



2022
Lleida

27 · 1
junio · juny
juliol · juliol

Cataluña
Catalunya

8º CONGRESO FORESTAL ESPAÑOL

La **Ciencia forestal** y su contribución a
los **Objetivos de Desarrollo Sostenible**

8CFE

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

Delimitación y cuantificación de los daños forestales producidos por “Filomena” mediante técnicas de teledetección en la Comunidad de Madrid

TOMÉ MORÁN, J.L.¹, ESTEBAN CAVA, J.¹, VACAS VEGA, M.B.², QUIÑONES LAINEZ, I.¹, MONTERO JUMÉNEZ, M.¹ y MARTÍN ALCON, S.¹

¹ AGRESTA Sociedad Cooperativa.

² Área de Conservación de Montes. Consejería de Medio Ambiente, Ordenación del Territorio y Sostenibilidad. Comunidad de Madrid.

Resumen

Entre el 6 y el 10 de enero de 2021 España sufrió los efectos de la borrasca “Filomena” que fueron especialmente severos entre el 8 y el 9 de enero, cuando se produjo una gran nevada que llegó a acumular más de 50 cm de nieve en el centro y este de la Comunidad de Madrid. Esto provocó importantes sobrecargas de nieve en masas forestales no adaptadas a estas condiciones climáticas, lo que derivó en daños en grandes superficies con roturas de ramas, copas e incluso derribos de pies.

Mediante este trabajo se elaboró una cartografía de daños originados por la borrasca, determinando tanto su nivel de afección como la estimación de la biomasa forestal muerta, en las masas arboladas de las comarcas de gestión forestal más afectadas de la Comunidad.

Para ello, se combinaron datos recogidos en un muestreo de más de 140 parcelas de campo, con información de índices de vegetación calculados a partir del procesado y análisis de cambios realizado sobre imágenes del satélite Sentinel-2 de los años anterior (febrero-marzo 2020) y posterior (febrero-marzo 2021) al temporal. A partir del diagnóstico del nivel de afección temporal se ha calculado la biomasa muerta mediante inventario forestal con LiDAR.

Palabras clave

Perturbaciones, Sentinel-2, LiDAR, sensores Remotos, daños.

1. Introducción

La borrasca Filomena, se formó en el este de los Estados Unidos entre los días 1 y 2 de enero de 2021, desplazándose hacia Europa arrastrada por una rama meridional del chorro polar y llegando hasta las Azores hacia el martes 5 de enero, cuando fue nombrada por la AEMET.

Aunque sufrimos sus efectos entre el 6 y el 10 de enero, la gran nevada generada por la borrasca en el interior de la península tuvo lugar en los días 8 y 9 de enero, llegando a acumular hasta 60 cm de nieve en las zonas del centro y este de la Comunidad de Madrid (Figura 1), incluida la capital. Tras desaparecer Filomena, el domingo 10 dio inicio una ola de frío que duró hasta el domingo 17 histórica por los registros alcanzados.

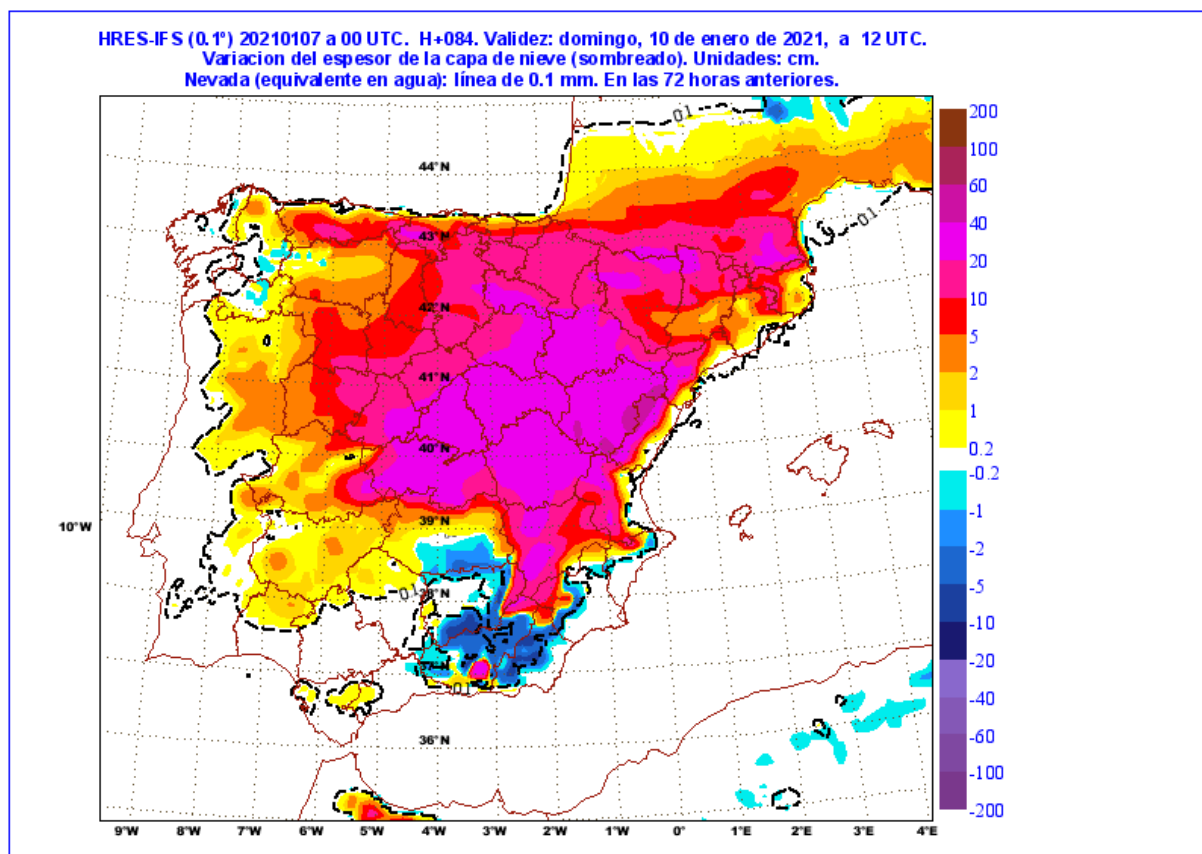


Figura 1. Variación del espesor de la capa de nieve en los tres días previos a las 00 UTC del 10 de enero, modelo HRES-IFS del ECMWF. Fuente AEMET.

Este evento ocurrido en plena pandemia afectó gravemente al área metropolitana de Madrid y las comunidades autónomas de Madrid y Castilla la Mancha fueron declaradas “zonas catastróficas” por el gobierno.

Una consecuencia directa del temporal sobre los bosques del centro de la península fue la acumulación de hasta 60 cm de espesor de nieve sobre las copas de los árboles, que permaneció durante varios días en las mismas gracias a la ola de frío posterior. En concreto en la Comunidad de Madrid, la nevada afectó con mayor intensidad a las masas forestales de la mitad sur, que no están adaptadas a soportar esta sobrecarga de nieve lo que provocó la rotura de ramas y copas (por rotura del fuste) en grandes superficies. En concreto las masas más afectadas en la comunidad han sido los pinares de pino piñonero (*Pinus pinea*), carrasco (*Pinus halepensis*) o rodeno (*Pinus pinaster*) y las frondosas de hoja perenne representados fundamentalmente por los encinares tanto en monte bajo como adehesados: (*Quercus ilex*).

