Tema: Računalni vid za sigurnost okoliša

Kolegij: Strojno učenje za primjene u okolišu

Ishodi učenja

Nakon završetka ove nastavne jedinice studenti će moći:

- Objasniti kako računalni vid pridonosi sigurnosti i praćenju okoliša.
- Opisati ključne koncepte detekcije objekata i klasifikacije slika u okolišnim kontekstima.
- Prepoznati kako se dronovi, satelitski podaci i senzori integriraju radi situacijske svijesti.
- Primijeniti jednostavan model računalnog vida za klasifikaciju satelitskih ili dronskih slika.
- Raspraviti kako automatizirana analiza slika podupire donošenje odluka u okolišu i ublažavanje rizika (npr. detekcija onečišćenja, praćenje šumskih požara, detekcija NUS-a, praćenje bioraznolikosti).

Uvod

Danas ćemo govoriti o računalnom vidu ne kao o apstraktnom konceptu umjetne inteligencije iz udžbenika strojnog učenja, nego kao o praktičnom alatu koji se već koristi za potporu sigurnosti okoliša.

Jednostavno rečeno, računalni vid odnosi se na učenje strojeva da „vide" - da analiziraju satelitske snimke, snimke dronova, zračne fotografije ili videosadržaje te iz njih izdvajaju smislene informacije. Ne radi se samo o prepoznavanju objekata na slici, nego o detekciji promjena, obrazaca i rizika u razmjerima koje je nemoguće obraditi ručno.

U primjenama povezanima s okolišem i sigurnošću ta sposobnost postaje ključna. Mnoga područja koja trebamo pratiti teško su dostupna ili opasna za pristup: industrijske zone, udaljene šume, područja pogođena sukobima ili područja kontaminirana neeksplodiranim ubojnim sredstvima. Tradicionalni terenski pregledi u takvim su kontekstima spori, skupi i često nesigurni.

Računalni vid, u kombinaciji sa strojnim učenjem, omogućuje nam kontinuirano praćenje tih područja pomoću vizualnih podataka. Automatizirani sustavi mogu obraditi velike količine satelitskih i dronskih snimki te prepoznati rane signale okolišnih prijetnji - kao što su istjecanja onečišćujućih tvari, nezakonita sječa, izbijanje šumskih požara ili strukturna oštećenja - znatno prije nego što se situacija pogorša.

Tijekom ovog predavanja razmotrit ćemo kako ti sustavi funkcioniraju u praksi: na koje se vrste podataka oslanjaju, koji su zadaci računalnog vida najrelevantniji za praćenje okoliša te kako se rezultati automatizirane analize slika prevode u stvarne odluke i aktivnosti ublažavanja rizika. Slika 7.1 prikazuje po čemu se računalni vid razlikuje od uobičajenog ljudskog vida.

