

Seminario: Las nuevas tecnologías aplicadas al conocimiento de los ecosistemas forestales - IFN5

Valsaín, Segovia, 5-7 de junio de 2024



Experiencias LiDAR multiplataforma para la estimación de variables forestales: SLS Gedi, ALS PNOA, UAV, HMLS

Juan de la Riva^{1,3}, Darío Domingo^{1,2,3}, Raúl Hoffrén^{1,2}, Teresa Lamelas^{1,3,4}, Antonio Montealegre^{1,3,4}

¹ Grupo de investigación GEOFOREST, Instituto Universitario de Ciencias Ambientales (Universidad de Zaragoza) – “Team LiDAR”

² Grupo de investigación CAMBIUM, iuFOR-EFAB (Universidad de Valladolid)

³ Departamento de Geografía y Ordenación del Territorio (Universidad de Zaragoza)

⁴ Centro Universitario de la Defensa (Academia General Militar)

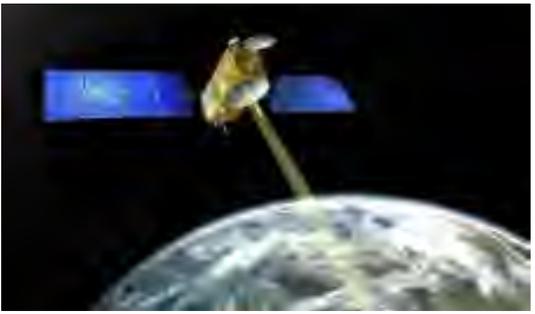
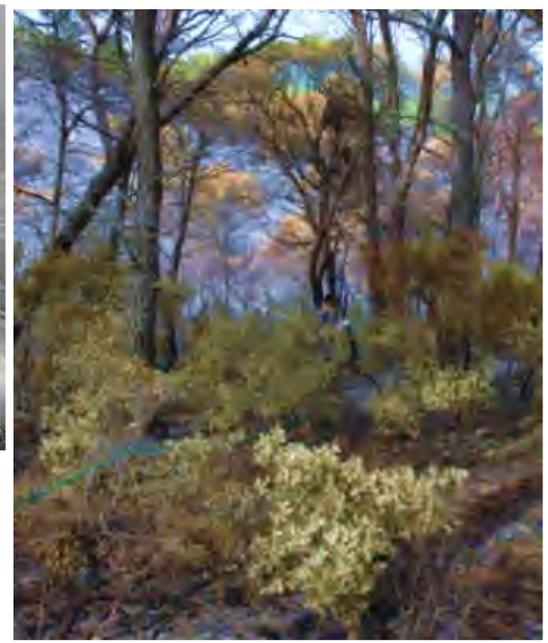
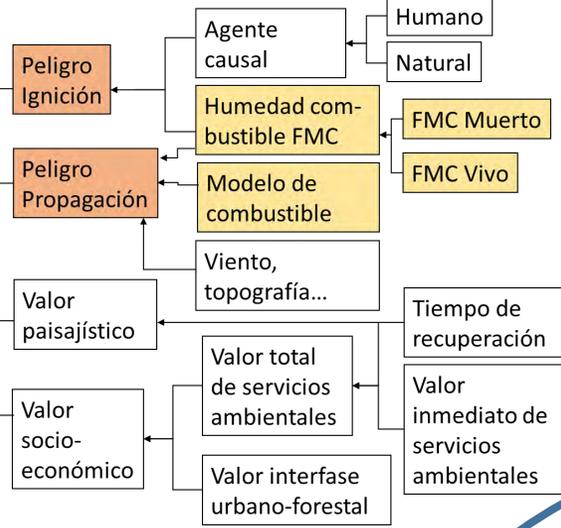
- **Introducción**
- **Estimación de variables forestales**
 - **Áreas de estudio**
 - **Tipos de plataformas LiDAR**
 - **Experiencias con LiDAR PNOA**
 - **Variables forestales**
 - **Transferibilidad**
- **Tipos de combustible Prometheus**
- **Actividad por plataformas LiDAR**
 - **Aeroportado PNOA**
 - **PNOA – SAR – Spot**
 - **PNOA – Sentinel**
 - **PNOA – DART**
 - **PNOA - Fotogrametría**
 - **Satélite GEDI**
 - **Dron LiDAR**
 - **Terrestre HMLS**
- **Conclusión**

Experiencias LiDAR multiplataforma para la estimación de variables forestales: SLS Gedi, ALS PNOA, UAV, HMLS

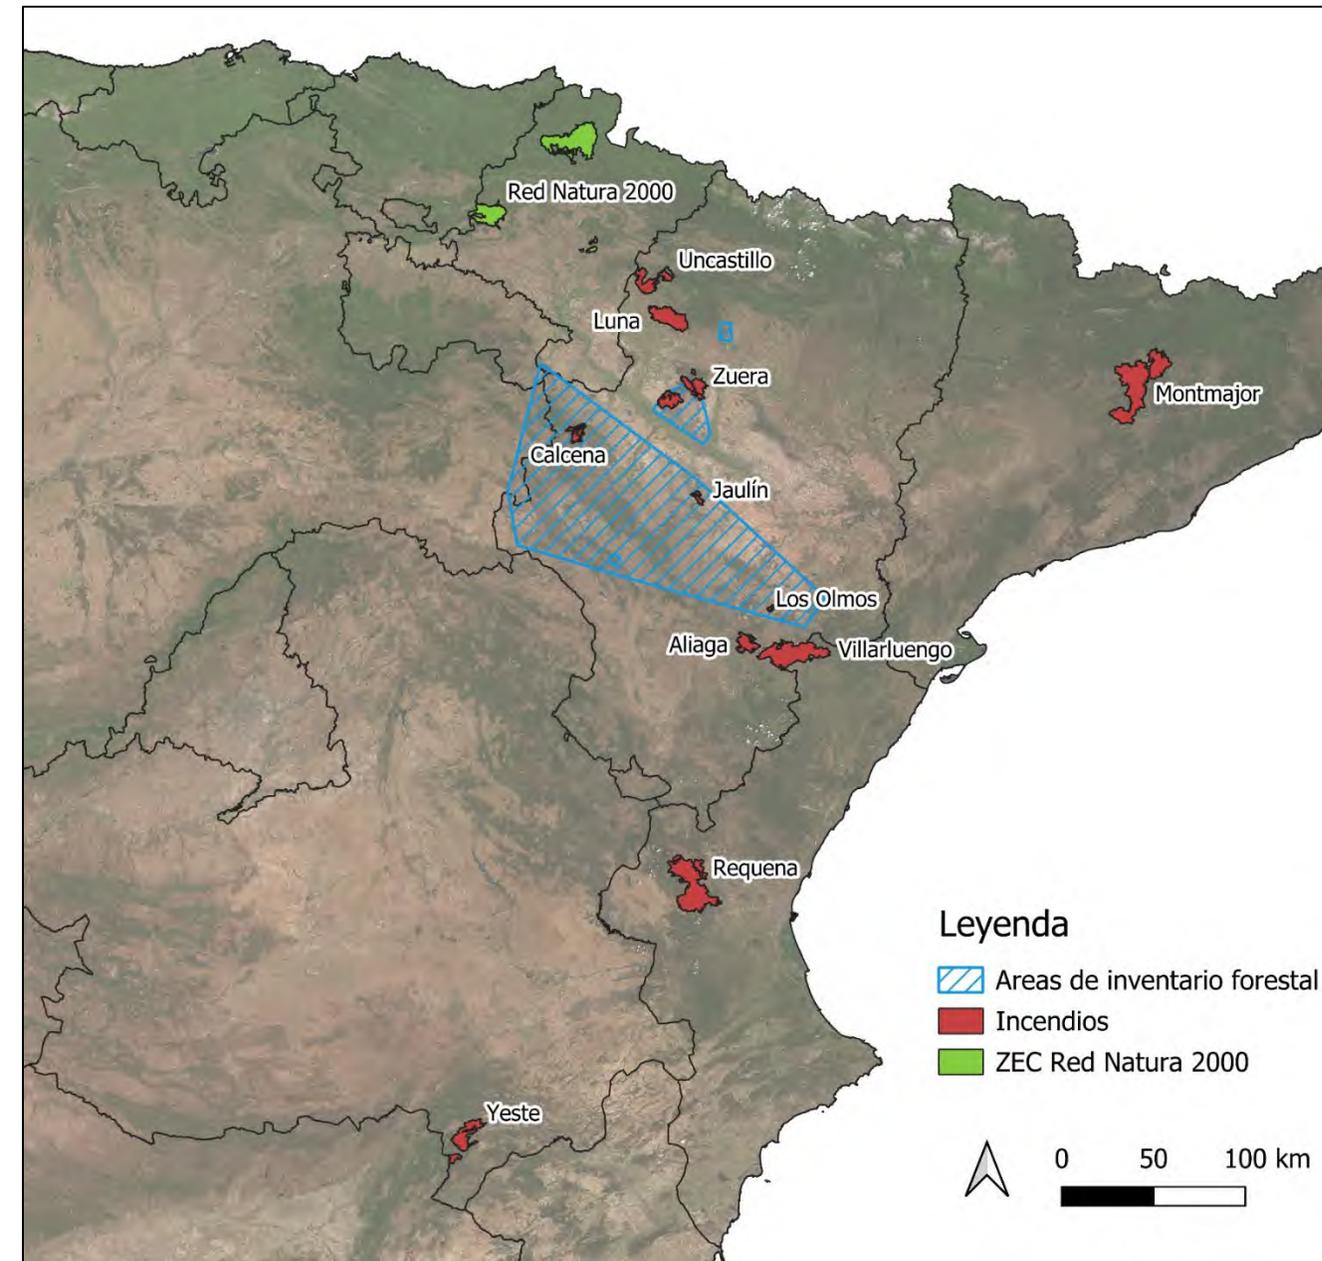
Peligro integrado

Riesgo

Valor integrado



Áreas de estudio



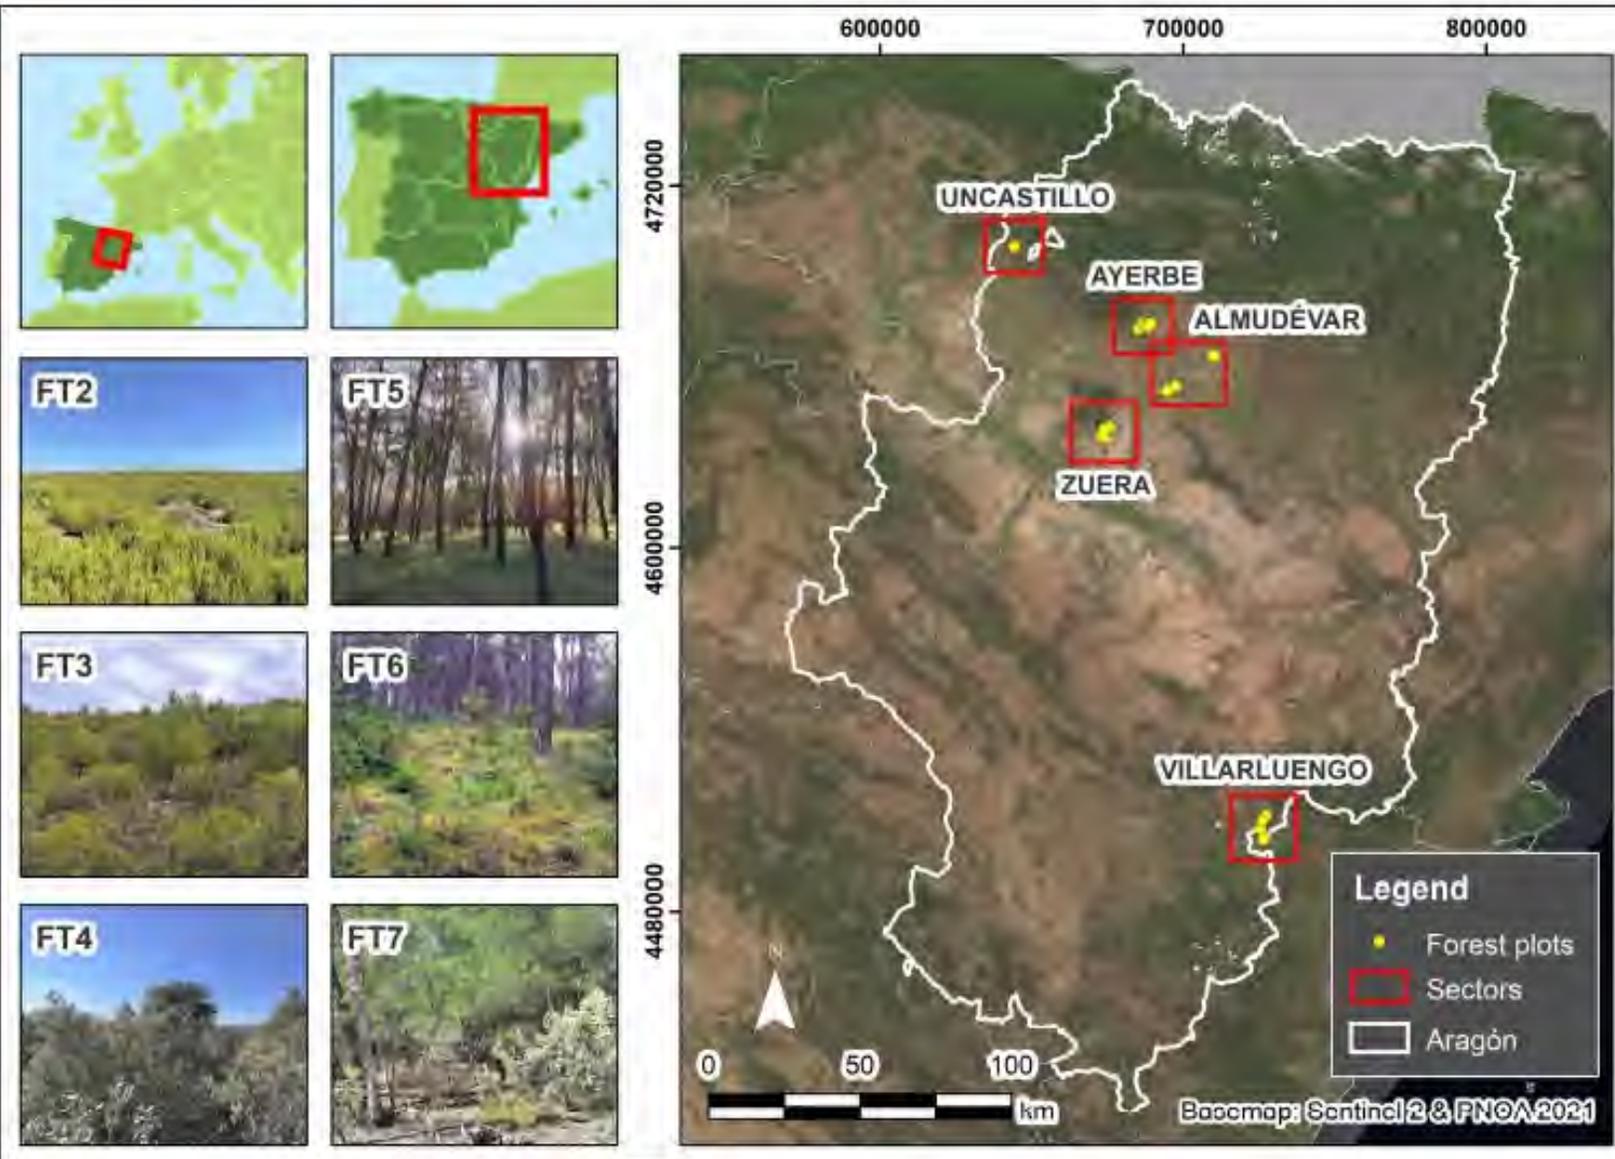
Información de campo y áreas de estudio:

- 192 (51 de föra) parcelas de inventario *Pinus halepensis*
- 11 áreas incendiadas:
 - 136 parcelas inventario forestal, de vegetación y modelo combustible
 - 169 parcelas CBI
- 3 espacios Red Natura 2000

Cartografía de variables dasométricas:

- Áreas objeto estudio
- Masas *Pinus halepensis* Aragón (e.g.: biomasa residual)

Áreas de estudio



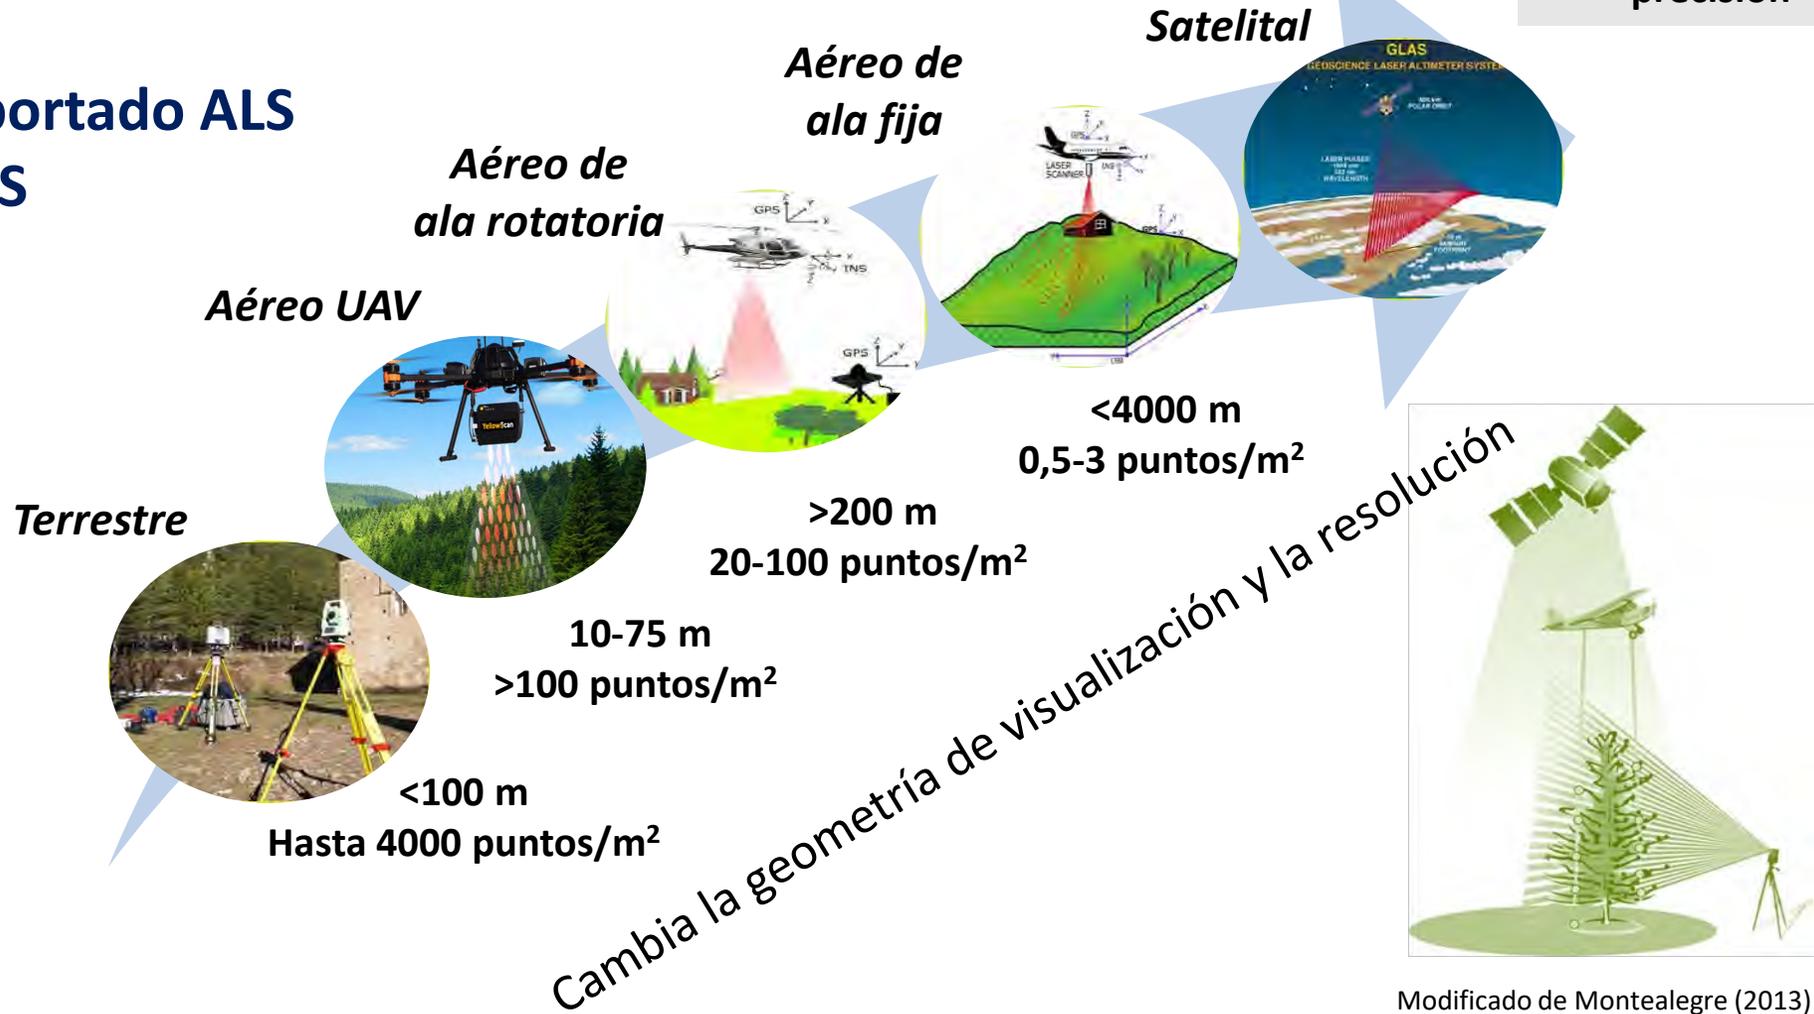
Información de dron y láser terrestre en masas de *P. halepensis*:

- 43 parcelas HMLS
- 82 parcelas con nubes de puntos fotogramétricas, datos RGB y multispectrales
- 73 parcelas CON nubes de puntos LiDAR UAV

Tipos de plataformas LiDAR

- Terrestre TLS
- Terrestre móvil MLS
- UAV
- Aerotransportado ALS
- Satelital SLS

