot from tree measurements. The dominant height, which was defined as the average height of the 100 thickest trees per ha, was not considered in this study; due to the size of the sample plots (314 m^2), its value was estimated from the 4 thickest trees in the plot and would have been affected by any measurement error.

The values of h, h_{blc}, and h_{bdc} for the remaining trees in the plots were estimated by fitting a system of three equations with the measurements of the 237 subsampled trees. The system was fitted simultaneously using the iterative seemingly unrelated regression (ITSUR) method in the MODEL procedure of SAS/ETS [41]. The fitted equations explained 78%, 64%, and 98% of the observed variability in h, h_{blc}, and h_{bdc}, respectively; the following

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

final expression, root-mean-square error (*RMSE*), and standard deviation of the parameter estimates (*SE*) were obtained as:

$$h = \left(1.3^{a_0} + (\overline{h}^{a_0} - 1.3^{a_0})\frac{1-exp(-a_1 \cdot d)}{1-exp(-a_1 \cdot dg)}\right)^{1/a_0} \quad RMSE = 1.94 \text{ m}$$
$$a_0 = 1.6732\ (SE = 0.4856); a_1 = 0.0444\ (SE = 0.0197) \tag{1}$$

$$h_{blc} = h \cdot \left(\frac{exp\left[b_0 \cdot \frac{d}{dg} + b_1 \cdot \overline{h} + b_2 \cdot G\right]}{1+exp\left[b_0 \cdot \frac{d}{dg} + b_1 \cdot \overline{h} + b_2 \cdot G\right]}\right) \quad RMSE = 2.21 \text{ m}$$
$$b_0 = -0.8009\ (SE = 0.1025);\ b_1 = -0.0326\ (SE = 0.0102);\ b_2 = 0.0306\ (SE = 0.0040) \tag{2}$$

$$h_{bdc} = h \cdot \left(\frac{exp\left[c_0 + c_1 \cdot \frac{h}{\overline{h}} + c_2 \cdot G\right]}{1+exp\left[c_0 + c_1 \cdot \frac{h}{\overline{h}} + c_2 \cdot G\right]}\right) \quad RMSE = 0.18 \text{ m}$$
$$c_0 = -1.9083\ (SE = 0.2600);\ c_1 = -0.9932\ (SE = 0.2264);\ c_2 = -0.0246\ (SE = 0.0032) \tag{3}$$

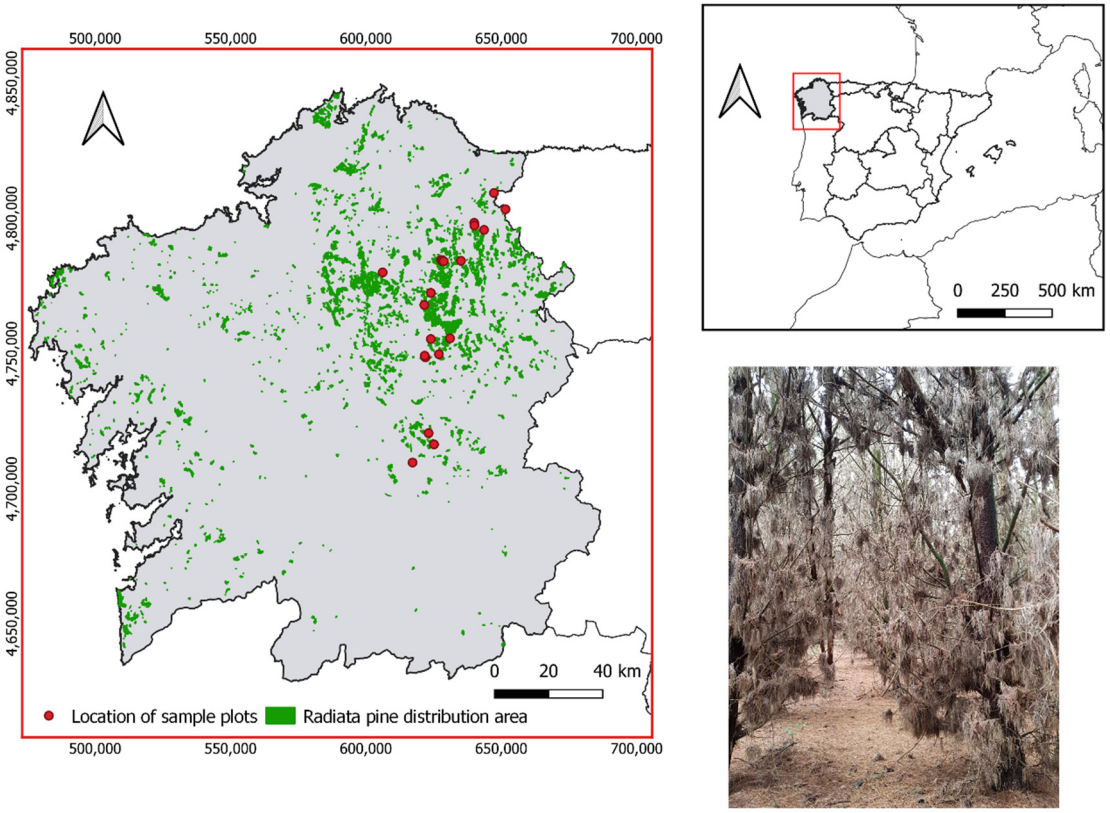

Figure 1. Geographical location of *Pinus radiata* stands in Galicia and of the 20 plots included in the study (**left**). View of one of the study plots (**lower right**).

In each plot, 2 to 4 trees in the subsample used for height measurement were subjectively selected to cover the observed diameter range. Those trees had no crown damage and branch development corresponded to the natural processes of intraspecific competition in these particular conditions. A total of 65 trees were selected and the dead crown branches within the first 6 m of the stem were destructively sampled. An upper sampling limit of 6 m was selected because this was the maximum pruning height for the species in the study area. All dead branches in each 1 m section from the base of the tree were cut and the material was bagged and taken to the laboratory, where it was physically separated into different size classes: needles, fine woody fuels (twigs diameter < 0.6 cm, hereafter *G*1), medium fuels (twigs 0.6 cm ≤ diameter < 2.5 cm, hereafter *G*2), and coarse fuels (branches 2.5 cm ≤ diameter < 7.6 cm and cones, hereafter *G*3). Most of the trees did not contain *G*3 material, so the *G*2 and *G*3 categories were grouped together (*G*23). Although there is no

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

full consensus about what is considered available fuel (see [11] for clarification), for the purposes of canopy fuel modelling, only the thinnest fraction (needles and *G*1) is usually considered. However, fuels thicker than 6 mm were also considered in this study to enable, e.g., the total biomass contributed by dead branches for different pruning heights to be determined. Once classified, the material was weighed and dried in a forced air oven (105 °C for 24 h for fine fuels and 48 h for coarse fuels) to determine the dry biomass of each fraction (W_{total}, $W_{needles}$, W_{G123}, W_{G23}, and W_{G1}).

The compatible system of tree biomass equations developed for radiata pine in Galicia [38,42] was used to estimate the biomass of needles and fine twigs (<0.6 cm diameter) in the live crown of all trees in the plot. Three structural canopy fuel variables were then estimated using the 'load over depth' method: canopy fuel load (*CFL*), canopy base height (*CBH*), and canopy bulk density (*CBD*). *CBH* was calculated as the mean value of the height to the base of live crown per plot; *CFL* was calculated as the biomass of needles and fine twigs for all trees in the plot, which were assumed to be the fuel consumed within the flaming front of a crown fire divided by the surface plot; and *CBD* was calculated by dividing *CFL* by crown length, which was estimated as the difference between the mean stand height ($\overline{h}$) and *CBH*. The mean value and standard deviation for the main stand and tree variables are shown in Table 1.

Table 1. Statistics for the main tree and stand variables.

Stand variables (n = 20)				
Variable	**Mean**	**Maximum**	**Minimum**	**Std. Dev.**
N (stems/ha)	985.03	1368.73	604.79	222.62
G (m^2/ha)	39.34	60.51	25.06	9.87
$\overline{d}$ (cm)	21.47	29.24	16.94	3.26
$\overline{h}$ (m)	19.56	25.57	14.19	3.15
RS	0.17	0.24	0.12	0.03
Live canopy variables (n = 20)				
Variable	**Mean**	**Maximum**	**Minimum**	**Std. Dev.**
CBH (m)	8.64	14.09	4.65	2.80
CFL (kg/m^2)	1.19	1.78	0.75	0.28
CBD (kg/m^3)	0.11	0.20	0.07	0.04
Tree variables (n = 629)				
Variable	**Mean**	**Maximum**	**Minimum**	**Std. Dev.**
d (cm)	21.05	49.8	4.8	8.04
h (m)	19.77	30.4	9.9	4.17
h_{blc} (m)	8.79	19.3	2.5	3.27
h_{bdc} (m)	0.39	1.1	0.1	0.18
Dead crown biomass within the first 6 m of destructively sampled trees (n = 65)				
Variable	**Mean**	**Maximum**	**Minimum**	**Std. Dev.**
W_{total} (kg)	19.06	63.92	3.12	11.68
$W_{needles}$ (kg)	3.17	11.55	0.22	2.19
W_{G1} (kg)	2.10	7.55	0.31	1.09
W_{G23} (kg)	13.79	47.06	1.82	9.41