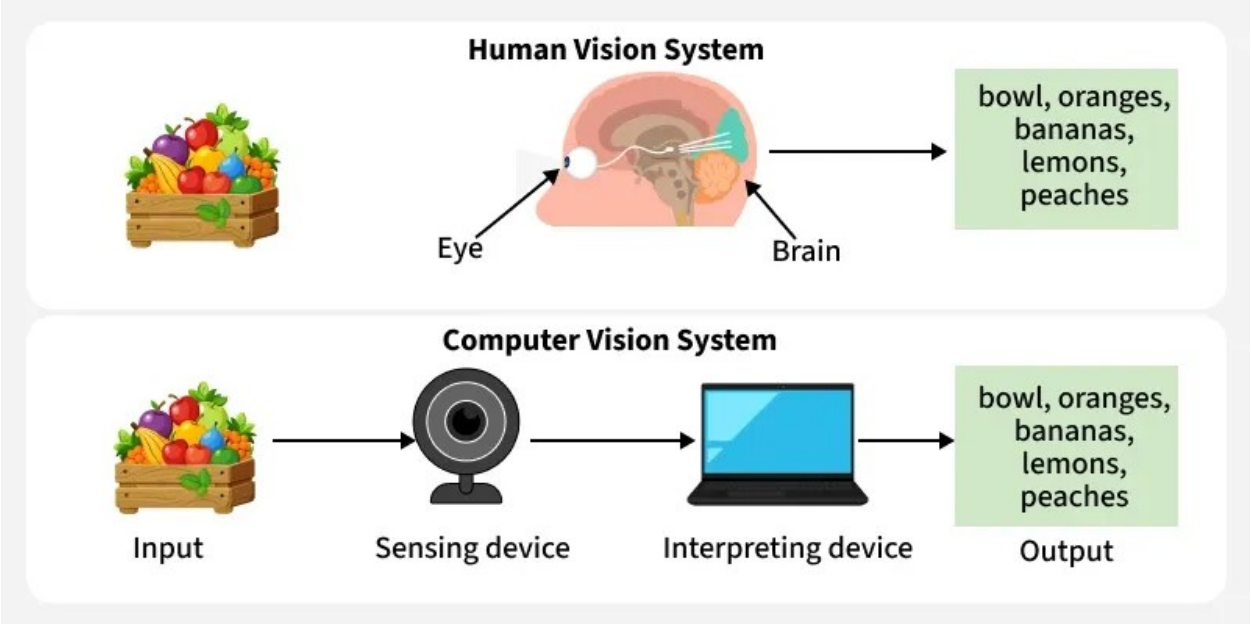

Slika 7.1 Shematski prikaz računalnog vida

Uloga i značenje računalnog vida

Kada govorimo o ulozi računalnog vida u praćenju okoliša, ključna je ideja skalabilnost. Tradicionalne metode praćenja snažno se oslanjaju na ljude - inspektore, terenska istraživanja i mjerenja na lokaciji. Ti pristupi funkcioniraju, ali se ne skaliraju dobro i često zakazuju upravo ondje gdje je praćenje najpotrebnije: u velikim, udaljenim ili opasnim područjima.

Računalni vid pruža skalabilniju i objektivniju alternativu. Umjesto oslanjanja na ljudsko opažanje, sirove piksele iz slika pretvaramo u strukturirane informacije koje se mogu automatski i dosljedno analizirati tijekom vremena.

U srži većine okolišnih sustava računalnog vida nalaze se dva temeljna zadatka: klasifikacija slika i detekcija objekata. Iako se često spominju zajedno, oni odgovaraju na različita praktična pitanja.

Klasifikacija slika usmjerena je na to što je prisutno na slici. Na primjer, model može odrediti prikazuje li satelitska snimka šumu, vodu, urbana područja ili degradirano zemljište. Ta je vrsta analize posebno korisna kada trebamo pratiti velika područja i promjene kroz vrijeme.

Detekcija objekata, nasuprot tome, usmjerena je na to gdje se točno nešto nalazi. Ona prepoznaje pojedinačne objekte ili značajke i njihove granice - poput srušenih stabala, nakupina otpada u rijekama ili oštećenih zgrada. Ta je razina detalja ključna kada se rezultati moraju povezati s konkretnim lokacijama radi terenske intervencije ili donošenja odluka.

Kombiniranjem tih zadataka sustavi računalnog vida pružaju situacijsku svijest gotovo u stvarnom vremenu. Modeli se mogu trenirati da prepoznaju spektralne obrasce povezane s naftnim mrljama, tragove dima u ranim fazama šumskih požara ili strukturne promjene vidljive na satelitskim i radarskim snimkama.

Praktična važnost ovog pristupa jest u tome što skraćuje vrijeme između okolišne promjene i odgovora. Umjesto reagiranja tek nakon što šteta postane vidljiva na terenu, nadležna tijela i organizacije mogu primiti rana upozorenja i djelovati prije nego što se situacija pogorša.

Strategije prikupljanja i integracije podataka

Učinkovitost računalnog vida u praćenju okoliša izravno ovisi o podacima koje prima. U praksi nijedan pojedinačni izvor podataka nije dovoljan. Sustavi sigurnosti okoliša oslanjaju se na kombiniranje više vrsta vizualnih podataka, pri čemu svaka vrsta odgovara na različita ograničenja razmjera, rezolucije i radnih uvjeta.

Satelitske snimke čine temelj za praćenje velikih razmjera. Platforme kao što su Sentinel i Landsat omogućuju kontinuirano promatranje velikih teritorija tijekom dugih vremenskih razdoblja. Multispektralni podaci, osobito u bliskom infracrvenom i kratkovalnom infracrvenom području, omogućuju procjenu zdravlja vegetacije, detekciju deforestacije i prepoznavanje promjena u korištenju zemljišta koje nisu vidljive na standardnim RGB snimkama.

Dronovi nadopunjuju satelitske podatke znatno višom prostornom rezolucijom i fleksibilnim razmještajem. Obično se koriste za lokalizirane preglede, primjerice za prepoznavanje manjih izvora onečišćenja ili detekciju neeksplodiranih ubojnih sredstava u područjima u kojima je pristup s tla nesiguran, kao što je prikazano na Slici 7.2.

