

FOREST4EU

Connecting forestry and agroforestry partnerships across Europe



Centar kompetencija d.o.o.
za istraživanje i razvoj



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 Feasr
2014 – 2022 of Regione Toscana, sub-
provision 16.2

“Support for pilot and cooperation projects”

Índice

1. Introdução.....	5
2. Câmaras Multiespectrais e Índices de Vegetação.....	8
3. Drones e Câmaras Multiespectrais no Mercado	11
4. Conclusões	15
5. Agradecimentos	15
6. Referências	15

Índice de ilustrações

Figura 1. Identificação de Superpixels com Contornos Brancos, Detecção de Copas em Declínio a Amarelo e Partes de Copas Mortas a Azul.....	14
--	----

Índice das tabelas

Tabela 1. Índices de Vegetação úteis para a monitorização florestal que podem ser calculados com câmaras multiespectrais	9
--	---

Drones e câmaras multiespectrais na monitorização da saúde das florestas (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.anzillotti@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

Sumário

A Monitorização da Sanidade Florestal (*Forest Health Monitoring*, FHM) é essencial para avaliar e manter a saúde dos ecossistemas florestais, especialmente no contexto das alterações climáticas. Embora os levantamentos tradicionais *in situ* sejam limitados pela subjetividade, complexidade logística e custos elevados, a deteção remota (*remote sensing*, RS) oferece uma alternativa mais eficiente. Entre as tecnologias de RS, os Veículos Aéreos Não Tripulados (*Unmanned Aerial Vehicles*, UAVs) equipados com câmaras multiespectrais têm-se mostrado particularmente eficazes. Estes drones fornecem soluções de monitorização de alta resolução, bom custo benefício e soluções de monitorização flexíveis, capturando dados detalhados em várias comprimentos de onda. Isto permite a identificação precisa de stress e danos na vegetação, facilitando intervenções oportunas e direcionadas. Como demonstrado pelo projeto GO-SURF, os UAVs com sensores multiespectrais estão a tornar-se ferramentas indispensáveis para a gestão florestal sustentável.

1. Introdução

A Monitorização da Sanidade Florestal (*Forest Health Monitoring, FHM*) é um processo destinado a avaliar o estado de saúde dos ecossistemas florestais (Trumbore et al. 2015). Esta monitorização envolve a observação e o registo de vários indicadores, como o grau de desfolha, a presença de doenças ou pragas e outros sinais de stress. O principal objetivo do FHM é detetar prontamente quaisquer alterações na saúde florestal para tomar medidas que mitiguem danos e preservem a saúde dos ecossistemas florestais (Ecke et al. 2022).

Estabelecer sistemas de FHM é particularmente relevante no contexto das alterações climáticas, onde a vegetação sofre cada vez mais os efeitos de stress, resultando na perda de atividade fotossintética (Puletti et al. 2019), e onde eventos extremos como incêndios, pragas (Kautz et al. 2024) e doenças estão a tornar-se mais impactantes. Portanto, tornou-se cada vez mais importante e essencial para cada gestor florestal, tanto público quanto privado, estabelecer sistemas de monitorização FHM para mitigar potenciais problemas nas florestas e intervir prontamente.

No contexto italiano e europeu, a monitorização *in situ* da sanidade florestal tem sido realizada há várias décadas a níveis local, regional e global, utilizando indicadores padrão baseados em levantamentos de campo conduzidos por pessoas capacitadas que, por exemplo, identificam o grau de desfolha da copa (Canullo et al. 2012). Estas redes de monitorização fornecem uma estrutura padronizada para avaliar a sanidade florestal, embora num número limitado de pontos, permitindo a monitorização em escala nacional, mas não alinhando com as necessidades dos gestores florestais. Gestores florestais públicos e privados enfrentam cada vez mais o impacto de perturbações florestais nas suas áreas de ação e, como mencionado anteriormente, é crucial implementar sistemas de monitorização FHM que identifiquem prontamente potenciais problemas, permitindo intervenções de mitigação no menor período de tempo.