Como resultado de estos fenómenos, miles de hectáreas fueron dañadas, causando una importante acumulación de biomasa muerta que puede causar o agravar incendios forestales y favorecer la propagación de plagas forestales.

La utilización de fuentes de datos satelitales tiene un gran potencial en el campo de la gestión y prevención aprovechando su alta resolución temporal y espacial. Es cierto que los datos recogidos en campañas de campo pueden también proporcionar información muy exhaustiva para la determinación de los daños forestales asociados con eventos meteorológicos extremos. Sin embargo, una de las principales limitaciones de los inventarios tradicionales es su elevado coste. En este sentido la integración de los muestreos tradicionales con información de sensores remotos es

un aspecto clave ya que permite reducir costes y obtener cartografías espacialmente explícitas al poder disponer de imágenes antes y después del temporal. En el año 2005 ya se demostró el potencial de las imágenes Landsat para evaluar de forma efectiva los daños causados en los montes de Canadá por una tormenta de nieve (King et al., 2005). Desde entonces se han ido desarrollando metodologías similares evaluando la capacidad de otros satélites con distintas características obteniéndose resultados muy favorables (Tomppo et. al., 2019; Tomppo et. al., 2021; Wang et al., 2019).

2. Objetivos

La Dirección General de Biodiversidad y Recursos Naturales, de la actual Consejería de Medio Ambiente, Vivienda y Agricultura de la Comunidad de Madrid tiene encomendadas, entre otras, las competencias autonómicas en materia de biodiversidad, montes, recursos naturales y aprovechamientos forestales, la promoción de la mejora del patrimonio natural y las actuaciones en materia de planificación, protección, conservación y restauración.

Como parte de las medidas emprendidas por esta Dirección General tras la tormenta se encargó el presente estudio que pretende delimitar y cuantificar estas afecciones en las comarcas de gestión forestal más afectadas: VI (Alcalá de Henares), VII (Este), VIII (Parque Regional (PR) del Sureste), IX (PR del Guadarrama), X (San Martín de Valdeiglesias), XI (Robledo de Chavela) y XV (PR de la Cuenca Alta del Manzanares).

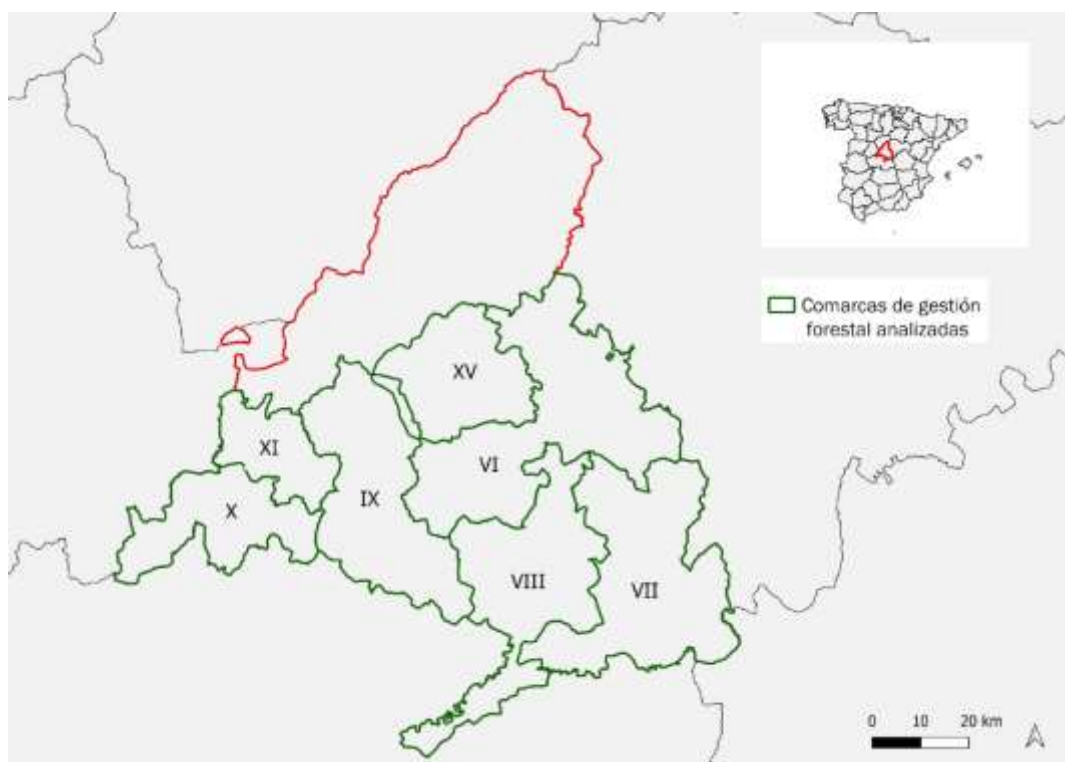


Figura 2. Localización de las comarcas de gestión forestal analizadas en la Comunidad de Madrid para la determinación del daño causado por la tormenta Filomena en enero 2021.

El objetivo fundamental es generar información orientada a cumplir con sus competencias utilizable en actuaciones tales como:

- La planificación de actividades de restauración de las superficies forestales afectadas y de infraestructuras en el medio forestal (vías forestales, senderos, etc.).
- La planificación de actividades de restauración en zonas con importante uso público en los montes gestionados por esta Dirección General.
- La planificación de actividades de restauración de los hábitats naturales y hábitats de especies afectados en zonas de alto valor ecológico dentro de espacios naturales protegidos o espacios protegidos Red Natura 2000.
- La planificación de una línea de subvenciones dirigida a financiar tratamientos silvícolas de restauración en fincas privadas.

Por otro lado, compartir esta información con la administración competente en materia de prevención y extinción de incendios forestales para utilizar en:

- La planificación de actuaciones de prevención de incendios forestales.
- La planificación de las labores de extinción de incendios forestales.
- La actualización de la cartografía de modelos de combustible,

3. Metodología

La metodología utilizada (Figura 2) para la identificación, delimitación y cuantificación de daños (en términos de biomasa forestal muerta) se basa los trabajos desarrollados por Santiago Martín Alcón y sus colaboradores en un estudio similar desarrollado tras un temporal de viento y nieve en la Comunidad Valenciana (Martín Alcón et al., 2019). En la siguiente figura se puede apreciar el flujo de trabajo adaptado al presente estudio con objeto de cuantificar la incidencia del temporal:

1. Análisis de cambios utilizando series temporales de imágenes satelitales de Sentinel-2 anteriores y posteriores al temporal para obtener un estimador de la magnitud del cambio.
2. Inventario de campo de afección (porcentaje de biomasa muerta) en un conjunto de parcelas localizadas en montes públicos y privados de las comarcas objetivo de la Comunidad de Madrid representativos en cuanto a formaciones forestales y niveles de afección por el temporal.
3. Generación del modelo predictivo definitivo para el nivel de afección, es decir, de la proporción de biomasa muerta.
4. Estimación de la biomasa forestal existente con anterioridad al temporal mediante LiDAR y extracción de la biomasa forestal muerta como consecuencia del mismo.
5. Evaluación y presentación de los resultados

En la identificación de las zonas con daños producidos por la nevada y cuantificación de los mismos se han generado índices de cambio utilizando series temporales de imágenes del satélite Sentinel-2 del programa Copernicus de la ESA (European Spatial Agency). La misión Sentinel-2 se compone de dos satélites (2A y 2B) con una resolución temporal de entre 3 y 4 días en nuestras latitudes, que proporcionan imágenes multispectrales con 13 bandas en el espectro visible, infrarrojo cercano e infrarrojos de onda corta además del espectro electromagnético y resoluciones espaciales de 10, 20 y 60 m en función de la banda. En concreto la zona de estudio de la Comunidad de Madrid abarca 4 escenas: 30 TUL, 30 TVL, 30 TUK y 30 TVK.

