

FOREST4EU

Connecting forestry and agroforestry partnerships across Europe



Funded by
the European Union

Funded by the European Union (Grant n. 101086216). Views and opinions expressed are however those of the authors only and do not necessarily reflect those of the European Union or REA. Neither the European Union nor the granting authority can be held responsible for them.

Operational Group (OG)




GO SURF

OG funding

OG SURF is a project funded by PRS Fearsr
2014 – 2022 of Regione Toscana, sub-
provision 16.2

“Support for pilot and cooperation projects”



Índice

1. Introducción.....	5
2. Cámaras multiespectrales e índices de vegetación.....	8
3. Drones y cámaras multiespectrales en el mercado.....	11
4. Conclusiones.....	15
5. Agradecimientos.....	15
6. Referencias.....	15

Tabla de ilustraciones

Figura 1. Identificación de superpíxeles con contornos blancos, detección de cubierta decreciente en amarillo y partes de cubierta muerta en azul.....	14
--	----

Índice de los cuadros

Tabla 1. Índices de vegetación útiles para la vigilancia forestal que pueden calcularse con cámaras multiespectrales.....	9
---	---

Drones y cámaras multispectrales en el monitoreo de la salud forestal (FHM)

*Francesca Giannetti^{1;2;3}, Yamuna Giambastiani^{2;3}, Lorenzo Massai^{2;3},
Patrizia Rossi¹, Solaria Anzillotti¹, Livia Passarino¹, Giuliano Secchi¹,
Davide Travaglini^{1;2}, Gherardo Chirici^{1;2}*

¹ Dipartimento di Scienze e Tecnologie Agrarie, Alimentari, Ambientali e Forestali (DAGRI), Università degli Studi di Firenze
francesca.giannetti@unifi.it; patrizia.rossi@unifi.it;
solaria.anzilotti@unifi.it; livia.passarino@unifi.it;
davide.travaglini@unifi.it; gherardo.chirici@unifi.it

² Laboratorio Congiunto ForTech

³ Bluebiloba start-up innovativa s.r.l.

yamuna.giambastiani@bluebiloba.com ; admin@bluebiloba.com

Resumen

El seguimiento de la salud de los bosques es esencial para evaluar y mantener la salud de los ecosistemas forestales, especialmente en el contexto del cambio climático. Mientras que los estudios in situ tradicionales se ven limitados por la subjetividad, la complejidad logística y los elevados costes, la teledetección ("Remote Sensing", RS) ofrece una alternativa más eficaz. Entre las tecnologías de RS, los vehículos aéreos no tripulados (UAV) equipados con cámaras multispectrales han demostrado ser especialmente eficaces. Estos drones ofrecen soluciones de vigilancia de alta resolución, rentables y flexibles, y captan datos detallados en varias longitudes de onda. Esto permite identificar con precisión el estrés y los daños en la vegetación, facilitando intervenciones oportunas y específicas. Como demuestra el proyecto GO-SURF, los vehículos aéreos no tripulados con sensores multispectrales se están convirtiendo en herramientas indispensables para la gestión forestal sostenible.

1. Introducción

El seguimiento de la salud forestal ("Forest Health Monitoring", FHM) es un proceso destinado a evaluar el estado de salud de los ecosistemas forestales (Trumbore et al. 2015). Este seguimiento implica la observación y el registro de diversos indicadores, como el grado de defoliación, la presencia de enfermedades o plagas y otros signos de estrés. El principal objetivo del FHM es detectar con prontitud cualquier cambio en la salud de los bosques con el fin de tomar medidas para mitigar los daños y preservar la salud de los ecosistemas forestales (Ecke et al. 2022).

El establecimiento de sistemas FHM es particularmente relevante en el contexto del cambio climático, donde la vegetación experimenta cada vez más efectos de estrés con una pérdida de actividad fotosintética (Puletti et al. 2019), y donde los eventos extremos como los incendios y las plagas de insectos (Kautz et al. 2024) y otros patógenos son cada vez más impactantes. Por ello, cada vez es más importante e imprescindible para todo gestor forestal, tanto público como privado, establecer sistemas de seguimiento de la FHM para mitigar posibles problemas en las masas forestales e intervenir con prontitud.