No entanto, os levantamentos clássicos *in situ* conduzidos por operadores apresentam um alto grau de incerteza porque a qualidade

depende da experiência e percepção subjetiva dos observadores. Portanto, são necessários cursos de formação específicos para realizar levantamentos de forma padronizada e ótima. Além disso, os levantamentos *in situ* são logisticamente complexos e caros em termos de tempo e trabalho, tornando-os viáveis apenas à escala da parcela ou lote individual. Por esta razão, a detecção remota (RS) estabeleceu-se como parte do FHM, permitindo a aquisição de indicadores de sanidade florestal de forma objetiva, quantitativa e repetitiva em várias escalas espaciais (Lambert et al. 2013; Ecke et al. 2024).

Neste contexto, a detecção remota baseada em satélites ainda domina a investigação e a aplicabilidade no setor de FHM. De facto, dados de imagem multiespectral publicamente acessíveis, como Landsat, MODIS e Sentinel-2, permitem sistemas de monitorização em grandes áreas, graças à resolução temporal e espacial que é frequentemente suficiente para identificar perturbações (Francini e Chirici 2022). No entanto, como destacado por algumas investigações, os satélites podem apresentar dificuldades na monitorização, por exemplo, devido à cobertura de nuvens (Giannetti et al. 2021) que pode obscurecer porções da floresta, tornando difícil em alguns contextos, como as áreas montanhosas dos Alpes, estabelecer sistemas de alerta precoce. Estas questões, por exemplo, são incompatíveis quando fatores bióticos ou abióticos causam alterações rápidas nas florestas. Para superar estes problemas, aeronaves tripuladas podem atender a estes requisitos, pois podem voar abaixo da cobertura de nuvens (Ecke et al. 2024). No entanto, na prática, devido aos altos custos e limitações logísticas, são usadas apenas anualmente ou bianualmente em grandes áreas. Isto torna-as, de facto, inadequadas para a identificação precoce de obstáculos (Ecke et al. 2024).

É neste contexto que os UAVs têm encontrado uso crescente, não como concorrentes, mas como uma tecnologia complementar às plataformas tradicionais de observação da Terra (Ecke et al. 2024). No contexto do Grupo Operacional Go-SURF, drones equipados com câmaras multiespectrais foram usados para mapear o stress das árvores. Os UAVs, em comparação com satélites e aeronaves, cobrem áreas

menores, mas são imbatíveis em resolução espacial, que pode alcançar uma Distância de Amostragem Terrestre na ordem dos centímetros. São também muito eficientes em termos de custos, flexibilidade e, especialmente, tempos de revisita, que podem ser frequentes, pois dependem apenas do operador.

A área que pode ser coberta com estes UAV varia de um hectare a vários quilômetros quadrados num único voo. A cobertura é principalmente influenciada pelo tipo de UAV, tecnologia de propulsão, tipo de câmara, tipo de terreno e acessibilidade da área. Além disso, as regulamentações de operação de UAVs devem ser consideradas como um fator limitante para a cobertura. No entanto, a nova regulamentação europeia permite voar a uma altitude de 120 metros acima do nível do solo com uma distância de *buffer* de 500 metros, o que permite cobrir 10-20 hectares num único voo.

No entanto, além do drone, o que faz a diferença na implementação de um sistema de FHM é o sensor que o drone pode transportar a bordo. Recentemente, numerosas novas câmaras multiespectrais tornaram-se disponíveis no mercado. Estas câmaras, graças à sua capacidade de capturar diferentes comprimentos de onda do espectro eletromagnético, podem ser usadas para mapear vários tipos de stress florestal (Barzagli et al. 2018; Zhang et al. 2019; Ecke et al. 2022).

No entanto, a variedade de câmaras disponíveis no mercado e os vários índices de vegetação que podem ser derivados delas tornam difícil navegar num panorama de pesquisa e avanço técnico em constante evolução. Por esta razão, este artigo visa fornecer uma visão geral dos índices de vegetação úteis para mapear o stress das florestas; uma visão geral de algumas das câmaras disponíveis no mercado e as técnicas de processamento mais simples ou promissoras, com base nos resultados do EIP-AGRI GO-SURF e também considerando a literatura internacional, para oferecer informações úteis aos técnicos envolvidos na monitorização florestal.