Std. Dev = standard deviation; N = stem density; G = stand basal area; $\overline{d}$ = mean diameter; $\overline{h}$ = mean height; *RS* = relative spacing index; *CBH* = canopy base height; *CFL* = canopy fuel load; *CBD* = canopy bulk density; d = tree diameter; h = tree height; h_{blc} = height to the live crown base; h_{bdc} = height to the dead crown base; and W_{total}, $W_{needles}$, W_{G23}, and W_{G1} = total, needles, medium and coarse (*G*23), and woody fine (*G*1) fuel biomass, respectively.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

2.1. Fuel Biomass Equations for the First 6 m of the Stem at Tree Level

Equations for estimating the biomass of each of the five fuel fractions were developed (W_{total}, $W_{needles}$, W_{G123}, W_{G23}, and W_{G1}) for the first 6 m of the stem using allometric models

of the form $\widehat{W_i} = \beta_0 \cdot X_i^{\beta_i}$, where $\widehat{W_i}$ is the fuel biomass of fraction i, X_i is a set of independent variables, and β_0 and β_i are parameters to be estimated. The fitted equations had to fulfil the property of additivity; i.e., the sum of biomass estimates from separate fractions had to equal the biomass estimates from the total biomass model (e.g., $W_{needles}$ + W_{G123} estimates had to equal W_{total} estimates or W_{G23} + W_{G1} estimates had to equal W_{G123} estimates). Therefore, the equation for each fuel fraction was fitted separately in a first step and the complete system of five equations (one per fraction) was then fitted simultaneously to guarantee additivity. The best set of independent variables was selected by using the stepwise selection method after linearizing the allometric models by applying logarithmic transformations to both sides of the equation.

The equation for estimating total fuel biomass $\widehat{W_{total}}$ is expressed as follows:

$$\widehat{W_{total}} = a_0 \cdot X_i^{a_i} \tag{4}$$

Two equations discriminating between branch and cone biomass (W_{G123}) and needle biomass ($W_{needles}$) were obtained by disaggregating Equation (4):

$$\widehat{W_{needles}} = exp[b_{0_n} + b_{i_n} \cdot log(X_i)]$$

$$\widehat{W_{G123}} = exp[b_{0_G123} + b_{i_G123} \cdot log(X_i)]$$

$$\frac{\widehat{W_{G123}}}{\widehat{W_{total}}} = \frac{\widehat{W_{G123}}}{\left(\widehat{W_{G123}} + \widehat{W_{needles}}\right)} = \frac{1}{1 + \left(\widehat{W_{needles}} / \widehat{W_{G123}}\right)}$$

The equation for estimating the branch and cone fuel biomass was then obtained as follows:

$$\widehat{W_{G123}} = \widehat{W_{total}} \cdot \frac{1}{1 + exp[b_0 + b_i \cdot log(X_i)]} \tag{5}$$

where $b_j = b_{j_n} - b_{j_G123}$; the equation to estimate the needles fuel biomass was expressed as follows:

$$\widehat{W_{needles}} = \widehat{W_{total}} - \widehat{W_{G123}} = \widehat{W_{total}} \cdot \left[\frac{exp[b_0 + b_i \cdot log(X_i)]}{1 + exp[b_0 + b_i \cdot log(X_i)]}\right] \tag{6}$$

Two equations for discriminating between coarse branch and cone biomass (W_{G23}) and fine branch biomass (W_{G1}) were derived by disaggregating Equation (5):

$$\widehat{W_{G23}} = exp[c_{0_G23} + c_{i_G23} \cdot log(X_i)]$$

$$\widehat{W_{G1}} = exp[c_{0_G1} + c_{i_G1} \cdot log(X_i)]$$

$$\frac{\widehat{W_{G23}}}{\widehat{W_{G123}}} = \frac{\widehat{W_{G23}}}{\left(\widehat{W_{G23}} + \widehat{W_{G1}}\right)} = \frac{1}{1 + \left(\widehat{W_{G1}} / \widehat{W_{G23}}\right)}$$

The equation for estimating the fine dead fuel biomass was then obtained as follows:

$$\widehat{W_{G23}} = \widehat{W_{G123}} \cdot \frac{1}{1 + exp[c_0 + c_i \cdot log(X_i)]} \tag{7}$$

where $c_j = c_{j_G1} - c_{j_G23}$; the equation for estimating the live fine fuel biomass was expressed as follows:

$$\widehat{W_{G1}} = \widehat{W_{G123}} - \widehat{W_{G23}} = \widehat{W_{G123}} \cdot \left[\frac{exp[c_0 + c_i \cdot log(X_i)]}{1 + exp[c_0 + c_i \cdot log(X_i)]}\right] \tag{8}$$

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

2.2. Vertical Fuel Biomass Distribution by Height in the First 6 m of the Stem at Tree Level

The 2-parameter Weibull probability density function (PDF) was selected to describe vertical fuel biomass distribution according to height along the first 6 m of the stem for each fuel fraction:

$$W_{acum_ij} = W_i \cdot \left[1 - exp\left(-\left(\frac{x_j}{p_{1i}}\right)^{p_{2i}}\right)\right], \text{ with } x_j = \frac{h_j - h_{bdc}}{\min(6, h_{blc}) - h_{bdc}} \quad (9)$$

where W_{acum_ij} is the cumulative fuel biomass of the fraction i (W_{total}, $W_{needles}$, W_{G123}, W_{G23}, and W_{G1}) at height h_j within the first 6 m of the stem; W_i is the entire 6 m stem's fuel biomass of fraction i; h_{bdc} and h_{blc} are the dead crown base height and the live crown base height, respectively; and p_1 and p_2 are the scale and shape parameters of the 2-parameter Weibull PDF, respectively.

To ensure additivity between fractions, the W_{acum_G1j}, W_{acum_G23j}, and $W_{acum_needlesj}$ equations were fitted so that the other fuel biomass classes (W_{acum_G123j} and W_{acum_totalj}) were estimated as the sum of the fitted fraction estimates.

2.3. Fuel Loads and Vertical Distribution in the First 6-m Layer above Ground at Stand Level

After developing the system of 8 equations for estimating fuel biomass and vertical distribution in the first 6 m of the stem of a specific tree, the equations were applied to all trees measured in each of the 20 sample plots. Thus, the fuel loads of each fraction and their vertical distribution in a 6 m layer above ground were estimated for the entire stand (Mg/ha). Finally, we used these estimates to fit a new system of 8 equations similar to that fitted for individual trees but now for entire stands.

The workflow for fitting the equation systems at individual tree and stand levels is shown in Figure 2, which provides a simple overview of the procedure described in detail in the above sections.

2.4. Statistical Analysis

The condition number was used to evaluate the presence of multicollinearity among variables in the equations fitted. According to Myers [43], condition numbers higher than $\sqrt{1000}$ indicate severe multicollinearity. The presence of heteroscedasticity was analysed by using the White test [44] and by visual inspection of Studentised residuals plotted against fitted values. In case of the presence of heteroscedasticity, each observation was weighted by the inverse of its estimated variance ($\hat{\sigma}_i^2$) under the assumption that this variance could be modelled as a power function of the independent variables [45]; i.e., $\hat{\sigma}_i^2 = (X_i)^{exp}$. The value of the exponential term (exp) was optimised to provide the most homogeneous Studentised residual plot by using the method of Harvey [46].

As the database contained multiple equidistant observations (1 m) for each tree or stand along the 6 m layer above ground, it was reasonable to expect autocorrelation within the residuals of each tree or stand. To overcome potential autocorrelation, an autoregressive error structure of order 1 (AR1) was added to the equations to estimate the vertical distribution of fuel loads. The Durbin–Watson test was used to evaluate the possible presence of autocorrelation.

Each of the systems of 8 equations for the respective individual tree level and stand level, both of which consisted of five allometric equations for the entire 6 m layer above ground and three vertical height distribution models along the 6 m layer, were fitted simultaneously using the MODEL procedure of SAS/ETS® [41]. In order to take cross-equation correlations into account, the ITSUR method was used to fit the system using the cross-equation error covariance matrix obtained by ordinary least squares to initiate the iterative procedure.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