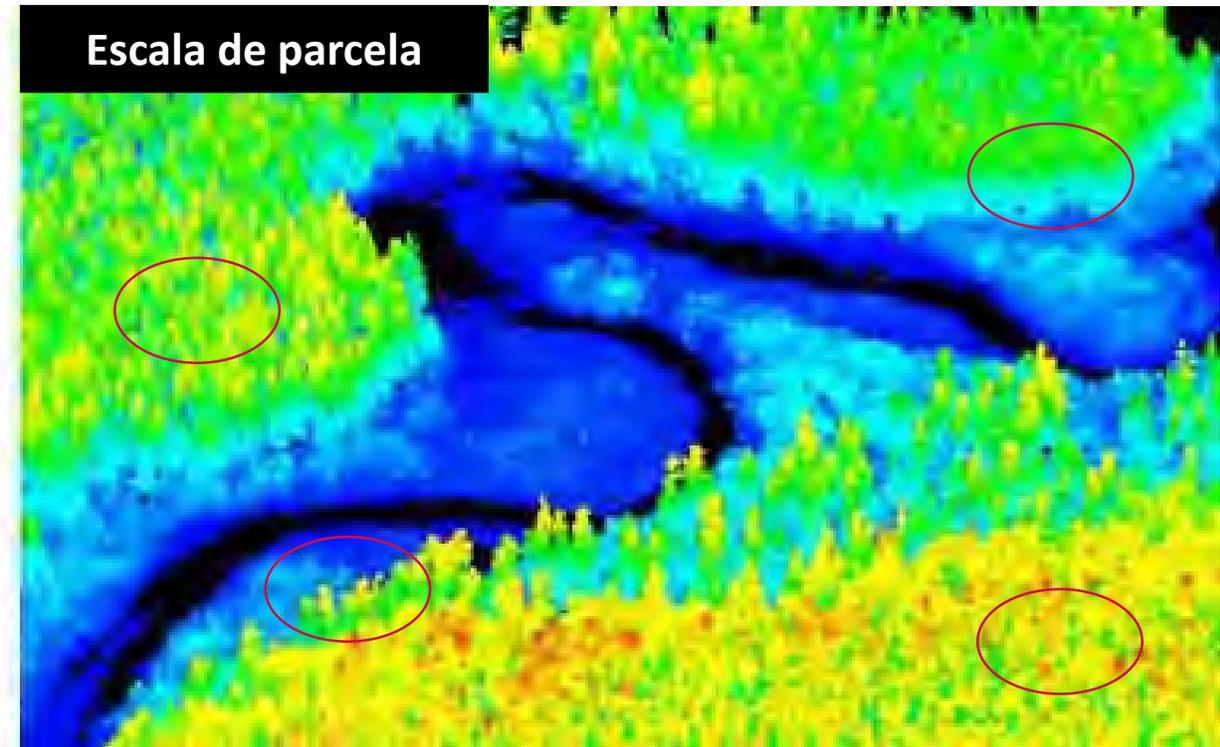
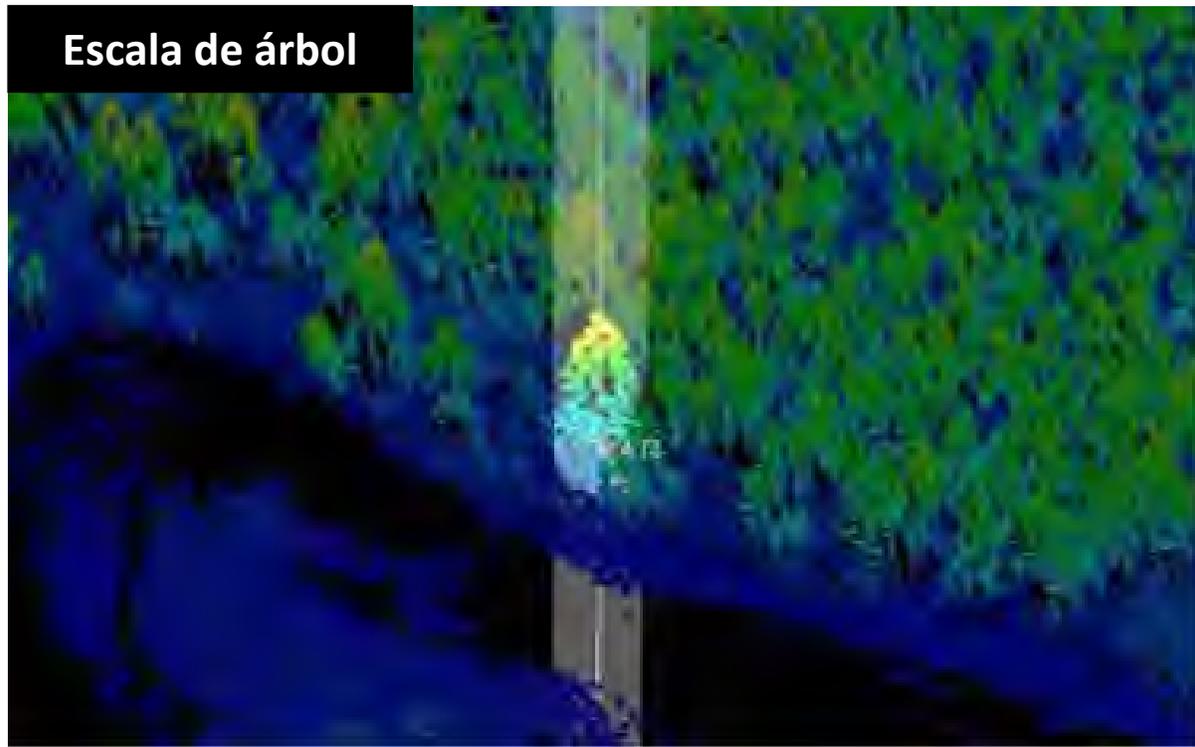
Mayor distancia al objeto y menor escala de detalle y precisión



Menor distancia al objeto y mayor escala de detalle y precisión

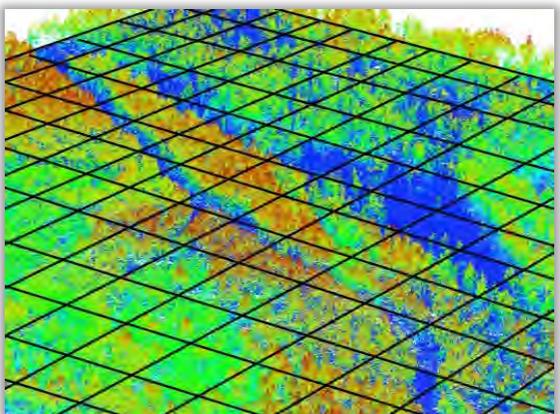
Extracción de información de las nubes de puntos LiDAR

- 1) **Escala de árbol:** localización de árboles individuales y obtención de atributos de árbol (por ejemplo, altura máxima del árbol, área de la copa, área basal ...)
- 2) **Escala de parcela o área:** los atributos se estiman sobre un área definida (cuadrada, rectangular o circular). Por ejemplo, altura máxima de la parcela, área basal, percentiles de altura, etc.

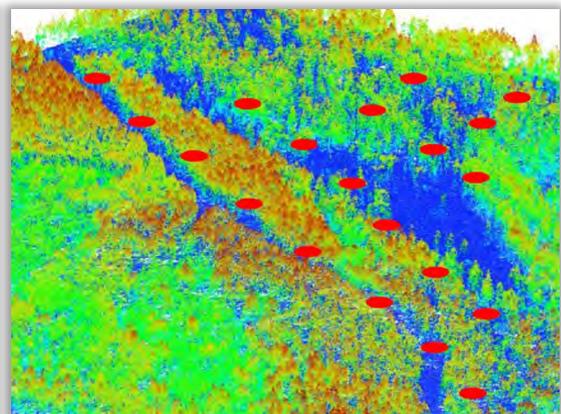


Extracción de información de las nubes de puntos LiDAR

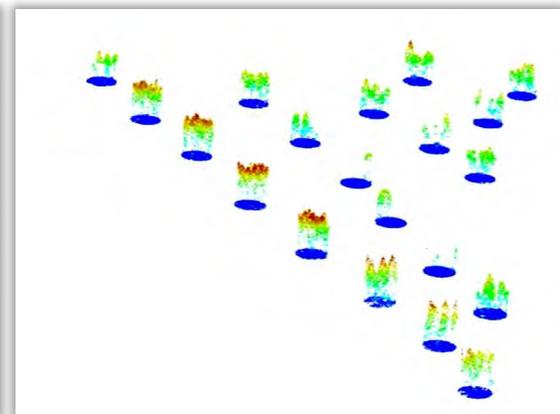
Tooke et al. (2014)



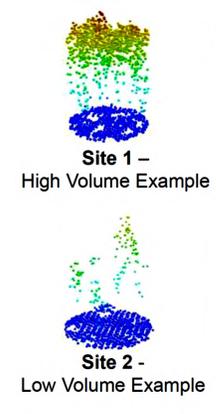
A) "Resumir" los datos LiDAR en un ráster



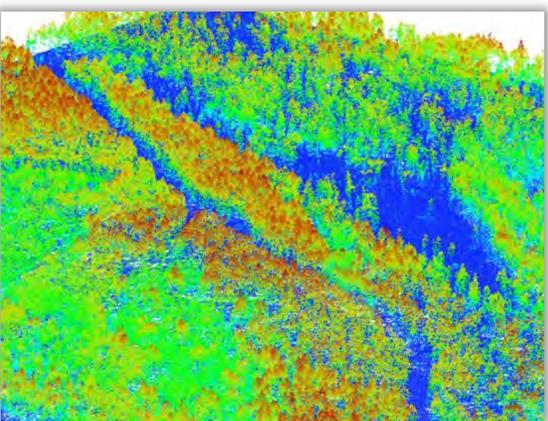
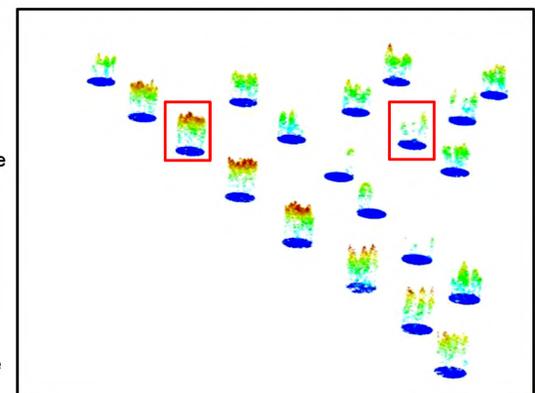
B) Seleccionar parcelas de muestreo



C) Extracción de datos de cada parcela



D) Analizar las métricas y establecer relaciones estadísticas



Nube de puntos original

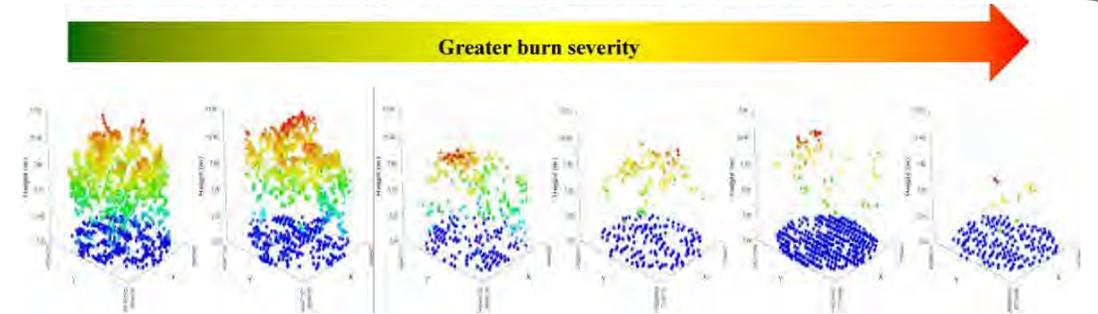
Métricas LiDAR	Características
Percentiles (P), altura mínima, máxima, media y moda.	Relacionadas directamente con la altura del dosel.
Desviación típica (SD), coeficiente de variación (CV), rango intercuartílico (IQ), asimetría y curtosis.	Caracterizan la variabilidad , dispersión y forma de la distribución de las alturas del dosel.
Porcentajes de primeros o todos los retornos sobre un umbral de altura.	Relacionadas con la densidad y cobertura del dosel.

Experiencias con LiDAR- PNOA

Estimar severidad de un incendio

<https://doi.org/10.3390/rs6054240>

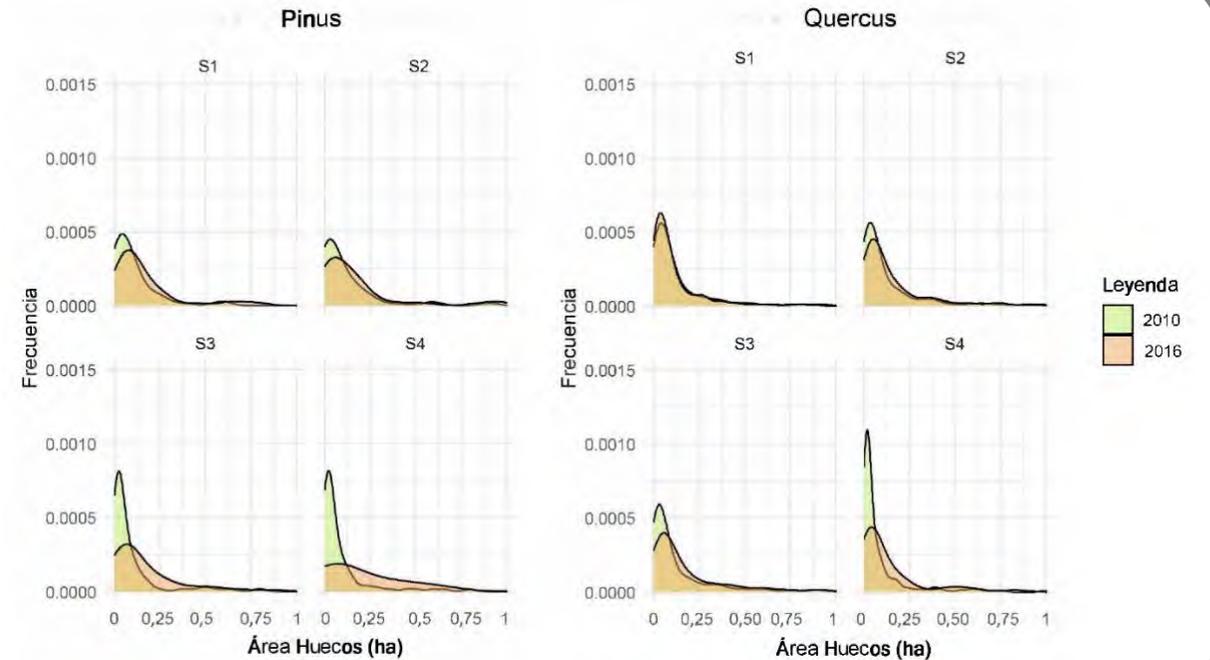
- Regresión logística: CBI vs variables LiDAR
- Precisión: 85,5%



Caracterizar cambios estructurales en áreas incendiadas

<https://doi.org/10.1080/15481603.2020.1738060>;
<https://doi.org/10.7818/ECOS.2103>

- Clasificación: quemado vs no quemado (89%); fecha incendio (69%); incendio antiguo vs reciente (75%)
- Alta correlación severidad vs descenso densidad dosel (encinar)
- Alta correlación severidad vs descenso altura y variabilidad (pinar)



Clasificar el estado de conservación en robledales

<https://doi.org/10.3390/rs15030710>

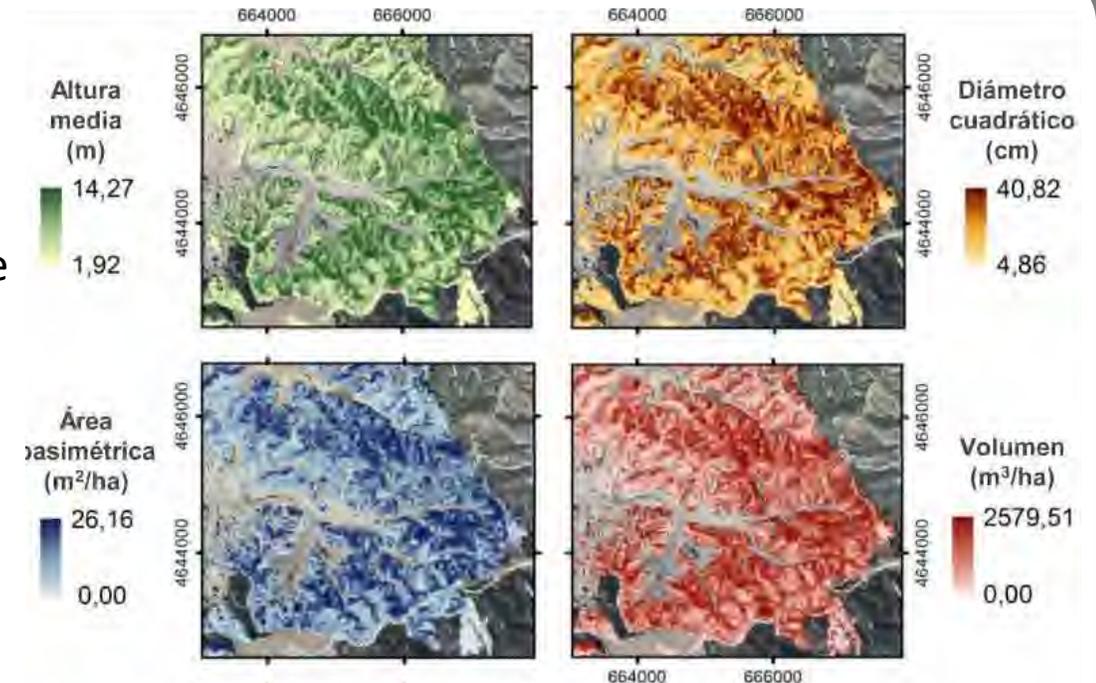
- Métricas LiDAR. RF (76% a 88%) masas de quercus
- Sentinel 2 no mejora las clasificaciones



Estimación de variables dasométricas

<https://doi.org/10.1093/forestry/cpw008>

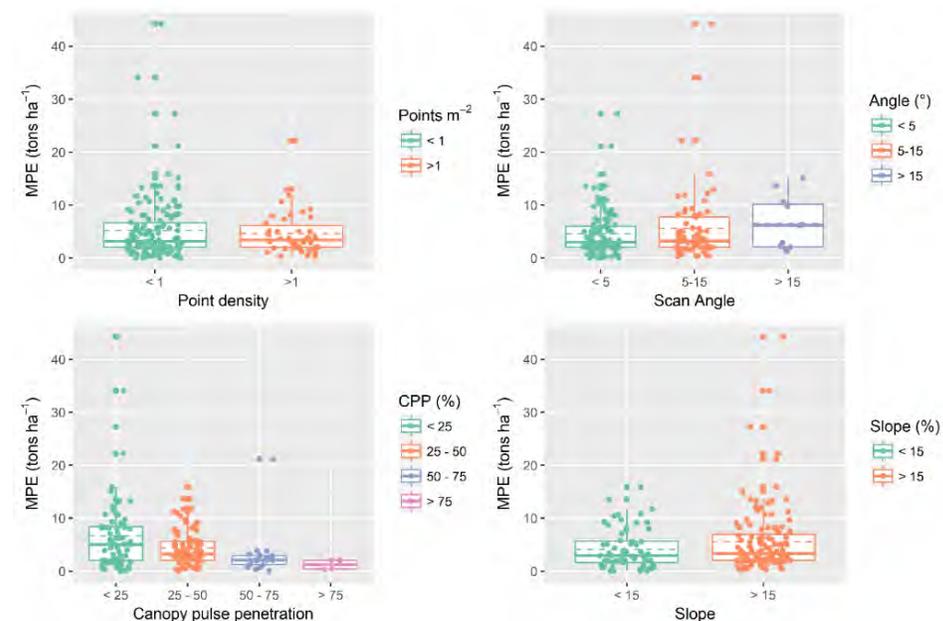
- Regresión lineal multivariante
- Hm (0,87 R²), Dg (0,84 R²), G (0,89 R²), V (0,89 R²), N (0,48 R²), CR (0,60 R²)



Estimación de biomasa total y biomasa residual

(<https://doi.org/10.3390/f9040158> ;
<https://doi.org/10.1080/15481603.2019.1641653>)

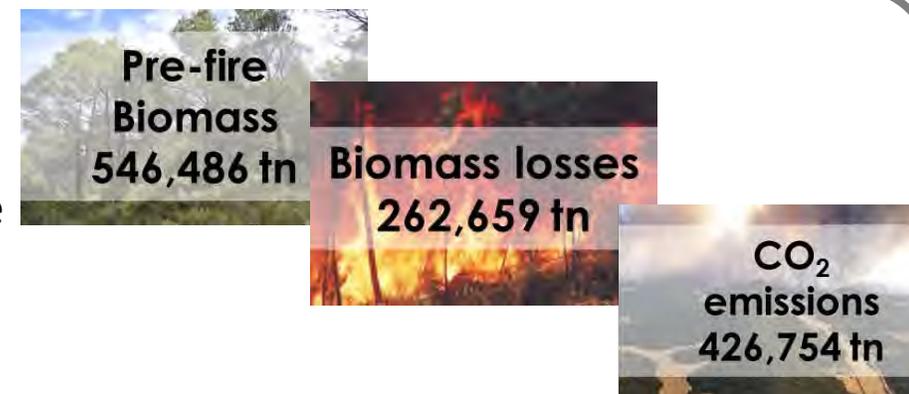
- BT: selección todos los subconjuntos + regresión lineal (0,87 R²; 19,21 %RMSE). 83 parcelas.
- BR: spearman + SVM (0,82 R²; 26,38 %RMSE). 192 parcelas.