2. Câmaras Multiespectrais e Índices de Vegetação

As câmaras multiespectrais são dispositivos de imagem avançados que capturam informações visuais em diferentes bandas do espectro eletromagnético. Estas bandas podem incluir o espectro visível (vermelho, verde, azul) e o infravermelho próximo (NIR), e em alguns casos, o vermelho-infravermelho. Utilizando estes diversos comprimentos de onda, as câmaras multiespectrais fornecem dados detalhados que podem ser usados para analisar vários aspetos da vegetação, solo e florestas. Especificamente, graças à capacidade de adquirir informações no espectro infravermelho, é possível investigar a atividade fotossintética das plantas, avaliar a saúde das árvores e destacar a presença de doenças ou outros tipos de problemas. Tal como as câmaras RGB, podem ser utilizadas para aquisições fotogramétricas que permitem a derivação não só de dados 2D (orto mosaico multiespectral), mas também de dados 3D, como nuvens de pontos e modelos digitais de superfície (DSM) úteis para analisar a estrutura das florestas (Barzagli et al. 2018; Giannetti et al. 2020).

No entanto, a sua principal vantagem, como mencionado anteriormente, é a sua capacidade de capturar imagens em diferentes comprimentos de onda do espectro eletromagnético, permitindo aos operadores distinguir variações no conteúdo de clorofila na vegetação que podem indicar prontamente a presença de stress, doenças ou pragas. De facto, graças à capacidade de adquirir informações em diferentes comprimentos de onda, podem ser facilmente utilizadas para extrair vários índices de vegetação através de operações matemáticas simples entre as imagens de diferentes bandas, também utilizando aplicações GIS comuns, como o QField, através das funções de calculadora de raster.

Entre os índices de vegetação que podem ser calculados, os apresentados na Tabela 1, são os mais promissores para detetar o stress em ambientes florestais e podem ser calculados com câmaras multiespectrais atualmente disponíveis.

Tabela 1. Índices de Vegetação úteis para a monitorização florestal que podem ser calculados com câmaras multiespectrais

Índice de Vegetação	Fórmula
NDVI (Normalized Difference Vegetation Index)	$NDVI = \frac{NIR-Red}{NIR+Red}$
NDRE (Normalized Difference Red Edge)	$NDRE = \frac{NIR-RedEdge}{NIR+RedEdge}$
GNDVI (Green Normalized Difference Vegetation Index)	$GNDVI = \frac{NIR-Green}{NIR+Green}$
LCI (Leaf Chlorophyll Index)	$LCI = \frac{RedEdge-Red}{RedEdge+Red}$
SAVI (Soil-Adjusted Vegetation Index)	$SAVI = \frac{(1+L)(NIR-Red)}{NIR+Red+L}$ L é uma constante que depende das condições do solo (tipicamente $L=0.5$)
OSAVI (Optimized Soil-Adjusted Vegetation Index)	$OSAVI = \frac{(NIR-Red)}{NIR+Red+0.16}$
MCARI (Modified Chlorophyll Absorption Ratio Index)	$MCARI = \frac{(RedEdge-Red)-0.2x(RedEdge-Green)}{RedEdge+Red}$
CIRE (Chlorophyll Index Red Edge)	$CIRE = \frac{NIR}{RedEdge} - 1$
EVI (Enhanced Vegetation Index)	
EVI (Enhanced Vegetation Index)	$EVI = 2.5 \times \frac{NIR-Red}{NIR+6xRed-7.5xBlue+1}$
VARI (Visible Atmospherically Resistant Index)	$VARI = \frac{Green-Red}{Green+Red-Blue}$

O NDVI (Normalized Difference Vegetation Index) é talvez o índice mais amplamente utilizado para monitorizar a vitalidade das plantas. No entanto, por vezes pode haver dificuldade na detecção precoce de stress em florestas. O índice baseia-se no facto de a clorofila em plantas vivas refletir fortemente a luz no infravermelho próximo (NIR) e absorver a luz vermelha. Valores elevados de NDVI, próximos de 1, indicam

vegetação densa e saudável, enquanto valores mais baixos de 0,7 sugerem stress, e valores abaixo de 0,6 indicam morte das plantas. No entanto, de acordo com a experiência do projeto GO-SURF e revisão da literatura no contexto do cultivo de choupos (Chianucci et al., 2021), o NDVI pode ser o índice menos preciso para detetar stress.