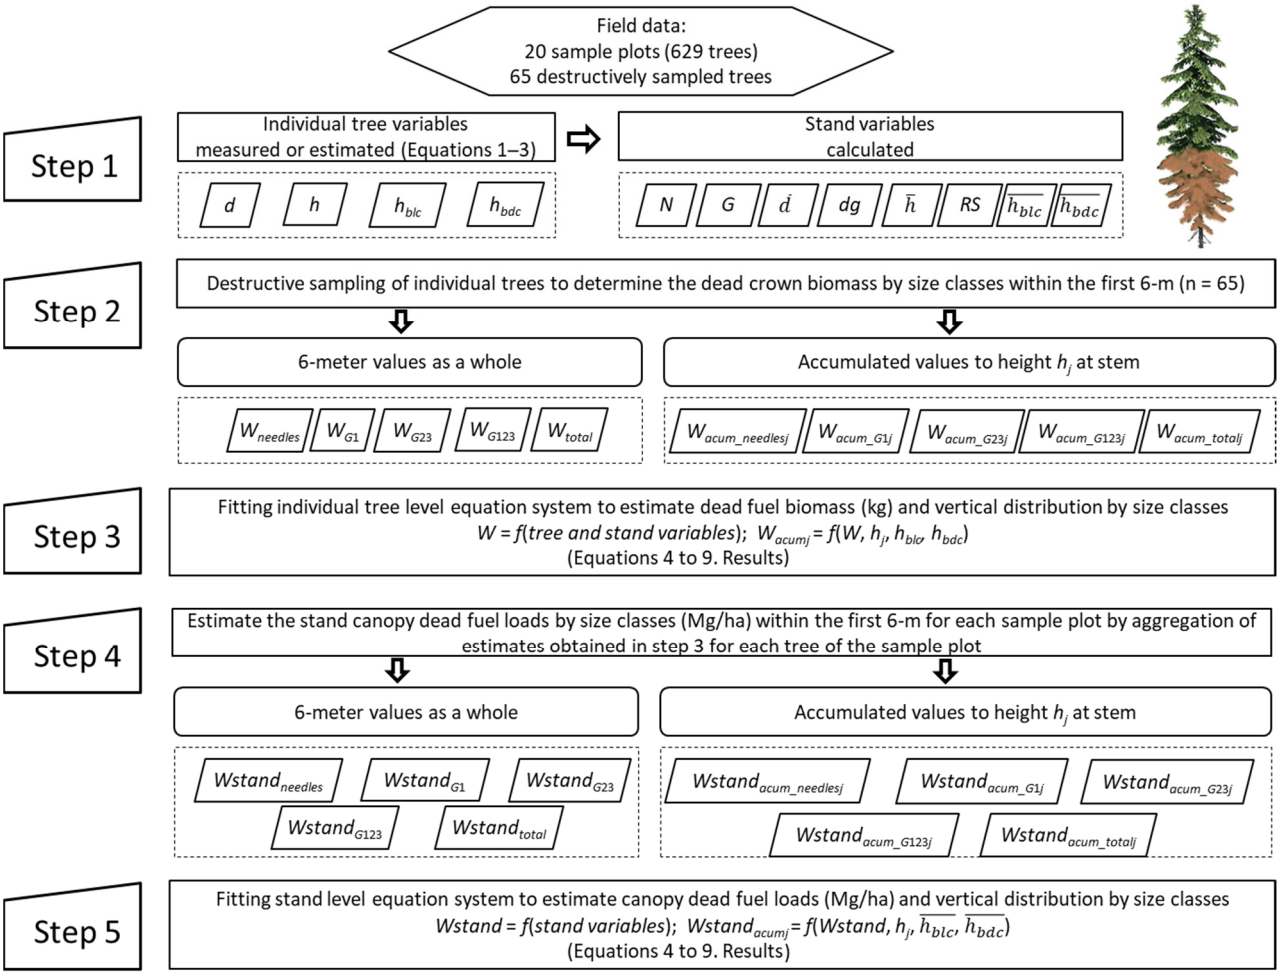

Figure 2. Workflow for fitting the equation systems at individual tree and stand levels.

The database used to fit the three vertical distribution models according to height for individual trees included k measurements for each tree with a maximum of $k = 6$, which corresponded to the fuel loads of each fraction at heights from 1 to 6 m above ground or up to the beginning of the live crown. However, there was only one observation of W_{total}, $W_{needles}$, W_{G123}, W_{G23}, and W_{G1} per individual tree for fitting Equations (4)–(8). As simultaneous fitting required the same number of observations for each equation in the system, the W_{total}, $W_{needles}$, W_{G123}, W_{G23}, and W_{G1} observations were repeated k times for each tree so that those values in the simultaneous fitting were weighted by the inverse of the number of observations $1/k$. The same procedure was used to fit the equations system at the stand level; e.g., [47,48].

Two goodness-of fit statistics were used to check the accuracy of estimates: model efficiency (*EF*) [49] and the root-mean-square error (*RMSE*):

$$EF = 1 - \frac{\sum_{i=1}^{n}\left(Y_i - \hat{Y}_i\right)^2}{\sum_{i=1}^{n}\left(Y_i - \overline{Y}\right)^2} \quad (10)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n}\left(Y_i - \hat{Y}_i\right)^2}{n-1}} \quad (11)$$

where Y_i, $\hat{Y}_i$, and $\overline{Y}$ are the measured, estimated, and mean values of the dependent variable, respectively; and n is the total number of observations used to fit the equation.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

3. Results

3.1. Fuel Biomass Equations and Vertical Distribution within the 6 m above the Ground Layer at the Tree Level

Once the best set of independent variables was selected for each of the five fuel biomass estimation equations (Equations (4)–(8)) for the total of the first 6 m in the stem, the entire system of eight equations was fitted simultaneously. The autoregressive terms were not initially included; however, the results of the Durbin–Watson test indicated the presence of autocorrelation in several of the vertical profile equations, so the fit was repeated. After including the AR1 term, no autocorrelation was detected.

As previously mentioned, the estimates of W_{acum_G123j} and W_{acum_totalj} were obtained as the sum of the W_{acum_G23j} + W_{acum_G1j} and W_{acum_G123j} + $W_{acum_needlesj}$ fitted fraction estimates, respectively, and the R^2 and *RMSE* for these two individual tree fractions were then calculated.

The results of the fit of the system of equations and the values of the goodness-of-fit statistics are shown in Table 2. All of the parameters included were significant ($\alpha = 0.05$) and the values of the condition number associated with each independent variable and the results of White's test did not indicate the presence of multicollinearity or heteroscedasticity, respectively.

The fuel biomass models explained between 35% and 59% of the observed variability in the needle fuel biomass ($W_{needles}$) and total woody and coarse fuel biomass (W_{G123} and W_{G23}) equations, respectively, with *RMSE* values ranging from 0.73 kg for fine woody fuels (W_{G1}) to 7.92 kg for total fuel (W_{total}). On the other hand, the cumulative fuel biomass models to a certain height in the stem (h_j) explained between 62% ($W_{acum_needlesj}$) and 81% (W_{acum_G1j}) of the total observed variability, with *RMSE* values ranging from 0.46 kg for the fine woody fuel biomass equation (W_{acum_G1j}) to 5.02 kg for the total fuel biomass equation (W_{acum_totalj}).

By way of example, Figure 3 shows the observed versus predicted values for needles ($W_{acum_needlesj}$), woody fines (W_{acum_G1j}), and total (W_{acum_totalj}) fuel loads as well as the vertical distribution of the residuals of these estimates for the same fractions and sections.

3.2. Fuel Load Equations and Vertical Distribution in the First 6 m Layer above Ground at Stand Level

Once the tree-level equations were fitted, they were applied to all the trees in each sample plot and the dead biomass values per hectare of the different fractions for the first 6 m of height from the ground were obtained by aggregating the values for each tree (Table 3).

As in the system for the individual tree, once the best set of independent variables was selected, the system of eight equations was fitted simultaneously (initially without including the autoregressive terms). In view of the results of the Durbin–Watson test, the system was refitted by including the order 1 autoregressive term (AR1). Multicollinearity and heteroscedasticity were not detected in any of the eight equations fitted. The models finally obtained, as well as the goodness-of-fit statistics, are shown in Table 4. All parameters included in the models were significant ($\alpha = 0.05$).

Again, once the eight equations were fitted, the $Wstand_{acum_G123j}$ and $Wstand_{acum_totalj}$ values for each stand were estimated as the sum of the $Wstand_{acum_G23j}$ + $Wstand_{acum_G1j}$ and $Wstand_{acum_G123j}$ + $Wstand_{acum_needlesj}$ estimates, respectively. The R^2 and *RMSE* values were then calculated for these two fractions.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Table 2. System of 8 equations fitted to estimate dead fuel biomass and vertical distribution according to fuel fractions for individual trees.

Fuel Biomass Equations	Equations for Vertical Fuel Biomass Distribution
$W_{total} = a_0 \cdot d^{a_1} \cdot {h_{bdc}}^{a_2}$ $a_0 = 0.0222\ (0.0084\ );\ a_0 = 1.9745\ (0.1046);\ \ a_0 = -0.6329\ (0.0711)$ $EF = 0.5676\ \ RMSE = 7.92$ kg	$W_{acum_totalj} = W_{acum_G123j} + W_{acum_needlesj}$ $EF = 0.7763\ \ RMSE = 5.02$ kg
$W_{G123} = \frac{W_{total}}{1+exp\left(b_0+b_1 \cdot h+b_2 \cdot \overline{h_{bdc}}+b_3 \cdot \overline{h_{blc}}\right)}$ $b_0 = -1.8248\ (0.2049); b_1 = -0.0792\ (0.0098); b_2 = 2.6755\ (0.2391); b_3 = 0.0733\ (0.0132)$ $EF = 0.5953\ \ RMSE = 6.68$ kg	$W_{acum_G123j} = W_{acum_G23j} + W_{acum_G1j}$ $EF = 0.7901\ \ RMSE = 4.13$ kg
$W_{needles} = \frac{W_{total} \cdot exp\left(b_0+b_1 \cdot h+b_2 \cdot \overline{h_{bdc}}+b_3 \cdot \overline{h_{blc}}\right)}{1+exp\left(b_0+b_1 \cdot h+b_2 \cdot \overline{h_{bdc}}+b_3 \cdot \overline{h_{blc}}\right)}$ $b_0 = -1.8248\ (0.2049); b_1 = -0.0792\ (0.0098); b_2 = 2.6755\ (0.2391); b_3 = 0.0733\ (0.0132)$ $EF = 0.3530\ \ RMSE = 1.89$ kg	$W_{acum_needlesj} = W_{needles}\left[1 - exp\left(-\left(\frac{x_i}{p_{1_needles}}\right)^{p_{2_Gneedles}}\right)\right]$ $p_{1_needles} = 0.3884\ (0.0507);\ \ p_{2_needles} = 1.44\ (0.10)$ $EF = 0.6220\ \ RMSE = 1.35$ kg
$W_{G23} = \frac{W_{G123}}{1+exp\left(c_0+c_1 \cdot d+c_2 \cdot RS+c_3 \cdot h_{bdc}+c_4 \cdot \frac{l_{dc}}{h}\right)}$ $c_0 = -1.8878\ (0.18); c_1 = -0.0413(0.004); c_2 = 5.536\ (0.54); c_3 = 0.9344\ (0.16);\ c_4 = -0.7637(0.18)$ $EF = 0.5927\ \ RMSE = 6.15$ kg	$W_{acum_G23j} = W_{G23}\left[1 - exp\left(-\left(\frac{x_i}{p_{1_G23}}\right)^{p_{2_G23}}\right)\right]$ $p_{1_G23} = 0.5612\ (0.0305);\ \ p_{2_G23} = 1.87\ (0.15)$ $EF = 0.7805\ \ RMSE = 3.81$ kg
$W_{G1} = \frac{W_{G123} \cdot exp\left(c_0+c_1 \cdot d+c_2 \cdot RS+c_3 \cdot h_{bdc}+c_4 \cdot \frac{l_{dc}}{h}\right)}{1+exp\left(c_0+c_1 \cdot d+c_2 \cdot RS+c_3 \cdot h_{bdc}+c_4 \cdot \frac{l_{dc}}{h}\right)}$ $c_0 = -1.8878\ (0.18); c_1 = -0.0413(0.004); c_2 = 5.536\ (0.54); c_3 = 0.9344\ (0.16);\ c_4 = -0.7637(0.18)$ $EF = 0.5826\ \ RMSE = 0.73$ kg	$W_{acum_G1j} = W_{G1}\left[1 - exp\left(-\left(\frac{x_i}{p_{1_G1}}\right)^{p_{2_G1}}\right)\right]$ $p_{1_G1} = 0.5365\ (0.0234);\ \ p_{2_G1} = 1.71\ (0.25)$ $EF = 0.8128\ \ RMSE = 0.46$ kg

