

Droni in multispektralne kamere za spremljanje zdravja gozdov

Francesca Giannetti, Oddelek za kmetijske, živilske, okoljske in gozdarske znanosti in tehnologije (DAGRI), Univerza v Firencah; Skupni laboratorij ForTech; Bluebiloba start-up innovativa s.r.l.

Yamuna Giambastiani, Skupni laboratorij ForTech; Bluebiloba start-up innovativa s.r.l.

Lorenzo Massai, Skupni laboratorij ForTech; Bluebiloba start-up innovativa s.r.l.

Patrizia Rossi, Oddelek za kmetijske, živilske, okoljske in gozdarske znanosti in tehnologije (DAGRI), Univerza v Firencah

Solaria Anzillotti, Oddelek za kmetijske, živilske, okoljske in gozdarske znanosti in tehnologije (DAGRI), Univerza v Firencah

Livia Passarino, Oddelek za kmetijske, živilske, okoljske in gozdarske znanosti in tehnologije (DAGRI), Univerza v Firencah

Giuliano Secchi, Oddelek za kmetijske, živilske, okoljske in gozdarske znanosti in tehnologije (DAGRI), Univerza v Firencah

Davide Travaglini, Oddelek za kmetijske, živilske, okoljske in gozdarske znanosti in tehnologije (DAGRI), Univerza v Firencah; Skupni laboratorij ForTech (Laboratorio Congiunto ForTech)

Gherardo Chirici, Oddelek za kmetijske, živilske, okoljske in gozdarske znanosti in tehnologije (DAGRI), Univerza v Firencah; Skupni laboratorij ForTech (Laboratorio Congiunto ForTech)

Objavljeno na spletu 11.08.2025 (<https://doi.org/10.20315/IG.2025.0037>)



Spremljanje stanja gozdov je bistvenega pomena za ocenjevanje in ohranjanje zdravja gozdnih ekosistemov, posebej v povezavi s podnebnimi spremembami. Dosedanje raziskovalne metode so omejene s subjektivnostjo ocene in opazovanja, logistično zapletenostjo in visokimi stroški. Daljinsko zaznavanje ponuja učinkovitejšo alternativo. Med tehnologijami daljinskega zaznavanja so se kot posebej učinkoviti izkazali brezpilotni letalniki (v nadaljevanju droni) (angleško Unmanned Aerial Vehicle – UAV), opremljeni z multispektralnimi kamerami. Takšni droni zagotavljajo visoko ločljive, stroškovno učinkovite in prilagodljive rešitve za spremljanje stanja gozdov, saj zajemajo podrobne podatke v različnih spektrih (pri različnih valovnih dolžinah) elektromagnetnega valovanja (EMV). To omogoča natančno prepoznavanje stresa in poškodb vegetacije, kar omogoča pravočasne in ciljno usmerjene ukrepe. Projekt GO-SURF je pokazal, da postajajo droni z multispektralnimi senzorji nepogrešljivo orodje za trajnostno upravljanje gozdov.

Spremljanje zdravja gozdov je proces, namenjen ocenjevanju zdravja gozdov (Trumbore et al. 2015). Spremljanje vključuje opazovanje in beleženje različnih kazalnikov kot so stopnja osutosti, prisotnost bolezni ali škodljivcev ter drugi znaki stresa. Glavni cilj spremljanja zdravja gozdov je pravočasno zaznavanje morebitnih sprememb, da se lahko pravočasno sprejme ukrepe za zmanjšanje škode in ohranitev zdravja gozdnih ekosistemov (Ecke et al. 2022).

Vzpostavitev sistemov spremljanja zdravja gozdov je posebej pomembna v kontekstu podnebnih sprememb, kjer vegetacija vse bolj doživlja učinke stresa z izgubo fotosintetske aktivnosti (Puletti et al. 2019) in kjer imajo izjemni dogodki kot so požari in gradacije žuželk (Kautz et al. 2024) ter drugi patogeni vse večji vpliv. Zato postaja vse pomembnejša vzpostavitev spremljanja zdravja gozdov z namenom blaženja možnih težav v gozdnih sestojih in pravočasnega posredovanja za vsakega upravljalca gozda.