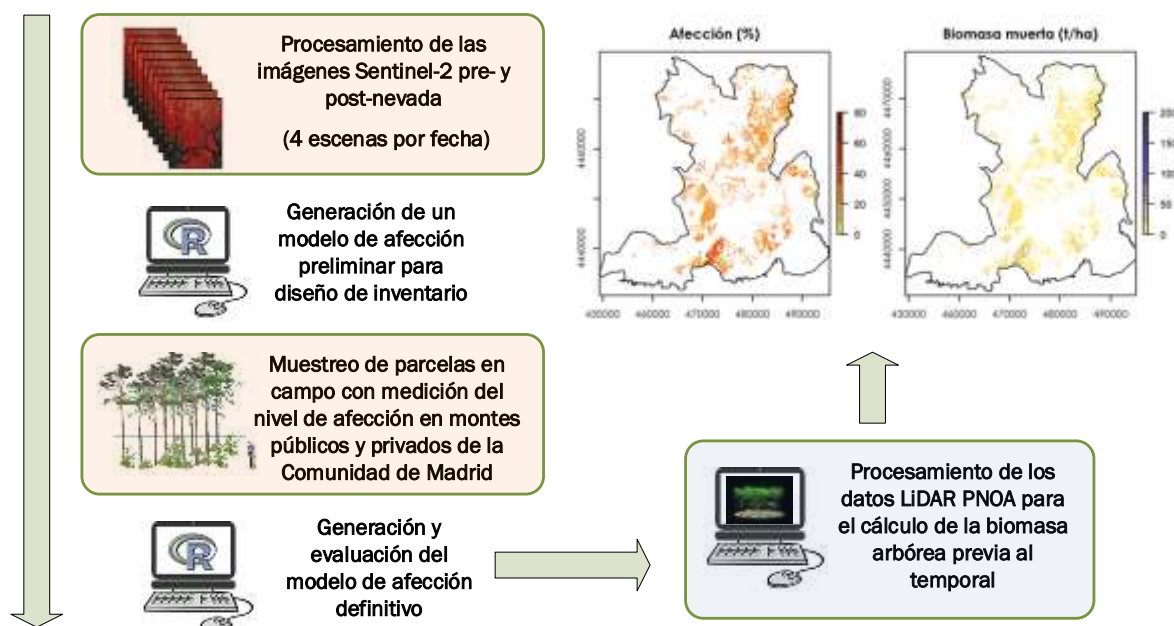


Figura 2. Esquema de la metodología aplicada.

Para el análisis de cambios es necesario utilizar imágenes anteriores y posteriores al temporal que posibiliten que la comparación realizada se hace en un momento equivalente fenológicamente hablando. Se ensayaron resultados tanto con imágenes de febrero como con imágenes de marzo, para lo cual se descargaron todas las imágenes disponibles con cobertura nubosa inferior al 40%. Tal y como se puede apreciar en la tabla 1 el mes de febrero de los años 2020 y 2021 fue mucho más nuboso que el mes de marzo, haciendo necesario el uso de un mayor número de imágenes y trabajar con compuestos temporales libres de nubes y sombras. Por lo tanto, los primeros pasos metodológicamente hablando implicaron la descarga de las imágenes de cada escena y fecha, incluyendo todas las bandas espectrales, y transformando todas ellas a una resolución de 20 metros.

Tabla 1. Imágenes incluidas en las series temporales utilizadas en el análisis de cambios para el periodo anterior y posterior al temporal (AAAA/MM/DD).

Mes	Periodo pre-temporal	Periodo post-temporal
Febrero	2020/02/12	2021/02/02
	2020/02/18	2021/02/05
	2020/02/16	2021/02/07
	2020/02/23	2021/02/10
	2020/02/26	2021/02/12
		2021/02/22
		2021/02/27
Marzo	2020/03/14	2020/03/14
		2021/03/31

Posteriormente se realizó un procesado de las imágenes seleccionadas para la conversión del nivel 1C (Top-of-atmosphere reflectances) al 2A (Bottom-of-atmosphere reflectances), mediante el plugin Sen2Cor de la ESA. Una vez hecho eso, se aplicaron los algoritmos de clasificación automática de la ESA de cara a la eliminación de todo aquello no identificado como vegetación. A continuación, se realizó un mosaicado de las series temporales, con el fin de obtener una sola

imagen libre de defectos para el periodo anterior y otra para el periodo posterior al temporal. Para ello, se calcula el NDVI (*Normalized Difference Vegetation Index*) de cada fecha y se genera una nueva imagen en la que cada píxel de cada banda toma el valor de la banda correspondiente en la fecha en la que dicho píxel tiene el mayor valor del índice NDVI. Esto se realiza por una parte con la serie anterior, y por otra con la posterior al temporal. Debido a la gran variedad de imágenes utilizadas en el mes de febrero este paso se replicó para las imágenes de febrero y las de marzo, que se trataron de manera independiente con objeto de analizar si generar un compuesto temporal de mayor calidad con un número menor de impactos podría permitir mejorar el modelo.

Partiendo de estos compuestos de imágenes, se seleccionaron aquellas bandas espectrales que aportan información relevante sobre el estado de la vegetación y el contenido de la humedad ((B3 (verde), B4 (rojo), B8 (infrarrojo cercano medio), B11 y B12 (infrarrojo cercano medio)) y se procesaron tres índices de vegetación (IV) (Tabla 2) que ya habían probado su eficacia en estudios previos de detección de cambios (Martín Alcón et al., 2019). Posteriormente se calcularon las diferencias absolutas y relativas en el valor de los mismos entre los mosaicos anterior y posterior al temporal. Las diferencias relativas se calcularon como las diferencias absolutas entre el mosaico antes de la tormenta y también usando las siguientes ecuaciones:

$$\text{Ecuación (1)} \quad \text{dif absolutas} = \text{IV mosaico después} - \text{IV mosaico antes}$$

$$\text{Ecuación (2)} \quad \text{dif relativas} = \frac{\text{IV (mosaico después - mosaico antes)}}{\text{IV (mosaico antes)}}$$

$$\text{Ecuación (3)} \quad \text{dif relativas2} = \frac{\text{IV mosaico después} - \text{IV mosaico antes}}{\sqrt{\text{IV (mosaico antes)}}}$$

Tabla 2. Relación de índices de vegetación calculados y utilizados en el análisis de imágenes para la detección y cuantificación de los daños.