W = dead fuel biomass (kg); d = tree diameter (cm); h = tree height (m); h_{blc} = height to the live crown base (m); h_{bdc} = height to the dead crown base (m); $\overline{h_{bdc}}$ = mean h_{bdc} of the stand; $\overline{h_{blc}}$ = mean h_{blc} of the stand; RS = relative spacing index; l_{dc} = length of the dead crown (h_{blc} -h_{bdc}); W_{acum_j} = accumulated dead fuel biomass to height h_j on the stem (kg) with max(h_j) = 6 and $x_i = \left(h_j - h_{bdc}\right) / \left(\min(6; h_{blc}) - h_{bdc}\right)$. Standard errors of parameter estimates are in brackets.

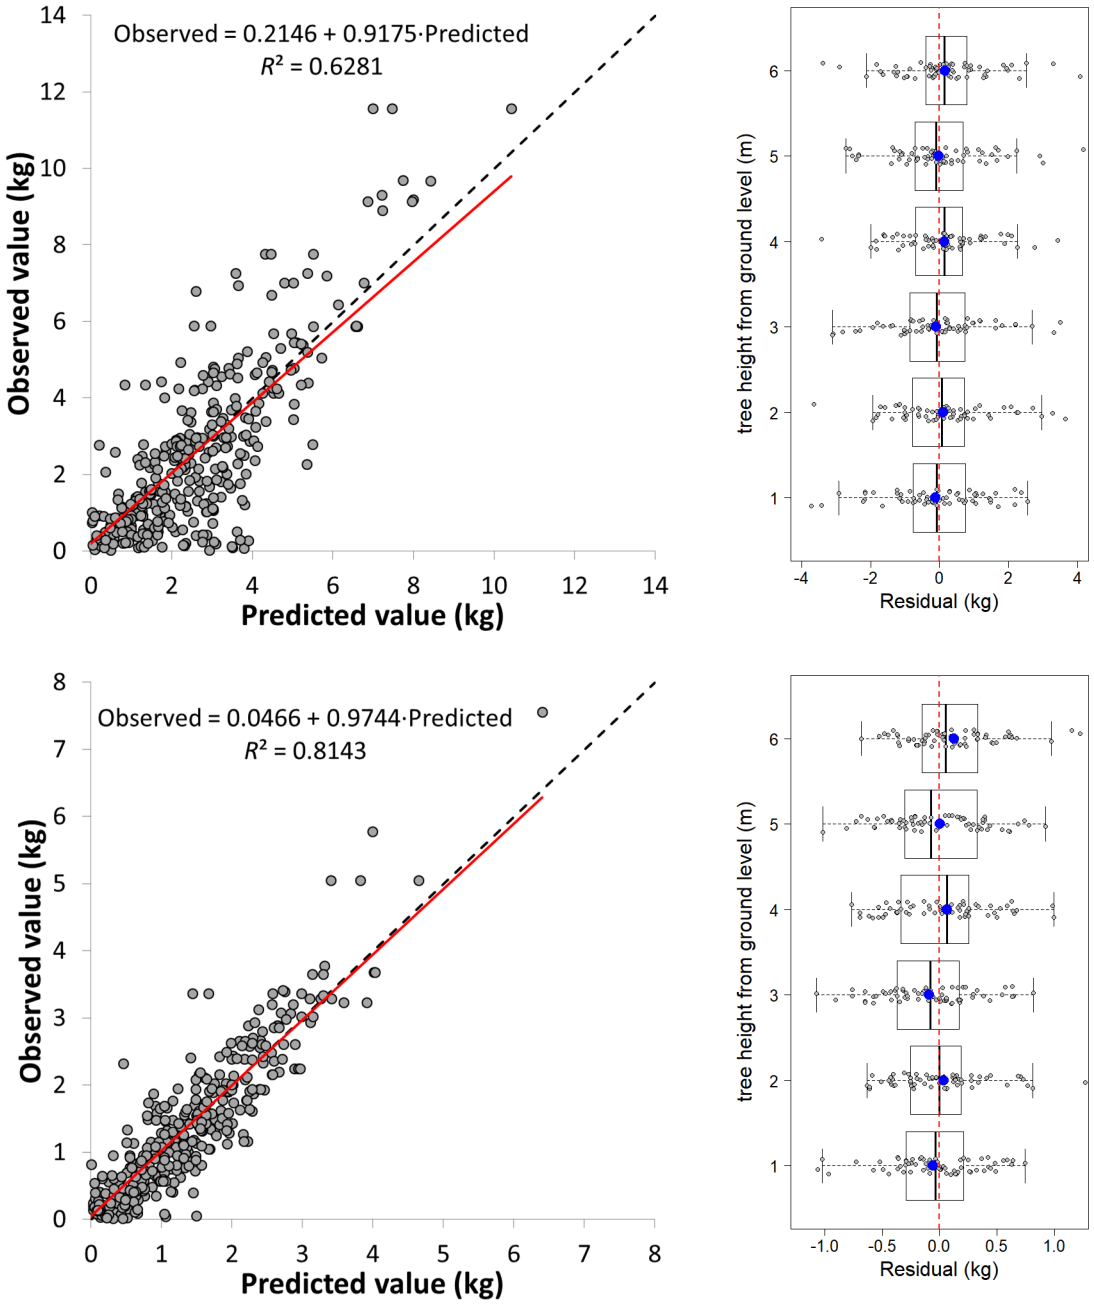

Figure 3. *Cont.*

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

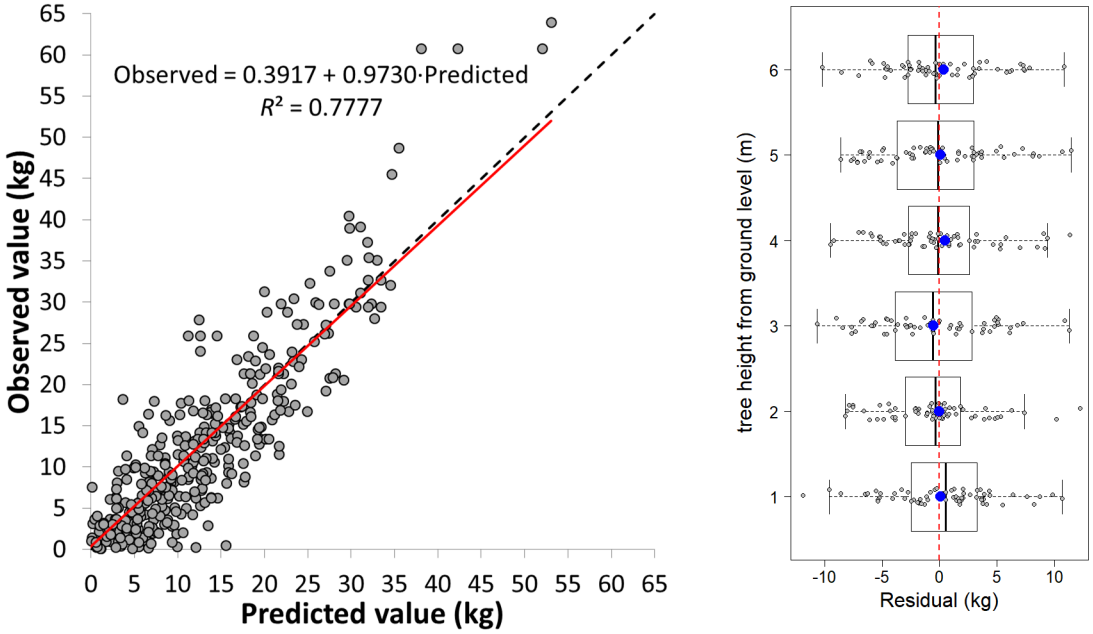

Figure 3. (**Left**) Scatter plots of observed versus predicted values for the vertical distribution of needles ($W_{acum_needlesj}$, upper), woody fines (W_{acum_G1j}, middle), and total (W_{acum_totalj}, lower) individual tree fuel loads. The solid red line denotes the fitted linear model and the dashed line denotes perfect agreement. (**Right**) Box plots of the vertical distribution of residuals of needles ($W_{acum_needlesj}$, upper), woody fine (W_{acum_G1j}, middle), and total (W_{acum_totalj}, lower) individual tree fuel loads according to heights from ground level. Blue dots denote the mean values.