En el contexto italiano y europeo, el seguimiento in situ de la salud de los bosques se lleva a cabo desde hace varias décadas a nivel local, regional y global, utilizando indicadores estándar basados en estudios de campo realizados por personal formado que, por ejemplo, identifica el grado de defoliación de las copas (Canullo et al. 2012). Estas redes de seguimiento proporcionan un marco normalizado para evaluar la salud de los bosques, aunque en un número limitado de puntos, lo que permite un seguimiento a escala nacional, pero no se ajusta a las necesidades de los gestores forestales. Los gestores forestales públicos y privados se enfrentan cada vez más al impacto de las perturbaciones forestales en sus masas y, como se ha mencionado anteriormente, es

crucial implementar sistemas de seguimiento de la FHM que identifiquen rápidamente los problemas potenciales, permitiendo intervenciones oportunas de mitigación.

Sin embargo, los muestreos clásicos in situ realizados por operadores presentan un alto grado de incertidumbre porque la calidad depende de la experiencia y la percepción subjetiva de los observadores. Por lo tanto, se necesitan cursos de formación específicos para realizar las encuestas estandarizada y óptimamente. Además, las encuestas in situ son logísticamente complejas y costosas en términos de tiempo y mano de obra, por lo que sólo son viables a escala de parcela o de parcela única. Por esta razón, la teledetección (RS) se ha establecido como parte de la FHM, permitiendo la adquisición de indicadores de salud forestal de forma objetiva, cuantitativa y repetitiva a varias escalas espaciales (Lambert et al. 2013; Ecke et al. 2024).

En este contexto, la teledetección por satélite sigue dominando la investigación y la aplicabilidad en el sector de la FHM. De hecho, los datos de imágenes multiespectrales de acceso público, como Landsat, MODIS y Sentinel-2, permiten sistemas de seguimiento en grandes áreas, gracias a la resolución temporal y espacial que a menudo es suficiente para identificar perturbaciones (Francini y Chirici 2022). Sin embargo, como se destaca en algunas investigaciones, los satélites pueden presentar dificultades en el seguimiento, por ejemplo debido a la nubosidad (Giannetti et al. 2021) que puede oscurecer partes del bosque, lo que dificulta en algunos contextos, como las zonas montañosas de los Alpes y los Apeninos, el establecimiento de sistemas de alerta temprana. Estas cuestiones, por ejemplo, son incompatibles cuando los factores bióticos o abióticos provocan cambios rápidos en los bosques. Para superar estos problemas, los aviones tripulados pueden cumplir estos requisitos porque pueden volar por debajo de la capa de nubes (Ecke et al. 2024). En la práctica, por los elevados costes y las limitaciones logísticas, solo se usan anual o bianualmente en grandes áreas. Esto hace que, de hecho, no sean adecuados para la identificación temprana del estrés (Ecke et al. 2024).

En este contexto, los vehículos aéreos no tripulados se utilizan cada vez más, no como competidores, sino como tecnología complementaria de las plataformas tradicionales de observación de la Tierra (Ecke et al. 2024). En el contexto del Grupo Operativo Go-SURF, se han utilizado drones equipados con cámaras multispectrales para cartografiar el estrés en las masas forestales. Los UAV, en comparación con los satélites y las aeronaves, cubren áreas más pequeñas, pero son imbatibles en resolución espacial, que puede alcanzar una distancia de muestreo del suelo del orden de centímetros. También son muy eficientes en cuanto a costes, flexibilidad y, sobre todo, tiempos de revisita, que pueden ser frecuentes al depender únicamente del operador.

El área que puede cubrirse con estos UAV oscila entre una hectárea y varios kilómetros cuadrados en un solo vuelo. En la cobertura influyen principalmente el tipo de UAV, la tecnología de propulsión, el tipo de cámara, el tipo de terreno y la accesibilidad de la zona. También hay que tener en cuenta la normativa sobre el funcionamiento de los UAV como factor limitante de la cobertura. Sin embargo, la nueva normativa europea permite volar a una altitud de 120 metros sobre el nivel del suelo con una distancia de seguridad de 500 metros, lo que permite incluso a los drones más potentes cubrir cómodamente entre 10 y 20 hectáreas en un solo vuelo.