V Italiji in Evropi se spremljanje zdravja gozdov na lokalni, regionalni in globalni ravni z uporabo standardnih kazalnikov, temelječih na strokovni oceni usposobljenih oseb na terenu, ki na primer ugotavljajo stopnjo osutosti krošenj, izvaja že več desetletij (Canullo et al. 2012). Ta omrežja spremljanj nam zagotavljajo poenoten okvir za ocenjevanje stanja zdravja gozdov, vendar na omejenem številu vzorčnih ploskev. To omogoča spremljanje na nacionalni ravni, vendar ni v skladu s potrebami upravljalcev gozdov. Javni in zasebni upravljalci gozdov se v svojih sestojih vse pogosteje soočajo z vplivom motenj na gozd. Kot je bilo že prej omenjeno, je uvedba sistemov spremljanja zdravja gozdov ključnega pomena za hitro prepoznavanje morebitnih težav in pravočasno ukrepanje za njihovo omejitev.

Klasične terenske raziskave so lahko zelo negotove, ker je njihova kvaliteta odvisna od izkušenosti in natančnosti ter subjektivnosti zaznavanja opazovalca. Zato so za standardizirano in optimalno izvajanje raziskav potrebna posebna usposabljanja (v obliki tečajev). Take raziskave so tudi logistično zahtevne in drage, zato so izvedljive le na ravni sestoja ali posamezne parcele. To je razlog za uveljavitev daljinskega zaznavanja kot del spremljanja zdravja gozdov. Daljinsko zaznavanje omogoča objektivno, kvantitativno in ponovljivo pridobivanje kazalnikov zdravja gozdov na različnih prostorskih enotah (Lambert et al. 2013; Ecke et al. 2024).

Satelitsko daljinsko zaznavanje je še vedno prevladujoče v raziskavah in v uporabi pri spremljanju zdravja gozdov. Javno dostopni multispektralni podatki, kot so Landsat, MODIS in Sentinel-2 omogočajo veliko površinsko spremljanje zahvaljujoč se veliki časovni in prostorski ločljivosti, ki pogosto zadostuje za prepoznavanje motenj (Francini and Chirici 2022). Kakorkoli, v nekaterih raziskavah je bilo poudarjeno, da satelitom pri spremljanju lahko predstavljajo težave na primer oblaki (Gianetti et al. 2021), ki lahko zakrijejo del površja. Zaradi tega je na nekaterih območjih, kot so gorata območja Alp in Apeninov, vzpostavitev sistemov zgodnjega opozarjanja zahtevna. Te pomanjkljivosti so nezdružljive s hitrimi spremembami v gozdu, povzročenimi z biotskimi ali abiotskimi dejavniki. Težavo bi lahko odpravili z uporabo letal, saj letijo pod oblaki (Ecke et al. 2024). V praksi se zaradi visokih stroškov in logističnih omejitev letala uporabi le na velikih površinah, enkrat ali dvakrat letno. Posledično niso primerna za zgodnje prepoznavanje stresa (Ecke et al. 2024).

Zaradi navedenih razlogov so brezpilotna letala vse bolj v uporabi vendar ne kot konkurenca, temveč kot dopolnilo obstoječim tehnologijam opazovanja površja (Ecke et al. 2024). V okviru operativne skupine GO-SURF so bili droni, opremljeni z multispektralnimi kamerami, uporabljeni za kartiranje stresa v gozdnih sestojih. Droni v primerjavi s sateliti in letali pokrivajo manjša območja, vendar zagotavljajo boljšo prostorsko ločljivost površja, ki lahko doseže red centimetra. Prav tako so zelo učinkoviti iz vidika stroškov, prilagodljivosti in še posebej pogostosti snemanj, ki je lahko zelo velika, saj je odvisna le od upravljalca.