Índice de Vegetación	Cálculo con las bandas de Sentinel-2	Descripción
NDVI	$(B08 - B04) / (B08 + B04)$	"Normalized Difference Vegetation Index"
EVI	$2.5 * (B08 - B04) / (B08 + 6 * B04 - 7.5 * B02 + 1)$	"Enhanced Vegetation Index"
DSWI	$(B08 - B03) / (B11 + B04)$	"Disease Water Stress Index"

El diseño del inventario ha consistido en un muestreo aleatorio, dirigido a muestrear con un peso semejante los diferentes niveles de cambio observados a través de teledetección con objeto de estimar la proporción de la biomasa arbórea muerta como consecuencia del temporal. Se han priorizado los montes de las comarcas objetivo en los que los técnicos de la Comunidad de Madrid han reportado afección de la tormenta. Se han realizado un total de 149 parcelas de 11,3 m de radio (superficie equivalente al píxel de Sentinel 400 m²) repartidas por todas las comarcas objetivo (Figura 3), todas ellas levantadas con un GPS Trimble R2 de precisión submétrico, tratando de recoger la mayor variabilidad posible en cuanto a formaciones forestales y niveles de afección con la intención de que la muestra fuera lo más representativa posible del total de la zona afectada. En estas parcelas se ha tomado información al respecto de las especies presentes (principal, secundaria y respectivas ocupaciones), densidad medida a partir de la distancia al sexto árbol, porcentaje de biomasa muerta respecto al total mediante estimación visual y tipo de daño observado (ninguno, ramas rotas, pies tronizados y/o pies arrancados).

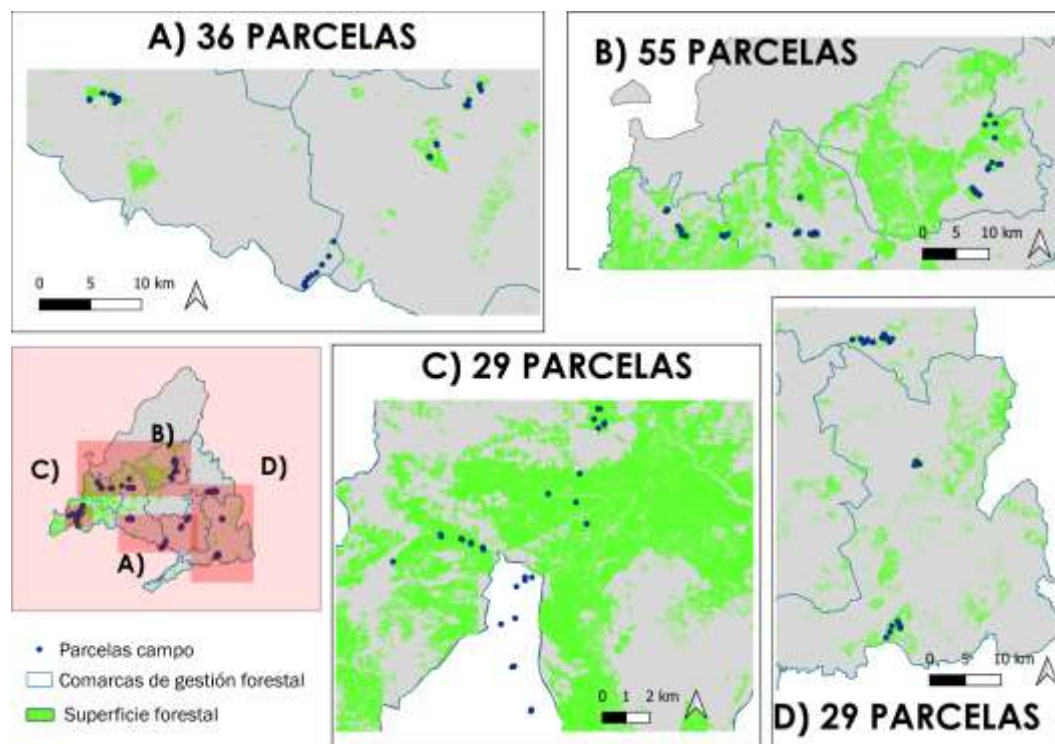


Figura 3. Localización de las parcelas de inventario realizadas, sobre la superficie forestal arbolada de las comarcas afectadas en la Comunidad Madrid.

Para la estimación de la biomasa forestal existente con anterioridad al temporal se han utilizado métodos de masa de inventario forestal con LiDAR. Estos métodos se basan en el ajuste de modelos de regresión que relacionan los estadísticos de la nube de puntos LiDAR, con las principales variables de masa forestal medidas en una muestra de parcelas de campo. La aplicación de los modelos a la información LiDAR procesada en continuo permite obtener cartografía de inventario forestal de alta resolución. Como fuentes de datos para la realización de los modelos se han utilizado el LiDAR del PNOA y las bases de datos del Inventario Nacional Forestal (IFN).

Tal como se puede ver en la siguiente figura, se ha trabajado aprovechando las dos coberturas LiDAR existentes en la Comunidad de Madrid. La primera cobertura se ha utilizado para el ajuste de modelos con parcelas del IFN4 ya que son prácticamente coetáneas, mientras que la segunda cobertura se ha utilizado para aplicar los modelos obtenidos sobre una cobertura LiDAR más moderna.