Sin embargo, además del dron, lo que marca la diferencia a la hora de establecer un sistema FHM es el sensor que el dron puede llevar a bordo. Recientemente han aparecido en el mercado numerosas cámaras multispectrales nuevas. Estas cámaras, gracias a su capacidad para captar diferentes longitudes de onda del espectro electromagnético, pueden utilizarse para cartografiar diversos tipos de estrés forestal (Barzagli et al. 2018; Zhang et al. 2019; Ecke et al. 2022).

Sin embargo, la variedad de cámaras disponibles en el mercado y los distintos índices de vegetación que pueden derivarse de ellas dificultan la navegación por un panorama de investigación y avances técnicos en constante evolución. Por esta razón, este artículo pretende ofrecer una visión general de los índices de vegetación útiles para cartografiar el estrés forestal, una visión general de algunas de las cámaras disponibles

en el mercado y las técnicas de procesamiento más sencillas o prometedoras, basándose en los resultados del GO-SURF del EIP-AGRI y considerando también la bibliografía internacional, para ofrecer información útil a los técnicos implicados en la monitorización forestal.

2. Cámaras multispectrales e índices de vegetación

Las cámaras multispectrales son dispositivos avanzados de captura de imágenes que captan información visual en diferentes bandas del espectro electromagnético. Estas bandas pueden incluir el espectro visible (rojo, verde, azul) y el infrarrojo cercano (NIR) y, en algunos casos, el infrarrojo cercano de borde rojo. Al utilizar estas distintas longitudes de onda, las cámaras multispectrales proporcionan datos detallados que pueden utilizarse para analizar diversos aspectos de la vegetación, el suelo y los bosques. En concreto, gracias a la capacidad de adquirir información en el espectro infrarrojo, es posible investigar la actividad fotosintética de las plantas, evaluar la salud de los árboles y poner de relieve la presencia de enfermedades u otros tipos de estrés. Al igual que las cámaras RGB, pueden utilizarse para adquisiciones fotogramétricas que permiten derivar no solo datos 2D (ortomosaico multispectral), sino también datos 3D como nubes de puntos y modelos digitales de superficie (DSM) útiles para analizar la estructura de los bosques (Barzagli et al. 2018; Giannetti et al. 2020).

Sin embargo, su principal ventaja, como ya se ha mencionado, es su capacidad para captar imágenes en diferentes longitudes de onda del espectro electromagnético, lo que permite a los operadores distinguir variaciones en el contenido de clorofila de la vegetación que pueden indicar rápidamente la presencia de estrés, enfermedades o patógenos. De hecho, gracias a la capacidad de adquirir información a diferentes longitudes de onda, pueden utilizarse fácilmente para derivar diversos índices de vegetación mediante sencillas operaciones matemáticas entre las imágenes de diferentes bandas, utilizando también

aplicaciones SIG comunes como QField a través de las funciones de calculadora raster.

Entre los índices de vegetación que pueden calcularse, presentamos en la Tabla 1 los más prometedores para monitorizar el estrés en entornos forestales y que pueden calcularse con las cámaras multispectrales disponibles actualmente.

Tabla 1. Índices de vegetación útiles para la vigilancia forestal que pueden calcularse con cámaras multispectrales.

Índice de vegetación	Fórmula
NDVI (Índice de vegetación de diferencia normalizada)	$NDVI = \frac{NIR - Red}{NIR + Red}$
NDRE (Borde rojo de diferencia normalizada)	$NDRE = \frac{NIR - RedEdge}{NIR + RedEdge}$
GNDVI (Índice de vegetación de diferencia normalizada verde)	$GNDVI = \frac{NIR - Green}{NIR + Green}$
LCI (Índice de clorofila foliar)	$LCI = \frac{RedEdge - Red}{RedEdge + Red}$
SAVI (Índice de vegetación ajustado al suelo)	$SAVI = \frac{(1+L)(NIR - Red)}{NIR + Red + L}$ <p>where <i>L</i> is a constant depending from the soil conditions (typically <i>L</i>= 0.5)</p>
OSAVI (Índice de vegetación optimizado ajustado al suelo)	$OSAVI = \frac{(NIR - Red)}{NIR + Red + 0.16}$
MCARI (Índice de absorción de clorofila modificado)	$MCARI = \frac{(RedEdge - Red) - 0.2x(RedEdge - Red)}{RedEdge + Red}$
CIRE (Índice clorofílico de borde rojo)	$CIRE = \frac{NIR}{RedEdge} - 1$
EVI (Índice de vegetación mejorado)	$EVI = 2.5 \times \frac{NIR - Red}{NIR + 6xRed - 7.5xBlue + 1}$
VARI (Índice de resistencia atmosférica visible)	$VARI = \frac{Green - Red}{Green + Red - Blue}$