Pérdidas de biomasa y emisiones de CO₂ en incendio

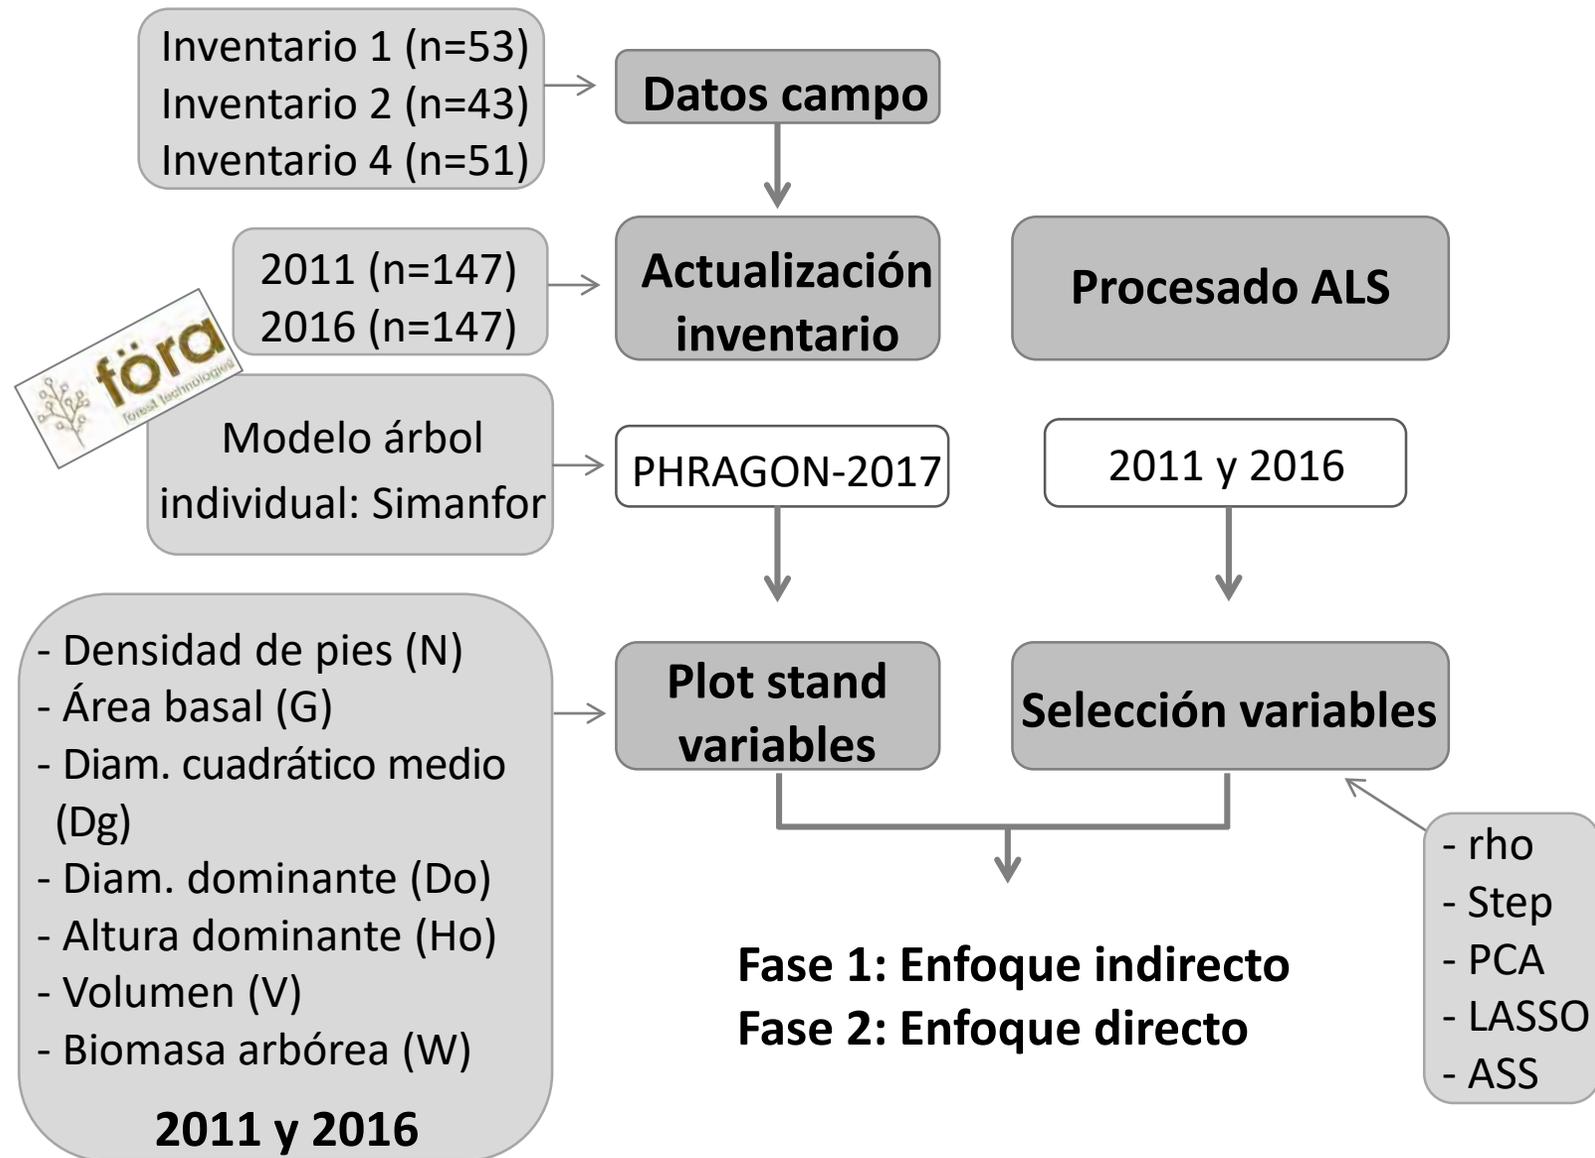
(<https://doi.org/10.1080/22797254.2017.1336067>;
<https://doi.org/10.1080/15481603.2017.1320863>)

- Biomasa prefuego: regresión lineal (0,88 R²; 11,08 %RMSE).
- Biomasa perdida (dNBR y factores de eficiencia de combustión)
- Carbono y emisiones de CO₂

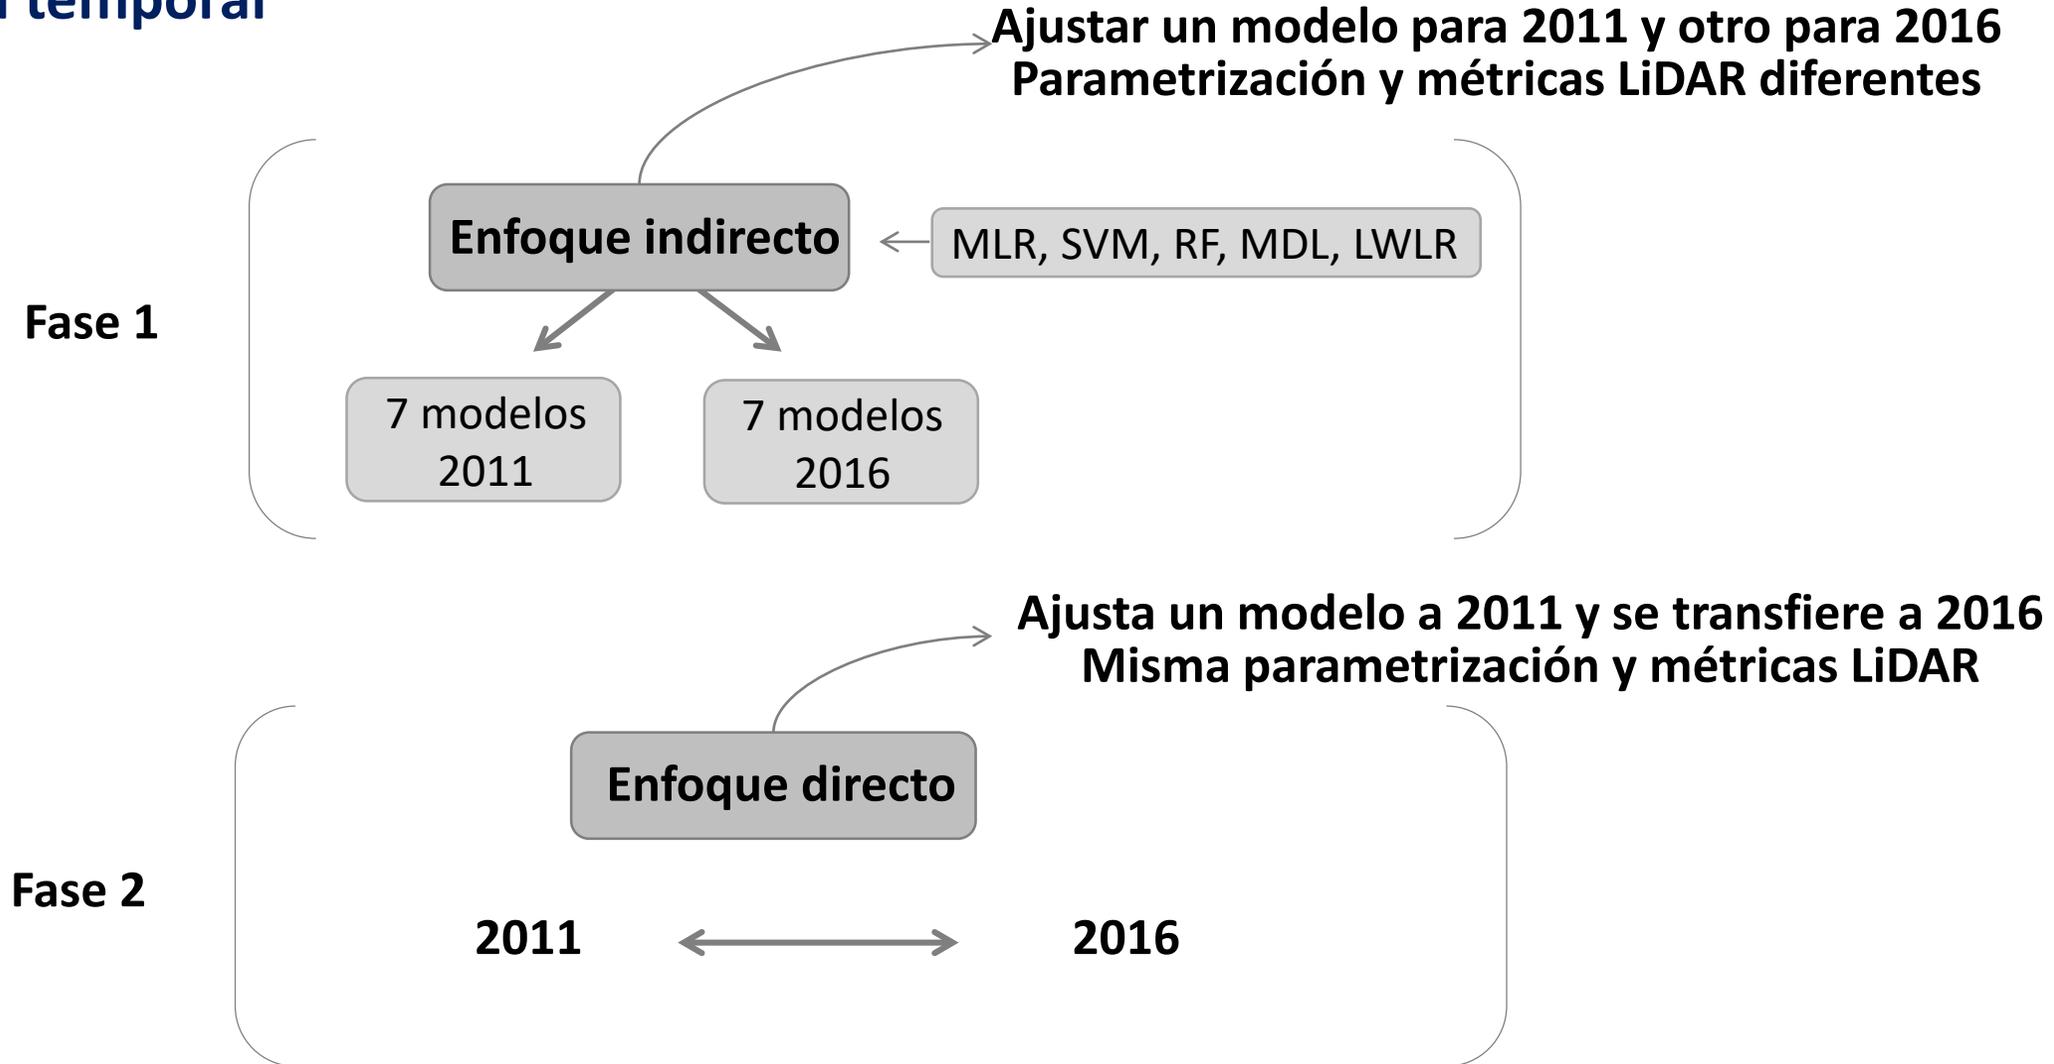


Transferibilidad temporal

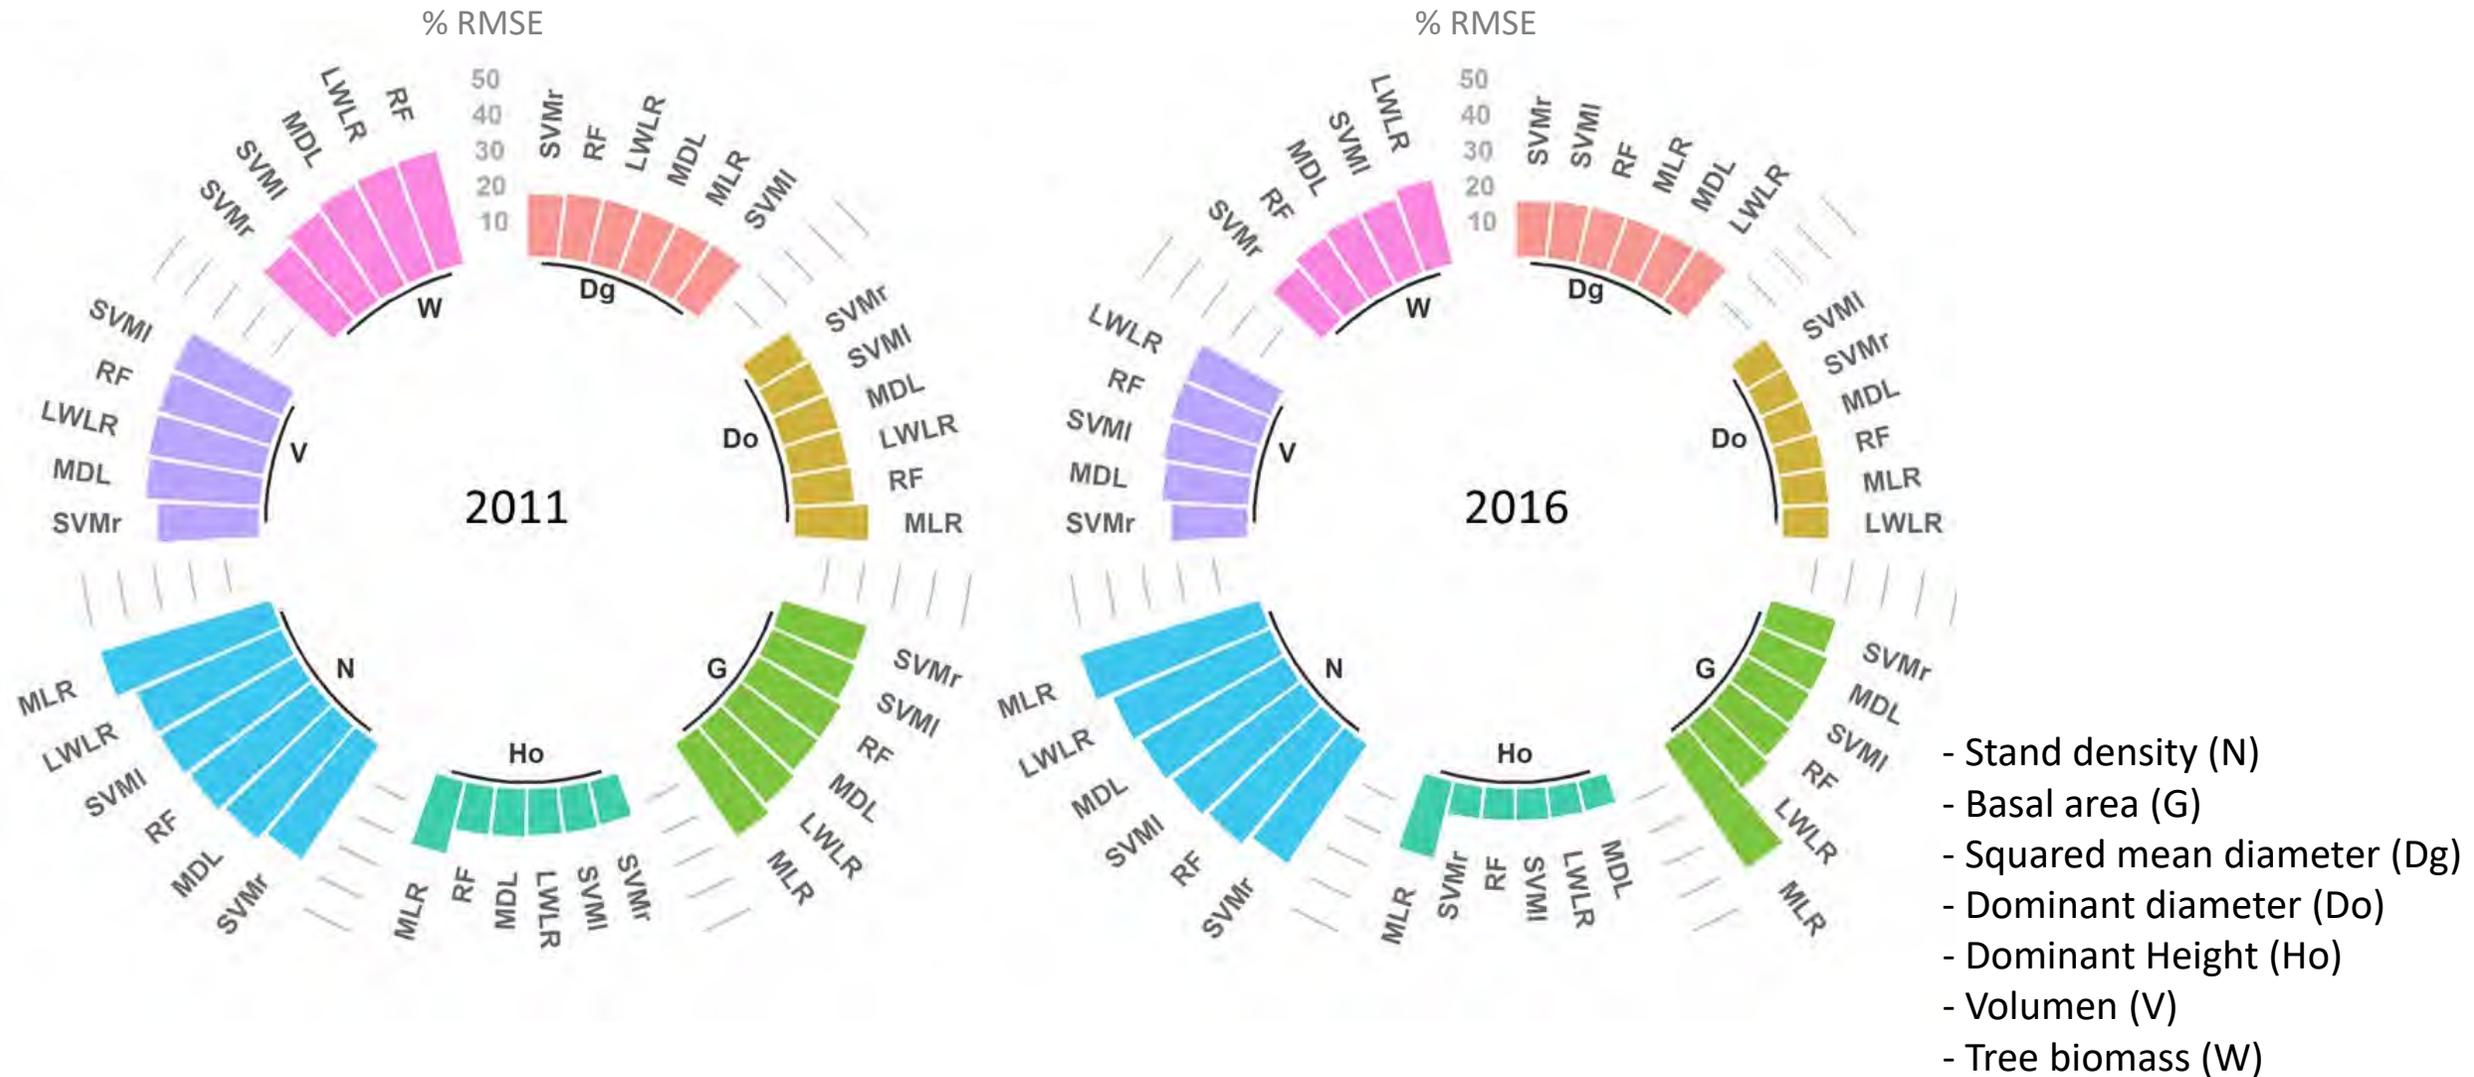
- 1) Evaluar la transferibilidad temporal de modelos comparando el **enfoque directo** y el **indirecto**, para predecir 7 variables forestales usando datos LiDAR multi-temporales.
- 2) Actualización de datos de inventario al año LiDAR usando **modelos de crecimiento de árbol individual**.



Transferibilidad temporal



Enfoque indirecto

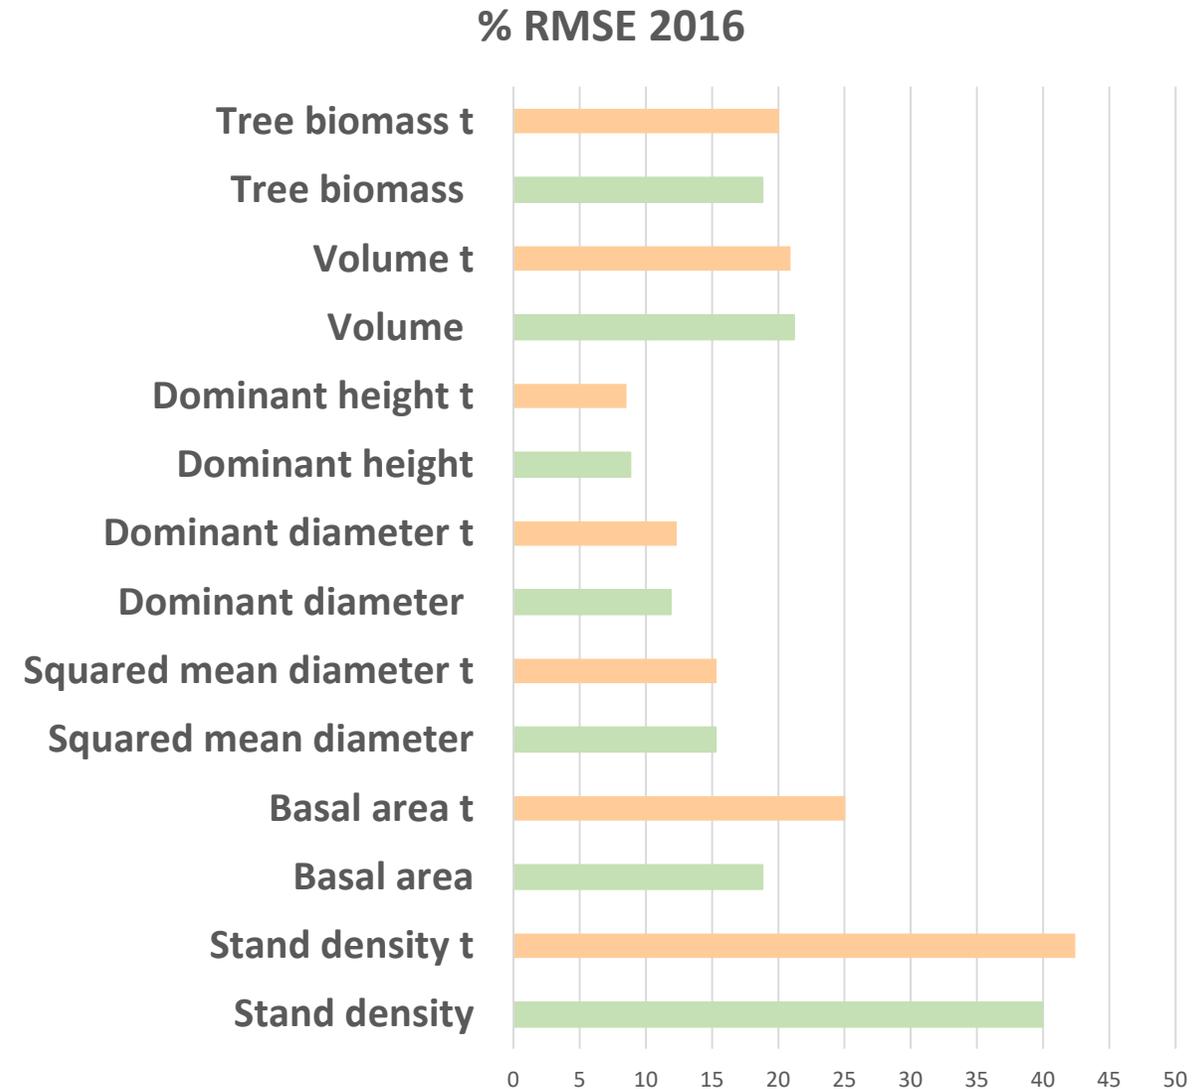


- Stand density (N)
- Basal area (G)
- Squared mean diameter (Dg)
- Dominant diameter (Do)
- Dominant Height (Ho)
- Volumn (V)
- Tree biomass (W)