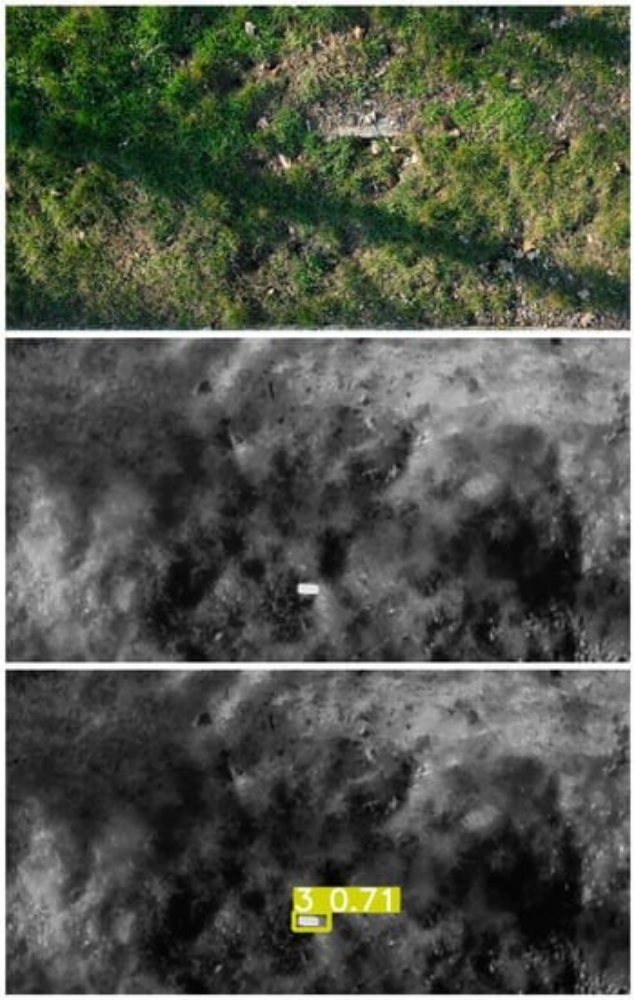

Slika 7.2 Dron s računalnim vidom

Radarski sustavi, osobito radar sa sintetičkom aperturom (Synthetic Aperture Radar, SAR), rješavaju ograničenja optičkih snimki. Budući da SAR ne ovisi o Sunčevoj svjetlosti i može prodrijeti kroz oblake i dim, omogućuje kontinuirano praćenje neovisno o vremenskim uvjetima ili dobu dana. SAR podaci posebno su vrijedni za detekciju strukturnih promjena i oštećenja zgrada. Slika 7.3 prikazuje primjer SAR snimke.



Slika 7.3 SAR snimka

U praksi se ti izvori podataka koriste zajedno. Izlazi modela računalnog vida integriraju se s geografskim informacijskim sustavima, u kojima se detektirani rizici i promjene prostorno kartiraju. Ta integracija pretvara sirove snimke u djelotvorne informacije koje podupiru donošenje odluka u okolišu i ublažavanje rizika.

Etička, sigurnosna i podatkovna razmatranja

Prije nego što dublje uđemo u modele i metrike, potreban je jedan praktičan kontrolni korak: okolišni računalni vid nije samo tehnička tema. Način na koji prikupljamo, pohranjujemo i dijelimo vizualne podatke može stvoriti stvarne etičke i sigurnosne rizike.

Prvo je pitanje privatnost i odgovornost za podatke. Rezolucija satelitskih i dronskih snimki stalno se poboljšava. To znači da isti skupovi podataka koji su korisni za praćenje šuma, rijeka ili industrijskih lokacija mogu nenamjerno zabilježiti i osjetljive ljudske aktivnosti. Stoga pitanje nije samo „Možemo li to detektirati?“, nego i „Trebamo li to prikupljati ili objavljivati na ovoj razini detalja?“

Drugo je pitanje rizik dvojne uporabe. Često se pretpostavlja da su okolišni podaci bezopasni, no to nije uvijek točno. Na primjer, precizne lokacije ugroženih vrsta ili detaljne informacije o ranjivostima infrastrukture mogu se zloupotrijebiti. Stoga stručnjaci moraju uravnotežiti znanstvenu transparentnost sa zaštitnim mjerama koje sprečavaju zloupotrebu.

Zaključak je jednostavan: dobro upravljanje dio je dobrog inženjerstva. Odgovorna kontrola pristupa, pažljivo oblikovane politike dijeljenja i svijest o scenarijima dvojne uporabe ključni su ako želimo da računalni vid jača okolišnu otpornost, a ne stvara nove rizike.

Temeljni koncepti i metode

Konceptualni okvir računalnog vida u sigurnosti okoliša

Nakon što smo razmotrili podatke - odakle dolaze i koja ograničenja imaju - možemo govoriti o tome kako računalni vid zapravo izdvaja informacije iz tih slika.

U praćenju okoliša računalni vid ne znači izgradnju najkompleksnijeg mogućeg modela. Riječ je o odabiru metoda koje su robusne, interpretabilne i dobro usklađene sa svojstvima podataka.

Većina okolišnih pipelinea računalnog vida izgrađena je oko malog skupa temeljnih ideja. Na visokoj razini te metode uzimaju sirovi vizualni ulaz - satelitske piksele, dronske slike ili radarske signale - i pretvaraju ga u strukturirane prikaze okoliša: karte pokrova zemljišta, detektirane objekte ili pokazatelje promjena.