El NDVI ("Normalized Difference Vegetation Index", Índice de vegetación de diferencia normalizada) es quizá el índice más utilizado para controlar la salud de las plantas. Sin embargo, su tendencia a saturarse puede dificultar a veces la detección precoz del estrés en los bosques. El índice se basa en el hecho de que la clorofila de las plantas vivas refleja intensamente la luz infrarroja cercana (NIR) y absorbe la luz roja. Los valores altos de NDVI, cercanos a 1, indican una vegetación densa y sana, mientras que los valores más bajos, inferiores a 0,7, sugieren estrés, y los inferiores a 0,6 indican la muerte de las plantas. Sin embargo, según la experiencia del proyecto GO-SURF y la revisión bibliográfica en el contexto del cultivo del álamo (Chianucci et al. 2021), el NDVI puede ser el índice menos preciso para detectar el estrés.

Por ejemplo, el GNDVI ("Green Normalized Difference Vegetation Index", índice de vegetación de diferencia verde normalizada) es más sensible para la alerta temprana del estrés. Este índice es similar al NDVI, pero utiliza la banda verde en lugar de la roja para la normalización con la banda NIR. Esto lo hace útil para monitorizar plantas con alta densidad foliar o identificar estrés hídrico, permitiendo alertas tempranas (Raddi et al. 2021). Para evaluar el contenido de clorofila, el LCI (Leaf Chlorophyll Index) es muy sensible a la clorofila presente en las hojas (Gallardo-Salazar et al. 2023). La clorofila absorbe la luz roja y refleja la luz de borde rojo, por lo que este índice es útil para estimar directamente el contenido de clorofila, que es un indicador de la capacidad fotosintética de la planta. Del mismo modo, el CIRE (Chlorophyll Index Red Edge) está aún más correlacionado con el estado nutricional de las plantas (Kleinsmann et al. 2023).

El NDRE ("Normalized Difference Red Edge" o borde rojo de diferencia normalizada) es especialmente útil para identificar el estrés de las plantas en secciones de la cubierta. El borde rojo es muy sensible a los cambios en la estructura de la hoja y el contenido de clorofila, lo que permite detectar pequeñas variaciones (Minařík y Langhammer 2016). Es útil para identificar plantas que puedan estar afectadas por enfermedades o deficiencias nutricionales antes de que estos problemas sean visibles a simple vista. El MCARI (Modified Chlorophyll

Absorption Ratio Index) está diseñado para ser menos sensible a las variaciones del suelo, lo que mejora la capacidad de detectar el estrés de las plantas en entornos heterogéneos con suelo expuesto (Zou et al. 2019). Para evaluar la actividad fotosintética y el vigor vegetativo, el EVI (Enhanced Vegetation Index) mejora la sensibilidad en zonas de vegetación de alta densidad y reduce las interferencias atmosféricas y del suelo en comparación con el NDVI. El VARI (Visible Atmospherically Resistant Index) se puede utilizar para supervisar la vegetación utilizando solo las bandas visibles, lo que lo hace útil en condiciones en las que las bandas NIR no están disponibles, como con las cámaras RGB.

3. Drones y cámaras multispectrales en el mercado

Entre los drones con sensor multispectral integrado, el DJI Mavic 3M combina una cámara RGB de 20 MP y cuatro cámaras multispectrales de 5 MP que capturan en las bandas verde ($560\text{nm}\pm 16\text{nm}$), roja ($650\text{nm}\pm 16\text{nm}$), de borde rojo ($730\pm 16\text{nm}$) y NIR ($860\text{nm}\pm 26\text{nm}$), junto con un sensor de luz integrado. Esta configuración capta la irradiancia solar, lo que permite compensar a posteriori cualquier fluctuación de luz en las imágenes. El fabricante asegura una autonomía de vuelo de 43 minutos con una cobertura por vuelo de 2 km^2 . El dron también está disponible con un módulo RTK, que proporciona una georreferenciación precisa del estudio con gran exactitud.