Transferibilidad temporal

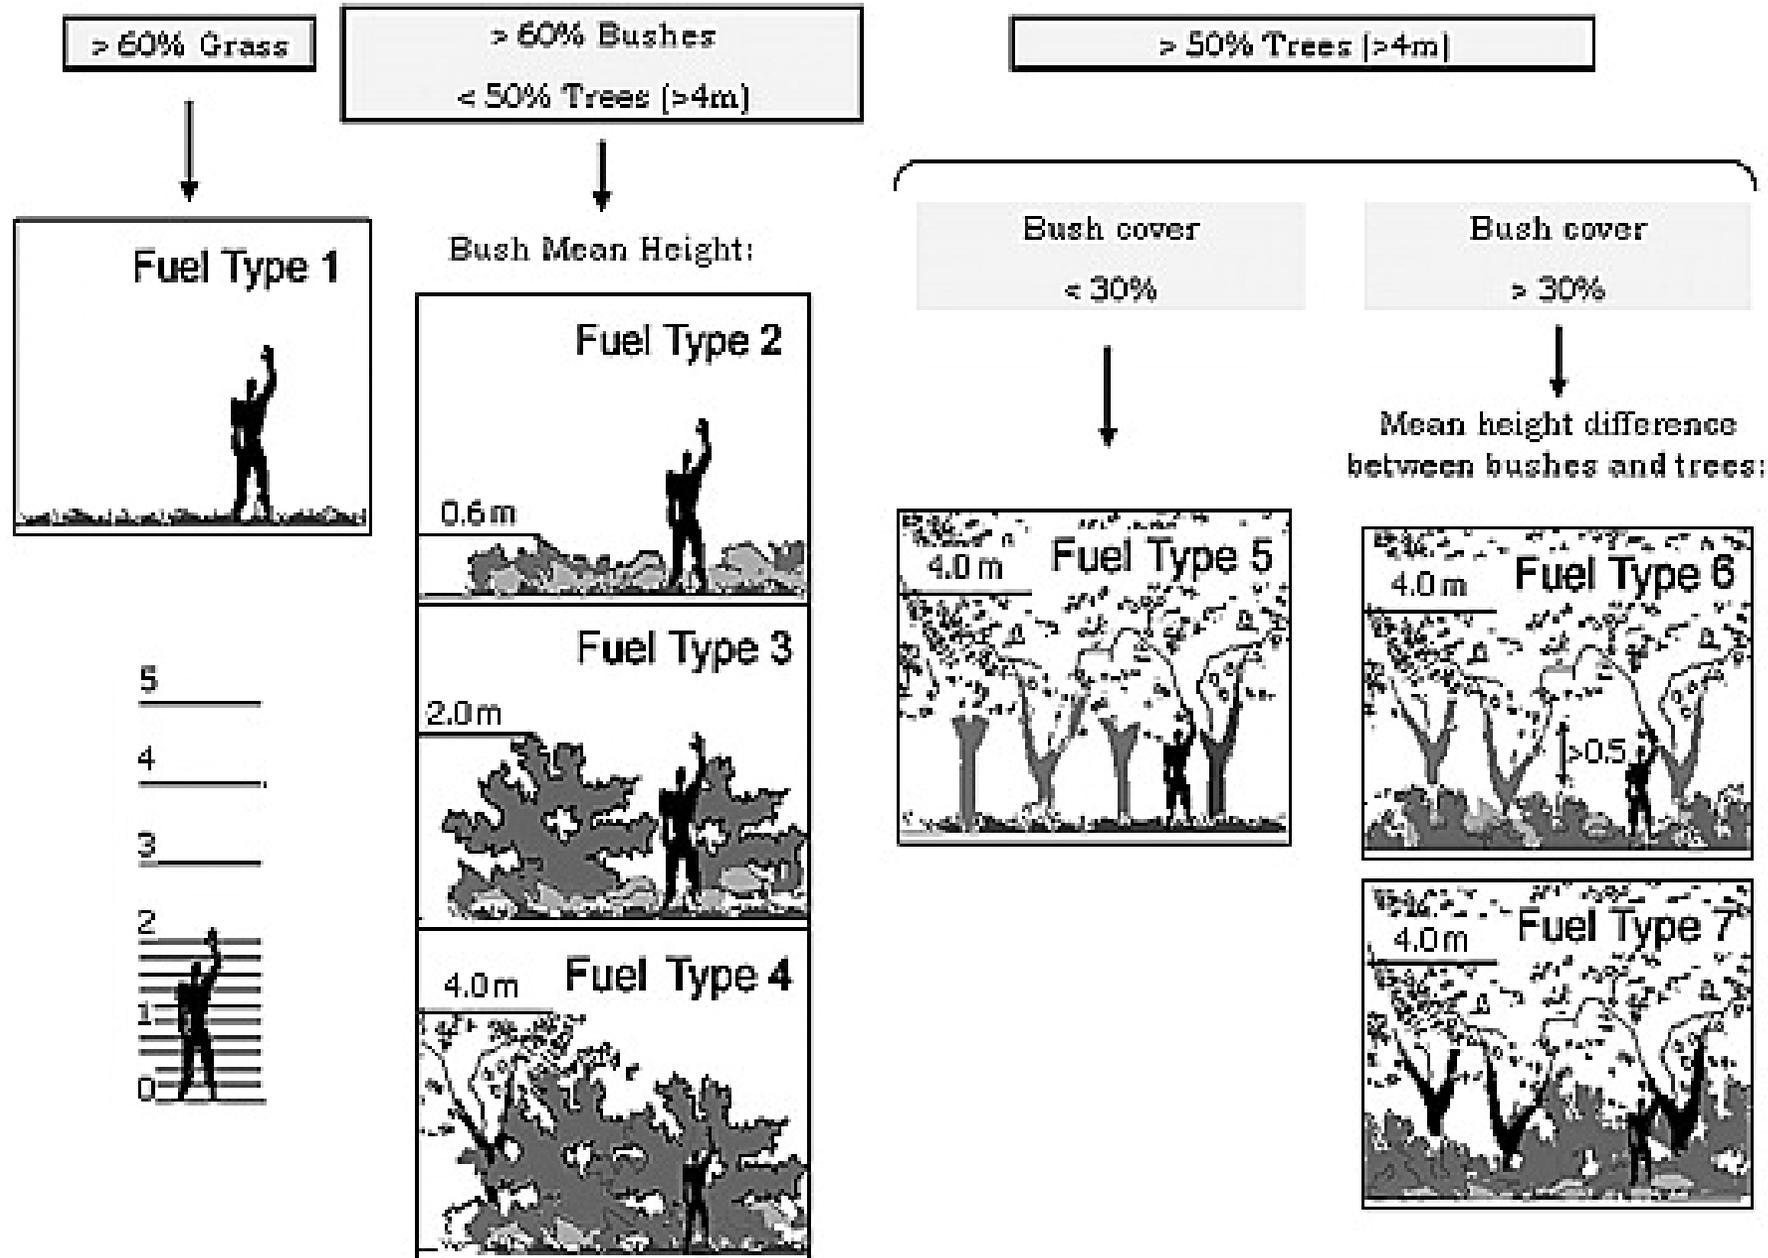
- Elevada precisión **modelos de crecimiento de árbol individual** para generar **datos concomitantes** con información LiDAR
- **All subsets selection Seqrep y SVM con kernel radial** proporciona los mejores resultados en el **enfoque indirecto** (se usa para el análisis de transferibilidad temporal)
- Enfoques directos e indirecto proporcionan **resultados similares**
- **Enfoque directo reduce tiempo y costes de inventarios y de generación de modelos.**

Enfoque directo



* t: modelo transferido

Tipos de combustible EU Prometheus

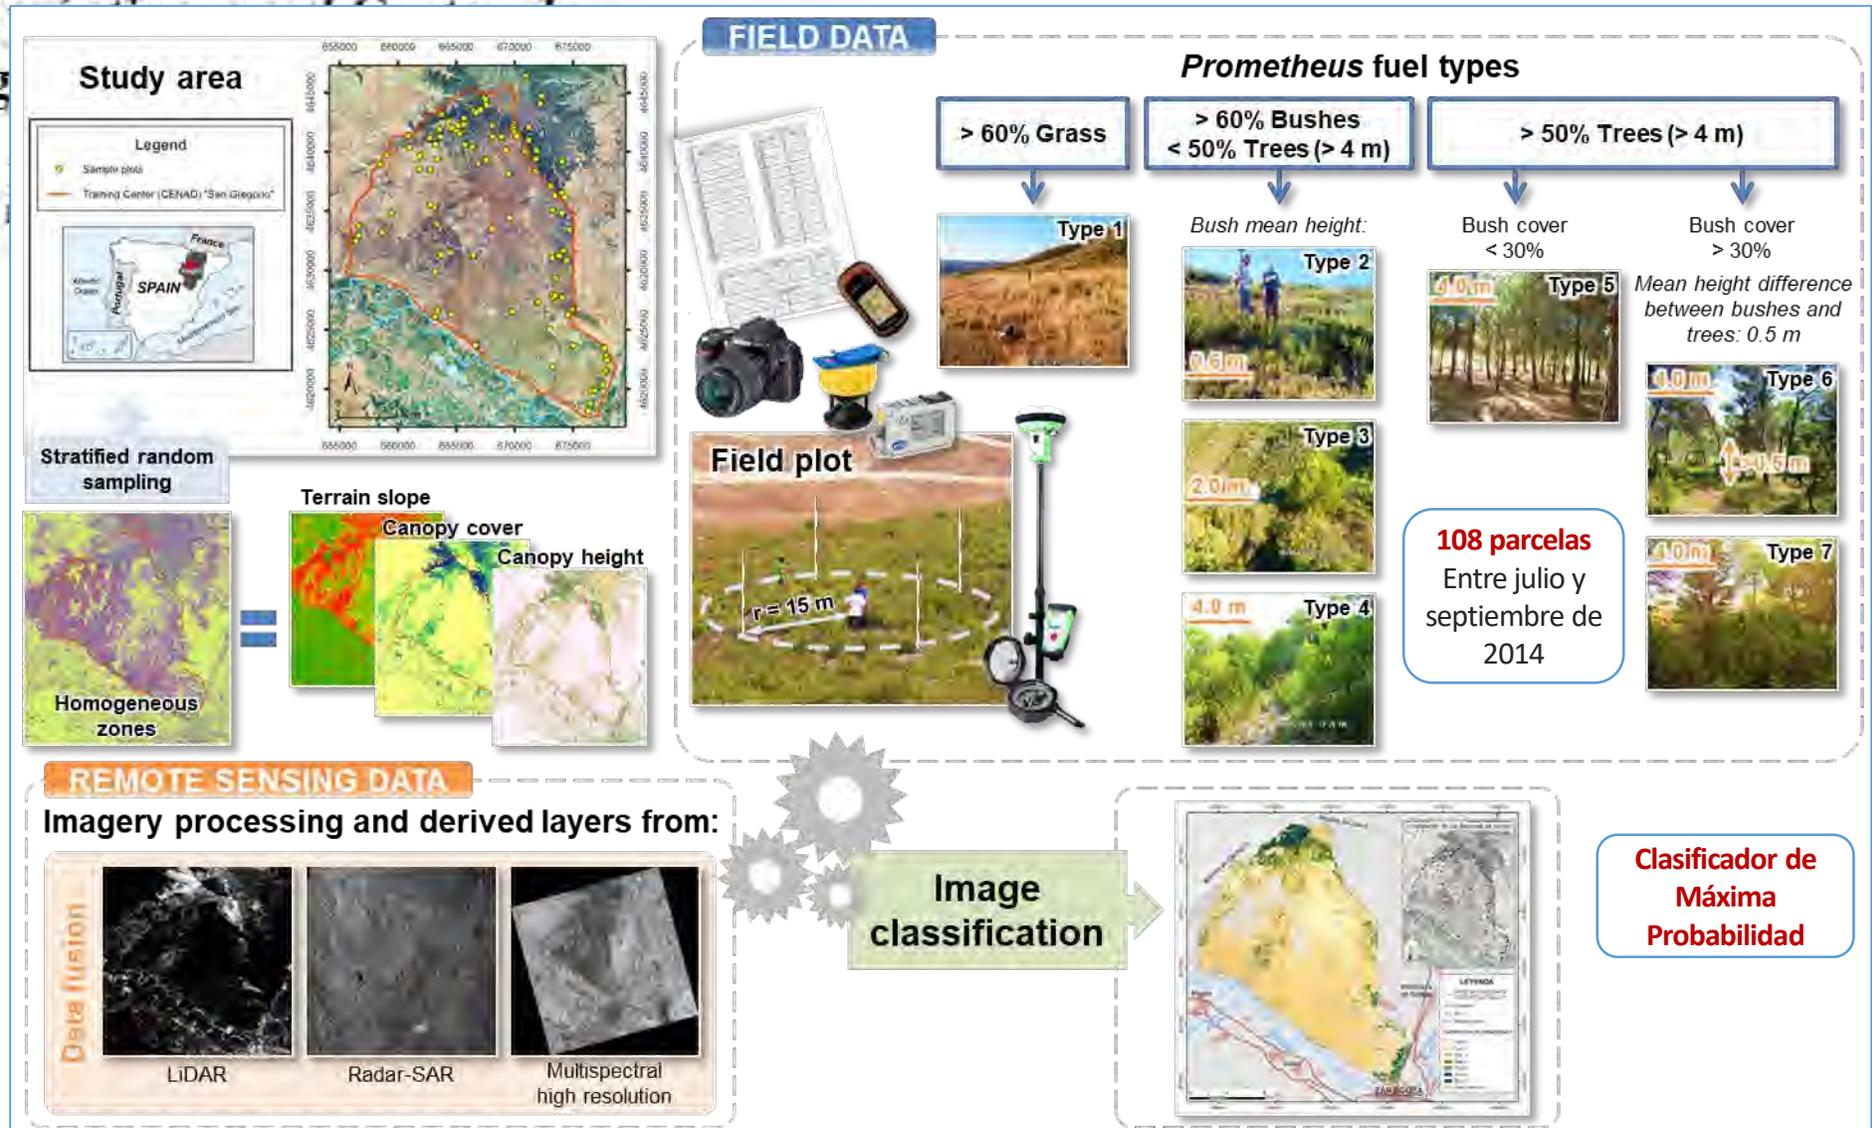


- Sistema mediterráneo-europeo (Comisión Europea, 1999; Riaño et al., 2002; Arroyo et al., 2008), ampliamente utilizado para cartografiar tipos de combustibles en otras regiones.
- Adapta la clasificación NFFL.
- El criterio de clasificación es el tipo, densidad y altura del elemento de propagación dividido en tres grandes grupos: pasto, matorrales u hojarasca.
- 7 tipos de combustible.

Cartografía de modelos de combustible mediante combinación de imágenes LiDAR, SAR

Adiestramiento “San Gregorio”

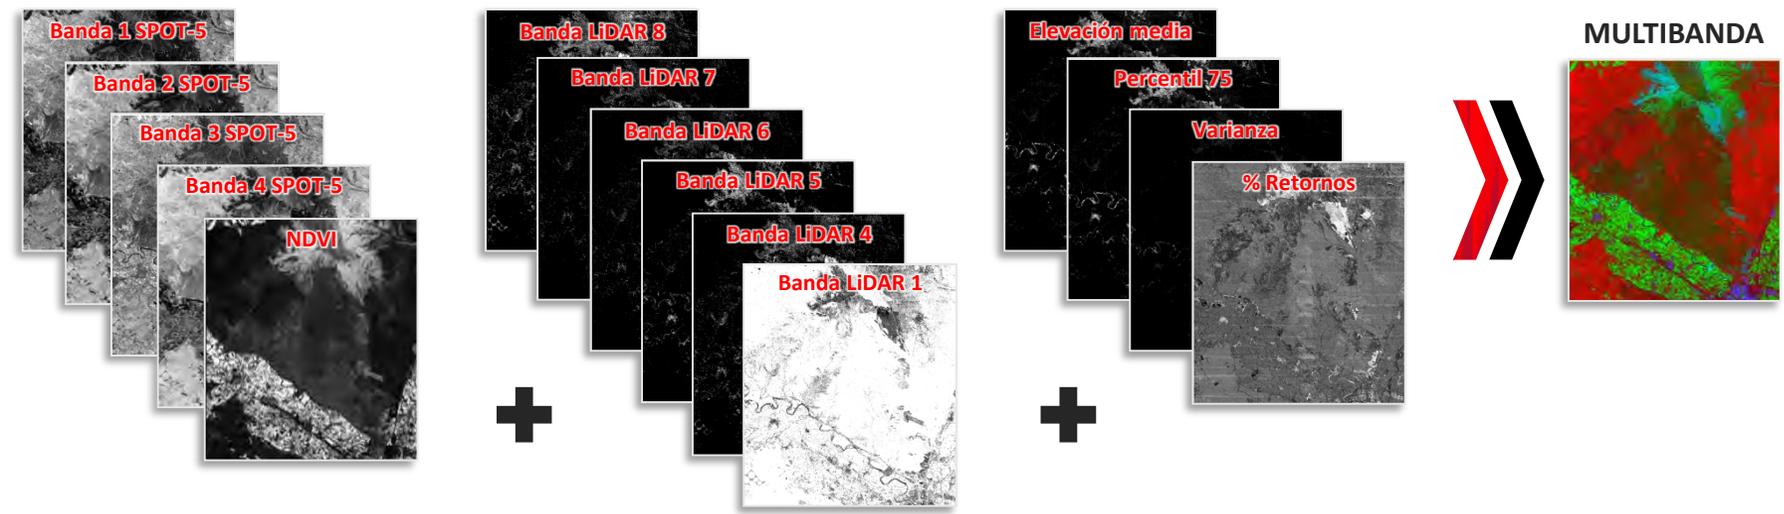
Montealegre Gracia, Antonio Luis, Alberto ^{2,3}, de la Riva Fernández, Juan



CENAD	108 parcelas inventario	Clasificación digital (Máxima probabilidad)	72,7% acierto global, Kappa 0,7
-------	-------------------------	---	---------------------------------

Multibanda	Acierto global	Índice Kappa
Bandas SPOT-5	59,2 %	0,5
Bandas SPOT-5 + NDVI + BL1,4,5,6,7,8 + EM, P₇₅, V, %Ret	72,7 %	0,7
ACP componentes 1 a 9 (bandas SPOT-5 + NDVI + BL1,4,5,6,7,8 + EM, P ₇₅ , V, %Ret)	61,4 %	0,6
MNF componentes 1 a 8 (bandas SPOT-5 + BL1,4,5,6,7,8+ EM, P ₇₅ , V, %Ret) + NDVI	72,3 %	0,7

Comparación de los mejores resultados derivados de la clasificación digital. Índice Kappa con un nivel de significación estadística $P\text{-valor} \leq 0,01$.



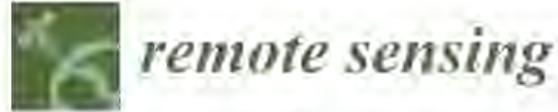
8 bandas LiDAR (BL) de densidad de retornos: 0-0,5 m (BL1), 2-4 m (BL4), >4 m (BL5), 3-3,5 m (BL6), 3,5-4 m (BL7) y 1-4 m (BL8).



TIPOS DE COMBUSTIBLE

		1	2	3	4	5	6	7	Suelo desnudo	TOTAL	
TIPOS DE COMBUSTIBLE	1	Nº de píxeles	27	4	0	1	0	0	0	4	36
		%	75,0%	11,1%	0,0%	2,8%	0,0%	0,0%	0,0%	11,1%	100,0%
	2	Nº de píxeles	1	35	10	0	1	0	0	3	50
		%	2,0%	70,0%	20,0%	0,0%	2,0%	0,0%	0,0%	6,0%	100,0%
	3	Nº de píxeles	0	7	10	2	0	1	0	0	20
		%	0,0%	35,0%	50,0%	10,0%	0,0%	5,0%	0,0%	0,0%	100,0%
	4	Nº de píxeles	0	0	2	16	0	0	0	0	18
	%	0,0%	0,0%	11,1%	88,9%	0,0%	0,0%	0,0%	0,0%	100,0%	
5	Nº de píxeles	0	0	2	2	40	8	4	0	56	
	%	0,0%	0,0%	3,6%	3,6%	71,4%	14,3%	7,1%	0,0%	100,0%	
6	Nº de píxeles	0	0	0	2	5	10	1	0	18	
	%	0,0%	0,0%	0,0%	11,1%	27,8%	55,6%	5,6%	0,0%	100,0%	
7	Nº de píxeles	0	0	0	4	0	3	22	0	29	
	%	0,0%	0,0%	0,0%	13,8%	0,0%	10,3%	75,9%	0,0%	100,0%	
Suelo desnudo	Nº de píxeles	1	4	1	0	0	0	0	34	40	
	%	2,5%	10,0%	2,5%	0,0%	0,0%	0,0%	0,0%	85,0%	100,0%	
TOTAL	Nº de píxeles	29	50	25	27	46	22	27	41	267	
	%	10,9%	18,7%	9,4%	10,1%	17,2%	8,2%	10,1%	15,4%	100,0%	





<https://doi.org/10.3390/rs12213660>

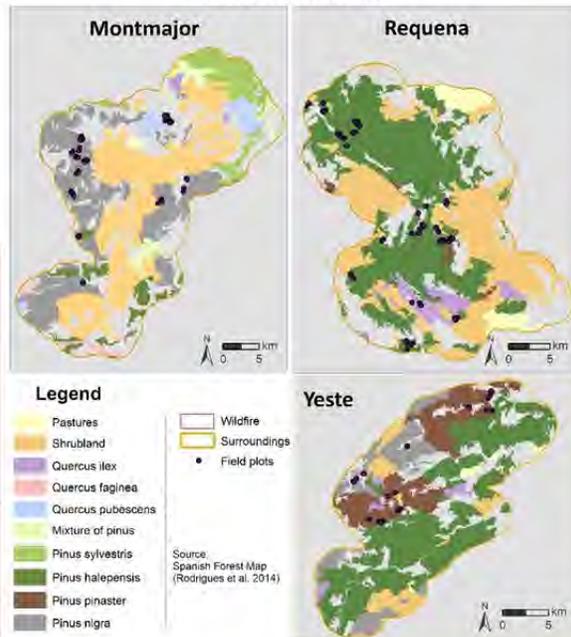
Article

Fuel Type Classification Using Airborne Laser Scanning and Sentinel 2 Data in Mediterranean Forest Affected by Wildfires

Dario Domingo ^{1,2,*}, Juan de la Riva ², Maria T. Alberto Garcia-Martin ^{2,3}, Paloma Ibarra ², Maite

	Metrics	Method	Fitting phase	Validation
P25 + % all ret. above mean + NDVI + rumple		SVMr	0.73	0.59
		SVMl	0.67	0.56
		RF	0.99	0.56
P25 + % all ret. above mean + rumple		SVMr	0.62	0.57
		SVMl	0.66	0.58
		RF	0.99	0.54
NDVI + NBR + Wetness + Brightness + NIR		SVMr	0.48	0.37
		SVMl	0.53	0.38
		RF	0.99	0.18

Map of each study site



Source: Spanish Forest Map (Rodriguez et al. 2014)

Article

Assessing the LiDAR Simul:

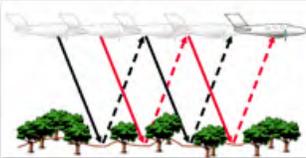
Sergio Revilla ^{1,2}, Mari: Antonio Luis Montealegr

MATERIALS

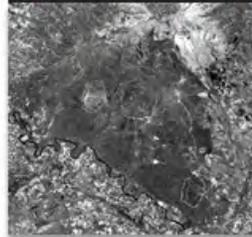
104 Field plots – Prometheus fuel types



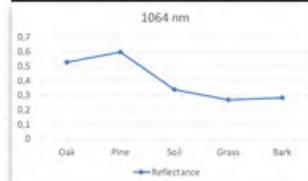
ALS-PNOA point clouds (2011 – 2016)



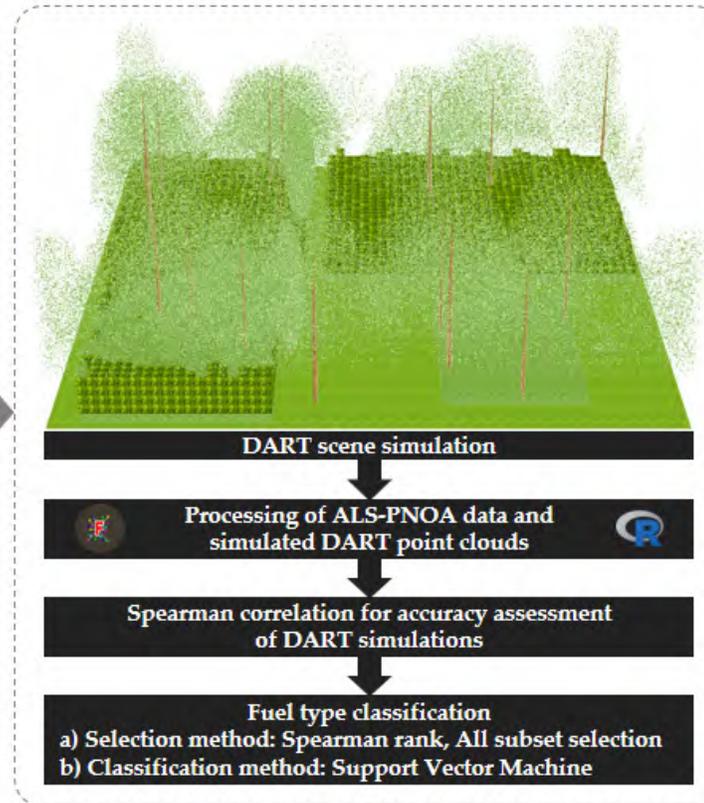
Two scenes Sentinel 2-A



Top-of-canopy reflectance measurements

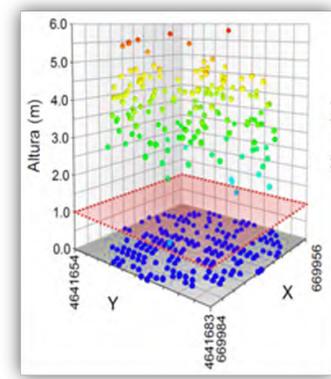
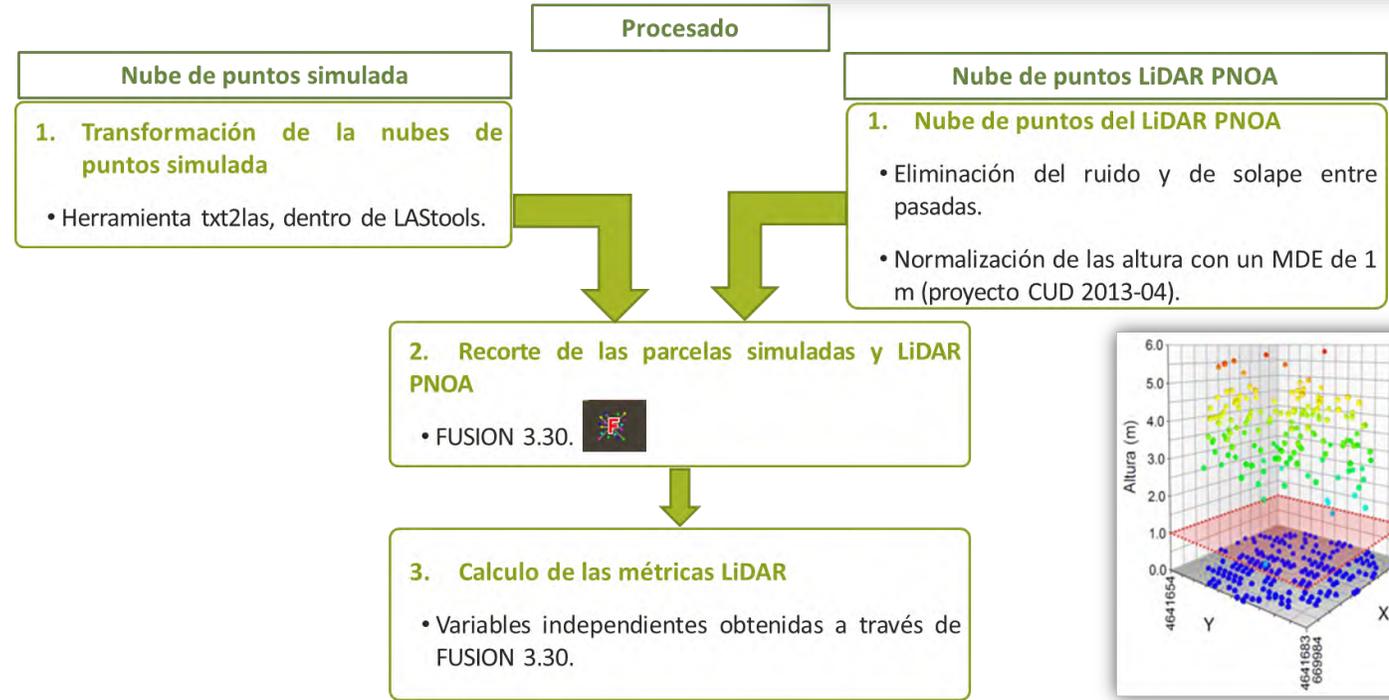
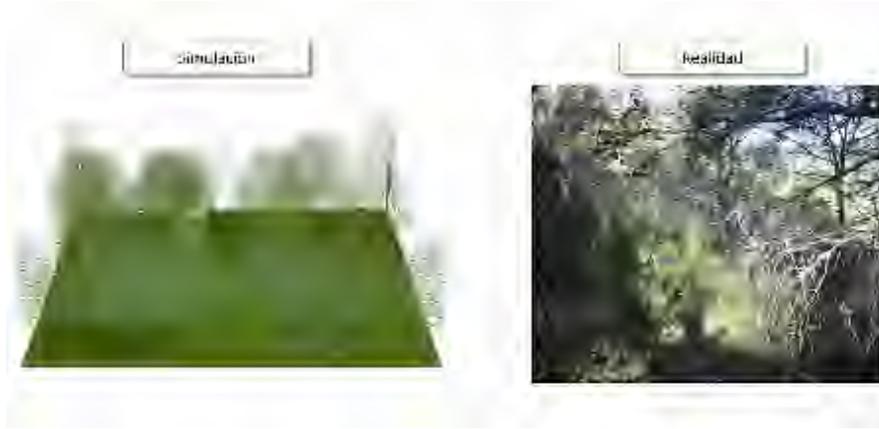


METHODS



RESULTS: OVERALL ACCURACY

Point cloud metrics	Year	Method	Fitting phase OA	Validation OA
P80 + Elev. LCV + Mean 0_0.6 + Rumple + LHDI	2011	SVMl	0.68	0.69
		SVMr	0.73	0.88
	2016	SVMl	0.76	0.72
		SVMr	0.85	0.91



1. Preselección de las métricas LiDAR

- Coeficientes de correlación de Spearman (Rho).
- Selección de todos los subconjuntos: exhaustivo, hacia delante, hacia atrás y remplazo secuencial. Uso del paquete leaps.



2. Support Vector Machine con kernel linear y radial ("e1071" R package)

- Muestra de entrenamiento: simulado 2011.
- Parametrización de cost (1-1.000) y gamma (0,01-1).



3. Análisis de la capacidad de clasificación de los modelos y transferibilidad.

- Estadísticos: *Accuracy* y *kappa*.
- *Validación clasificación: PNOA 2011*
- *Validación transferibilidad: PNOA 2016*



Correlación y RMSE entre las métricas de las nubes simuladas y las reales del PNOA

Variable	2011			2016		
	Correlación	RMSE	%RMSE (PNOA 2011)	Correlación	RMSE	%RMSE (PNOA 2016)
P25	0,11	1,28	1,52	0,34	1,18	2,29
P50	0,69	2,16	1,06	0,75	1,46	0,78
P75	0,94	1,28	0,45	0,92	1,30	0,44
P95	0,94	1,42	0,38	0,95	1,40	0,35
Elevación media	0,92	1,13	0,59	0,92	1,00	0,54
Elevación máxima	0,93	1,92	0,42	0,97	1,62	0,31
Elevación cuadrática media	0,94	1,04	0,44	0,96	0,97	0,41
Elevación cúbica media	0,94	1,03	0,40	0,97	0,95	0,35
Desviación absoluta media	0,95	0,40	0,37	0,95	0,45	0,36
Distancia intercuartílica	0,92	1,16	0,57	0,91	1,19	0,48
Desviación estándar	0,95	0,46	0,35	0,97	0,43	0,30
Varianza	0,95	1,20	0,37	0,97	1,80	0,48
Primeros retornos sobre la media	0,54	169,13	1,02	0,34	429,42	1,13
Porcentaje de todos los retornos sobre la moda	0,35	54,26	0,58	0,59	41,63	0,48
Media de los retornos de 0 a 0,6	0,33	0,11	1,70	0,36	0,07	0,45
Proporción de retornos de 0 a 0,6	0,41	0,39	0,69	0,77	0,36	0,59
Media de los retornos de 0,6 a 2	0,52	0,88	0,91	0,71	0,52	0,53
Proporción de retornos de 0,6 a 2	0,22	0,13	1,70	0,56	0,12	1,07
Media de los retornos de 2 a 4	0,65	1,50	0,72	0,74	1,34	0,64
Proporción de retornos de 2 a 4	0,72	0,17	1,20	0,73	0,12	1,37
Media de los retornos superiores a 4	0,89	1,62	0,51	0,94	1,55	0,47
Proporción de retornos superiores a 4	0,91	0,19	0,91	0,93	0,18	0,89

Predicted	Reference							Total plots	User's accuracy (%)
	Fuel type 1	Fuel type 2	Fuel type 3	Fuel type 4	Fuel type 5	Fuel type 6	Fuel type 7		
Fuel type 1	11	4	0	0	0	0	0	15	73,3
Fuel type 2	1	17	1	0	0	0	0	19	89,5
Fuel type 3	1	3	14	0	0	0	0	18	77,8
Fuel type 4	0	0	0	8	1	0	0	9	88,9
Fuel type 5	0	0	0	0	19	0	0	19	100
Fuel type 6	0	0	0	0	1	9	0	10	90,0
Fuel type 7	0	0	0	0	0	0	14	14	100
Total plots	13	24	15	8	21	9	14	104	88,5 ¹
Producer's accuracy (%)	84,6	70,8	93,3	100	90,5	100	100	91,3 ²	88,5 ³

Table 11. Confusion matrix for the most accurate classification model after validation for year 2016. ¹ Overall accuracy, ² Mean user's accuracy, ³ Mean producer accuracy.

Predicted	Reference							Total plots	User's accuracy (%)
	Fuel type 1	Fuel type 2	Fuel type 3	Fuel type 4	Fuel type 5	Fuel type 6	Fuel type 7		
Fuel type 1	9	1	0	0	0	0	0	10	90,0
Fuel type 2	4	23	1	0	0	0	0	28	82,1
Fuel type 3	0	0	14	0	0	0	0	14	100
Fuel type 4	0	0	0	8	0	0	0	8	100
Fuel type 5	0	0	0	0	21	2	0	23	91,3
Fuel type 6	0	0	0	0	0	6	0	6	100
Fuel type 7	0	0	0	0	0	1	14	15	93,3
Total plots	13	24	15	8	21	9	14	104	93,8 ²
Producer's accuracy (%)	69,2	95,8	93,3	100	100	66,7	100	89,3 ²	91,3 ³

RESULTS: OVERALL ACCURACY

Point cloud metrics	Year	Method	Fitting phase OA	Validation OA
P80 + Elev. LCV + Mean 0_0.6 + Rumple + LHDI	2011	SVMl	0.68	0.69
		SVMr	0.73	0.88
	2016	SVMl	0.76	0.72
		SVMr	0.85	0.91



Contents lists available at ScienceDirect

International Journal of Applied Earth Observations and GeoInformation

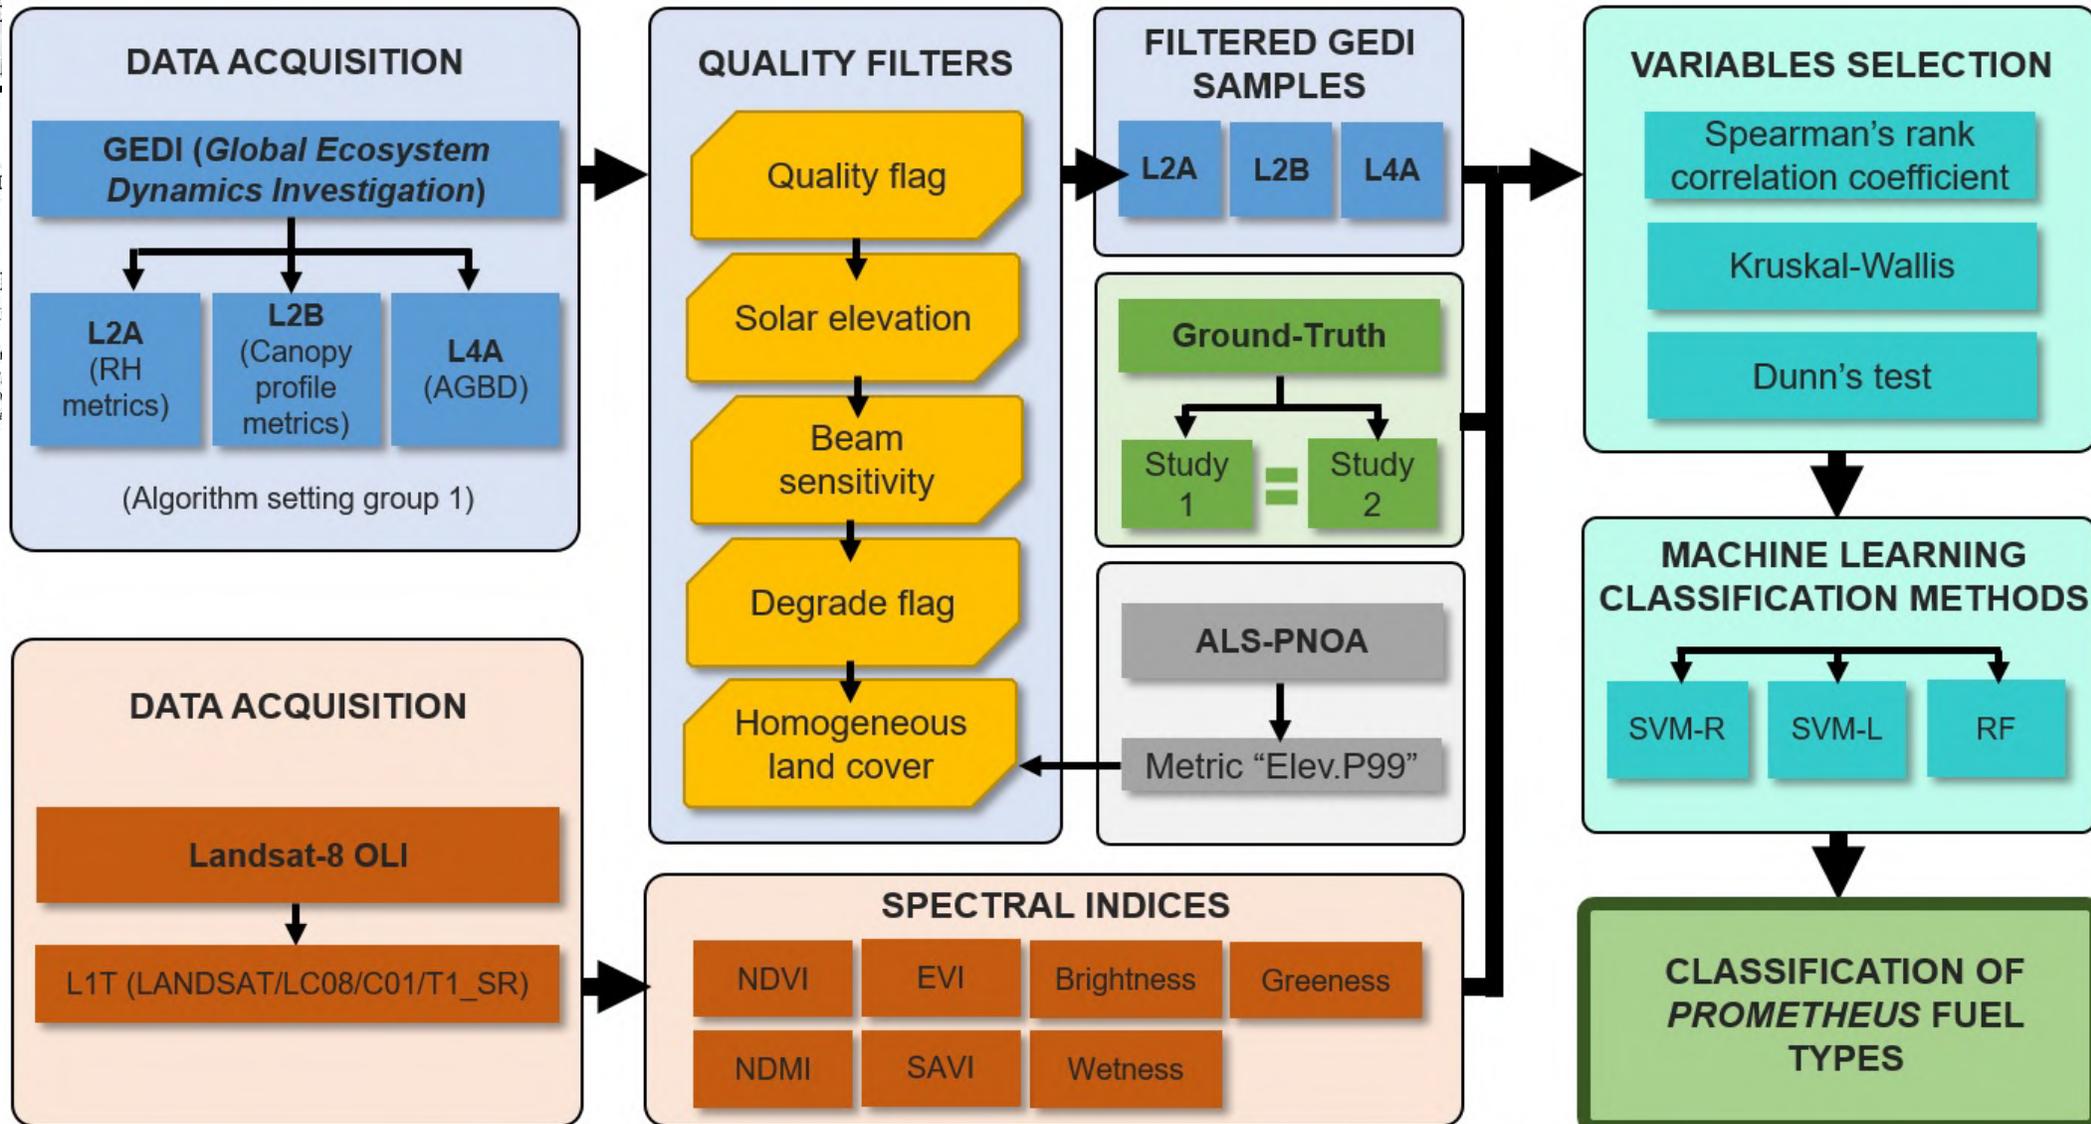


Assessing GEDI-NASA system learning techniques

Raúl Hoffrén^{a,*}, María Teresa Lama^b, Antonio Luis Montealegre^{a,b}, Albert

^a Geofores IUCA, Department of Geography and Land Management
^b Centro Universitario de la Defensa, Academia General Militar
^c EFAB uFOR, University of Valladolid, Campus Duques de Sotomayor
^d Instituto Geográfico de Aragón, María Agustín 36, Ed. Pignatelli

<https://doi.org/10.1016/j.jag.2022.103175>



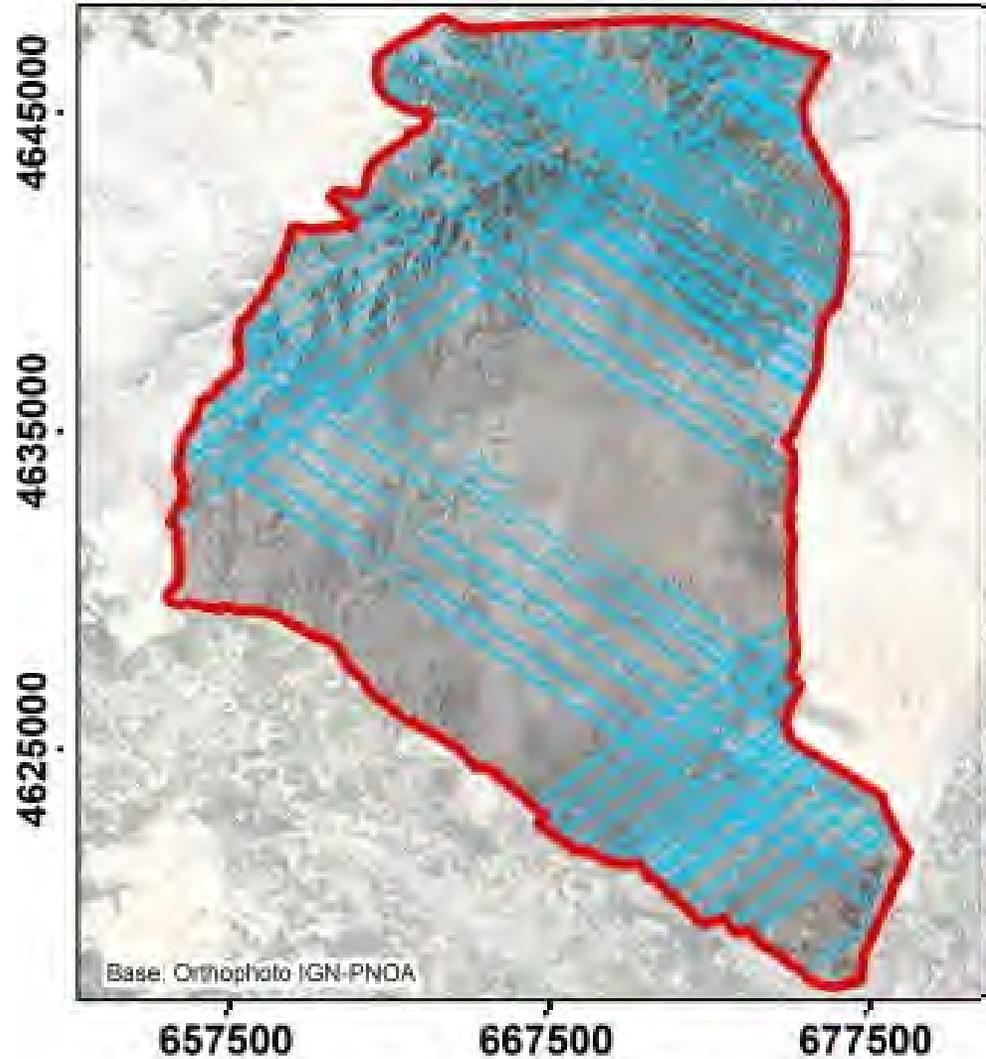


Table S4. Confusion matrix of the SVM-R model (overall accuracy = 61.54%; kappa = 0.51) for the selected GEDI variables (RH85 + PAI + AGBD).