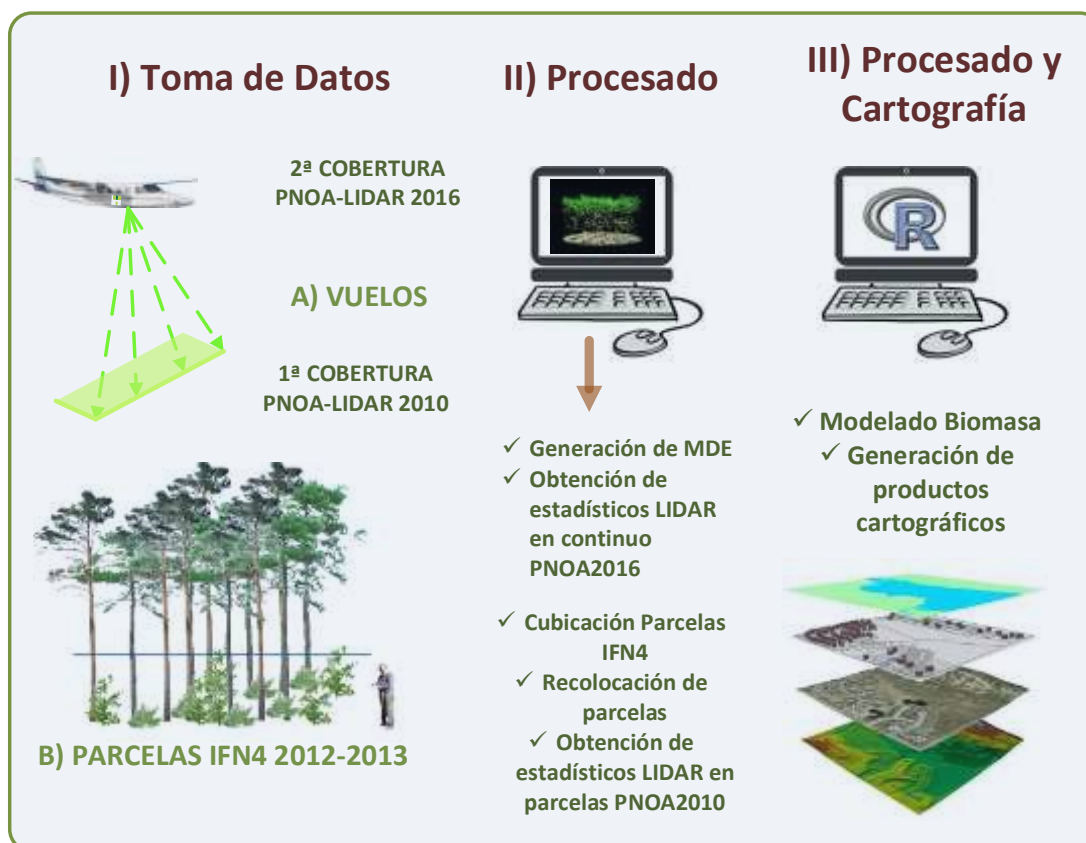


Figura 4. Flujo de procesado de los modelos de LiDAR para estimar la biomasa previa al temporal.

Todo el procesado LiDAR se realiza utilizando desarrollos de software propios de Agresta S. Coop. y trabajando sobre el paquete LidR (Roussel et al., 2020). El flujo de trabajo para el tratamiento de los datos LiDAR es el siguiente:

- 1 Generación de los modelos digitales del terreno (MDE) con de 2 metros de paso de malla a partir de los retornos del LiDAR.
- 2 Normalización de los retornos procedentes de la vegetación utilizando el MDE generado para transformar la elevación de cada uno de los retornos de vegetación en alturas sobre el nivel del mar en altura sobre el terreno.
- 3 Cálculo de estadísticos de los retornos de vegetación de la nube de puntos LiDAR en píxeles de 20 metros de lado (equivalente a la resolución espectral seleccionada). Para el cálculo de esta batería de estadísticos se utilizan únicamente los retornos que están por encima de 2 metros de altura sobre el suelo con objeto de eliminar posibles retornos derivados de afloramientos rocosos y matorral, caracterizando la vegetación arbórea mediante los principales estadísticos de elevaciones y coberturas.

Los modelos de biomasa de las especies objetivo se han calculado utilizando parcelas del IFN4 y datos LiDAR de 2010 en Madrid. Las parcelas del IFN4 levantadas en Madrid entre los años 2012 y 2013, se han recolocado para alcanzar una mejor precisión de cara a poder comparar los valores de campo con los valores de la nube de puntos LiDAR. Para trabajar con una superficie de parcela equivalente a la utilizada para la evaluación de daños 20x20m (400 m²) se han procesado las parcelas del IFN4 para un radio de 11,3 m, se han utilizado las ecuaciones de cubicación del IFN para la estimación de las variables de árbol individual.

Se ajustaron modelos no paramétricos mediante la técnica de modelización no paramétrica conocida como Random Forest (Breiman, 2001), utilizando el paquete ranfomForest (Liaw y Wiener, 2002) del software estadístico R (R Development Core Team, 2014) para la siguiente variable objetivo: volumen con corteza (V). Estos modelos se ajustaron para las principales especies forestales presentes en las comarcas objetivo: *Pinus halepensis*, *Pinus pinaster*, *Pinus pinea* y *Quercus ilex*.

A partir del V (m^3) y a través de los factores de expansión de biomasa aérea (FEBA, expresados en t/m^3), se obtiene la biomasa aérea en toneladas de materia seca. Para el cálculo de estos FEBA se parte del V, el cual se multiplica por el factor de densidad (FD), y se divide por el ratio de biomasa de fuste respecto al total de biomasa aérea (BF). Estos valores son específicos para cada especie y se han extraído de la monografía del INIA Producción de biomasa y fijación de CO₂ por los bosques españoles (Montero et al., 2005).

Finalmente, los modelos de biomasa aérea obtenidos se aplicaron espacialmente utilizando la especie principal extraída para cada píxel del área de trabajo del mapa forestal 1:25000 de la Comunidad de Madrid, con lo que se ha generó una cartografía continua de biomasa aérea de las especies estudiadas.

El modelo predictivo del nivel de afección en términos de proporción de biomasa muerta del total de biomasa aérea del estrato arbóreo se construyó utilizando Random Forest. Inicialmente se partió de un total de 24 variables candidatas a explicativas para el modelo predictivo, todas ellas derivadas del procesamiento de las imágenes de Sentinel-2. De estas variables, 8 eran las diferencias absolutas (Ecuación 1) entre los valores de los IV de las imágenes post y pre-temporal, otras 8 eran las diferencias relativas de esos mismos índices (Ecuación 2) y las últimas 8 las diferencias relativas calculadas según la ecuación 3 (Ecuación 3). Se generó una batería de distintos modelos predictivos para determinar qué tipo de variables predictoras de diferencias estaba generando mejor resultados, de manera que se obtuvo un modelo ajustado para las diferencias absolutas, otro combinando las diferencias absolutas y las relativas y otro analizando todas las variables predictoras al completo. Cada uno de estos modelos se ajustó con las variables predictoras más óptimas seleccionadas según la metodología desarrollada en el paquete de R VSURF (GENUER et al., 2016). Finalmente se seleccionó el mejor modelo atendiendo a la bondad de ajuste del mismo con respecto a los datos medidos en campo.

Finalmente, el cálculo de la cantidad de biomasa muerta en cada punto se realizó aplicando el porcentaje o nivel de afección estimado sobre el total de la biomasa arbórea existente en el punto calculado por LiDAR, obteniendo así una estimación de la biomasa muerta en toneladas por hectárea (T/ha). De cara a evitar posibles errores de borde entorno a las vías de comunicación, los resultados se han enmascarado entorno a las mismas. Se ha utilizado la cartografía de infraestructuras: caminos, pistas, carreteras y autovías del Geoportal de la Infraestructura de Datos Espaciales de la Comunidad de Madrid para generar una máscara con la que eliminar posibles resultados erróneos en los cinco metros anexos a las citadas vías.

4. Resultados y discusión.

Analizados los modelos para las diferencias de los compuestos de febrero y marzo se determinó que en todos los casos la bondad de ajuste era mayor cuando trabajábamos con diferencias absolutas frente a diferencias relativas, obteniéndose resultados más precisos con el de marzo (RMSE relativo del 32.86%) que con el de febrero (RMSE relativo del 38.68 %). De esta manera la cartografía de afección del temporal, utilizada en los resultados de este informe, se generó con las predicciones obtenidas con el modelo de marzo a excepción de una pequeña zona al oeste de la Comarca de San Martín de Valdeiglesias (Figura 5), que representa el 7,61 % de la

superficie forestal arbolada de la comarca, no cubierta por imagen de marzo que cumpla los criterios de calidad definidos (menos del 40 % de nubes). En dicha zona se aplicaron los resultados obtenidos por el modelo ajustado con los mosaicos de febrero.