Table 3. Statistics for the main variables in the first 6 m of dead canopy and the entire canopy.

Variables for the First 6 m of Dead Canopy (n = 20)				
Variable	**Mean**	**Maximum**	**Minimum**	**Std. Dev.**
$Wstand_{total}$ (Mg/ha)	19.58	34.77	9.86	6.78
$Wstand_{needles}$ (Mg/ha)	2.97	5.06	1.68	0.93
$Wstand_{G1}$ (Mg/ha)	1.94	2.62	1.15	0.35
$Wstand_{G23}$ (Mg/ha)	14.67	27.51	5.31	0.61
$\overline{h_{bdc}}$ (m)	0.41	0.83	0.24	0.14
CFL_{dead} (kg/m^2)	0.49	0.73	0.34	0.10
% CFL_{dead}	29.49	36.03	22.35	3.23
Variable for the entire canopy (dead + live) (n = 20)				
Variable	**Mean**	**Maximum**	**Minimum**	**Std. Dev.**
CFL_{total} (kg/m^2)	1.68	2.51	1.09	0.36

Std. Dev = standard deviation; $Wstand_{total}$, $Wstand_{needles}$, $Wstand_{G1}$, and $Wstand_{G23}$ = total, needles, fine woody (G1), and medium and coarse (G23) fuel load in the first 6 m of dead canopy, respectively; $\overline{h_{bdc}}$ = mean dead canopy base height in the stand; CFL_{dead} = available canopy fuel load of the first 6 m of dead canopy (needles + G1); $\%CFL_{dead}$ = percentage of CFL_{dead} over *CFL* of the entire canopy (CFL_{total}).

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Table 4. System of 8 equations fitted simultaneously to estimate dead fuel loads and their vertical distribution according to fuel fraction at stand level.

Fuel Load Equations	Equations for Vertical Fuel Load Distribution
$Wstand_{_total} = a_0 \cdot G^{a_1} \cdot \overline{h_{bdc}}^{a_2}$ $a_0 = 0.2303\ (0.0119); a_1 = 1.1311 (0.0142); a_2 = -0.2993\ (0.0148)$ $EF = 0.9780\ RMSE = 1.01$ Mg/ha	$Wstand_{acum_totalj} = Wstand_{acum_needlesj} + Wstand_{acum_G123j}$ $EF = 0.9909\ RMSE = 0.75$ Mg/ha
$Wstand_{_G123} = \frac{Wstand_{_total}}{1+exp\left(b_0+b_1 \cdot \overline{h_{bdc}}+b_2 \cdot \left(\overline{h}-\overline{h_{blc}}\right)\right)}$ $b_0 = -1.8633\ (0.0156);\ b_1 = 2.3581\ (0.0259);\ b_2 = -0.0740\ (0.0011)$ $EF = 0.9794\ \ RMSE = 0.90$ Mg/ha	$Wstand_{acum_G123j} = Wstand_{acum_G1j} + Wstand_{acum_G23j}$ $EF = 0.9911\ \ RMSE = 0.67$ Mg/ha
$Wstand_{_needles} = \frac{Wstand_{_total} \cdot exp\left(b_0+b_1 \cdot \overline{h_{bdc}}+b_2 \cdot \left(\overline{h}-\overline{h_{blc}}\right)\right)}{1+exp\left(b_0+b_1 \cdot \overline{h_{bdc}}+b_2 \cdot \left(\overline{h}-\overline{h_{blc}}\right)\right)}$ $b_0 = -1.8633\ (0.0156);\ b_1 = 2.3581\ (0.0259);\ b_2 = -0.0740\ (0.0011)$ $EF = 0.9771\ \ RMSE = 0.14$ Mg/ha	$Wstand_{acum_needlesj} = Wstand_{_needles}\left[1 - exp\left(-\left(\frac{x_i}{p_{1_needles}}\right)^{p_{2_needles}}\right)\right]$ $p_{1_needles} = 0.4005\ (0.0021);\ \ p_{2_needles} = 1.58\ (0.02)$ $EF = 0.9912\ \ RMSE = 0.11$ Mg/ha
$Wstand_{_G23} = \frac{Wstand_{_G123}}{1+exp\left(c_0+c_1 \cdot G+c_2 \cdot \overline{h}\right)}$ $c_0 = -0.4127\ (0.0201);\ c_1 = -0.0226\ (0.0005);\ c_2 = -0.0342\ (0.0015)$ $EF = 0.9819\ \ RMSE = 0.82$ Mg/ha	$Wstan_{d_{acum_G23j}} = Wstand_{_G23}\left[1 - exp\left(-\left(\frac{x_i}{p_{1_G123}}\right)^{p_{2_G123}}\right)\right]$ $p_{1_G23} = 0.5564\ (0.0033);\ \ p_{2_G23} = 2.06\ (0.03)$ $EF = 0.9911\ \ RMSE = 0.61$ Mg/ha
$Wstand_{_G1} = \frac{Wstand_{_G123} \cdot exp\left(c_0+c_1 \cdot G+c_2 \cdot \overline{h}\right)}{1+exp\left(c_0+c_1 \cdot G+c_2 \cdot \overline{h}\right)}$ $c_0 = -0.4127\ (0.0201);\ c_1 = -0.0226\ (0.0005);\ c_2 = -0.0342\ (0.0015)$ $EF = 0.8829\ \ RMSE = 0.12$ Mg/ha	$Wstan_{d_{acum_G1j}} = Wstand_{_G1}\left[1 - exp\left(-\left(\frac{x_i}{p_{1_G1}}\right)^{p_{2_G1}}\right)\right]$ $p_{1_G1} = 0.5280\ (0.0036);\ \ p_{2_G1} = 1.90\ (0.03)$ $EF = 0.9837\ \ RMSE = 0.09$ Mg/ha

Wstand = fuel load (Mg/ha); h_{blc} = height to the base of the live crown (m); h_{bdc} = height to the dead crown base (m); $\overline{h_{bdc}}$ = mean h_{bdc} of the stand; $\overline{h_{blc}}$ = mean h_{blc} of the stand; $\overline{h}$ = mean height of the stand; G = stand basal area; $Wstand_{acum_j}$ = accumulated dead fuel load to height h_j in the stem (Mg/ha) with max(h_j) = 6 and $x_i = \left(h_j - \overline{h_{bdc}}\right) / \left(\min\left(6, \overline{h_{blc}}\right) - \overline{h_{bdc}}\right)$. Standard errors of parameter estimates are in brackets.

The fuel load models explained between 88% and 98% of the observed variability in the fine woody fuel load ($Wstand_{G1}$) and the other fuel fractions ($Wstand_{total}$, $Wstand_{G123}$, $Wstand_{needles}$, and $Wstand_{G23}$) equations, respectively. The *RMSE* values ranged from 0.12 Mg/ha for fine woody fuel ($Wstand_{G1}$) to 1.01 Mg/ha for total fuel load ($Wstand_{total}$). The cumulative fuel load models explained more than 98% of the total observed variability, with *RMSE* values ranging from 0.09 Mg/ha for the fine woody fuel load equation ($Wstand_{acum_G1j}$) to 0.75 Mg/ha for the total fuel load equation ($Wstand_{acum_totalj}$).

Figure 4 shows the observed versus predicted values for needles ($Wstand_{acum_needlesj}$), woody fine ($Wstand_{acum_G1j}$), and total ($Wstand_{acum_totalj}$) fuel loads as well as the vertical distribution of the residuals of these estimates for the same fractions and sections.