Otro dron de DJI con sensor integrado es el P4 Multispectral, equipado con seis cámaras diferentes de 2,08 MP: una cámara RGB y cinco cámaras multispectrales que capturan en las bandas azul ($450\pm 16\text{nm}$), verde ($560\pm 16\text{nm}$), roja ($650\pm 16\text{nm}$), de borde rojo ($730\pm 16\text{nm}$) e infrarroja cercana ($840\pm 26\text{nm}$). Este dron también cuenta con un sensor de luz y un módulo RTK para la corrección de la luz en la imagen y la georreferenciación precisa del levantamiento. El fabricante afirma una autonomía de vuelo de 27 minutos y una superficie operativa máxima por vuelo de $0,63\text{ km}^2$. En un estudio reciente realizado en Alemania (Ecke et al. 2024), este dron se utilizó para adquirir imágenes multispectrales de alta resolución de 235 zonas diferentes de

seguimiento forestal a gran escala (parcelas de nivel I del PCI) distribuidas en Baviera durante un periodo de seguimiento de tres años (2020-2022). A pesar de la heterogeneidad del conjunto de datos adquiridos a lo largo del tiempo bajo diversas condiciones meteorológicas y de iluminación, en bosques con composiciones diversas repartidos por una amplia zona de estudio, el artículo demuestra cómo fue posible clasificar cinco especies arbóreas, a nivel de género, árboles muertos y el estado de salud de las principales especies arbóreas en 14 clases diferentes utilizando la arquitectura EfficientNet CNN. El artículo destaca que esta metodología de seguimiento puede reducir significativamente los costes y tiempos de adquisición sobre el terreno, permitiendo la estandarización de los datos.

Entre las cámaras que pueden montarse en varios tipos de drones, como el DJI Matrice 300, el Wingtra One Gen II y el senseFly eBeeX, la MicaSense RedEdge-MX destaca como una de las más eficientes, pero también una de las más caras. Esta cámara captura imágenes en las bandas azul ($475\text{nm}\pm 20\text{nm}$), verde ($560\text{nm}\pm 20\text{nm}$), rojo ($668\text{nm}\pm 10\text{nm}$), borde rojo ($717\text{nm}\pm 10\text{nm}$) e infrarrojo cercano ($840\text{nm}\pm 40\text{nm}$), ofreciendo una alta precisión y consistencia espectral, lo que la hace ideal para analizar la vegetación forestal. La cámara está equipada con un sensor de luz y un panel de reflectancia para la calibración, que debe capturarse en el despegue y el aterrizaje del dron.

Esta cámara también se probó en el proyecto GO-SURF, en el que se utilizó para adquirir imágenes de diversas zonas de la región de la Toscana mediante el dron Wingtra One Gen II. El procesamiento de imágenes mediante técnicas de segmentación basadas en el método "Simple Linear Iterative Clustering (SLIC)" (Achanta et al. 2012) permitió identificar plantas muertas y en declive mediante la identificación de umbrales de estrés. SLIC es un algoritmo utilizado para la segmentación de imágenes, en particular para la creación de superpíxeles -grupos de píxeles contiguos con características similares, que simplifican el análisis de imágenes reduciendo el número de elementos a considerar y manteniendo al mismo tiempo la mayor parte de la información