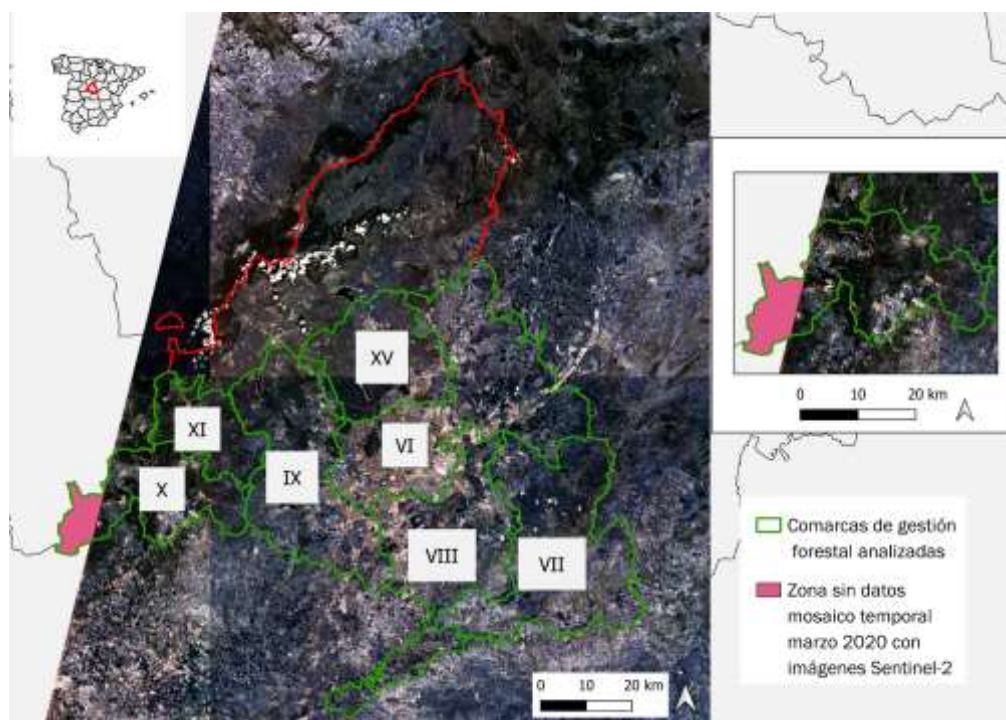


Figura 5. Zona no cubierta por el compuesto temporal de marzo de 2020 al oeste de la comarca de San Martín de Valdeiglesias.

No obstante, se observó que en zonas forestales abiertas de estructura adehesada la presencia de suelo en el pixel afectaba a los resultados de severidad. En marzo los cultivos o pastizales de las zonas adehesadas presentan un mayor desarrollo y, por consiguiente, una mayor respuesta espectral en las regiones del infrarrojo cercano. Esta respuesta da lugar a diferencias espectrales más acusadas que sobrestiman las predicciones de la severidad. Consecuentemente, con el apoyo de la cartografía del mapa forestal español a escala 1:25.000, se seleccionaron las teselas en las que la especie principal era la encina y que presentaban una estructura forestal adehesada. Finalmente, cuando en estas zonas la severidad predicha por el modelo de marzo estaba sobreestimada se priorizó las predicciones de severidad del modelo de febrero.

El modelo predictivo de severidad de marzo se calibró con las variables de diferencias absolutas (Figura 6), siendo la diferencia del índice DSWI la variable más importante.




Figura 6. Variables seleccionadas en el modelo de randomforest ordenadas por importancia de las mismas en el modelo predictivo. DSWI (diferencias absolutas en Índice SWI, DNDVI diferencias absolutas en Índice NDVI, DEVI diferencias absolutas en Índice EVI, dBn diferencias absolutas en la banda correspondiente de Sentinel-2).

El modelo generado con este conjunto de variables fue evaluado por validación cruzada sobre la propia muestra de entrenamiento, obteniendo un RMSE medio de 5,99 (Figura 7) tal y como puede verse en la siguiente figura:

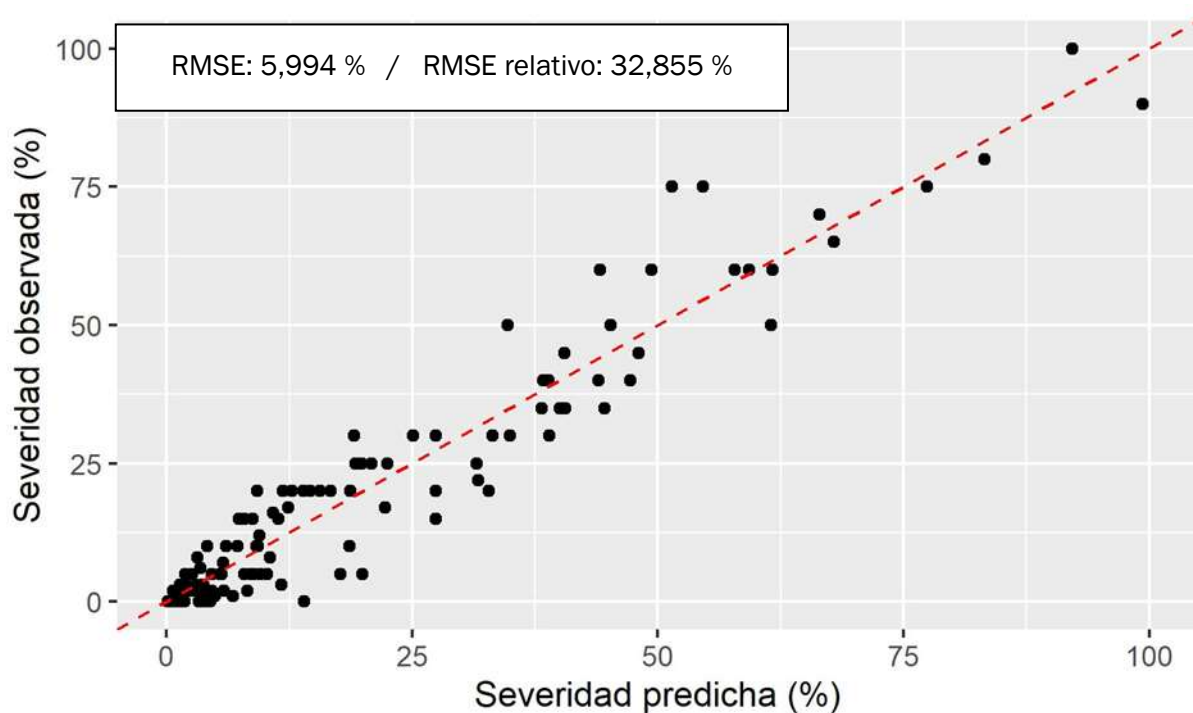


Figura 7. Ajuste del modelo predictivo de nivel de afección por el temporal sobre la propia muestra de entrenamiento.

A continuación, se presentan los resúmenes de los resultados obtenidos a nivel de comarca de estudio y para toda la zona (Tablas 2 y 3) teniendo en cuenta distintos niveles de afección. Las zonas “sin datos” corresponden a zonas donde no se disponía de imagen satelital viable debido a la presencia de nubes o sombras y al enmascaramiento de la cartografía entorno a las vías de comunicación.