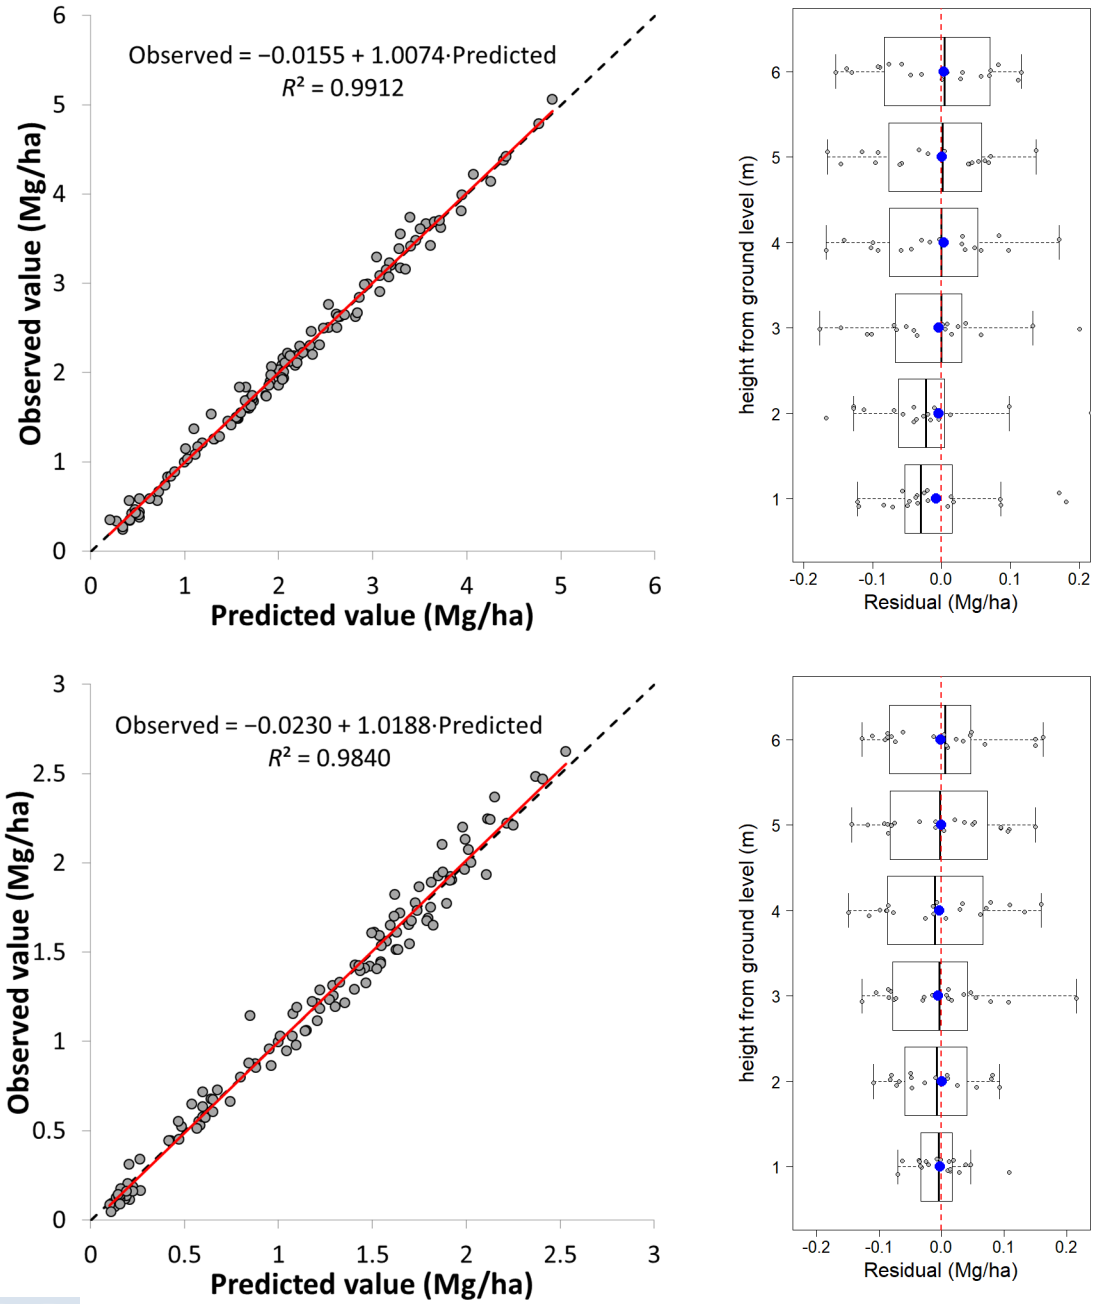

Figure 4. *Cont.*

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

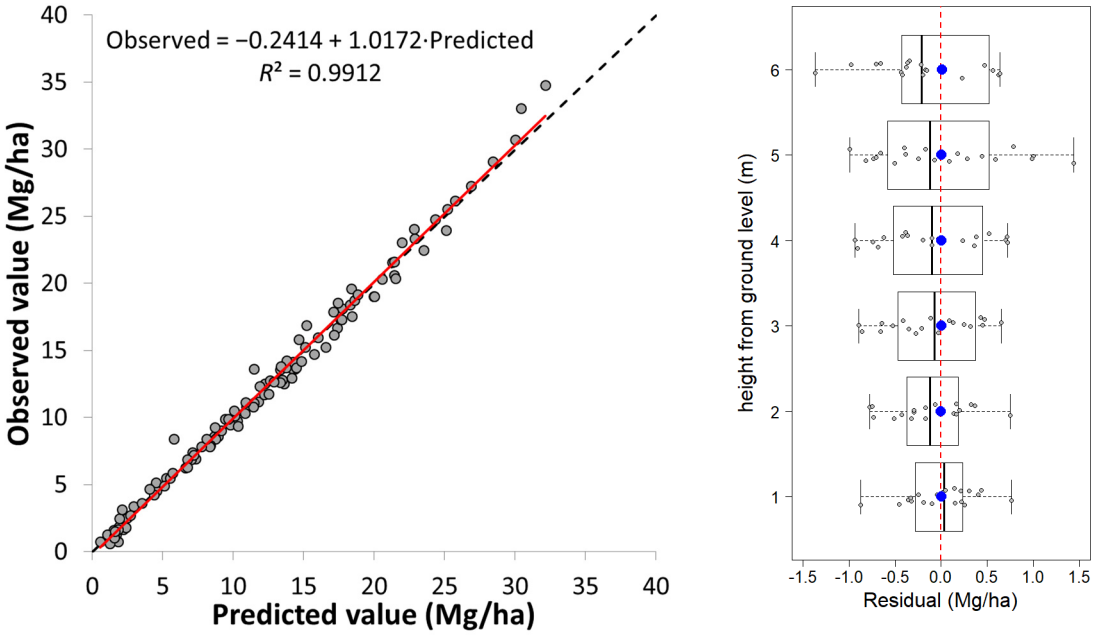

Figure 4. (**Left**) Scatter plots of observed versus predicted values for the vertical distribution of needles ($Wstand_{acum_needlesj}$, upper), woody fine ($Wstand_{acum_G1j}$, middle), and total ($Wstand_{acum_totalj}$, lower) stand fuel loads. The solid red line denotes the fitted linear model and the dashed line denotes perfect agreement. (**Right**) Box plots of the vertical distribution of residuals of needles ($Wstand_{acum_needlesj}$, upper), woody fines ($Wstand_{acum_G1j}$, middle), and total ($Wstand_{acum_totalj}$, lower) stand fuel loads according to heights from ground level. Blue dots denote the mean values.

4. Discussion

The values of the stand variables and live-canopy structural variables (*CBH*, *CFL*, and *CBD*) observed in this study were within the range of values obtained for *Pinus radiata* in other studies conducted in the same geographic area and under similar climatic, physiographic, and edaphic conditions; e.g., [11,12,14,21]. Moreover, the observed mean values of stem density (*N*), stand basal area (*G*), mean height ($\overline{h}$), and *CFL* were consistent with those reported by Gomez-Vazquez et al. [14] for the same species and the mean value of *CBD* (0.11 kg/m^3) was the same as that observed by Arellano-Pérez et al. [21] and slightly exceeded the threshold of 0.1 kg/m^3 empirically deduced by Agee [50] as the approximate value necessary to support active crowning.

The mean *CBH* in the sample plots analysed in this study was 8.6 m (sd = 2.8 m) with a maximum of 14.1 m, whereas the mean height of dead fuel initiation was 0.4 m (sd = 0.1 m) with a maximum of 0.8 m. Thus, the dead canopy base height rather than the live height should be used to assess the potential for crown fire initiation in closed and unmanaged radiata pine stands. Consequently, a fire behaviour system based on *FSG* rather on *CBH* should be used; namely, PPPY [5] or AMICUS [39]. Users of USDA Forest Service fire behaviour modelling tools, which rely on the crown fire initiation equation in [3] that used *CBH* as an input, are advised to incorporate ladder fuels in the surface fuel complex as previously suggested [7,51], even if this solution is only partially satisfactory because it implies custom fuel modeling or making an adjustment to the surface fireline intensity. Regarding *CFL*, the mean value observed when including only the fine live canopy was 1.19 kg/m^2 (sd = 0.28 kg/m^2) with a maximum of 1.78 kg/m^2; these values increased to 1.68 kg/m^2 (sd = 0.36 kg/m^2) and 2.51 kg/m^2, respectively, when adding the load provided by the needles and fine twigs of the dead branches that extended into the surface fuel layer to the fine live crown. Therefore, the important contribution of dead ladder fuel to the total available fuel load (mean and maximum values of 29.5% (sd = 3.2) and 36%, respectively, in this study) must be highlighted because it implies an increase of similar proportions in the heat per unit area released by a fire consuming all fine components. For example, according

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

to Byram [52] and considering the usual low net heat of combustion of 18,000 kJ/kg [5,40], the energy released by the crowns would increase from 21,420 kJ/m^2 to 30,240 kJ/m^2, which represents a 41.1% increase in fireline intensity. Our findings confirmed that these pine plantations did not have a homogeneous distribution of live and dead fine fuel in the canopy, similar to their Australian counterparts [40]. Instead, two clearly different fuel layers were present: a lower layer predominantly comprising dead fuels characterised by high flammability when dry enough and an upper layer predominantly comprising live fuels with a higher bulk density.