relevante. Concretamente, en el proyecto GO-SURF se procesaron imágenes multispectrales utilizando el software fotogramétrico Metashape Agisoft para generar un ortomosaico en diferentes bandas (azul, verde, rojo, borde rojo, infrarrojo cercano). Las imágenes se importaron en el software R-Cran, utilizando varios paquetes de procesamiento para inicializar el algoritmo. Durante la inicialización, el algoritmo distribuye uniformemente los centros de los superpíxeles por la imagen. Estos centros se eligen para cubrir toda la imagen de manera uniforme. A continuación, cada píxel de la imagen se asigna al centro de superpíxel más cercano en función de la distancia combinada (espacio y color). La distancia combinada tiene en cuenta tanto las coordenadas espaciales como los valores de color (espacio CIELAB). El algoritmo itera hasta segmentar las copas de los árboles individuales. Este algoritmo también se puede utilizar mediante software de escritorio como SAGA GIS. Las pruebas realizadas en el proyecto GO-SURF mostraron que la segmentación del entorno forestal funciona muy bien incluso utilizando sólo la banda del borde rojo, no múltiples bandas. Esta banda parece ser la más sensible a la hora de identificar copas individuales o porciones de copas con una actividad fotosintética similar. El método de segmentación reduce el tiempo en comparación con métodos complejos y detecta con precisión copas individuales o porciones de copas con diferentes actividades fotosintéticas, como porciones de copas muertas o en declive. Sin embargo, para clasificar las distintas clases de decaimiento (porción de cubierta muerta, porción de cubierta en declive, porción de cubierta viva), es necesario extraer índices de vegetación de los polígonos generados por SLIC, calibrando umbrales para identificar plantas muertas. Así, para cada superpíxel, se aplican umbrales a los índices de vegetación para clasificar los superpíxeles como representativos de plantas sanas, estresadas o muertas. La ventaja de este método es que la segmentación de superpíxeles reduce el número de unidades que hay que analizar, lo que hace que el análisis sea más rápido y eficaz. Además, los superpíxeles tienden a seguir los contornos naturales de las plantas, lo que mejora la precisión de la clasificación en comparación con los métodos de píxel único.




Figura 1. Identificación de superpíxeles con contornos blancos, detección de cubierta decreciente en amarillo y partes de cubierta muerta en azul

El uso de superpíxeles SLIC en imágenes de drones representa una técnica avanzada para la identificación y el seguimiento de plantas muertas. Al segmentar las imágenes en regiones homogéneas y aplicar umbrales a los índices de vegetación, es posible obtener un mapa preciso de las zonas problemáticas, lo que permite realizar intervenciones oportunas y específicas en la gestión de los cultivos.

Entre otras cámaras multispectrales del mercado con un coste inferior a las anteriormente mencionadas se encuentran la Parrot Sequoia, la Sentera Double 4K, la Mapir Survey3 y la Mapir Survey2. Todas estas cámaras, al igual que las demás, adquieren información multispectral en las bandas roja, azul, verde e infrarroja cercana, pero no en la infrarroja cercana de borde rojo. Esto las hace menos eficaces para calcular algunos de los índices mencionados anteriormente.

4. Conclusiones

Es imposible tener una visión completa de todas las cámaras disponibles en el mercado en este momento. Sin embargo, basándonos en nuestra experiencia, es esencial centrarse en aquellas cámaras que permiten calcular diferentes índices de vegetación, lo que puede contribuir a cartografiar con precisión los daños potenciales. Esto se debe a que cada vez es más importante poder intervenir con prontitud. A pesar de algunas limitaciones, los drones equipados con cámaras multispectrales representan una herramienta potente y versátil para la vigilancia forestal, como demuestra el proyecto GO-SURF ya ejecutado a nivel italiano. Se prevé que los nuevos avances tecnológicos y la creciente accesibilidad a los drones harán que estas herramientas sean cada vez más fundamentales en la gestión forestal sostenible.

5. Agradecimientos

Esta contribución se ha realizado en el marco del proyecto FOREST4EU, financiado por el Programa de Investigación e Innovación Horizonte Europa de la Unión Europea mediante el acuerdo de subvención nº 101086216.

6. Referencias

Achanta R, Shaji A, Smith K, et al (2012) Superpíxeles SLIC comparados con los métodos de superpíxeles más avanzados

Barzagli A, Nocentini S, Del Perugia B, et al (2018) L'utilizzo del telerilevamento a supporto della gestione forestale sostenibile. Primi risultati del progetto Fresh Life Demonstrating Remote Sensing

Integration in Sustainable Forest Management (Life14_ENV/IT/000414).
L'Italia For E Mont 73:169-194. <https://doi.org/10.4129/ifm.2018.4.5.03>

Canullo R, Allegrini M-C, Campetella G (2012) Manuale nazionale di riferimento per la raccolta dei dati di vegetazione nella rete italiana CONECOFOR LII (Programma per il controllo degli ecosistemi forestali - UNECE, ICP Forests). Braun-Blanquetia 48:5-65

Chianucci F, Puletti N, Grotti M, et al (2021) Influence of image pixel resolution on canopy cover estimation in poplar plantations from field , aerial and satellite optical imagery. Ann Silv Res 46:8-13