Važno je da odabir metode proizlazi iz zadatka i podataka, a ne iz trenda ili složenosti modela. Praćenje velikih razmjera, detekcija promjena i sigurnosno kritične primjene zahtijevaju pristupe koji su stabilni tijekom vremena i tolerantni na šum, nepotpune oznake i nesavršenu referentnu istinu.

Imajući to na umu, možemo pogledati dva najčešća zadatka računalnog vida koja se koriste u sigurnosti okoliša: klasifikaciju slika i detekciju objekata.

Klasifikacija slika naspram detekcije objekata

U okolišnom računalnom vidu većina praktičnih sustava oslanja se na dva usko povezana zadatka: klasifikaciju slika i detekciju objekata. Iako se često spominju zajedno, oni služe različitim svrhama i odgovaraju na različita pitanja.

Klasifikacija slika usmjerena je na to što je prisutno na slici. Model dodjeljuje oznake cijeloj slici ili unaprijed definiranim područjima, što nam omogućuje razumijevanje općih obrazaca - poput tipova pokrova zemljišta, stanja vegetacije ili oštećenih naspram neoštećenih područja. Taj pristup osobito dobro funkcionira za praćenje velikih razmjera, kada je cilj pratiti promjene kroz vrijeme, a ne pojedinačne objekte. Slika 7.4 prikazuje primjer pristupa segmentaciji slike.

Detekcija objekata, nasuprot tome, usmjerena je na to gdje se točno nešto nalazi. Umjesto označavanja područja, model prepoznaje pojedinačne objekte i njihove precizne položaje. Ta razina detalja postaje ključna kada se analiza mora povezati s konkretnim radnjama na terenu - primjerice, lociranjem neeksplodiranih ubojnih sredstava, prepoznavanjem specifičnih nakupina otpada ili kartiranjem pojedinačnih oštećenih zgrada. Slika 7.5 prikazuje rezultat algoritma detekcije objekata primijenjenog na automobile na parkiralištu.

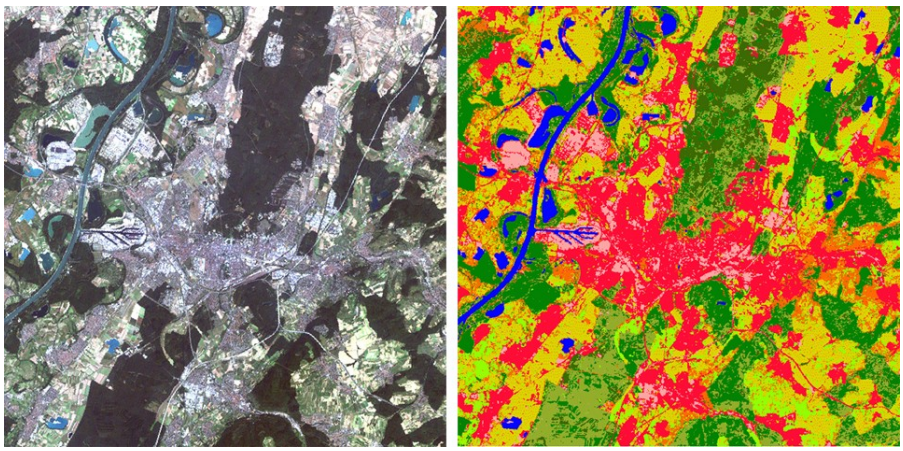

Slika 7.4 Primjer segmentacije slike

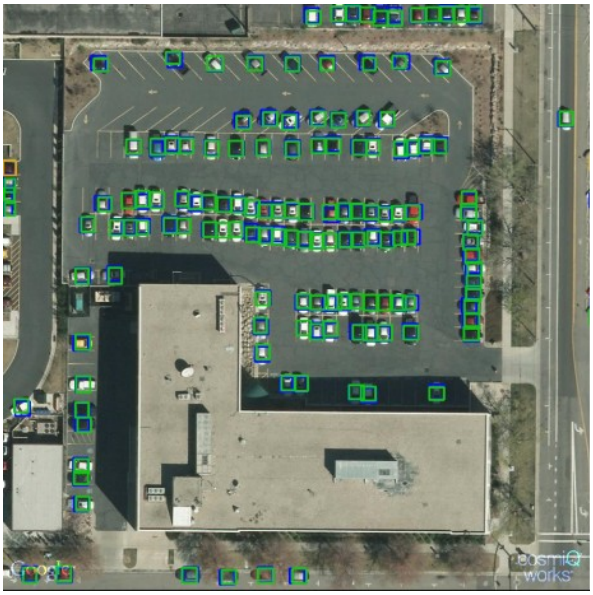

Slika 7.5 Detekcija objekata

Ključna razlika između tih pristupa nije tehnička složenost, nego namjera. Klasifikacija nam pomaže razumjeti obrasce u velikim razmjerima, dok detekcija objekata omogućuje ciljanu intervenciju. U mnogim stvarnim sustavima praćenja okoliša obje se metode kombiniraju: klasifikacija se koristi za prepoznavanje područja od interesa, a detekcija objekata za detaljnu analizu tih područja.