Por exemplo, o Green Normalized Difference Vegetation Index (GNDVI) é mais sensível para a deteção precoce de stress. Este índice é semelhante ao NDVI, mas usa a banda verde em vez da banda vermelha para normalização com a banda NIR. Isto torna-o útil para monitorizar plantas com densidade foliar elevada ou identificar stress hídrico, permitindo avisos precoces (Raddi et al., 2021). Para avaliar o conteúdo de clorofila, o Índice de Clorofila Foliar (LCI) é muito sensível à clorofila presente nas folhas (Gallardo-Salazar et al., 2023). A clorofila absorve luz vermelha e reflete em vermelho-infravermelho, tornando este índice útil para estimar diretamente o conteúdo de clorofila, que é um indicador da capacidade fotossintética da planta. Da mesma forma, o Índice de Clorofila no vermelho-infravermelho (CIRE) está ainda mais correlacionado com o estado nutricional das plantas (Kleinsmann et al., 2023).

O Índice de Vegetação de Diferença Normalizada no Red Edge (NDRE) é particularmente útil para identificar stress nas copas. O vermelho-infravermelho é muito sensível a mudanças na estrutura das folhas e no conteúdo de clorofila, permitindo a deteção de pequenas variações (Minařík e Langhammer, 2016). É útil para identificar plantas que podem ser afetadas por doenças ou deficiências nutricionais antes que esses problemas sejam visíveis a olho nu. O Índice de Absorção de Clorofila Modificado (MCARI) é projetado para ser menos sensível a variações do solo, aumentando a capacidade de detetar stress vegetal em ambientes heterogêneos com solo exposto (Zou et al., 2019). Para avaliar a atividade fotossintética e o vigor vegetativo, o Índice de Vegetação Melhorado (EVI) melhora a sensibilidade em áreas de vegetação de alta densidade e reduz as interferências atmosféricas e do solo em comparação com o NDVI. O Índice Resistente à Atmosfera Visível (VARI) pode ser usado de forma a monitorizar a vegetação usando apenas as

bandas visíveis, tornando-o útil em condições onde as bandas NIR não estão disponíveis, como com câmaras RGB.

3. Drones e Câmaras Multiespectrais no Mercado

Entre os drones com um sensor multiespectral integrado, o DJI Mavic 3M combina uma câmara RGB de 20 MP e quatro câmaras multiespectrais de 5 MP que capturam nas bandas verde ($560\text{nm}\pm 16\text{nm}$), vermelha ($650\text{nm}\pm 16\text{nm}$), vermelho-infravermelho ($730\pm 16\text{nm}$) e NIR ($860\text{nm}\pm 26\text{nm}$), juntamente com um sensor de luz integrado. Esta configuração captura a radiância solar, permitindo a compensação pós-processamento de quaisquer flutuações de luz nas imagens. O fabricante afirma uma autonomia de voo de 43 minutos com uma cobertura por voo de 2 km². O drone também está disponível com um módulo RTK, fornecendo georreferenciação precisa do levantamento com alta precisão.

Outro drone DJI com um sensor integrado é o P4 Multiespectral, equipado com seis câmaras diferentes de 2,08 MP — uma câmara RGB e cinco câmaras multiespectrais que capturam nas bandas azul ($450\pm 16\text{nm}$), verde ($560\pm 16\text{nm}$), vermelha ($650\pm 16\text{nm}$), vermelho-infravermelho ($730\pm 16\text{nm}$) e infravermelha próxima ($840\pm 26\text{nm}$). Este drone também apresenta um sensor de luz e módulo RTK para correção de luz na imagem e georreferenciação precisa do levantamento. O fabricante afirma uma autonomia de voo de 27 minutos e uma área operacional máxima por voo de 0,63 km². Num estudo recente na Alemanha (Ecke et al., 2024), este drone foi usado para adquirir imagens multiespectrais de alta resolução de 235 diferentes áreas de monitorização florestal em grande escala (parcelas ICP Nível-I) distribuídas na Baviera ao longo de um período de monitorização de três anos (2020-2022). Apesar do conjunto de dados heterogéneo adquirido ao longo do tempo sob várias condições meteorológicas e de iluminação, em florestas com composições diversas espalhadas por uma grande área de estudo, o artigo demonstra como foi possível classificar cinco espécies de árvores, ao nível do género, árvores mortas e o estado