Ecke S, Dempewolf J, Frey J, et al (2022) UAV-Based Forest Health Monitoring: A Systematic Review. Remote Sens 14:1-45. <https://doi.org/10.3390/rs14133205>

Ecke S, Stehr F, Frey J, et al (2024) Towards operational UAV-based forest health monitoring: Species identification and crown condition assessment by means of deep learning. Comput Electron Agric 219:108785. <https://doi.org/10.1016/j.compag.2024.108785>

Francini S, Chirici G (2022) Un conjunto de datos derivados de Sentinel-2 de las perturbaciones forestales ocurridas en Italia entre 2017 y 2020. Data Br 42:108297. <https://doi.org/10.1016/j.dib.2022.108297>

Gallardo-Salazar JL, Lindig-Cisneros RA, López-Toledo L, et al (2023) Análisis del vigor de Pinus hartwegii Lindl. a lo largo de un gradiente altitudinal mediante imágenes multiespectrales UAV: Evidencia de Declive Forestal Posiblemente Asociado al Cambio Climático. Forests 14:. <https://doi.org/10.3390/f14061176>

Giannetti F, Pecchi M, Travaglini D, et al (2021) Estimating VAIA windstorm damaged forest area in Italy using time series Sentinel-2 imagery and continuous change detection algorithms. 1-16

Giannetti F, Puliti S, Puletti N, et al (2020) Modelling Forest structural indices in mixed temperate forests: comparison of UAV photogrammetric DTM-independent variables and ALS variables. *Ecol Indic* 117:106513. <https://doi.org/10.1016/j.ecolind.2020.106513>

Kautz M, Feurer J, Adler P (2024) Early detection of bark beetle (*Ips typographus*) infestations by remote sensing - A critical review of recent research. *Para Ecol Manage* 556:. <https://doi.org/10.1016/j.foreco.2023.121595>

Kleinsmann J, Verbesselt J, Kooistra L (2023) Monitoring Individual Tree Phenology in a Multi-Species Forest Using High Resolution UAV Images. *Remote Sens* 15:1-30. <https://doi.org/10.3390/rs15143599>

Lambert J, Drenou C, Denux J-P, et al (2013) Monitoring forest decline through remote sensing time series analysis. *GIScience Remote Sens* 50:437-457. <https://doi.org/10.1080/15481603.2013.820070>

Minařík R, Langhammer J (2016) Use of a multispectral UAV photogrammetry for detection and tracking of forest disturbance dynamics. *Int Arch Photogramm Remote Sens Spat Inf Sci - ISPRS Arch* 41:711-718. <https://doi.org/10.5194/isprsarchives-XLI-B8-711-2016>

Puletti N, Mattioli W, Bussotti F, Pollastrini M (2019) Seguimiento de los efectos de eventos de sequía extrema en la salud de los bosques mediante imágenes Sentinel-2. *J Appl Remote Sens* 13:1. <https://doi.org/10.1117/1.jrs.13.020501>

Raddi S, Giannetti F, Martini S, et al. (2021) Monitorización de la respuesta a la sequía y el contenido de clorofila en *Quercus* mediante una cámara de infrarrojo cercano (NIR) de calidad de

consumidor: comparación con la espectroscopia de reflectancia.
New For. <https://doi.org/10.1007/s11056-021-09848-z>

Trumbore S, Brando P, Hartmann H (2015) Salud forestal y cambio global. *Science* (80-) 349:814-818.
<https://doi.org/10.1126/science.aac6759>

Zhang L, Zhang H, Niu Y, Han W (2019) Mapeo del estrés hídrico del maíz basado en la teledetección multiespectral UAV. *Remote Sens* 11:605. <https://doi.org/10.3390/rs11060605>

Zou X, Liang A, Wu B, et al (2019) Enfoque de alto rendimiento basado en UAV para el cribado de cultivares de *Cunninghamia lanceolata* (Lamb.) de crecimiento rápido mediante aprendizaje automático. *Forests* 10:. <https://doi.org/10.3390/f10090815>



FOREST4EU



Funded by
the European Union

Funded by the European Union (Grant n. 101086216). Views and opinions expressed are however those of the authors only and do not necessarily reflect those of the European Union or REA. Neither the European Union nor the granting authority can be held responsible for them.



 forest4eu.eu



-  FOREST4EU Project
-  FOREST4EU Project
-  info@forest4eu.eu