Table S5. Confusion matrix of the SVM-L model (overall accuracy = 57.46%; kappa = 0.45) for the selected GEDI variables (RH85 + PAI + AGBD).

Table S6. Confusion matrix of the RF model (overall accuracy = 61.54%; kappa = 0.51) for the selected GEDI variables (RH85 + PAI + AGBD).

Fuel types	FT1	FT2	FT3	FT4	FT5	FT7	User's accuracy
FT1	51	14	1	0	0	0	77.27%
FT2	6	13	6	4	0	2	41.94%
FT3	4	8	18	9	0	3	42.86%
FT4	0	4	9	13	0	2	46.43%
FT5	0	0	0	0	0	0	0.00%
FT7	0	3	4	4	2	41	75.93%
Producer's accuracy	83.61%	30.95%	47.67%	43.33%	0.0%	85.42%	

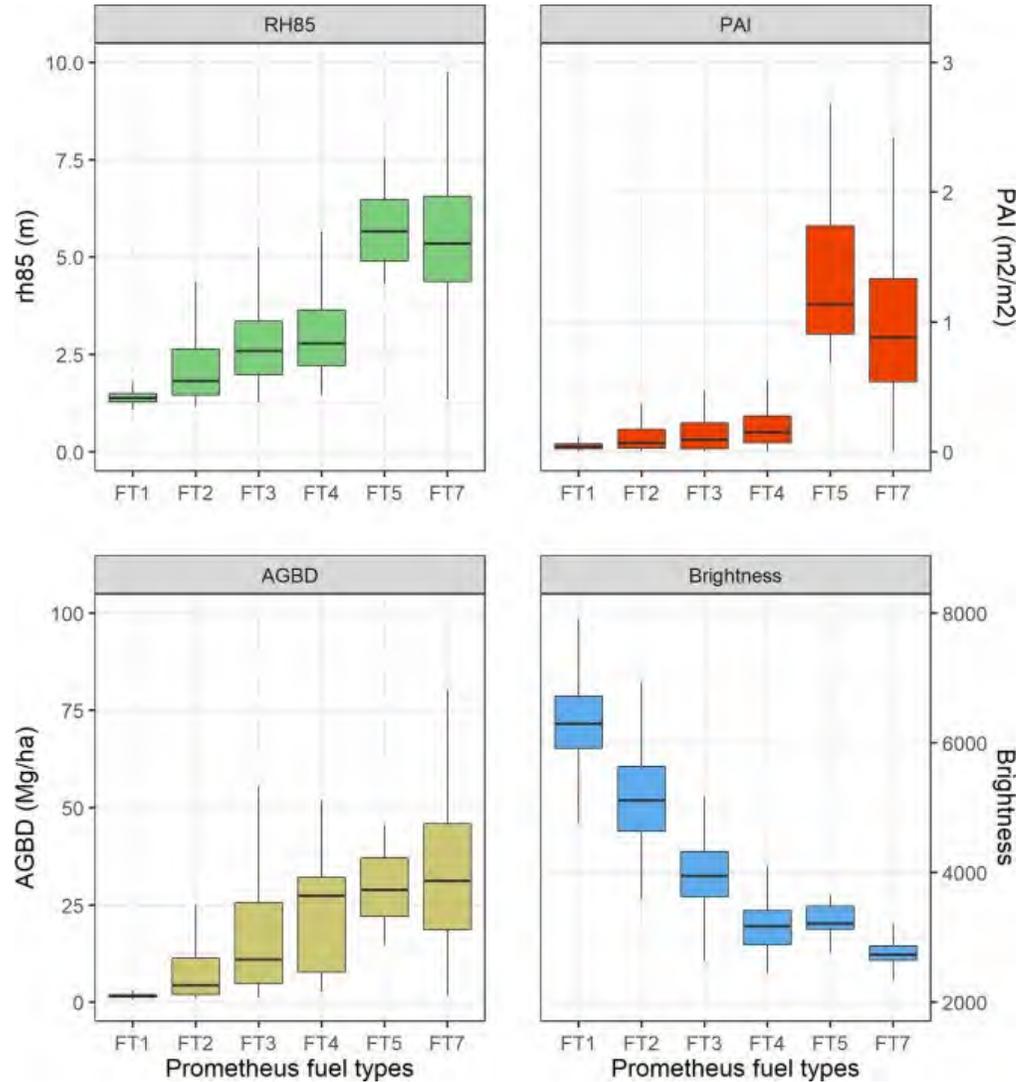


Fig. 4. Distribution values of the selected GEDI and Landsat-8 OLI variables for the Prometheus fuel types classification.

Table S7. Confusion matrix of the SVM-R model (overall accuracy = 81.90%; kappa = 0.77) for the selected GEDI and Landsat-8 OLI variables (RH85 + PAI + AGBD + Brightness).

Table S8. Confusion matrix of the SVM-L model (overall accuracy = 81.00%; kappa = 0.76) for the selected GEDI and Landsat-8 OLI variables (RH85 + PAI + AGBD + Brightness).

Table S9. Confusion matrix of the RF model (overall accuracy = 83.71%; kappa = 0.79) for the selected GEDI and Landsat-8 OLI variables (RH85 + PAI + AGBD + Brightness).

Fuel types	FT1	FT2	FT3	FT4	FT5	FT7	User's accuracy
FT1	59	5	0	0	0	0	92.19%
FT2	2	36	5	0	0	1	81.82%
FT3	0	1	27	6	0	0	79.41%
FT4	0	0	5	19	0	3	70.37%
FT5	0	0	0	1	0	0	0.00%
FT7	0	0	1	4	2	44	86.27%
Producer's accuracy	96.72%	85.71%	71.05%	63.33%	0.00%	91.67%	

PNOA – UAV Fotogrametría

Remote Sensing Applications: Society and Environment 31 (2023) 100997

Aragón

82 parcelas

Nubes de puntos RGB: 3000 pto/m²; multispectral: 85 pto/m²). P50, coef. variación, % retornos >4 m, disimilitud textural media y índice de clorofila verde

RF: 71% / muestra de datos integrada con nubes de puntos normalizadas a 0,5 m de DEM

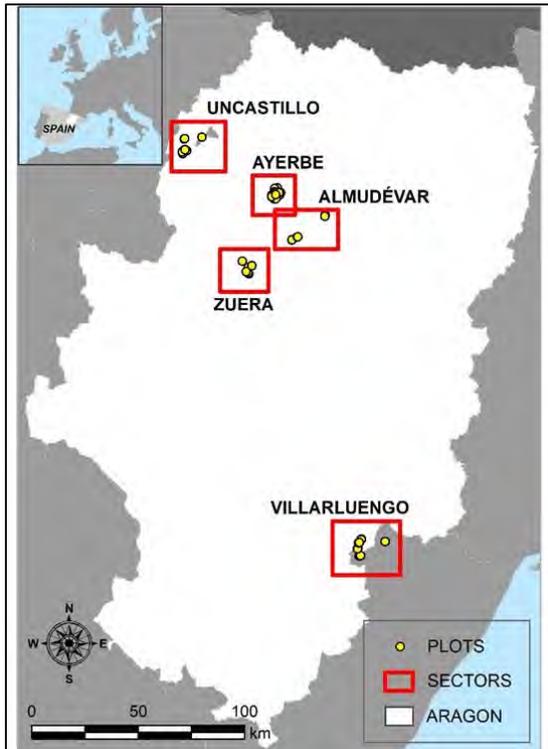


UAV-derived photogrammetric point clouds and multispectral indices for fuel estimation in Mediterranean forests

Raúl Hoffrén ^{a, *}, María Teresa Lamelas ^{a, b}, Juan de la Riva ^a

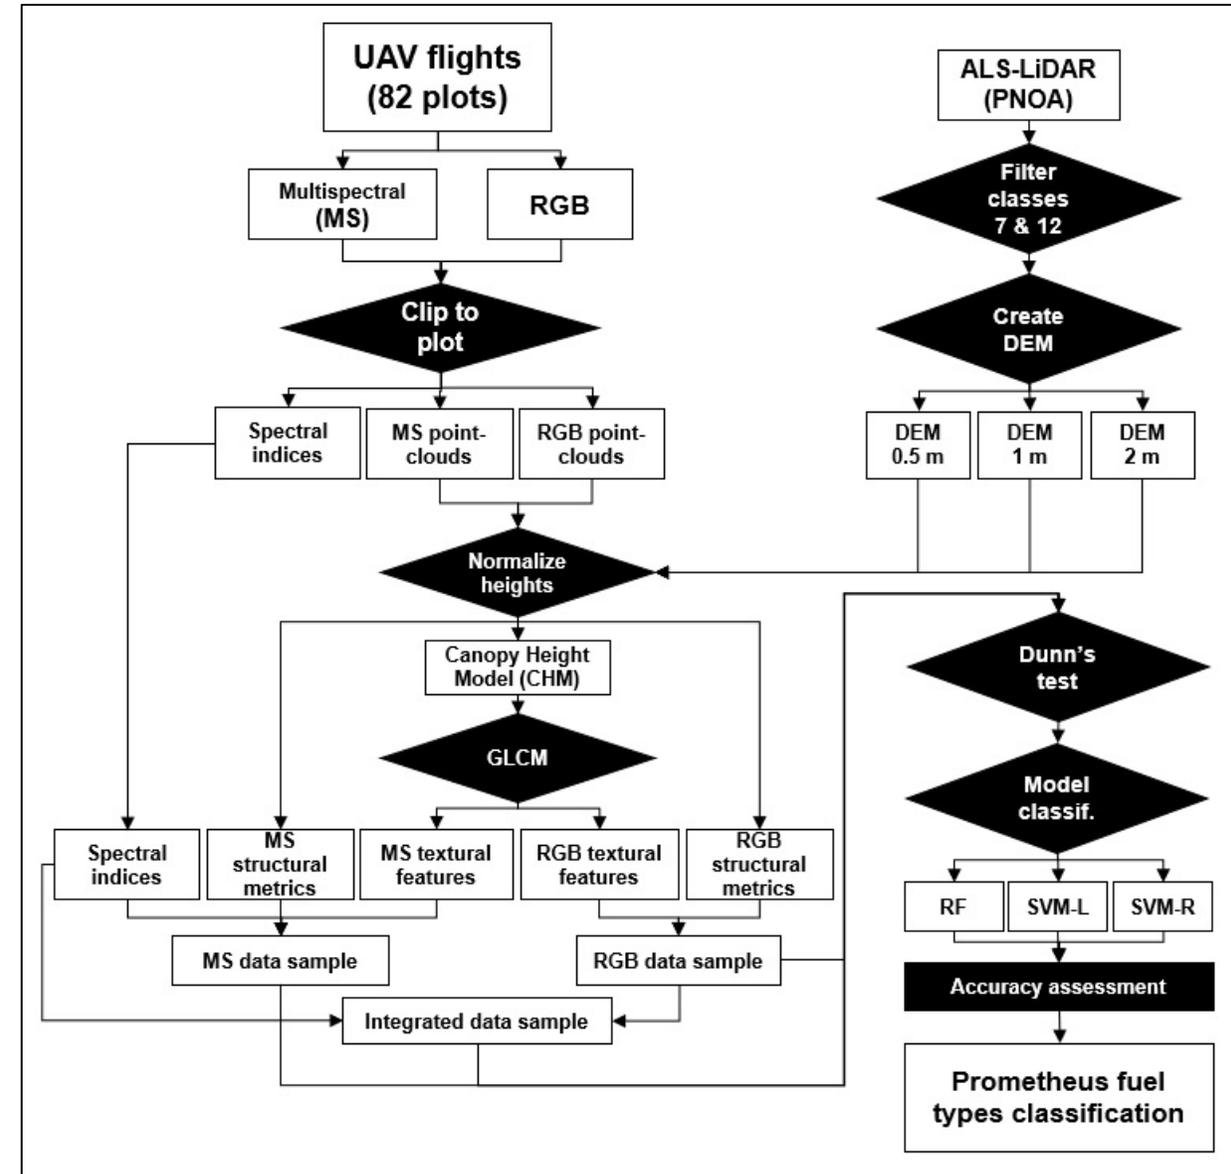
^a Geoforest-IUCA, Department of Geography and Land Management, University of Zaragoza, Pedro Cerbuna 12, 50009, Zaragoza, Spain
^b Centro Universitario de la Defensa, Academia General Militar, Ctra. de Iruya s/n, 50090, Zaragoza, Spain

<https://doi.org/10.1016/j.rsase.2023.100997>



Sensores

- Sony WX (RGB)
- Parrot Sequoia (4 bandas multispectrales: Green-Red-RedEdge-NIR)



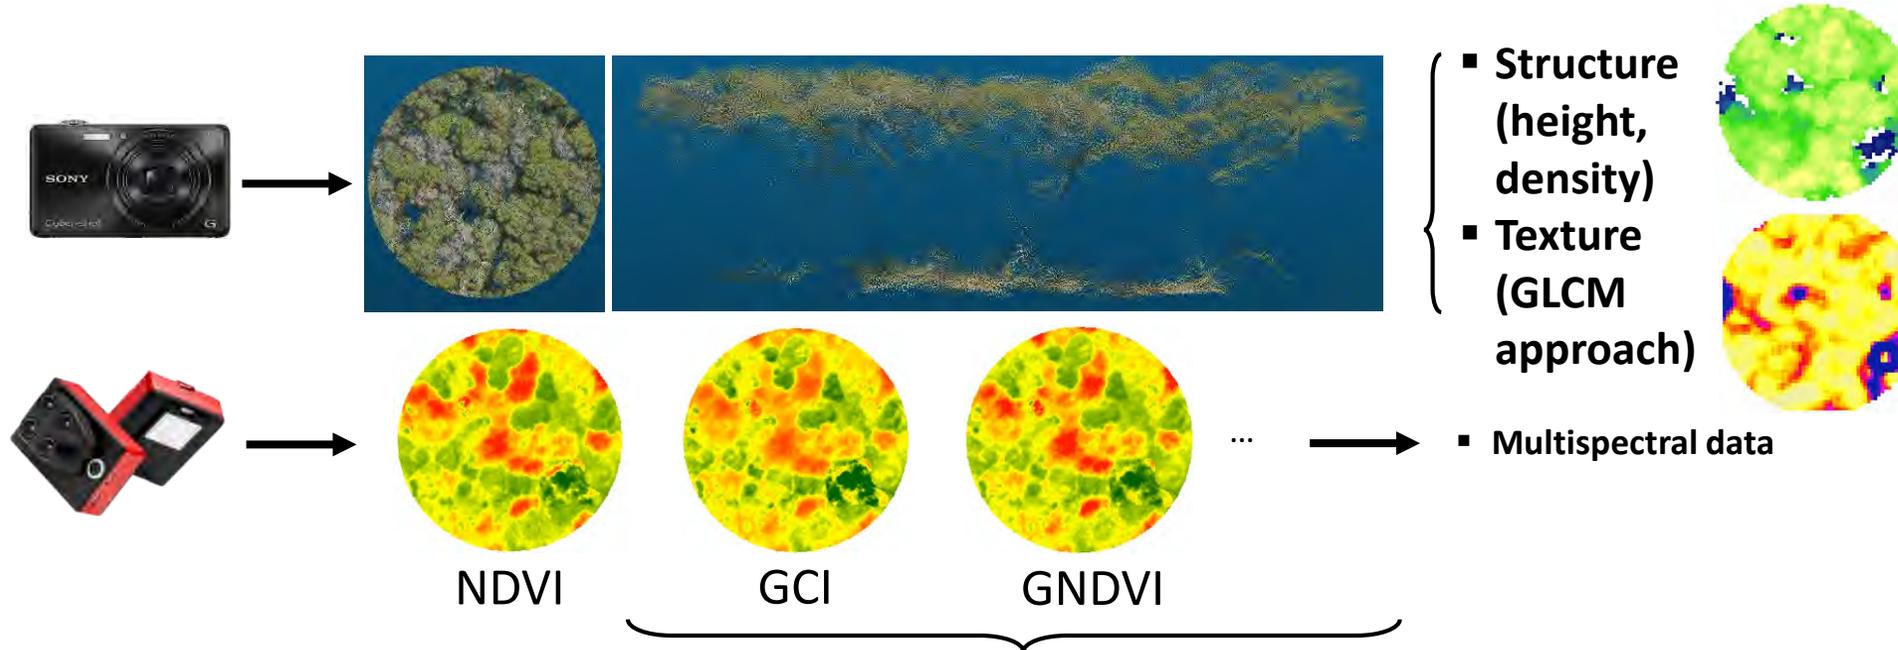
PNOA – UAV Fotogrametría

Aragón

82 parcelas

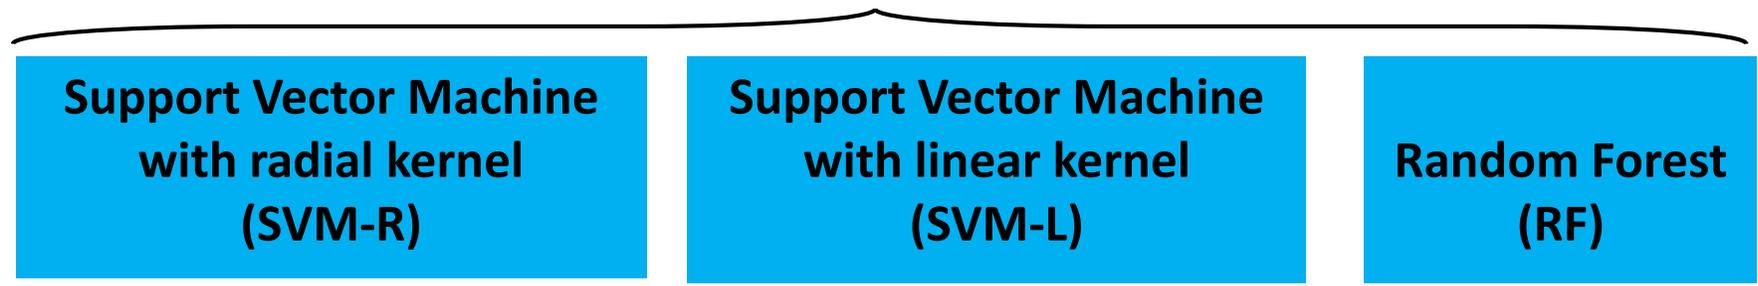
Nubes de puntos RGB: 3000 ptos/m²;
multiespectral: 85 ptos/m²).P50, coef.
variación, % retornos >4 m, disimilitud
textural media y índice de clorofila verde

RF: 71% / muestra de datos
integrada con nubes de
puntos normalizadas a 0,5
m de DEM



- Muestras de datos:
- **Muestra RGB:** variables estructurales y texturales relevantes de la cámara RGB.
 - **Muestra de datos MS:** variables estructurales, texturales y espectrales del sensor multiespectral.
 - **Muestra integrada:** variables estructurales y texturales de la cámara RGB más la variable espectral del sensor multiespectral.

Variables selection Dunn's test
Most relevant variables to include in the Machine Learning classification models



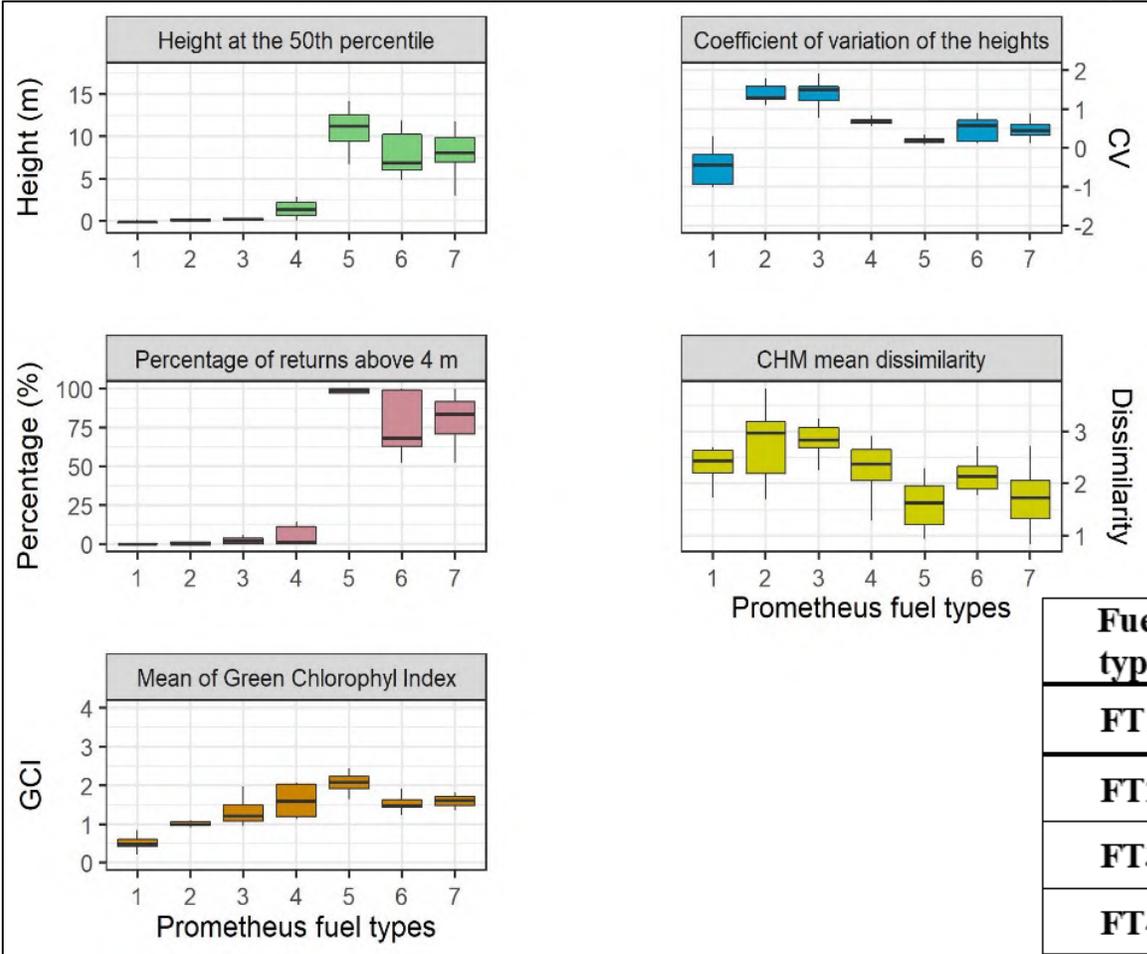
PNOA – UAV Fotogrametría

Aragón

82 parcelas

Nubes de puntos RGB: 3000 ptos/m²;
multiespectral: 85 ptos/m²).P50, coef.
variación, % retornos >4 m, disimilitud
textural media y índice de clorofila verde

RF: 71% / muestra de datos
integrada con nubes de
puntos normalizadas a 0,5
m de DEM



Fuel type	FT1	FT2	FT3	FT4	FT5	FT6	FT7	User's accuracy
FT1	98	0	10	10	0	0	0	83%
FT2	2	90	37	0	0	0	0	70%
FT3	0	16	31	10	0	0	0	54%
FT4	0	4	2	47	0	0	9	76%
FT5	0	0	0	0	73	29	10	65%
FT6	0	0	0	0	17	54	29	54%
FT7	0	0	0	3	10	37	192	79%
Prod.'s accuracy	98%	82%	39%	67%	73%	45%	80%	

Please find enclosed our manuscript:

Classification and mapping of fuels in Mediterranean forests using a LiDAR unmanned aerial vehicle and integration possibilities with handheld mobile laser scanner systems

by Raúl Hoffrén, María Teresa Lamelas, and Juan de la Riva.