sanitário das principais espécies de árvores em 14 classes diferentes utilizando a CNN EfficientNet. O artigo destaca que esta metodologia de monitorização pode reduzir significativamente os custos e os tempos de aquisição de campo, permitindo a padronização dos dados.

Entre as câmaras que podem ser montadas em vários tipos de drones, como o DJI Matrice 300, o Wingtra One Gen II e o senseFly eBeeX, destaca-se a MicaSense RedEdge-MX como uma das mais eficientes, mas também uma das mais caras. Esta câmara capta imagens nas bandas, azul ($475\text{nm}\pm 20\text{nm}$), verde ($560\text{nm}\pm 20\text{nm}$), vermelha ($668\text{nm}\pm 10\text{nm}$), vermelha-infravermelha ($717\text{nm}\pm 10\text{nm}$) e infravermelha próxima ($840\text{nm}\pm 40\text{nm}$), oferecendo uma alta precisão espectral e consistência, sendo ideal para analisar a vegetação florestal. A câmara está equipada com um sensor de luz e um painel de reflectância para calibração, que deve ser capturado na descolagem e aterragem do drone.

Esta câmara também foi testada no projeto GO-SURF, onde foi utilizada para adquirir imagens de várias áreas na região da Toscana, utilizando o drone Wingtra One Gen II. O processamento de imagem através de técnicas de segmentação baseadas no método "Simple Linear Iterative Clustering (SLIC)" (Achanta et al. 2012) permitiu a identificação de plantas mortas e em declínio, identificando os limiares de stress. O SLIC é um algoritmo usado para segmentação de imagens, particularmente para criar *superpixels* - grupos de *pixels* contíguos com características semelhantes, que simplificam a análise de imagem, reduzindo o número de elementos a considerar, mantendo a maior parte da informação relevante. Especificamente, no projeto GO-SURF, as imagens multispectrais foram processadas usando o *software* Metashape Agisoft para gerar um mosaico de ortos em diferentes bandas (azul, verde, vermelha, vermelha-infravermelha, infravermelha próxima). As imagens foram importadas para o *software* R-Cran, utilizando vários pacotes de processamento para inicializar o algoritmo. Durante a inicialização, o algoritmo distribui uniformemente os centros de *superpixels* por toda a imagem. Estes centros são escolhidos para cobrir uniformemente toda a imagem. Cada *pixel* na imagem é então atribuído ao centro de *superpixel* mais próximo com base na distância combinada

(espaço e cor). A distância combinada considera tanto as coordenadas espaciais como os valores de cor (espaço CIELAB). O algoritmo é repetido até segmentar as copas individuais. Este algoritmo pode também ser usado através de *software* de *desktop* como o SAGA GIS. Os testes realizados no projeto GO-SURF mostraram que a segmentação do ambiente florestal funciona muito bem mesmo utilizando apenas a banda vermelha-infravermelha, e não múltiplas bandas. Esta banda parece ser mais sensível para identificar copas individuais ou partes de copas com atividade fotossintética semelhante. O método de segmentação reduz o tempo em comparação com métodos complexos e deteta com precisão de copas individuais ou partes de copas com diferentes atividades fotossintéticas, como partes de copas mortas ou em declínio. No entanto, para classificar diferentes classes de decomposição (parte da copa morta, em declínio e viva), os índices de vegetação precisam ser extraídos dos polígonos gerados pelo SLIC, calibrando limiares para identificar plantas mortas. Assim, para cada *superpixel*, são aplicados limiares aos índices de vegetação para classificar *superpixels* representando as plantas saudáveis, stressadas ou mortas. A vantagem deste método é que a segmentação de *superpixels* reduz o número de unidades a analisar, tornando a análise mais rápida e eficiente. Além disso, os *superpixels* tendem a seguir os contornos naturais das plantas, melhorando a precisão da classificação em comparação com métodos de *pixel* único.