Območje, ki ga je mogoče pokriti z droni je od enega do več sto ha v enem letu. Na površino pokritosti vplivajo predvsem vrsta drona, tehnologija pogona, vrsta kamere, teren in dostopnost območja. Prav tako je kot omejitven dejavnik za pokritost potrebno upoštevati predpise o delovanju dronov. Nova evropska uredba dovoljuje letenje na višini 120 metrov nad tlemi z varnostno razdaljo 500 metrov, kar najzmogljivejšim dronom omogoča pokrivanje 10 do 20 ha s posameznim preletom.

Poleg dronov je za vzpostavitev sistema spremljanja zdravja gozdov pomemben tudi senzor na njem. Na trgu je na voljo veliko multispektralnih kamer. Te kamere so zahvaljujoč sposobnosti zajemanja različnih valovnih dolžin elektromagnetnega valovanja uporabne za kartiranje različnih vrst stresa v gozdu (Barzagli et al. 2018; Zhang et al. 2019; Ecke et al. 2022).

Kljub temu se je zaradi velike raznolikosti kamer, ki so na voljo na trgu in različnih vegetacijskih indeksov, ki jih je mogoče iz njih pridobiti, težko usmerjati po nenehno razvijajočem se področju raziskav in tehničnega napredka. Zato je namen tega članka na podlagi rezultatov projekta EIP-AGRI GO-SURF in ob upoštevanju mednarodne literature zagotoviti pregled vegetacijskih indeksov, ki so uporabni za kartiranje stresa v gozdu, pregled nekaterih kamer, ki so na voljo na trgu, in najpreprostejših ter najobetavnejših tehnik obdelave podatkov v želji ponuditi koristne informacije tehnikom, ki se ukvarjajo s spremljanjem gozdov.

Multispektralne kamere in vegetacijski indeksi

Multispektralne kamere so napredne naprave, ki zajemajo vizualne informacije v različnih spektrih elektromagnetnega valovanja. Ti lahko vključujejo vidni spekter in bližnjo infrardečo svetlobo (NIR), v nekaterih primerih pa rdeči rob (angleško Red edge). Z zaznavanjem različnih valovnih dolžin multispektralne kamere zagotavljajo podrobne podatke, ki jih je mogoče uporabiti za analizo različnih lastnosti vegetacije, tal in gozda. Zaradi zmožnosti pridobivanja informacij v infrardečem spektru je mogoče raziskati fotosintetsko aktivnost rastlin, oceniti zdravje dreves in ugotoviti prisotnost bolezni

ali druge vrste stresa. Tako kot kamere v vidnem spektru jih je mogoče uporabiti za fotogrametrično zajemanje. To omogoča ne zgolj pridobivanje 2D podatkov (multispektralni ortomozaik), temveč tudi 3D podatkov, kot so oblaki točk in digitalni modeli površja, uporabnih za analizo strukture gozda (Barzagli et al. 2018; Giannetti et al. 2020).

Glavna prednost multispektralnih kamer je, kot je bilo že prej omenjeno, sposobnost zajemanja slik v različnih valovnih dolžinah spektra elektromagnetnega valovanja. To uporabnikom omogoča prepoznavanje razlik v vegetaciji glede na vsebnosti klorofila. Tako lahko dobljeni podatki hitro pokažejo prisotnost stresa, bolezni ali patogenov. Zaradi zmožnosti pridobivanja informacij po različnih valovnih dolžinah jih je mogoče enostavno uporabiti za izpeljavo različnih vegetacijskih indeksov s preprostimi matematičnimi operacijami med slikami, posnetimi v različnih spektrih tudi z uporabo običajnih aplikacij GIS (geografski informacijski sistemi), kot je to mogoče v aplikaciji QField z uporabo funkcij rastrskega kalkulatorja.