The goodness-of-fit statistics of the two equation systems developed indicated robust and accurate estimates, so these systems contributed to filling the gap on how to quantify dead ladder fuels and improve the estimates of potential heat release per unit and fireline intensity. Although both equation systems can be used for the same purpose of estimating dead ladder fuels load according to classes and their vertical distribution in the stand, their advantages and limitations must be considered. The use of the tree-level equation systems (Table 2) requires a large number of independent variables and the calculation is more complicated than the direct use of the stand-level system (Table 4). The process involves calculating the biomass of each tree, aggregating the biomass of all trees in the sample plot, and expressing the result relative to the unit area (ha). However, despite apparently poorer goodness-of-fit statistics, the tree-level system is more accurate because it is based on actual dead fuel data obtained from destructively sampled trees whereas the stand-level system (Table 4) is based on tree biomass values estimated by the system of equations at the individual tree level (Table 2). On the other hand, the stand-level system is simpler to apply because it only required a sample of trees to obtain representative mean values rather than the measurement of the total, dead crown initiation, and live crown initiation heights of all trees in the plot.

In any case, the use of either approach will basically depend on the required balance between the accuracy of the estimates to be obtained (higher accuracy with the individual-tree approach) and the cost that can be assumed in the field inventory (lower cost with the stand approach).

5. Conclusions

Accurate characterization of the load and vertical distribution of ladder fuels is essential for forest managers given the importance of this type of fuel as a surface-to-crown-fire transition factor by providing greater vertical fuel continuity. In addition, ladder fuels in unmanaged pine stands of species characterised by poor self-pruning such as the *Pinus radiata* considered here can greatly hinder firefighting efforts and safety by limiting mobility and visibility due to their high density. Both systems of models fitted in this study can be used to quantify the dead ladder fuels extending to near the ground in closed-canopy and unpruned pure and even-aged *P. radiata* stands. This information will allow forest managers to simulate how different pruning heights up to 6 m affect potential crown-fire hazards for a range of meteorological and fuel moisture scenarios as well as for different treatment alternatives for the woody debris generated (removal, mastication, or no management). These modelling systems should be used in combination with live *CFL* models for radiata pine (e.g., [12]) to estimate the total load of the fine fuel fraction in this type of stand. This will prevent underestimation of the available canopy fuel load as well as overestimation of the fuel strata gap and will thus prevent errors in assessing crown fire potential activity, including onset of crowning, type of crown fire, and the associated fire behaviour characteristics (fire-spread rate and fireline intensity).

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

Author Contributions: Conceptualization, C.A.-R., P.F. and A.D.R.-G.; methodology, C.A.-R., P.F., J.G.Á.G., S.A.-P. and A.D.R.-G.; software, J.G.Á.G.; formal analysis, C.A.-R. and J.G.Á.G.; investigation, C.A.-R., S.A.-P. and A.D.R.-G.; resources, C.A.-R., P.F., S.A.-P., J.G.Á.G. and A.D.R.-G.; data curation, C.A.-R. and A.D.R.-G.; writing—original draft preparation, C.A.-R., P.F., J.G.Á.G., S.A.-P. and A.D.R.-G.; supervision, A.D.R.-G.; project administration, A.D.R.-G.; funding acquisition, A.D.R.-G. All authors have read and agreed to the published version of the manuscript.

Funding: This research was funded by the projects GEPRIF (RTA2014-00011-c06-04) and VIS4FIRE (RTA 2017-0042-C05-05) of the Spanish Ministry of Economy, Industry, and Competitiveness; DIABOLO (GA 633464) of the European Union's H2020 research; UIDB/04033/2020 of the Portuguese Foundation for Science and Technology; and a pre-doctoral grant to the first author funded by the "Consellería de Educación, Universidade e Formación Profesional" and the "Consellería de Economía, Emprego e Industria" of the Galician Government and the EU operational program "FSE Galicia 2014–2020".

Institutional Review Board Statement: Not applicable.

Informed Consent Statement: Not applicable.

Data Availability Statement: Not applicable.

Acknowledgments: We are grateful to Mario López Fernández for his inestimable technical support in conducting all the field sampling tasks in the plot network.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Keane, R.E. *Wildland Fuel Fundamentals and Applications*; Springer International Publishing: New York, NY, USA, 2015.
2. Reardon, J. Ground Fuel. In *Encyclopedia of Wildfires and Wildland-Urban Interface (WUI) Fires*; Manzello, S.L., Ed.; Springer: Cham, Switzerland, 2020; pp. 1–8.
3. Van Wagner, C.E. Conditions for the start and spread of crown fire. *Can. J. For. Res.* **1977**, *7*, 23–34. [CrossRef]
4. Alexander, M.E.; Cruz, M.G. Crown fire dynamics in conifer forests. In *Synthesis of Knowledge of Extreme Fire Behavior: Volume I for Fire Managers*; Werth, P.A., Potter, B.E., Clements, C.B., Finney, M.A., Goodrick, S.L., Alexander, M.E., Cruz, M.G., Forthofer, J.A., McAllister, S.S., Eds.; USDA, Forest Service, Pacific Northwest Research Station: Corvallis, OR, USA, 2011; Volume PNW-GTR-854, pp. 107–144.
5. Cruz, M.G.; Alexander, M.E.; Fernandes, P.M. Development of a model system to predict wildfire behaviour in pine plantations. *Aust. For.* **2008**, *71*, 113–121. [CrossRef]
6. Sando, R.W.; Wick, C.H. *A Method of Evaluating Crown Fuels in Forest Stands*; USDA, Forest Service, Res. Pap. NC-84: St. Paul, MN, USA, 1972.
7. Scott, J.H.; Reinhardt, E.D. *Assessing Crown Fire Potential by Linking Models of Surface and Crown Fire Behavior*; USDA Forest Service, Rocky Mountain Research Station, Res. Pap. RMRS-RP-29: Fort Collins, CO, USA, 2001.
8. Stocks, B.J.; Alexander, M.E.; Wotton, B.M.; Stefner, C.N.; Flannigan, M.D.; Taylor, S.W.; Lavoie, N.; Mason, J.A.; Hartley, G.R.; Maffey, M.E.; et al. Crown fire behaviour in a northern jack pine—Black spruce forest. *Can. J. For. Res.* **2004**, *34*, 1548–1560. [CrossRef]
9. Keyser, T.; Smith, F.W. Influence of crown biomass estimators and distribution on canopy fuel characteristics in ponderosa pine stands of the Black Hills. *For. Sci.* **2010**, *56*, 156–165.
10. Cruz, M.; Alexander, M. Assessing crown fire potential in coniferous forests of western North America: A critique of current approaches and recent simulation studies. *Int. J. Wildland Fire* **2010**, *19*, 377–398. [CrossRef]
11. Ruiz-González, A.D.; Álvarez-González, J.G. Canopy bulk density and canopy base height equations for assessing crown fire hazard in *Pinus radiata* plantations. *Can. J. For. Res.* **2011**, *41*, 839–850. [CrossRef]
12. Fernández-Alonso, J.M.; Alberdi, I.; Álvarez-González, J.G.; Vega, J.A.; Cañellas, I.; Ruiz-González, A.D. Canopy fuel characteristics in relation to crown fire potential in pine stands: Analysis, modelling and classification. *Eur. J. For. Res.* **2013**, *132*, 363–377. [CrossRef]
13. Hevia, A.; Crabiffosse, A.; Majada, J.; Álvarez-González, J.G.; Ruiz-González, A.D. Modelo de distribución de la carga de combustibles finos en el dosel de copas de rodales regulares de *Pinus pinaster*: Efecto de claras combinadas con podas. *Cuad. La SECF* **2012**, *34*, 123–133.
14. Gómez-Vázquez, I.; Crecente-Campo, F.; Diéguez-Aranda, U.; Castedo-Dorado, F. Modelling canopy fuel variables in *Pinus pinaster* Ait. and *Pinus radiata* D. Don stands in northwestern Spain. *Ann. For. Sci.* **2012**, *70*, 161–172. [CrossRef]
15. Ruiz-González, A.D.; Castedo-Dorado, F.; Vega, J.A.; Jiménez, E.; Fernández-Alonso, J.M.; Álvarez-González, J.G. Modelling canopy fuel dynamics of maritime pine stands in north-west Spain. *Int. J. Wildland Fire* **2015**, *24*, 92–102. [CrossRef]
16. Arellano-Pérez, S.; Álvarez-González, J.G.; Vega Hidalgo, J.A.; Ruiz González, A.D. Modelos de estimación de la distribución vertical de combustibles finos de copa en masas de pinar a partir de datos del IV Inventario Forestal Nacional. In Proceedings of the VII Congreso Forestal Español: "Gestión Del Monte: Servicios Ambientales y Bioeconomía", Plasencia, Spain, 26–30 June 2017.
17. Hevia, A.; Álvarez-González, J.G.; Ruiz-Fernández, E.; Ruiz-González, A.D.; Majada, J.; González-Ferreiro, E. Modelling canopy fuel and forest stand variables and characterizing the influence of thinning in the stand structure using airborne LiDAR. *Rev. Teledetección* **2016**, *45*, 41–55. [CrossRef]