Tabla 3. Resumen general de las superficies (ha) por nivel de afección del temporal, a nivel de comarca.

Comarca	Sup. forestal	Sup. forestal arbolada	Superficie por nivel de afección del temporal				
			Nivel de afección (%)				Sin datos*
			<10	10-25	25-50	≥ 50	
Alcalá de Henares	8.950,80	7.313,45	3.506,75	1.355,10	1.042,95	256,70	1.151,95
Este	23.316,75	11.926,30	3.281,45	3.593,15	2.797,35	484,80	1.769,55
PR del Guadarrama	27.643,40	20.827,05	14.992,25	2.911,30	926,20	135,00	1.862,30
PR del Sureste	8.797,75	4.585,20	1.734,65	1.433,10	677,75	113,45	626,25
PRCAM Sur	33.736,40	26.170,65	1.9430,55	4.135,90	921,65	116,75	1.565,80
Robledo de Chavela	29.937,55	21.386,40	17.616,50	1.295,90	361,70	33,90	2.078,40
San Martín de Valdeiglesias	41.239,70	32.982,35	22.753,70	3.640,70	960,15	155,85	5.471,95
Total zona de estudio	173.622,35	125.191,40	83,315.85	18,365.15	7,687.75	1,296.45	14,526.20

Tabla 4. Resumen general del porcentaje de superficie afectado respecto a la superficie forestal arbolada a nivel de comarca según los umbrales de daño definido.

Comarca	Sup. forestal	Sup. forestal arbolada	Superficie por nivel de afección del temporal (en % respecto a la superficie forestal arbolada)				
			Nivel de afección (%)				Sin datos*
			<10	10-25	25-50	≥ 50	
Alcalá de Henares	8.950,80	7.313,45	47,95%	18,53%	14,26%	3,51%	15,75%
Este	23.316,75	11.926,30	27,51%	30,13%	23,46%	4,06%	14,84%
PR del Guadarrama	27.643,40	20.827,05	71,98%	13,98%	4,45%	0,65%	8,94%
PR del Sureste	8.797,75	4.585,20	37,83%	31,25%	14,78%	2,47%	13,66%
PRCAM Sur	33.736,40	26.170,65	74,25%	15,80%	3,52%	0,45%	5,98%
Robledo de Chavela	29.937,55	21.386,40	82,37%	6,06%	1,69%	0,16%	9,72%
San Martín de Valdeiglesias	41.239,70	32.982,35	68,69%	11,04%	2,91%	0,47%	16,59%
Total zona de estudio	173.622,35	125.191,40	66,55%	14,67%	6,14%	1,04%	11,60%

Tal como se puede ver en el resumen presentado (Tablas 3 y 4) si bien la afección es generalizada para la Comunidad de Madrid solamente entorno al 1,04 % de la superficie forestal analizada tiene daños de más del 50 %, cifra que se eleva hasta el 7,18 % si tenemos en cuenta las superficies que han sufrido daños de más del 25 %, nivel de afección de daños presente en aproximadamente 9.000 ha arboladas.

A nivel de comarcal se aprecia un gradiente de afección en cuanto a severidad que disminuye de este a oeste. La Comarca Este es la que tiene unos niveles mayores de afección de daños por encima del 25%, que representan el 27,52 % de su superficie arbolada, seguido de las comarcas de Alcalá de Henares y del Sureste con un porcentaje de superficie arbolada afectada del 17,77 % y 17,26 %, respectivamente. Por el contrario, las comarcas de Robledo de Chavela y de San Martín de Valdeiglesias son las menos afectadas por el temporal, únicamente el 1,85 % de la superficie arbolada de Robledo y el 3,38 % de la de San Martín presentó niveles de severidad superiores al 25 %.

Si analizamos únicamente el total de superficie afectada (Figura 8) en cada una de las comarcas, la comarca Este es la más afectada con niveles de afección de daños superiores al 25% de biomasa arbolada en 3.282,15 ha de su superficie forestal arbolada, respectivamente, triplicado a la superficie afectada en las comarcas de Alcalá de Henares (1.299,65 ha) y el Parque Regional de la Cuenca Alta del Manzanares (PRCAM) (1.038,40 ha).




Figura 8. Resumen de resultados de superficies (ha) por nivel de afección (%) por comarca.

A continuación, se presentan los resultados obtenidos a nivel de comarca de biomasa muerta (Tabla 5). Más del 80% de la zona de estudio presenta pérdidas de biomasa inferiores a 15 T/ha y únicamente en 1.330 ha (1.06% de la superficie forestal arbolada) se observan pérdidas superiores a 40 T/ha. A nivel de comarca, los resultados reflejan que las comarcas con mayores pérdidas de biomasa (>100 T/ha) son San Martín de Valdeiglesias y Alcalá de Henares. Las mayores pérdidas de biomasa entre 40 – 100 T/ha también están presentes en la superficie forestal arbolada de esta última, concretamente en 447,05 ha.

Tabla 5. Resumen general de las superficies (ha) por nivel de biomasa muerta a nivel de comarca.

Comarca	Sup. forestal	Sup. forestal arbolada	Superficie por nivel biomasa aérea muerta				
			Biomasa muerta (t/ha)				Sin datos*
			<15	15-40	40-100	≥ 100	
Alcalá de Henares	8.950,80	7.313,45	4.712,85	996,05	447,05	5,05	1.151,95
Este	23.316,75	11.926,30	8.433,05	1.581,25	142,40	0,05	1.769,55
PR del Guadarrama	27.643,40	20.827,05	17.991,80	816,25	155,00	1,70	1.862,30
PR del Sureste	8.797,75	4.585,20	3.326,80	549,55	82,60	0,00	626,25
PRCAM Sur	33.736,40	26.170,65	23.664,70	719,40	219,80	0,95	1.565,80
Robledo de Chavela	29.937,55	21.386,40	18.998,80	293,15	15,85	0,20	2.078,40
San Martín de Valdeiglesias	41.239,70	32.982,35	26.147,90	1.102,80	249,55	10,15	5.471,95
Total zona de estudio	173.622,35	125.191,40	103.275,90	6.058,45	1.312,25	18,10	14.526,20

Estos resultados nos han permitido tener una visión conjunta de la afección de la Tormenta en las comarcas más afectadas de la comunidad de Madrid, cubriendo los objetivos inicialmente propuestos.

No obstante, la metodología utilizada deja mas del 10 % de la superficie arbolada “sin datos” fundamentalmente por problemas de nubosidad. Las condiciones climáticas que a menudo suceden a este tipo de episodios y la mayor afección de tormentas en los ecosistemas montañosos vinculados a una mayor nubosidad hacen que la presencia de nubes pueda ser una de las principales limitaciones para la aplicación de esta metodología con rapidez suficiente para poder organizar la gestión tras la emergencia. En ese sentido ahora mismo se está trabajando en el desarrollo de metodologías que combinan distintas fuentes de datos abiertos del programa Copernicus. La combinación de datos ópticos de Sentinel-2 con datos radar de apertura sintética (SAR) de Sentinel 1 puede ser una buena solución para trabajar allí donde las nubes supongan un Limitante. Los resultados usando Sentinel 1 son menos precisos en comparación con Sentinel-2, Gaia Vaglio Laurin y sus colaboradores en 2020 usaron ambos métodos para evaluar la Tormenta de Vaia en el Norte de Italia, comprobando que la precisión bajaba del 86 % al 68 % al usar Sentinel 1. Sin embargo, el SAR no depende del tiempo atmosférico, por lo que su utilización permite mapear los efectos de la tormenta en menos de una semana (Tomppo et. al, 2021).