Med vegetacijskimi indeksi, ki jih je mogoče izračunati na podlagi podatkov, zajetih s trenutno razpoložljivimi multispektralnimi kamerami, so v preglednici 1 navedeni najobetavnejši za spremljanje stresa v gozdnih okoljih.

Preglednica 1: Vegetacijski indeksi, uporabni za spremljanje gozdov, ki jih je mogoče izračunati iz podatkov, pridobljenih z multispektralnimi kamerami.

Vegetacijski indeks	Formula
NDVI (normalizirana razlika vegetacijskega indeksa)	$NDVI = \frac{NIR - Red}{NIR + Red}$
NDRE (normalizirana razlika rdečega robu)	$NDRE = \frac{NIR - RedEdge}{NIR + RedEdge}$
GNDVI (zeleni normalizirani indeks razlike vegetacije)	$GNDVI = \frac{NIR - Green}{NIR + Green}$
LCI (indeks listnega klorofila)	$LCI = \frac{RedEdge - Red}{RedEdge + Red}$
SAVI (vegetacijski indeks prilagojen tlom)	$SAVI = \frac{(1+L)(NIR - Red)}{NIR + Red + L}$ kjer je L konstanta, odvisna od razmer v tleh (običajno $L = 0,5$)
OSAVI (optimizirani vegetacijski indeks prilagojen tlom)	$OSAVI = \frac{(NIR - Red)}{NIR + Red + 0.16}$
MCARI (modificiran indeks razmerja absorpcije klorofila)	$MCARI = \frac{(RedEdge - Red) - 0.2 \times (RedEdge - Green)}{RedEdge + Red}$
CIRE (indeks klorofila rdeči rob)	$CIRE = \frac{NIR}{RedEdge} - 1$
EVI (izboljšani vegetacijski indeks)	$EVI = 2.5 \times \frac{NIR - Red}{NIR + 6 \times Red - 7.5 \times Blu + 1}$
VARI (vidni atmosfersko odporni indeks)	$VARI = \frac{Green - Red}{Green + Red - Blu}$

Indeks NDVI (Normalized Difference Vegetation Index) je verjetno najbolj razširjen indeks za spremljanje zdravja rastlin. Njegova nagnjenost k nasičenosti v določenih primerih ovira zgodnje odkrivanje stresa v gozdovih. Indeks temelji na dejstvu, da klorofil v živih rastlinah močno odbija bližnjo infrardečo svetlobo (NIR) in absorbira rdečo svetlobo. Visoke vrednosti NDVI (blizu 1) kažejo na gosto in zdravo vegetacijo, medtem ko nižje vrednosti (pod 0,7) kažejo na stres. Vrednosti pod 0,6 kažejo na odmiranje rastlin. Nasprotno pa je na podlagi izkušenj iz projekta GO-SURF in pregleda literature v okviru gojenja topola (Chianucci et al. 2021) NDVI morda najmanj natančen indeks za zaznavanje stresa.

GNDVI (Green Normalized Difference Vegetation Index) je na primer bolj občutljiv zgodnji kazalnik stresa. Podoben je indeksu NDVI, vendar za normalizacijo s spektrom NIR namesto rdečega uporablja zeleni del spektra. Zaradi tega je ta indeks uporaben za spremljanje rastlin z veliko gostoto listov in prepoznavanje vodnega stresa. To omogoča zgodnje opozarjanje na stres (Raddi et al. 2021). Za ocenjevanje vsebnosti klorofila je primeren indeks LCI (Leaf Chlorophyll Index). Zelo je občutljiv na prisotnost klorofila v listih (Gallardo-Salazar et al. 2023). Klorofil absorbira rdečo svetlobo in odbija svetlobo rdečega roba. Ravno zato je ta indeks uporaben za neposredno oceno vsebnosti klorofila, ki je kazalnik fotosintetske aktivnosti rastline. Podobno je indeks CIRE (Chlorophyll Index Red Edge) še bolj povezan s hranili v rastlinah (Kleinsmann et al. 2023).