Koncepti modela računalnog vida za sigurnost okoliša

Kada govorimo o modelima u okolišnom računalnom vidu, glavno pitanje nije „koja je najnaprednija arhitektura“, nego „što možemo pouzdano primijeniti s podacima i ograničenjima koja imamo“. Okolišne snimke su šumovite, referentna istina skupa je za prikupljanje, a uvjeti se mijenjaju tijekom vremena - godišnja doba, osvjetljenje, naoblaka pa čak i vrste senzora.

U praksi je odabir modela određen izlazom koji nam treba: segmentacijom ili detekcijom

Segmentacija: U-Net

Ako je cilj kartirati područja - na primjer opseg poplavne vode, granice šuma ili oštećene zone - segmentacija je prirodan izbor. Široko korištena arhitektura u tom je kontekstu U-Net, jer je dizajnirana za izradu maski na razini piksela te za obuhvaćanje i lokalnih detalja i šireg prostornog konteksta. Slika 7.6

pokazuje zašto se naziva upravo U-Net. U praćenju okoliša to je korisno kad god nam je važno gdje se granica nalazi i kolika je zahvaćena površina.

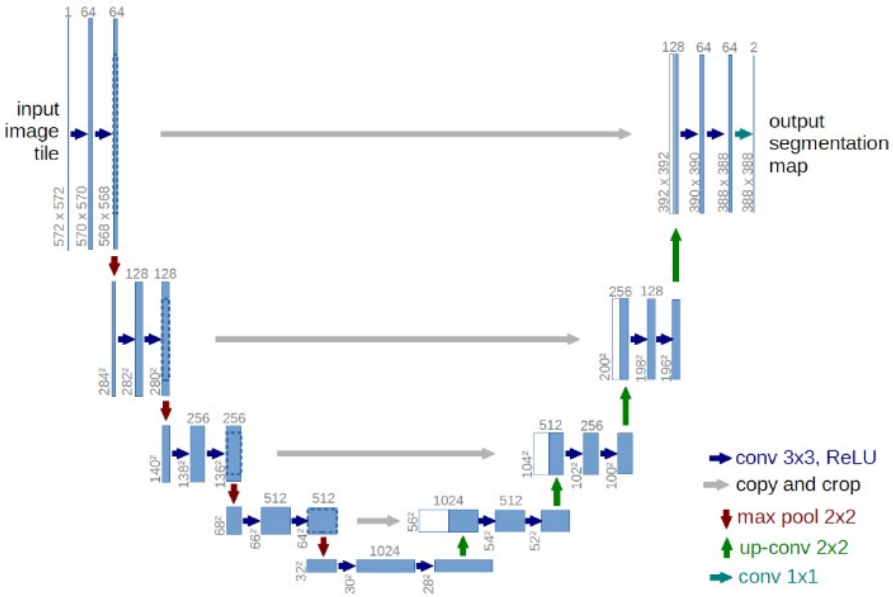

Slika 7.6 Arhitektura modela U-Net

Detekcija: MobileNet / YOLO-lite

Ako je cilj pronaći pojedinačne objekte - poput komada otpada, specifičnih oštećenih struktura ili kandidata za NUS - obično koristimo modele za detekciju objekata. U mnogim operativnim okruženjima, osobito na dronovima ili rubnim uređajima, prednost dajemo lakim arhitekturama kao što su detektori temeljeni na MobileNetu ili YOLO-lite, jer uravnotežuju brzinu i točnost te mogu raditi uz ograničene računalne resurse.

Pretrenirani modeli i prijenosno učenje

Ponavljajući izazov u sigurnosti okoliša jest ograničena količina označenih podataka. U opasnim ili nedostupnim područjima prikupljanje i označavanje snimki skupo je ili nemoguće.

Zato je prijenosno učenje tako često: počinjemo s modelom pretreniranim na velikom općem skupu podataka, a zatim ga fino podešavamo na manjem okolišnom skupu podataka - primjerice prilagođavamo model urbanih snimki za prepoznavanje specifičnih obrazaca oštećenja zgrada ili prilagođavamo detektor za prepoznavanje objekata nalik NUS-u iz dronskih snimki.

Kombiniranje komplementarnih algoritama

Okolišni pipelinei često kombiniraju više algoritamskih pristupa kako bi poboljšali robusnost.

Na primjer, modeli Random Forest mogu smanjiti „salt-and-pepper“ šum u velikim homogenim područjima, što je korisno za klasifikaciju pokrova zemljišta. Istodobno, jednostavniji neuronski modeli poput MLP-a ponekad mogu odvojiti manje ili rijetke klase koje su nedovoljno zastupljene - primjerice suptilne industrijske anomalije ili promjene malog razmjera koje se izgube u širim klasama.