Figura 1. Identificação de Superpixels com Contornos Brancos, Detecção de Copas em Declínio a Amarelo e Partes de Copas Mortas a Azul

O uso de Superpixels SLIC em imagens de drones representa uma técnica avançada para identificar e monitorizar plantas mortas. Ao criar segmentos de imagens em regiões homogêneas e aplicar limites em índices de vegetação, é possível obter um mapa preciso de áreas problemáticas, permitindo intervenções oportunas e direcionadas na gestão de culturas.

Entre outras câmaras multiespectrais disponíveis no mercado a um custo mais baixo em comparação com as mencionadas anteriormente estão a Parrot Sequoia, a Sentera Double 4K, a Mapir Survey3 e a Mapir Survey2. Todas estas câmaras, tal como as outras, adquirem informação multiespectral nas bandas de vermelho, azul, verde e infravermelho próximo, mas não no vermelho-infravermelho. Isso torna-as menos eficazes no cálculo de alguns dos índices mencionados anteriormente

4. Conclusões

É impossível ter uma visão completa de todas as câmaras disponíveis no mercado neste momento. No entanto, com base na nossa experiência, é essencial focar nas câmaras que permitem o cálculo de diferentes índices de vegetação, o que pode contribuir para mapear com precisão danos potenciais. Isso porque é cada vez mais importante poder intervir prontamente. Apesar de algumas limitações, os drones equipados com câmaras multiespectrais representam uma ferramenta poderosa e versátil para a monitorização florestal, como demonstrado pelo projeto GO-SURF já implementado em Itália. Antecipa-se que futuros desenvolvimentos tecnológicos e uma maior acessibilidade aos drones tornarão estas ferramentas cada vez mais fundamentais na gestão florestal sustentável.

5. Agradecimentos

Esta contribuição foi feita no âmbito do projeto FOREST4EU, financiado pelo Programa de Investigação e Inovação Horizon Europe da União Europeia, ao abrigo do Acordo de Subsídio N° 101086216

6. Referências

- Achanta R, Shaji A, Smith K, et al (2012) SLIC superpixels compared to state-of-the-art superpixel methods
- 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) A Sentinel-2 derived dataset of forest disturbances occurred in Italy between 2017 and 2020. *Data Br* 42:108297. <https://doi.org/10.1016/j.dib.2022.108297>
- Gallardo-Salazar JL, Lindig-Cisneros RA, Lopez-Toledo L, et al (2023) Analysis of the Vigor of *Pinus hartwegii* Lindl. along an Altitudinal Gradient Using UAV Multispectral Images: Evidence of Forest Decline Possibly Associated with Climatic Change. *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. *For 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, Denoux 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) Monitoring the effects of extreme drought events on forest health by Sentinel-2 imagery. *J Appl Remote Sens* 13:1. <https://doi.org/10.1117/1.jrs.13.020501>

Raddi S, Giannetti F, Martini S, et al (2021) Monitoring drought response and chlorophyll content in *Quercus* by consumer-grade, near-infrared (NIR) camera: a comparison with reflectance spectroscopy. *New For.* <https://doi.org/10.1007/s11056-021-09848-z>

Trumbore S, Brando P, Hartmann H (2015) Forest health and global change. *Science* (80-) 349:814–818. <https://doi.org/10.1126/science.aac6759>

Zhang L, Zhang H, Niu Y, Han W (2019) Mapping Maize Water Stress Based on UAV Multispectral Remote Sensing. *Remote Sens* 11:605. <https://doi.org/10.3390/rs11060605>

Zou X, Liang A, Wu B, et al (2019) UAV-based high-throughput approach for fast growing *Cunninghamia lanceolata* (Lamb.) cultivar screening by machine learning. *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