18. González-Ferreiro, E.; Arellano-Pérez, S.; Castedo-Dorado, F.; Hevia, A.; Vega, J.A.; Vega-Nieva, D.; Álvarez-González, J.G.; Ruiz-González, A.D. Modelling the vertical distribution of canopy fuel load using national forest inventory and low-density airbone laser scanning data. *PLoS ONE* **2017**, *12*, e0176114. [CrossRef] [PubMed]
19. Alberdi, I.; Vallejo, R.; Álvarez-González, J.G.; Condés, S.; González-Ferreiro, E.; Guerrero, S.; Hernández, L.; Martínez-Jauregui, M.; Montes, F.; Oliveira, N.; et al. The multi-objective Spanish National Forest Inventory. *For. Syst.* **2017**, *26*, e04S. [CrossRef]
20. Fidalgo-González, L.; Arellano-Pérez, S.; Castedo-Dorado, F.; Ruiz-González, A.D.; González-Ferreiro, E. Estimación de la distribución vertical de combustibles finos del dosel de copas en masas de *Pinus sylvestris* empleando datos LiDAR de baja densidad. *Rev. Teledetección* **2019**, *53*, 1–16. [CrossRef]
21. Arellano-Pérez, S.; Castedo-Dorado, F.; López-Sánchez, C.A.; González-Ferreiro, E.; Yang, Z.; Díaz-Varela, R.A.; Álvarez-González, J.G.; Vega, J.A.; Ruiz-González, A.D. Potential of Sentinel-2A data to model surface and canopy fuel characteristics in relation to crown fire hazard. *Remote Sens.* **2018**, *10*, 1645. [CrossRef]
22. Finney, M.A. An overview of FlamMap fire modeling capabilities. In *Fuels Management-How to Measure Success: Conference Proceedings*; Andrews, P.L., Butler, B.W., Eds.; USDA, Forest Service, Rocky Mountain Research Station: Fort Collins, CO, USA, 2006; Volume 41, pp. 213–220.
23. Cruz, M.G.; Alexander, M.E.; Wakimoto, R.H. Modeling the likelihood of crown fire occurrence in conifer forest stands. *For. Sci.* **2004**, *50*, 640–658.
24. Arellano-Pérez, S.; Vega, J.A.; Ruíz-González, A.D.; Arellano, A.; Álvarez-González, J.G.; Vega-Nieva, D.J.; Pérez, E. *Foto-guía de Combustibles Forestales de Galicia y Comportamiento del Fuego Asociado*; Andavira: Santiago de Compostela, Spain, 2017.
25. Vega, J.A.; Arellano-Pérez, S.; Álvarez-González, J.G.; Fernández, C.; Jiménez, E.; Fernández-Alonso, J.M.; Vega-Nieva, D.J.; Briones-Herrera, C.; Alonso-Rego, C.; Fontúrbel, T.; et al. Modelling aboveground biomass and fuel load components at stand level in shrub communities in NW Spain. *For. Ecol. Manag.* **2022**, *505*, 119926. [CrossRef]
26. Alonso-Rego, C.; Arellano-Pérez, S.; Cabo, C.; Ordoñez, C.; Álvarez-González, J.G.; Díaz-Varela, R.A.; Ruiz-González, A.D. Estimating fuel loads and structural characteristics of shrub communities by using terrestrial laser scanning. *Remote Sens.* **2020**, *12*, 3704. [CrossRef]
27. Alonso-Rego, C.; Arellano-Pérez, S.; Guerra-Hernández, J.; Molina-Valero, J.A.; Martínez-Calvo, A.; Pérez-Cruzado, C.; Castedo-Dorado, F.; González-Ferreiro, E.; Álvarez-González, J.G.; Ruiz-González, A.D. Estimating Stand and Fire-Related Surface and Canopy Fuel Variables in Pine Stands Using Low-Density Airborne and Single-Scan Terrestrial Laser Scanning Data. *Remote Sens.* **2021**, *13*, 5170. [CrossRef]
28. Vega, J.A. Efectos del Fuego Prescrito Sobre el Suelo en Pinares de *Pinus pinaster* Ait. de Galicia. Ph.D. Thesis, Universidad Politécnica de Madrid, Madrid, Spain, 2001.
29. Fernandes, P.M.; Rigolot, E. The fire ecology and management of maritime pine (*Pinus pinaster* Ait.). *For. Ecol. Manag.* **2007**, *241*, 1–13. [CrossRef]
30. MARM. *Cuarto Inventario Forestal Nacional. Galicia*; Ministerio de Medio Ambiente y Medio Rural y Marino: Madrid, Spain, 2011.
31. DGCN. *Tercer Inventario Forestal Nacional 1997–2006: Galicia*; Ministerio de Medio Ambiente: Madrid, Spain, 2000.
32. Consellería del Medio Rural. ORDEN de 9 de Febrero de 2021. Available online: https://www.xunta.gal/dog/Publicados/2021/20210226/AnuncioG0426-110221-0005_es.html (accessed on 12 April 2022).
33. Keeley, J.E.; Zedler, P.H. Evolution of life histories in *Pinus*. In *Ecology and Biogeography of Pinus*; Richardson, D.M., Ed.; Cambridge University Press: Cambridge, UK, 1998; pp. 219–250.
34. Menning, K.M.; Stephens, S.L. Fire climbing in the forest: A semiqualitative, semiquantitative approach to assessing ladder fuel hazards. *West. J. Appl. For.* **2007**, *22*, 88–93. [CrossRef]
35. Hirsch, K.; Martell, D. A review of initial attack fire crew productivity and effectiveness. *Int. J. Wildland Fire* **1996**, *6*, 199–215. [CrossRef]
36. Kramer, H.A.; Collins, B.M.; Lake, F.K.; Jakubowski, M.K.; Stephens, S.L.; Kelly, M. Estimating ladder fuels: A new approach combining field photography with LiDAR. *Remote Sens.* **2016**, *8*, 766. [CrossRef]
37. Norgaard, K.M. The Politics of fire and the social impacts of fire exclusion on the Klamath. *Humboldt J. Soc. Relat.* **2014**, *36*, 77–101.
38. Balboa-Murias, M.A.; Rodríguez-Soalleiro, R.; Merino, A.; Álvarez-González, J.G. Temporal variations and distribution of carbon stocks in aboveground biomass of radiata pine and maritime pine pure stands under different silvicultural alternatives. *For. Ecol. Manag.* **2006**, *237*, 29–38. [CrossRef]
39. Plucinski, M.P.; Sullivan, A.L.; Rucinski, C.J.; Prakash, M. Improving the reliability and utility of operational bushfire behaviour predictions in australian vegetation. *Environ. Model Softw.* **2017**, *91*, 1–12. [CrossRef]
40. Cruz, M.G.; Alexander, M.E.; Plucinski, M.P. The effect of silvicultural treatments on fire behaviour potential in radiata pine plantations of South Australia. *For. Ecol. Manag.* **2017**, *397*, 27–38. [CrossRef]
41. SAS Institute Inc. *SAS/ETS®9.1 User's Guide*; SAS Institute Inc.: Cary, NC, USA, 2004.
42. Dieguez-Aranda, U.; Rojo-Alboreca, A.; Castedo-Dorado, F.; Álvarez-González, J.G.; Barrio-Anta, M.; Crecente-Campo, F.; González-González, J.M.; Pérez-Cruzado, C.; Rodriguez-Soalleiro, R.; López-Sánchez, C.A.; et al. *Herramientas Selvícolas para la Gestión Forestal Sostenible en Galicia*; Consellería do Medio Rural, Xunta de Galicia: Santiago de Compostela, Spain, 2009.
43. Myers, R.H. *Classical and Modern Regression with Applications*, 2nd ed.; Duxbury Press: Belmont, CA, USA, 1990.
44. White, H.A. Heteroskedasticity-consistent covariance matrix estimator and a direct test for heteroskedasticity. *Econometrica* **1980**, *48*, 817–838. [CrossRef]

45. Cailliez, F. *Estimación del Volumen Forestal y Predicción del Rendimiento*; FAO: Rome, Italy, 1980.
46. Harvey, A.C. Estimating regression models with multiplicative heteroscedasticity. *Econometrica* **1976**, *44*, 461–465. [CrossRef]
47. Diéguez-Aranda, U.; Castedo-Dorado, F.; Álvarez-González, J.G.; Rojo, A. Compatible taper function for Scots pine plantations in northwestern Spain. *Can. J. For. Res.* **2006**, *36*, 1190–1205. [CrossRef]
48. Hevia, A.; Crabiffosse, A.; Álvarez-González, J.G.; Ruiz-González, A.D.; Majada, J. Novel approach to assessing residual biomass from pruning: A case study in Atlantic *Pinus pinaster* Ait. timber forests. *Renew. Energ.* **2017**, *107*, 620–628. [CrossRef]
49. Mayer, D.G.; Butler, D.G. Statistical validation. *Ecol. Model.* **1993**, *68*, 21–32. [CrossRef]
50. Agee, J.K. The influence of forest structure on fire behavior. In Proceedings of the 17th Annual Forest Vegetation Management Conference, Sacramento, CA, USA, 16–18 January 1996.
51. Hall, S.A.; Burke, I.C. Considerations for characterizing fuels as inputs for fire behavior models. *For. Ecol. Manag.* **2006**, *227*, 102–114. [CrossRef]
52. Byram, G.M. Combustion of forest fuels. In *Forest Fire: Control and Use*; Davis, K.P., Ed.; McGraw-Hill: New York, NY, USA, 1959; pp. 61–89.

USC UNIVERSIDADE DE SANTIAGO DE COMPOSTELA

USC
UNIVERSIDADE
DE SANTIAGO
DE COMPOSTELA

En este documento de tesis se presentan los resultados de un estudio sobre la utilización de diferentes metodologías para la estimación de cargas y estructura vertical de los combustibles forestales incluyendo matorral desarbolado y sotobosque, combustibles de escalera y del dosel de copas en pinares. Los modelos obtenidos se basan en datos LiDAR aéreo (ALS) y terrestre (TLS) e inventarios de campo tradicionales.