Praktična je ideja jednostavna: umjesto da sve uložimo u jedan model, kombiniramo metode koje griješe na različite načine.

Ključna poruka

Dakle, „koncept“ modela ovdje nije jedna arhitektura - riječ je o operativnom dizajnerskom izboru. U-Net je snažan zadani izbor za segmentacijske karte, MobileNet / YOLO-lite praktični su izbori za brzu detekciju, a prijenosno učenje često čini razliku između „možemo to izgraditi“ i „nemamo skup podataka od kojeg bismo krenuli“.

Statističke metrike učinkovitosti

Nakon što definiramo što naši modeli trebaju raditi - klasificirati područja ili detektirati pojedinačne objekte - sljedeće je pitanje kako vrednujemo njihovu učinkovitost. U praćenju okoliša to nije tako jednostavno kao što se možda čini.

Mnogi okolišni skupovi podataka izrazito su neuravnoteženi. Na primjer, oštećena područja mogu pokrivati samo mali dio velikog područja, dok većina ostaje nepromijenjena. U takvim slučajevima jednostavna točnost može zavarati, jer model može postići visoku točnost, a pritom ne uspijevati detektirati pojave koje nas zapravo zanimaju.

Zbog toga se okolišni računalni vid oslanja na metrike koje bolje odražavaju prostorno podudaranje i kvalitetu detekcije.

Presjek nad unijom (Intersection over Union, IoU)

Jedna od najčešće korištenih metrika za segmentaciju i analizu područja jest presjek nad unijom, odnosno IoU.

IoU mjeri koliko se dobro predviđeno područje preklapa s referentnim područjem, odnosno područjem referentne istine, kao što je prikazano na Slici 7.7.

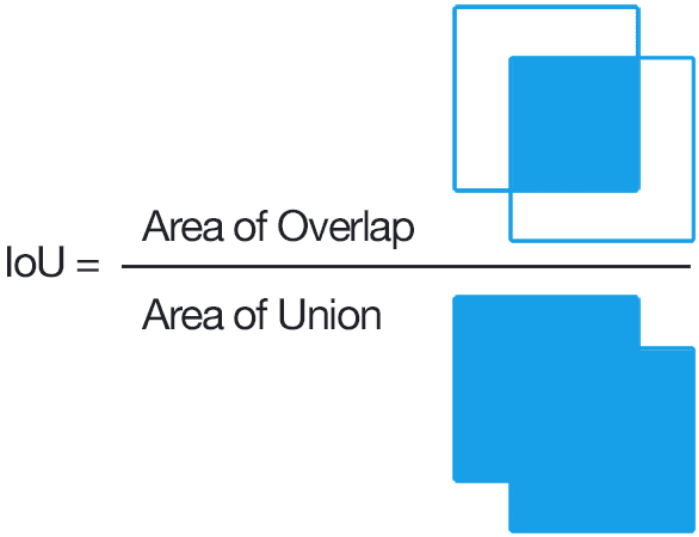

Slika 7.7 Ilustracija izračuna presjeka nad unijom

Intuitivno, IoU odgovara na jednostavno pitanje: koliko se ta dva područja preklapaju?
Veći IoU upućuje na jače prostorno podudaranje između izlaza modela i podataka označenih od strane stručnjaka. U zadacima kao što su kartiranje deforestacije ili procjena oštećenja zgrada, vrijednosti IoU-a blizu jedan označavaju visokokvalitetna predviđanja.

Preciznost, odziv i F1-mjera

Kada prijeđemo sa segmentacije područja na detekciju objekata, dodatne metrike postaju važne.

Preciznost nam govori koliko je detektiranih objekata doista ispravno. To je ključno u sigurnosnim zadacima, gdje lažno pozitivni rezultati mogu dovesti do nepotrebnih ili čak opasnih intervencija.

Odziv mjeri koliko relevantnih objekata model uspješno detektira. Propuštanje objekta, poput neeksplodiranog ubojnog sredstva ili ranog dima šumskog požara, može imati ozbiljne posljedice.

F1-mjera objedinjuje preciznost i odziv u jednu vrijednost, uravnotežujući lažno pozitivne i lažno negativne rezultate. Zbog toga je osobito korisna u okolišnim primjenama, gdje je neuravnoteženost klasa česta i obje vrste pogrešaka imaju značenje.

Zašto su te metrike važne u praksi?

U praćenju okoliša metrike nisu samo brojevi za usporedbu modela. One utječu na odluke u stvarnom svijetu.

Na primjer, povećanje pragova detekcije može poboljšati preciznost, ali smanjiti odziv. Odgovarajuća ravnoteža ovisi o zadatku: primjene sigurnosti okoliša često daju prednost minimiziranju propuštenih detekcija, čak i uz cijenu prihvaćanja određenog broja lažnih alarma.