Generación de métricas LiDAR

Selección de variables: Test de Dunn

Modelos de clasificación *machine learning*

Random Forest (RF)

Support Vector Machine lineal (SVM-L)

Support Vector Machine radial (SVM-R)

Evaluación del rendimiento de los modelos

Coficiente "accuracy" Matrices de confusión

Espacialización del mejor modelo

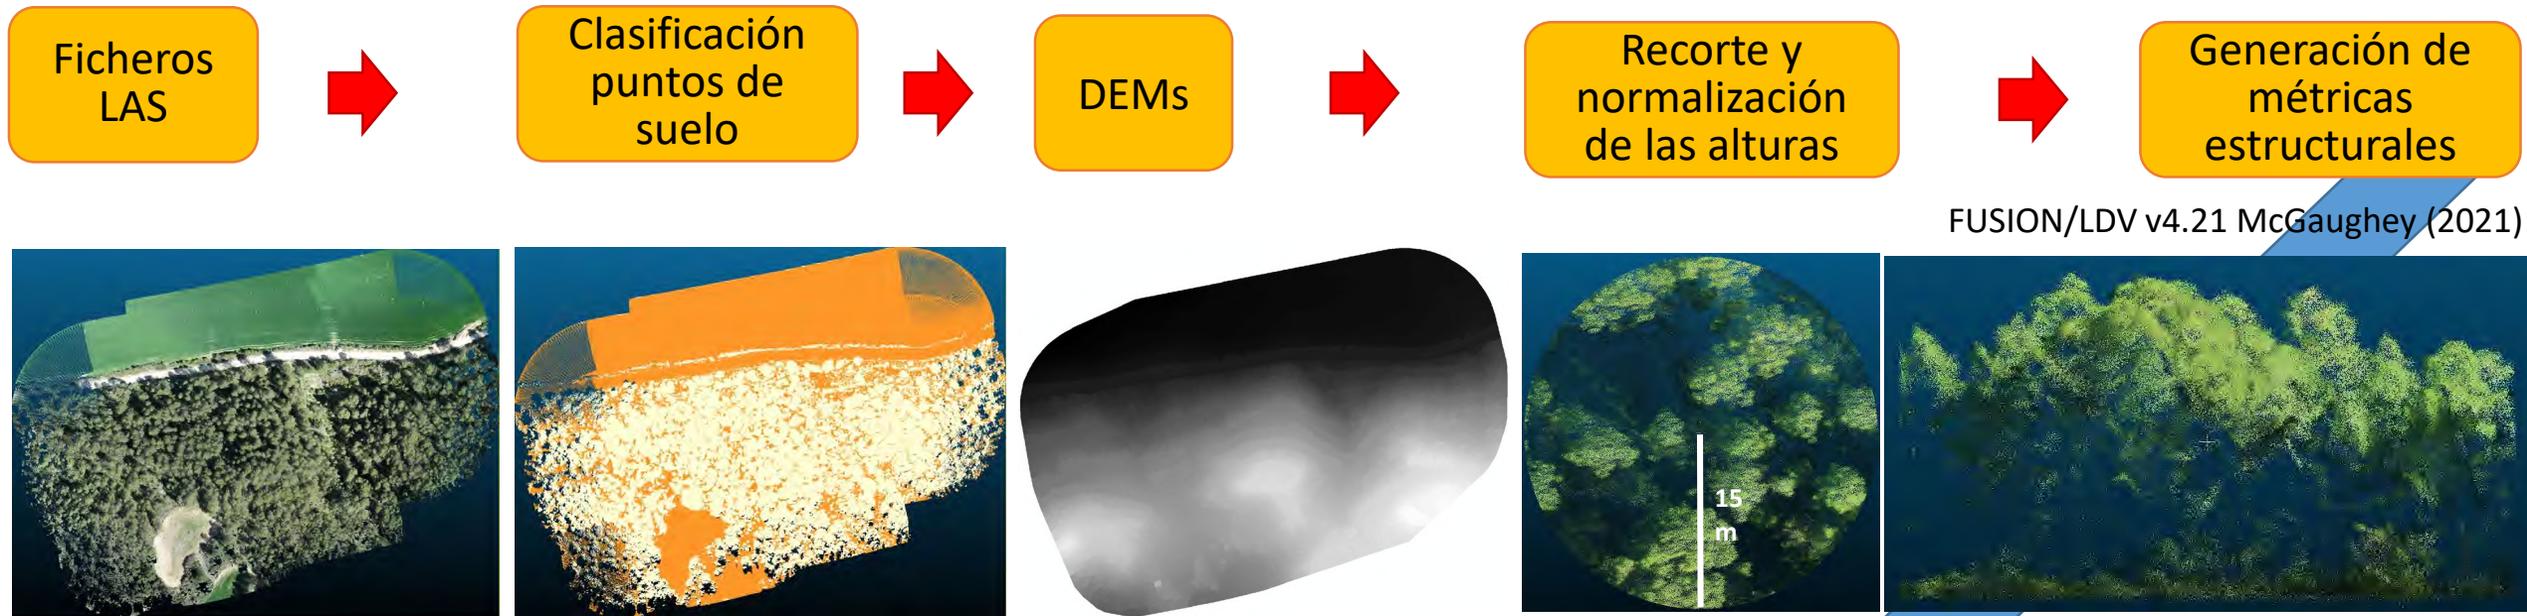
DJI Zenmuse L1 (LiDAR)



DJI Matrice 300 RTK

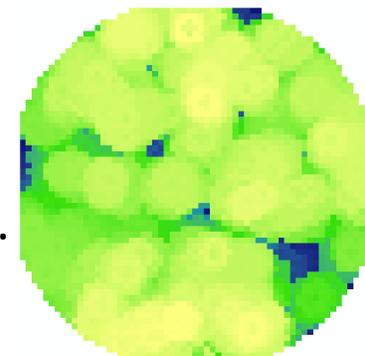


Generación de métricas LiDAR



FUSION/LDV v4.21 McGaughey (2021)

- **Distribución de las alturas:** Altura mínima, máxima, media; percentiles de altura.
- **Variabilidad de las alturas:** Varianza, desviación estándar, coeficiente de variación.
- **Densidad del dosel:** Total y porcentaje de puntos a umbrales de altura (< 0,60, 0,60-2, 2-4, >4 m).
- **Índices de diversidad estructural:** LHDI, LHEI, rumple index.

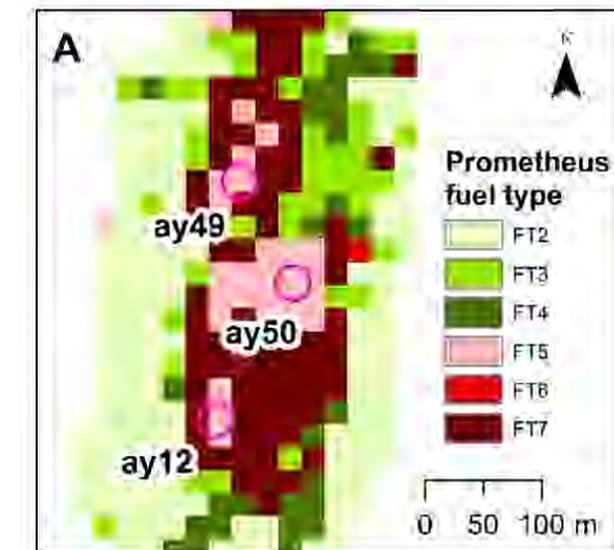
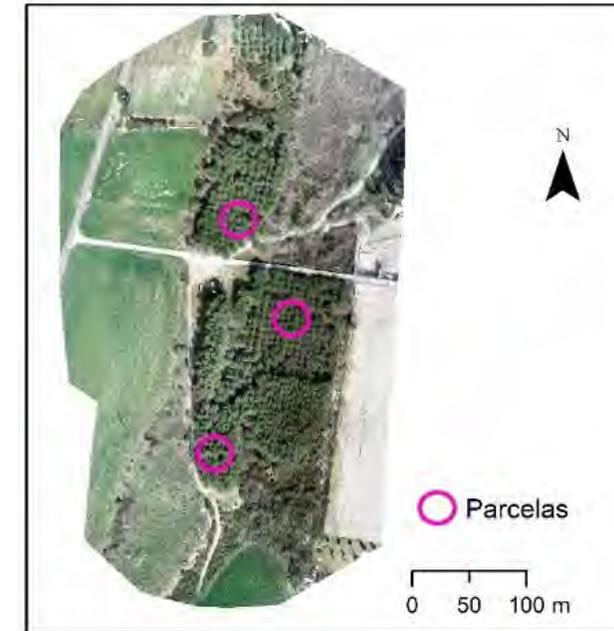
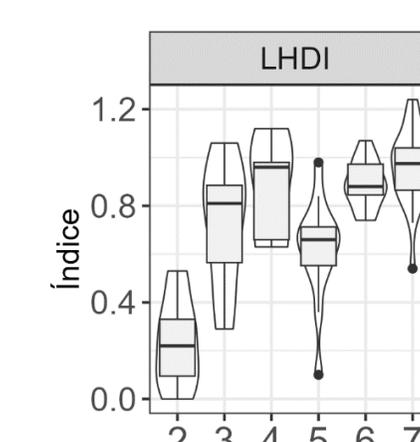
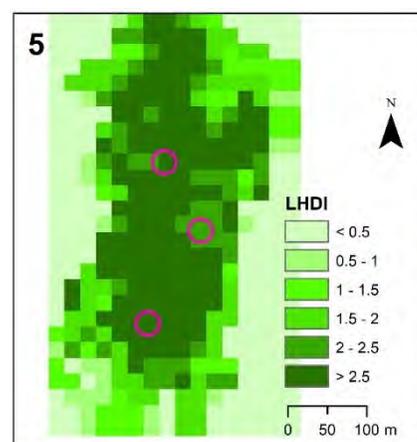
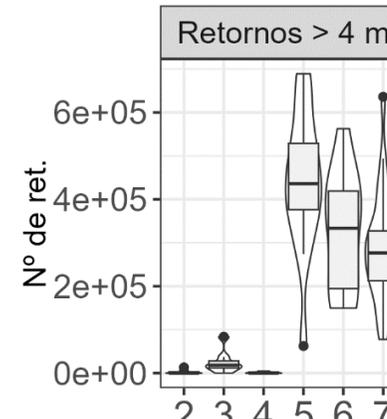
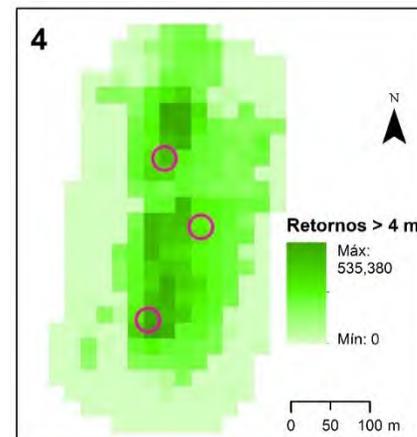
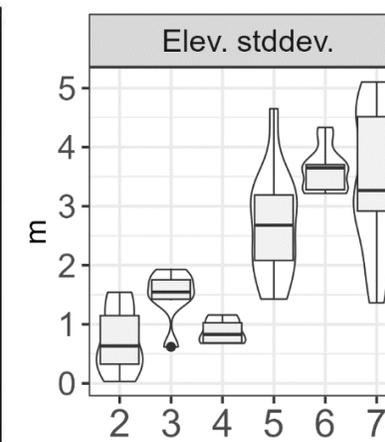
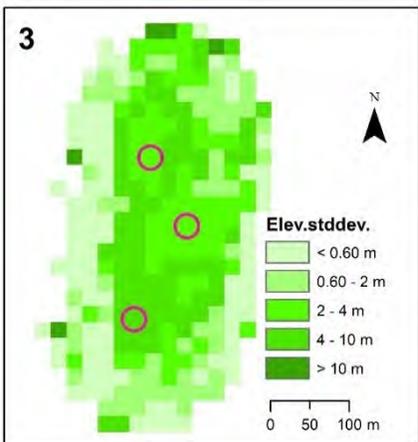
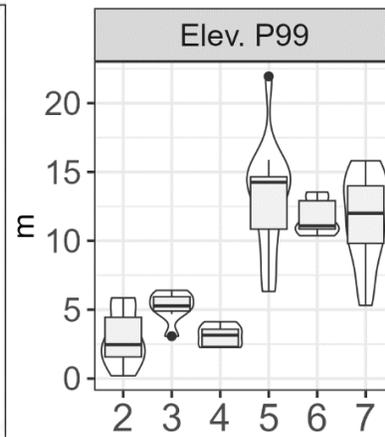
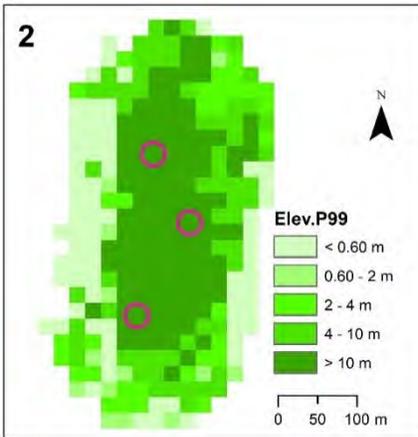
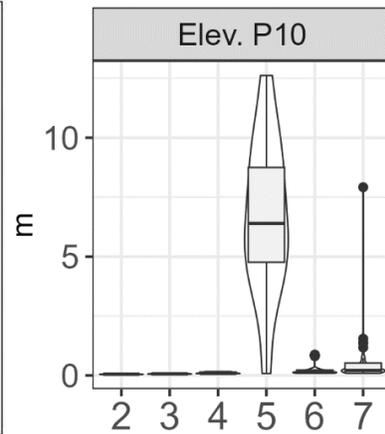
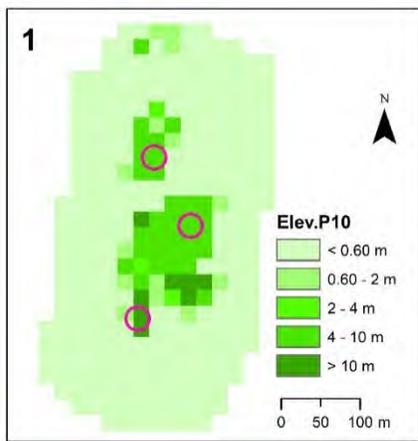


Aragón

73 parcelas UAV
43 parcelas HMLS

Modelos RF: 81,3%
SVM-L: 75,1% / SVM-R: 78,3%

Variables seleccionadas para los modelos de clasificación



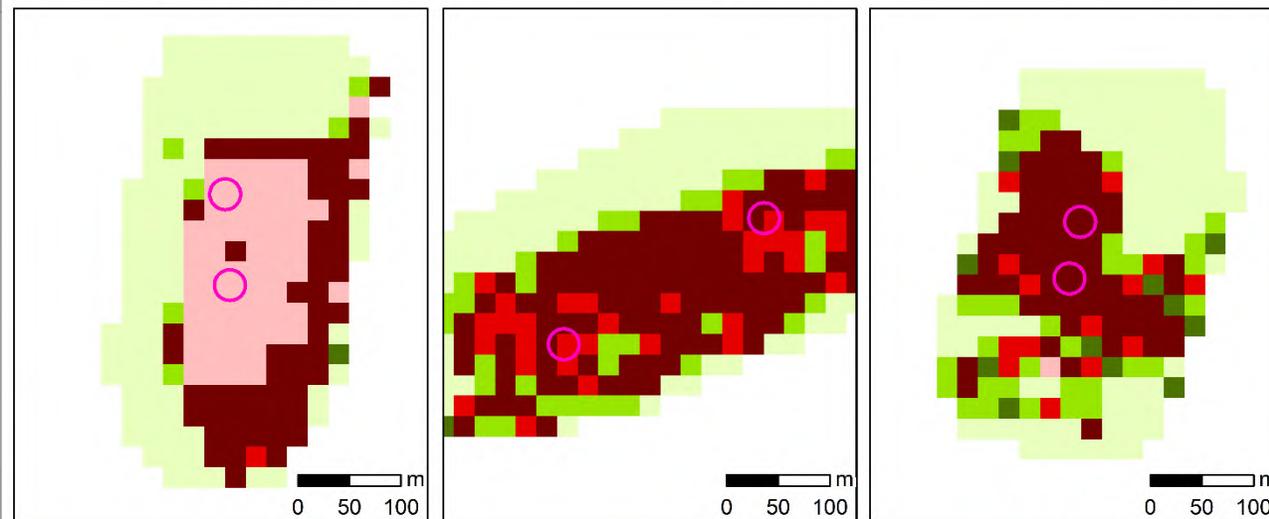
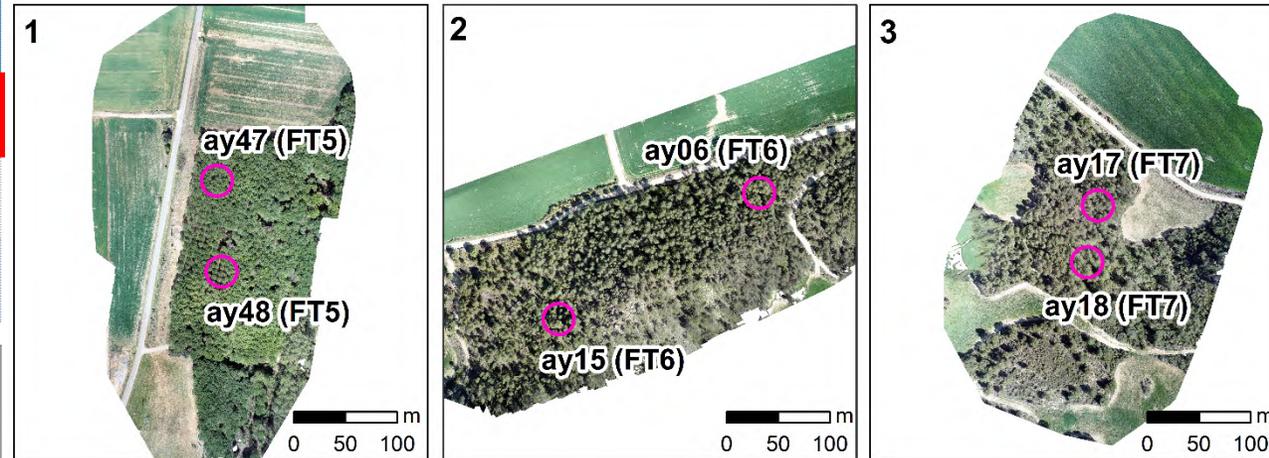
Tipos de combustible

Tipos de combustible

Evaluación del rendimiento de los modelos

Espacialización del mejor modelo (RF) (resolución: 20 m)

Modelo de clasificación	Coefficiente "accuracy"
RF	81,28%
SVM-L	75,10%
SVM-R	78,32%



○ Forest plots
 ▲ Prometheus fuel types:
 ■ FT1-FT2
 ■ FT3
 ■ FT4
 ■ FT5
 ■ FT6
 ■ FT7

Tipo comb.	2	3	4	5	6	7	User acc.
2	99	20	0	0	0	0	83%
3	10	42	0	10	0	8	60%
4	1	0	50	0	0	0	98%
5	0	0	0	120	0	10	92%
6	0	0	0	0	91	31	75%
7	0	8	0	10	29	191	80%
Prod. acc.	90%	60%	100%	86%	76%	80%	

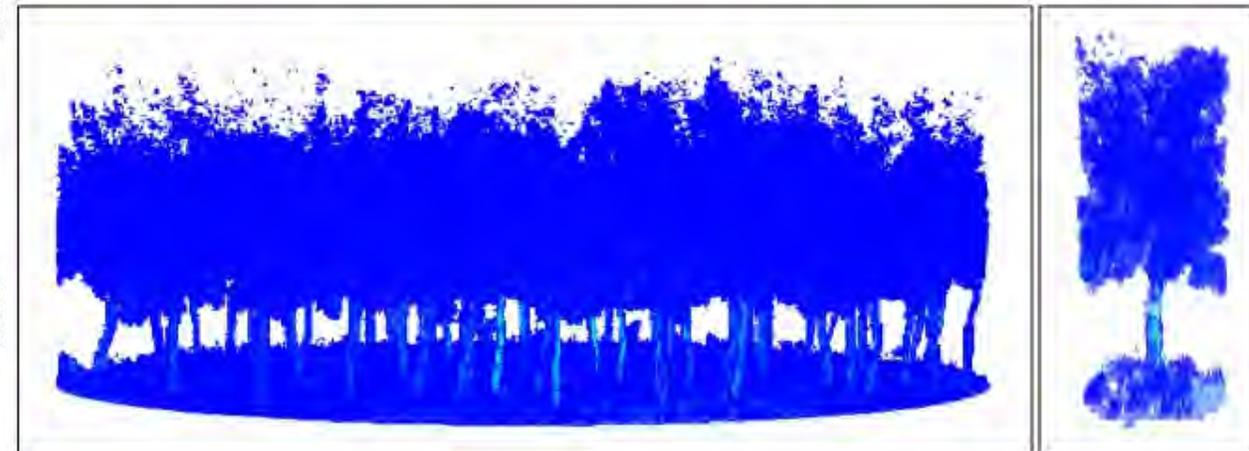
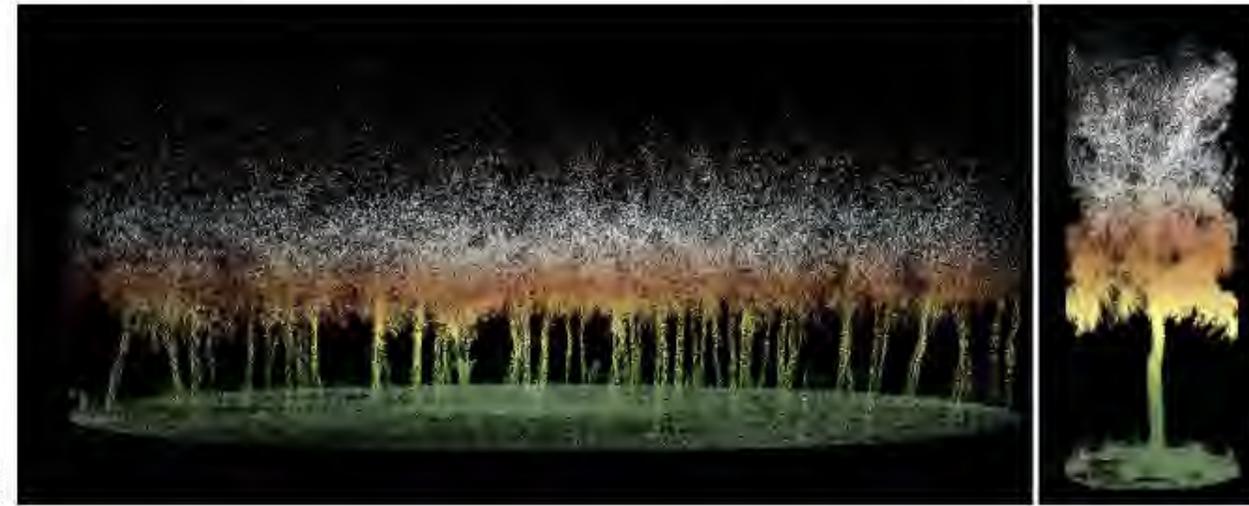
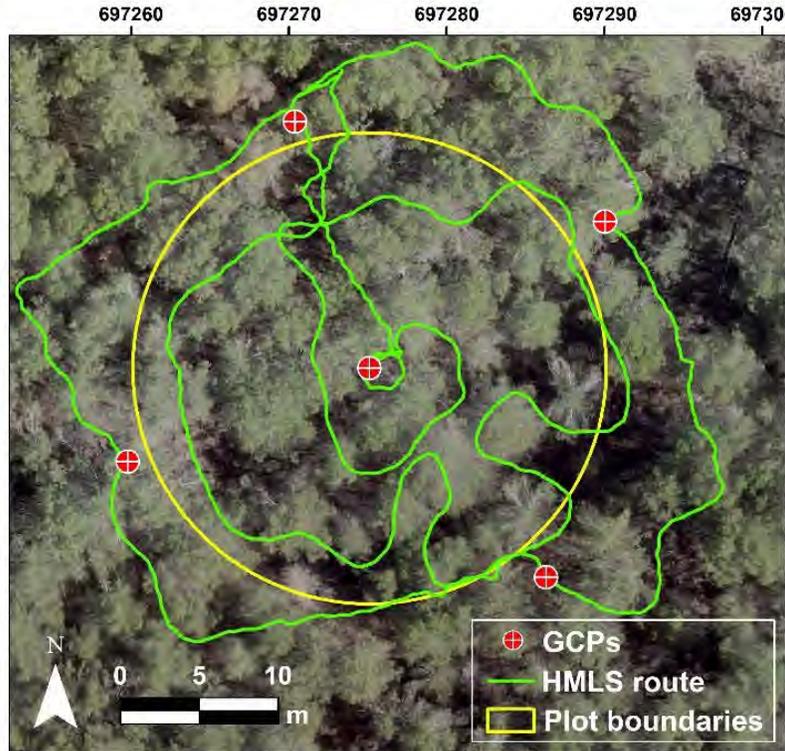