Este tipo de metodologías de análisis de daños derivados de perturbaciones son especialmente importantes de cara a un futuro en el que se espera que aumenten tanto la frecuencia como la intensidad de este tipo de episodios en los bosques europeos debido al cambio climático (Seidl et al., 2014; Forcieri et al., 2020). Actuar de una manera rápida retirando la madera muerta es fundamental de cara a posibilitar que las masas se recuperen y no se van afectadas en un momento especialmente complicado por enfermedades fúngicas y explosiones de perforadores (McCarthy et al., 2012).

5. Conclusiones

Los resultados de este trabajo muestran el gran potencial de la constelación Sentinel-2 de Copernicus para el seguimiento de cambios en nuestros bosques, y en concreto para la identificación y cuantificación de daños tras perturbaciones climáticas como la borrasca Filomena.

Datos abiertos, que trabajando sobre metodologías de aprendizaje automático nos permiten trabajar a escala regional, pero con capacidad de ser precisos incluso a escala local. De esta manera es posible dar respuesta en un plazo de tiempo razonable de cara a planificar la gestión de las tareas necesarias para gestionar un desastre natural como el que nos ocupa. No obstante, trabajar solo con imágenes ópticas tiene ciertas limitaciones derivadas de la presencia de nubes por lo que sería interesante estudiar metodologías donde datos se combinen datos ópticos y radar (Sentinel-1) que complementen las imágenes ópticas permitiendo trabajar incluso en los meses en los que la nubosidad es más problemática.

6. Agradecimientos

Este estudio se realizó en el marco del proyecto: “Delimitación y cuantificación mediante técnicas de teledetección de los daños del temporal Filomena en las Comarcas de Gestión Forestal VI, VII, VIII, IX, X, XI y XV de la Comunidad de Madrid” bajo encargo de la Dirección General de Biodiversidad y Recursos Naturales (Comunidad de Madrid). Los redactores de este estudio agradecen la colaboración los técnicos responsables de las comarcas estudiadas y a los propietarios de las fincas privadas de “Castillo de Viñuelas”, “Casa Gótzquez”, “Rincón de los Canchos” y “Encomienda Mayor de Castilla” por su colaboración a la hora de realizar los trabajos de campo. Por último, queremos agradecer la política de datos abiertos que permite tener acceso a todas las fuentes de datos utilizadas en el presente estudio.

7. Bibliografía

BREIMAN, L.; 2001. Random Forests. Machine Learning, DOI-10.1023/A:1010933404324, 45(1): 5-32.

FORZIERI, G., GIRARDELLO, M., CECCHERINI, G.; SPINONI, J.; FEYE, L.; HARTMANN, H.; BECK, P.S.A.; CAMPS-VALLS, G.; CHIRICI, G. MAURI, A.; CESCATTI, A. 2021. Emergent vulnerability to climate-driven disturbances in European forests. Nature Commun 12, 1081 (2021). <https://doi.org/10.1038/s41467-021-21399-7>.

GENUER, R.; POGGI, J.-M.; TULEAU-MALOT, C.; 2016. Variable selection using Random Forests. Pattern Recognition Letters, 31(14): 2225-2236, 2016. Disponible en: <https://cran.r-project.org/package=VSURF>.

MCCARTHY, J.K., HOOD, I.A., KIMBERLEY, M.O., DIDHAM, R.K., BAKYS, R., FLEET, K.R. et al. 2012. Effects of season and region on sapstain and wood degrade following simulated storm damage in Pinus radiata plantations. For. Ecol. Manage. 277, 81–89.

MARTÍN ALCÓN, S.; GIL-TENA, A.; YAÑEZ-RAUSELL, L.; y CANTÓN MEGÍA, J. 2019. Cuantificación de la biomasa forestal muerta como consecuencia de perturbaciones a partir del análisis de imágenes Sentinel-2 y LiDAR. III Congreso forestal de la Comunidad Valenciana: Gestión de incendios forestales en el contexto del cambio climático. 153-164. Universitat de València. Valencia.

MONTERO, G.; RUIZ-PEINADO, R.; MUÑOZ, M.; 2005. Producción de biomasa y fijación de CO₂ por los bosques españoles, Ed. INIA (MEC), pp. 270 pp., Madrid.

KING, D.J.; OLTHOF, I.; PELLIKKA, P.K.E.; SEED E.D.; BUTSON, C. Modelling and Mapping Damage to Forests from an Ice Storm Using Remote Sensing and Environmental Data. *Natural Hazards* (2005) 35: 321–342. DOI 10.1007/s11069-004-1795-4.

LAURIN, G.V.; FRANCINI, S.; LUTI, T.; CHIRICI, G.; PIROTTI, F.; PAPALE, D. 2021. Satellite open data to monitor forest damage caused by extreme climate-induced events: a case study of the Vaia storm in Northern Italy, *Forestry: An International Journal of Forest Research*, Volume 94, Issue 3, July 2021, Pages 407–416, <https://doi.org/10.1093/forestry/cpaa043>.

LIAW, A.; WIENER, M.; 2002. Classification and Regression by randomForest. *R News*, 2(3): 18–22.

R DEVELOPMENT CORE TEAM; 2014. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria

ROUSSEL, J-R.; AUTY, D.; COOPS, N.; TOMPALSKI, P.; GOODBODY, T.R.H.; MEADOR A.S.; BOURDON J-F.; BOISSIEU, F.; ACHIM, A. 2020. lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. *Remote Sensing of Environment*, Volume 251, 112061, ISSN 0034-4257.

SEIDL, R., SCHELHAAS, M.-J., RAMMER, W. & VERKERK, P. J. 2014. Increasing forest disturbances in Europe and their impact on carbon storage. *Nat. Clim. Change* 4, 806–810.

TOMPPPO, E.; ANTROPOV, O.; PRAKS, J. 2019. Boreal Forest Snow Damage Mapping Using Multi-Temporal Sentinel-1 Data. *Remote Sens.*, 11, 384. <https://doi.org/10.3390/rs11040384>

TOMPPPO, E.; RONOUD, G.; ANTROPOV, O.; HYTÖNEN, H.; PRAKS, J. 2021. Detection of Forest Windstorm Damages with Multitemporal SAR Data—A Case Study: Finland. *Remote Sens.* 2021, 13, 383. <https://doi.org/10.3390/rs130303>

WANG, X., YANG, F., GAO, X., WANG, W., & ZHA, X. (2019). Evaluation of Forest Damaged Area and Severity Caused by Ice-snow Frozen Disasters over Southern China with Remote Sensing. *Chinese Geographical Science*, 29(3), 405–416. doi:10.1007/s11769-019-1041-3