Razumijevanje tih kompromisa ključno je za odgovornu i učinkovitu primjenu sustava računalnog vida.

Čimbenici koji utječu na izmjerenu učinkovitost

Kada govorimo o metrikama učinkovitosti modela, važno je razumjeti jednu ključnu točku: izmjerena učinkovitost sustava računalnog vida nije određena samo modelom.

U praćenju okoliša na učinkovitost snažno utječu svojstva podataka i uvjeti u kojima se ti podaci prikupljaju.

Razlike u prostornoj rezoluciji

Jedno često ograničenje proizlazi iz razlika u prostornoj rezoluciji. Oznake referentne istine često se izrađuju pomoću snimki vrlo visoke rezolucije ili ručnom interpretacijom, dok modeli mogu raditi na satelitskim podacima umjerene rezolucije.

Kao rezultat toga, čak i model koji dobro radi rijetko postiže savršeno preklapanje s referentnim podacima. To nije nužno pogreška modeliranja, nego posljedica usporedbe informacija zabilježenih na različitim prostornim skalama.

Okolišni šum i atmosferski uvjeti

Optičke snimke izrazito su osjetljive na okolišni šum. Oblaci, sjene, dim i promjenjivi uvjeti osvjetljenja mogu utjecati na kvalitetu slike i smanjiti učinkovitost modela.

Radarski podaci, poput SAR-a, pomažu prevladati neka od tih ograničenja jer omogućuju promatranja neovisna o vremenskim uvjetima. Međutim, radarske snimke

uvode vlastite izazove, uključujući veći signalni šum i manje intuitivne vizualne obrasce, što može otežati određivanje granica objekata i klasifikaciju.

Vremenska stabilnost i sezonski učinci

Još jedan važan čimbenik jest vremenska varijabilnost. Okolišni uvjeti mijenjaju se tijekom vremena zbog godišnjih doba, vremenskih obrazaca i dinamike korištenja zemljišta.

Za poboljšanje stabilnosti u dugoročnom praćenju često se koriste tehnike kao što su normalizirani diferencijski indeksi. Ti indeksi smanjuju utjecaj razlika u osvjetljenju i sezonskih varijacija, pa je lakše detektirati smislene okolišne promjene umjesto privremenih kolebanja.

Ključna poruka

Glavna je poruka da se metrike učinkovitosti uvijek moraju tumačiti u kontekstu. U okolišnom računalnom vidu niže vrijednosti metrika ne znače automatski lošu kvalitetu modela - često odražavaju ograničenja podataka iz stvarnog svijeta.

Razumijevanje tih čimbenika pomaže stručnjacima postaviti realna očekivanja i projektirati sustave praćenja koji su robusni, a ne umjetno optimizirani.

Primjene u ublažavanju okolišnog rizika

Nakon rasprave o podacima, metodama, metrikama i njihovim ograničenjima možemo se usredotočiti na najpraktičnije pitanje: kako se računalni vid zapravo koristi za smanjenje okolišnog rizika?

U stvarnim scenarijima automatizirana analiza slika podupire donošenje odluka ranom detekcijom rizika, na velikim područjima i često na mjestima gdje je izravan ljudski pregled težak ili opasan.

Praćenje onečišćenja i otpada

Jedna od najčešćih primjena jest praćenje onečišćenja. Modeli računalnog vida mogu detektirati naftne mrlje na vodenim površinama ili prepoznati nezakonito odlaganje otpada u rijekama i udaljenim područjima.

Ključna je prednost ovdje razmjer. Veliki se teritoriji mogu kontinuirano pratiti, što nadležnim tijelima omogućuje usmjeravanje inspekcija i čišćenja na najkritičnije lokacije, umjesto oslanjanja na sporadične terenske dojave [7].

Detekcija neeksplodiranih ubojnih sredstava (NUS)

U područjima pogođenima sukobima i postkonfliktnim regijama računalni vid izravno pridonosi ljudskoj sigurnosti. Analizom dronskih snimki i satelitskih podataka visoke rezolucije modeli mogu pomoći u prepoznavanju područja koja potencijalno sadrže neeksplodirana ubojna sredstva.

Ti sustavi ne zamjenjuju stručnjake za razminiranje. Umjesto toga, smanjuju rizik sužavanjem područja pretrage i prioritizacijom zona koje zahtijevaju hitnu pozornost.

Detekcija šumskih požara i dima

Računalni vid koristi se i za ranu detekciju šumskih požara. Modeli mogu prepoznati obrasce dima ili toplinske anomalije prije nego što požari postanu veliki i nekontrolirani.

Čak i mala poboljšanja u vremenu detekcije mogu imati znatan učinak, smanjujući okolišnu štetu, troškove odgovora i rizike za obližnje zajednice.

Procjena oštećenja zgrada

Još jedna kritična primjena jest procjena štete nakon prirodnih katastrofa ili tijekom oružanih sukoba.