Article

Evaluation of Handheld Mobile Laser Scanner Systems for the Definition of Fuel Types in Structurally Complex Mediterranean Forest Stands

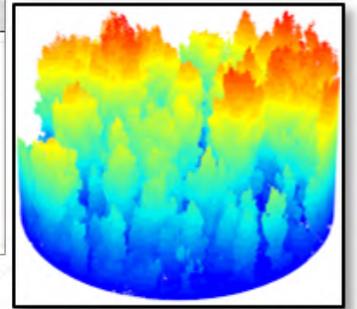
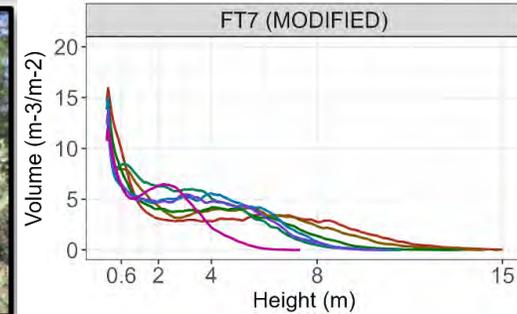
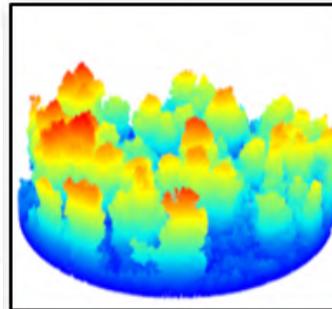
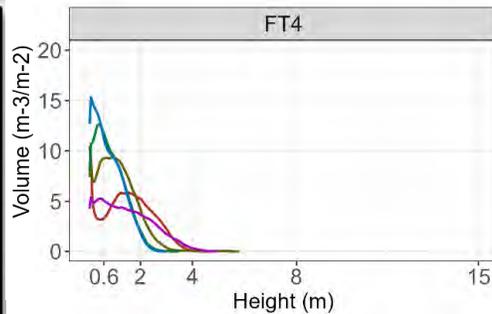
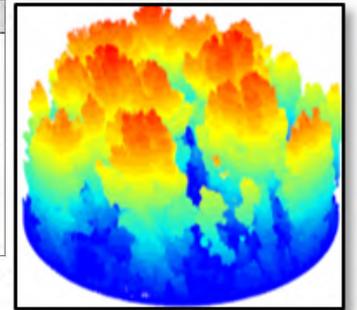
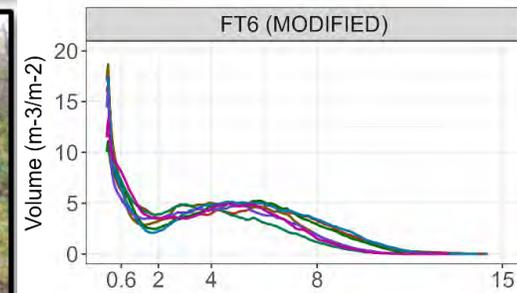
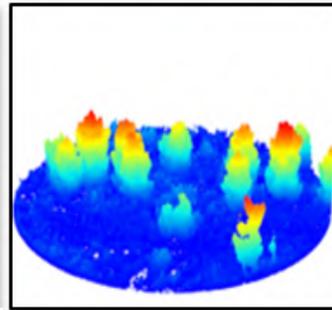
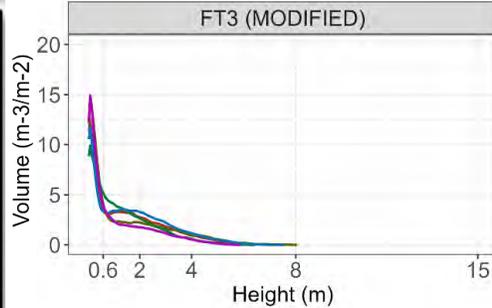
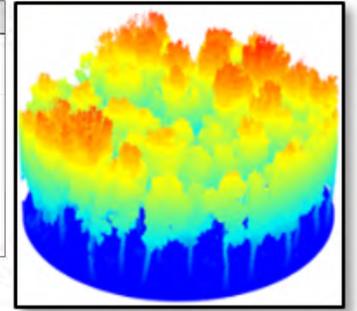
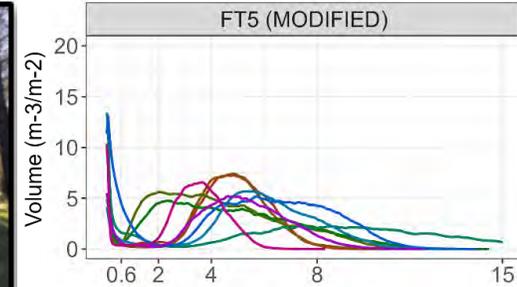
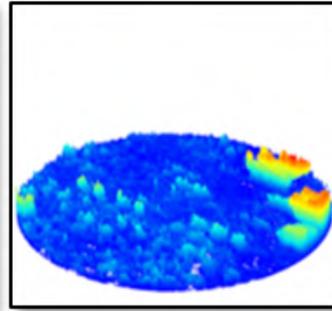
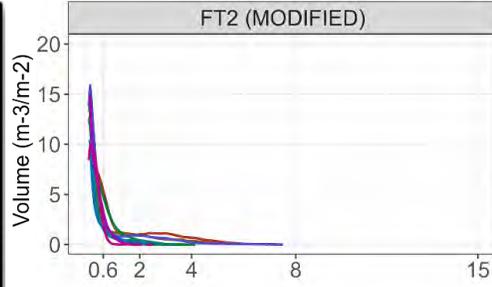
Raül Hofirén ^{1,2}, Maria Teresa Lamelas ^{2,3} and Juan de la Riva ^{1,2,4}

HMLS unit



<https://doi.org/10.3390/fire7020059>

Definition of vertical distribution of fuel volume by Prometheus fuel types in structurally complex forest stands

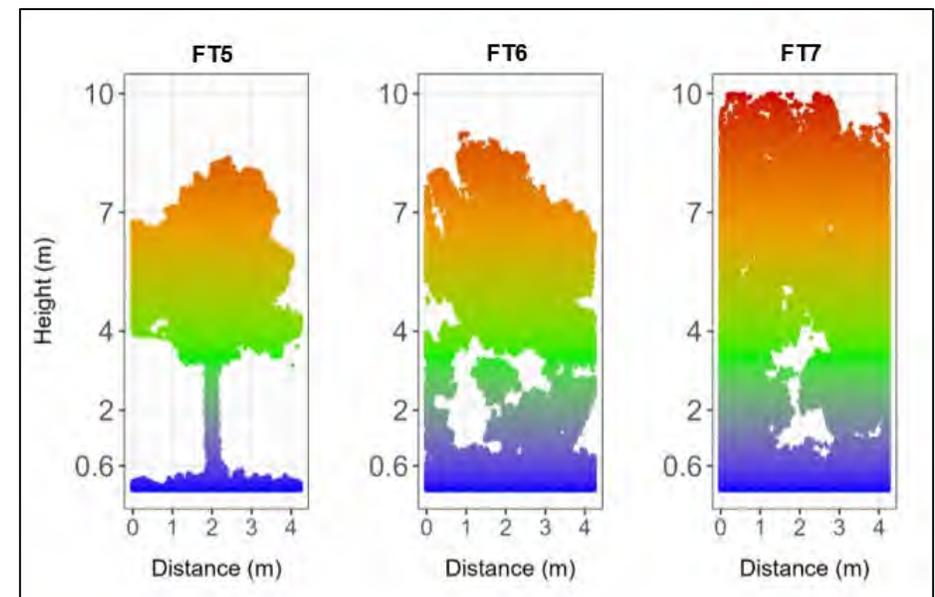
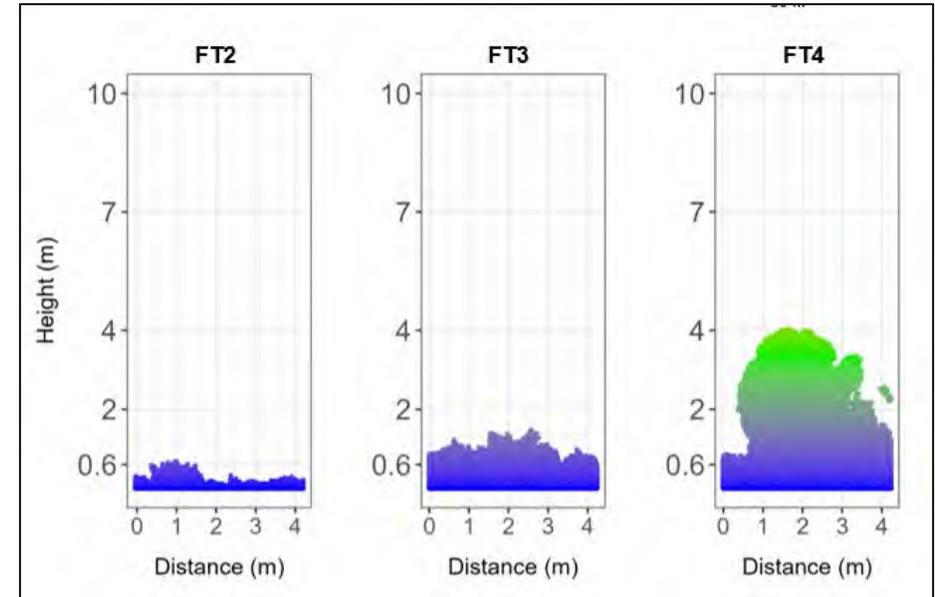
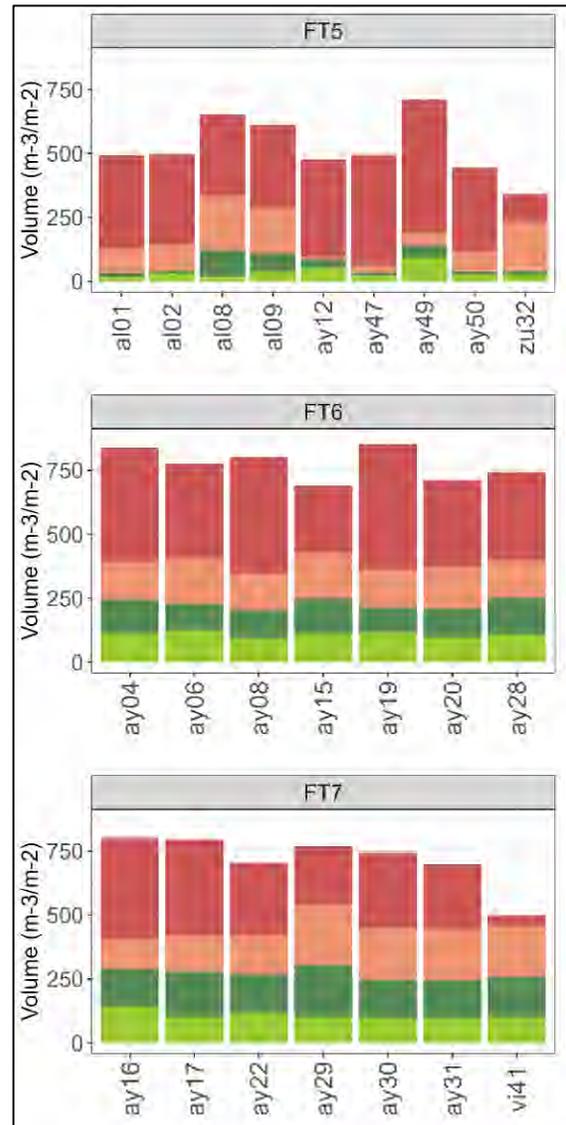
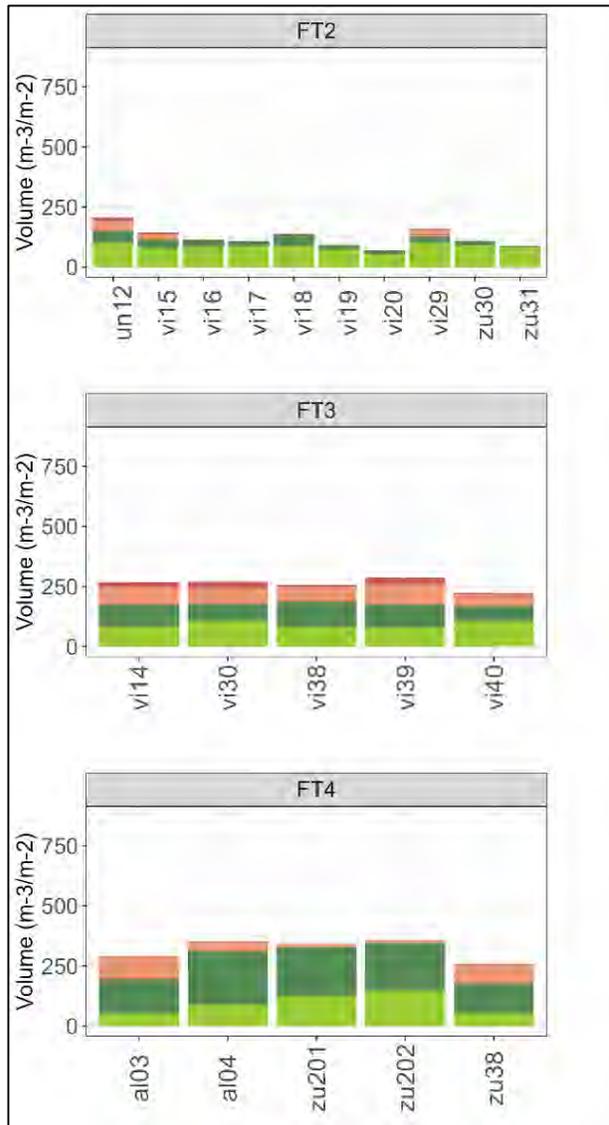


Combustibles HMLS

Aragón

43 parcelas

Medición directa /
Voxelización / Identificación



Conclusión

Año / Tema	Área estudio	Nº parcelas	Método	Ajuste	DOI
2014 – Severidad fuego	Aragón	4 incendios	Estimar severidad de incendio medida en campo (CBI) con variables LiDAR: regresión logística	Severidad: 85,5% precisión	https://doi.org/10.3390/rs6054240
2016 – Variables estructurales	CENAD	45 parcelas inventario	Regresión lineal multivariante	Hm (0,87 R ²), Dg (0,84 R ²), G (0,89 R ²), V (0,89 R ²), N (0,48 R ²), CR (0,60 R ²)	https://doi.org/10.1093/forestry/cpw008
2017 - Estimación AGB y emisiones de CO ₂ ante potencial incendio	CENAD	45 parcelas inventario	Regresión lineal multivariante y análisis de parámetros que afectan a la precisión del modelo	AGB: 0,84 R ² ; 27,35 %RMSE. La pendiente, orientación, cobertura, ángulo de escaneo y nº de retornos laser no afecta a la estimación.	https://doi.org/10.1080/15481603.2017.1320863
2017 - Pérdida biomasa y emisión CO ₂	Prepirineo	46 parcelas inventario en 1 incendio	Biomasa pre-fuego. Biomasa perdida (dNBR y factores de eficiencia de combustión). Carbono y emisiones de CO ₂ .	Regresión lineal multivariante: 0,88 R ² ; 11,08 %RMSE	https://doi.org/10.1080/22797254.2017.1336067
2018 - Biomasa total	CENAD - Ayerbe	83 parcelas inventario	Actualización de inventarios a año LiDAR. Métodos de selección de variables. Modelado (paramétrico y no paramétrico)	Selección por todos los subconjuntos. Regresión lineal multivariante: 0,87 R ² ; 19,21 %RMSE	https://doi.org/10.3390/rs9040158
2019 - Biomasa residual	Aragón	192 parcelas inventario	Actualización de inventarios a año LiDAR. Métodos de selección de variables. Modelado (paramétrico y no paramétrico). Análisis de parámetros que afectan a la precisión del modelo.	Selección variables: Spearman. SVM con kernel radial: 0,82 R ² ; 26,38 %RMSE. Incremento precisión: densidad (> 1p/m ²), menor ángulo de escaneo (<5°) y mayor penetración del pulso en el dosel (75%). Menor precisión: pendientes elevadas (>15%)	https://doi.org/10.1080/15481603.2019.1641653
2019 - Transferibilidad temporal	CENAD - Sistema Ibérico	147 parcelas inventario	Actualización datos campo: modelo de crecimiento de árbol individual (PHRAGON-2017). Comparación enfoque directo e indirecto (LiDAR multitemporal).	Enfoque directo proporciona resultados similares al indirecto y reduce el tiempo y costes de inventario y generación de modelos. Selección por todos los subconjuntos. SVM con kernel radial (N, Ho, G, Do, Dg, V, W): 0,6-0,9 R ² ; 8,8 - 48,1 %RMSE	https://doi.org/10.3390/rs11030261
2020 – Diversidad estructural en zonas incendiadas	CENAD	6 incendios	Distinguir con variables LiDAR: quemado vs no quemado; fecha del incendio; incendios antiguos vs recientes. Análisis de diferencias estadísticamente significativas (Kruskal-Wallis) y modelos de clasificación (k-NN; SVM; RF).	Incendios recientes: 70% retornos LiDAR en estrato herbáceo y arbustivo; bajos valores de diversidad estructural. Incendios hace 20 años: recuperación parcial estrato arbustivo y arbolado y valores diversidad estructural. Clasificación quemado vs no quemado RF 89% ; fecha incendio SVM 69%; incendio antiguo vs reciente SVM 75%.	https://doi.org/10.1080/15481603.2020.1738060
2021 - Severidad fuego y cambios estructurales	Incendio Moncayo (ZGZ)	1 incendio	Cambios estructurales generados por incendio (LiDAR multitemporal prefuego y 4 años postfuego) y correlación con la severidad del incendio (dNBR) en masas de quercinias y pinar.	Disminución de altura, densidad del dosel, variabilidad y diversidad estructural (menos estratos). Huecos más grandes y reducción de huecos pequeños. Alta correlación severidad vs descenso de la densidad del dosel (encinar). Alta correlación severidad vs descenso de altura y variabilidad estructural (pinar).	https://doi.org/10.7818/ECOS.2103
2023 - Estado conservación	Navarra robledales (Red Natura 2000)	3 zonas	Clasificación de estado de conservación de masas de robledal (cobertura, pendiente y altura) con LiDAR y Sentinel-2 (RF, SVM)	RF 83% Quercus robur (9160); 76% Quercus pyrenaica (9230); 88% Quercus faginea (9240). Sentinel 2 no mejora las clasificaciones sustancialmente.	https://doi.org/10.3390/rs15030710

Conclusión

Año / Tema	Área estudio	Nº parcelas	Método	Ajuste	DOI
2015 - Combustibles PNOA - SAR - Spot5	CENAD	108 parcelas	Clasificación digital (Máxima probabilidad)	72,7% acierto global, Kappa 0,7	http://cud.uvigo.es/imagenes/Documentacion/des/eid2015/actas2015.pdf
2020 - Combustibles PNOA y Sentinel 2	Este de España	136 parcelas / 3 incendios	Clasificación (RF, SVM) con LiDAR y Sentinel-2	SVM-R: 59% / P25 - % retornos sobre la media, Rumble, NDVI	https://doi.org/10.3390/rs12213660
2021 - Combustibles DART	CENAD	104 parcelas	Modelos de transferencia radiativa	2011 SVM-L: 0,88 - 2016 SVM-R / 0,91 - P80, Elevación LCV, Media 0-0,6, Rumble, LHDl	https://doi.org/10.3390/rs13030342
2023 - Combustibles GEDI	CENAD	2 cartografías previas	Clasificación (RF, SVM) con GEDI (59.554-9.703-1.112 huellas) y Landsat 8 OLI	SVM-LR: 83,71 / P85, Plant Area Index, Aboveground Biomass Density de GEDI, Brillo Landsat-8 OLI	https://doi.org/10.1016/j.jag.2022.103175
2023 - Combustibles Fotogrametría dron	Aragón	82 parcelas	Nubes de puntos RGB: 3000 ptos/m ² ; multiespectral: 85 ptos/m ²). P50, coef. variación, % retornos >4 m, disimilitud textural media y índice de clorofila verde	RF: 71% / muestra de datos integrada con nubes de puntos normalizadas a 0,5 m de DEM	https://doi.org/10.1016/j.rsase.2023.100997
2024 - Combustibles LiDAR UAV y HMLS	Aragón	73 parcelas UAV 43 parcelas HMLS	Modelos RF: 81,3% SVM-L: 75,1% / SVM-R: 78,3%		IN PRESS
2024 - Combustibles HMLS	Aragón	43 parcelas	Medición directa / Voxelización / Identificación		https://doi.org/10.3390/fire7020059

91,3 %

83,7 %

71 %

81,3 %