NDRE (Normalized Difference Red Edge) je posebej uporabna pri prepoznavanju stresa rastlin v delih krošenj. Rdeči rob je zelo občutljiv na spremembe v strukturi listov in vsebnosti klorofila. To omogoča zaznavanje že majhnih odstopanj (Minařík and Langhammer 2016). Uporaben je za prepoznavanje z boleznimi prizadetih rastlin in rastlin, ki jim primanjkuje hranil, še preden je to opazno s prostim očesom. Indeks MCARI (Modified Chlorophyll Absorption Ratio Index) je zasnovan tako, da je manj občutljiv na spremembe v tleh. Tako ima večjo sposobnost zaznavanja stresa rastlin v heterogenih okoljih z izpostavljenimi tlemi (Zou et al. 2019). EVI (Enhanced Vegetation Index) pri ocenjevanju fotosintetske aktivnosti in vitalnosti vegetacije izboljša občutljivost na območjih z visoko gostoto vegetacije. V primerjavi z NDVI zmanjša atmosferske in talne motnje. Indeks VARI (Visible Atmospherically Resistant Index) se lahko uporablja za spremljanje vegetacije samo z uporabo delov vidnega spektra. Zato je uporaben v razmerah, ko pasovi NIR niso na voljo, na primer pri kamerah RGB.

Droni in multispektralne kamere na trgu


Med droni z integriranimi multispektralnimi senzorji je DJI Mavic 3M tak, ki združuje 20 MP RGB kamero in štiri 5 MP multispektralne kamere, ki zajemajo zelen ($560 \text{ nm} \pm 16 \text{ nm}$), rdeč ($650 \text{ nm} \pm 16 \text{ nm}$), rdeči rob ($730 \pm 16 \text{ nm}$), in NIR ($860 \text{ nm} \pm 26 \text{ nm}$) del spektra skupaj z vgrajenim senzorjem svetlobe. Ta nastavev zajema sončno obsevanje, kar omogoča naknadno obdelavo in kompenzacijo morebitnih svetlobnih nihanj na slikah. Proizvajalec trdi, da leti avtonomno 43 minut in v enem letu pokrije dva km² površine. Dron je na voljo tudi skupaj z modulom RTK, ki zagotavlja georeferenciranje raziskave z visoko natančnostjo.

Dron, prav tako podjetja DJI, ima vgrajen senzor P4 Multispectral. Opremljen je s šestimi različnimi 2,08 MP kamerami. Ena je RGB, pet pa je multispektralnih kamer, ki zajemajo v modrem ($450 \pm 16 \text{ nm}$), zelenem ($560 \pm 16 \text{ nm}$), rdečem ($650 \pm 16 \text{ nm}$), rdečem robu ($730 \pm 16 \text{ nm}$) in skoraj infrardečem ($840 \pm 26 \text{ nm}$) delu spektra. Tudi ta dron je opremljen s svetlobnim senzorjem in modulom RTK, ki omogočata korelacijo svetlobe na sliki in natančno georeferenciranje raziskave. Proizvajalec navaja, da avtonomno leti 27 minut in da njegovo operativno območje v enem letu

obsega največ 0,63 km². V nedavni študiji v Nemčiji (Ecke et al. 2024) je bil ta dron uporabljen za pridobitev multispektralnih posnetkov visoke ločljivosti 235 različnih obsežnih območij za spremljanje gozdov (ploskve ICP ravni I), ki so bile v triletnem obdobju spremljanja (2020-2022) razporejene na Bavarskem. Kljub heterogeno razporejenim podatkom, pridobljenim skozi daljše časovno obdobje, v različnih vremenskih in svetlobnih razmerah, v gozdovih z raznoliko sestavo, razprostirajočih se na velikem študijskem območju, članek prikazuje, kako je bilo mogoče z uporabo tehnike EfficientNet CNN arhitekture razvrstiti pet drevesnih vrst na ravni rodu, odmrla drevesa in zdravstveno stanje glavnih drevesnih vrst v 14 različnih razredov. Članek poudarja, da ta metodologija spremljanja bistveno zmanjša stroške in čas pridobivanja podatkov na terenu ter omogoča standardizacijo podatkov.

Med kamerami, ki se jih lahko namesti na različne vrste dronov kot so DJI Matrice 300, Wingtra OneGen II in senseFly eBeeX je ena izmed najučinkovitejših (pa tudi najdražjih) kamera MicaSense RedEdge-MX. Ta kamera slike zajema v modrem (475 nm $\pm$ 20 nm), zelenem (560 nm $\pm$ 20 nm), rdečem (668 nm $\pm$ 10 nm), rdečem robu (717 nm $\pm$ 10 nm) in bližnjem infrardečem (840 nm $\pm$ 40 nm) delu spektra. To ji omogoča veliko spektralno natančnost in konsistenco, zato je idealna za analizo gozdne vegetacije. Opremljena je s svetlobnim senzorjem in odbojno ploščo za kalibracijo, ki jo je potrebno zajeti ob vzletu in pristanku drona.

Kamera MicaSense RedEdge-MX je bila preizkušena tudi v projektu GO-SURF, kjer je bila uporabljena za zajemanje slik na različnih območjih v Toskani. Uporabljena je bila na dronu One Gen II. Obdelava slik s tehnikami segmentacije na podlagi metode „Simple Linear Iterative Clustering (SLIC)“ (Achanta et al. 2012) je z določitvijo pragov stresa omogočila prepoznavanje odmrlih in propadajočih rastlin. SLIC je algoritem, ki se uporablja za segmentacijo slik, zlasti za ustvarjanje superpikslov – skupin sosednjih pikslov s podobnimi lastnostmi, ki poenostavijo analizo slik, saj zmanjšajo število elementov, ki jih je potrebno upoštevati, ohranijo pa večino pomembnih informacij. V projektu GO-SURF so bile slike obdelane s fotogrametrično programsko opremo Metashape Agisoft v različnih delih spektra (moder, zelen, rdeč, rdeči rob, NIR). Slike so bile uvožene v programsko opremo R-Cran z uporabo različnih paketov za obdelavo za inicializacijo algoritma. Med inicializacijo algoritma po sliki enakomerno razporedi središča superpikslov. Ta središča so izbrana tako, da enakomerno pokrivajo celotno sliko. Vsak piksel na sliki je nato dodeljen najbližjemu središču superpiksla na podlagi kombinirane razdalje (prostor in barva). Kombinirana razdalja upošteva prostorske koordinate in barvne vrednosti (CIELAB). Algoritem se ponavlja, dokler ne segmentira posameznih krošenj. Ta algoritem se lahko uporablja tudi za programsko opremo kot je SAGA GIS. Testi, opravljeni v okviru projekta GO-SURF so pokazali, da segmentacija gozda deluje zelo dobro tudi ob uporabi samo rdečega dela spektra. Zdi se, da je ta del spektra najbolj občutljiv na prepoznavanje posameznih krošenj ali delov krošenj s podobno fotosintetsko aktivnostjo. Metoda segmentacije zmanjša čas v primerjavi s kompleksnimi metodami in natančno zazna posamezne krošnje ali dele krošenj z različno fotosintetsko aktivnostjo, kot so odmrli ali propadajoči deli krošenj. Vendar za razvrstitev različnih razredov propadanja je potrebno iz poligonov, ki jih je ustvaril SLIC izluščiti vegetacijske indekse in kalibrirati pragove za prepoznavanje odmrlih rastlin. Tako se za vsak superpiksel uporabijo pragovi za vegetacijske indekse, da se superpiksli razvrstijo med zdrave, tiste v stresu ali med odmrle rastline. Prednost te metode je, da segmentacija superpikslov zmanjša število enot za analizo, kar naredi analizo hitrejšo in učinkovitejšo. Poleg tega superpiksli običajno sledijo naravnim obrisom rastlin, kar izboljša natančnost klasifikacije v primerjavi z metodo z enim pikslom.



Slika 1: Prepoznavanje superpikslov z belimi obrisi, zaznavanje osutosti krošnje z rumenimi obrisi in odmrli deli krošnje obrisani z modro.

Uporaba superpikslov SLIC na posnetkih, posnetih z droni, predstavlja napredno tehniko prepoznavanja in spremljanja odmrlih dreves. S segmentacijo slik na homogena območja in uporabo pragov za vegetacijske indekse je mogoče pridobiti natančne karte problematičnih območij, kar omogoča pravočasne in ciljno usmerjene ukrepe.

Med multispektralnimi kamerami na trgu, ki so cenejše od prej omenjenih, so Parrot Sequoia, Sentra Double 4K, Mapir Survey3 in Mapir Survey2. Vse te kamere, tako kot druge, zajemajo multispektralne informacije v rdečem, modrem, zelenem in NIR delu spektra, ne pa tudi v rdečem robu. Zaradi tega so manj učinkovite pri izračunu nekaterih prej omenjenih indeksov.

Sklepi

Nemogoče je imeti popoln pregled vseh kamer, ki so na voljo na trgu. Zato se je na podlagi izkušenj smiselno osredotočiti na kamere, ki omogočajo izračun različnih vegetacijskih indeksov, kar lahko prispeva h kartiranju morebitne škode. Zelo pomembno je namreč, da ob nastali škodi ukrepamo čim prej. Kljub nekaterim omejitvam droni, opremljeni z multispektralnimi kamerami, predstavljajo močno in vsestransko orodje za spremljanje stanja gozdov. Primer je projekt GO-SURF, ki to že uporablja v

Italiji. Pričakovati je, da bodo zaradi nadaljnjega tehnološkega razvoja in vse večje dostopnosti dronov ta orodja postala vse pogostejša in pomembnejša pri trajnostnem gospodarjenju z gozdovi.

Zahvala

Ta prispevek je nastal v okviru projekta FOREST4EU, ki je financiran iz programa Evropske unije za raziskave in inovacije Obzorje Evropa v okviru sporazuma o dodelitvi nepovratnih sredstev št. 101086216.

Prevod

Matevž Triplat, Gozdarski inštitut Slovenije, Oddelek za gozdno tehniko in ekonomiko
Žiga Lukančič, Gozdarski inštitut Slovenije, Oddelek za gozdno tehniko in ekonomiko

Viri in literatura:

Achanta R., Shaji A., Smith K., Lucchi A., Fua P., Süssstrunk S. 2012. SLIC Superpixels Compared to State-of-the-Art Superpixel Methods. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 34, no. 11, pp. 2274-2282, Nov. 2012, doi: 10.1109/TPAMI.2012.120.

Barzagli A., Nocentini S., Del Perugia B., Travaglini D., Giannetti F., Zolli C., Carrara S., Nerli M., Rossi P., Barbati A., Ferrari B., Tomao A., Lasserre B., Santopuoli G., Marchetti M., Balsi M., Chirici G. 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

Chianucci F., Puletti N., Grotti M., Bisaglia C., Giannetti F., Romano E., Brambilla M., Cabassi G., Mattioli W., Bajocco S., Li L., Corona P., Chirici G., Tattoni C. 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., Schwaller A., Endres E., Klemmt H.J., Tiede D., Seifert T. 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., Tiede D., Dempewolf J., Klemmt H.J., Endres E., Seifert T. 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 J.L., Lindig-Cisneros R.A., Lopez-Toledo L., Endara-Agramont A.R., Blanco-García A., Sáenz-Romero C. 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., Francini S., D'Amico G., Vangi E., Coccozza C., Chirici G. 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., Travaglini D., Chirici G. 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., Denux J.P., Balent G., Cheret V. 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., Farilella F., Chirici G., Tani A., Maltoni A., Mariotti B. 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., Su J., Zheng R., Li J. 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>