Radarski sustavi, osobito SAR, posebno su vrijedni u tim scenarijima jer rade neovisno o vremenskim i svjetlosnim uvjetima. Strukturna oštećenja uzrokuju mjerljive promjene u refleksijama radarskog signala, što omogućuje detekciju oštećenja čak i kada optičke snimke nisu dostupne. Slike 7.8 i 7.9 ilustriraju kako se procjena oštećenja može vizualizirati.



Slika 7.8 Procjena oštećenja zgrada nakon potresa u Turskoj

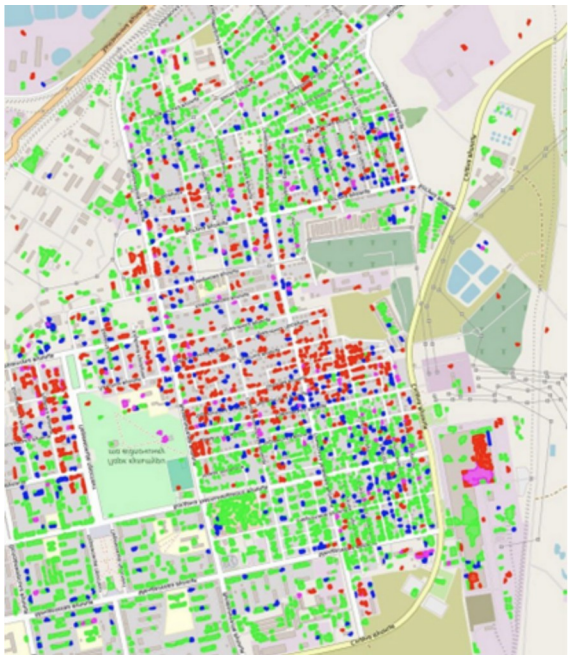

Slika 7.9 Oštećenja grada Rubižne (Ukrajina) uslijed borbenih djelovanja

Ti se izlazi obično integriraju u GIS platforme, gdje podupiru hitni odgovor, planiranje humanitarne pomoći i određivanje prioriteta obnove [9].

Praćenje deforestacije i bioraznolikosti

Dugoročni okolišni rizici kao što su deforestacija i gubitak bioraznolikosti prate se usporedbom satelitskih snimki kroz vrijeme.

Računalni vid omogućuje dosljednu, ponovljivu detekciju postupnih promjena u pokrovu zemljišta, podupirući napore očuvanja i političke odluke - osobito u regijama u kojima kontinuirano terensko praćenje nije izvedivo [6], [7], [8]. Rezultat takvog praćenja prikazan je na Slici 7.10.

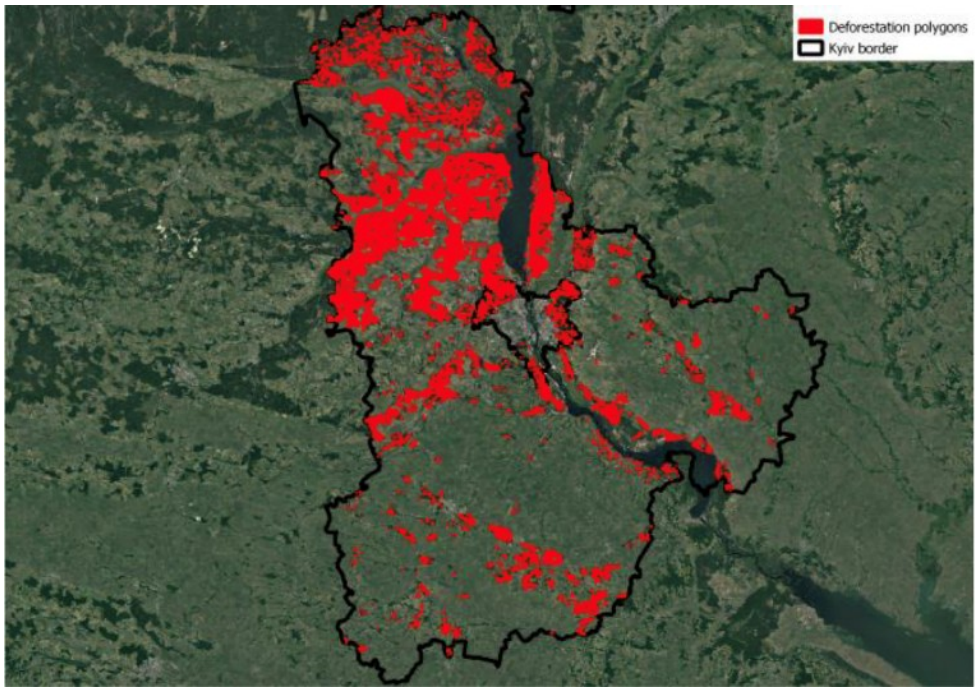

Slika 7.10 Vizualizacija detekcije deforestacije

Ključna poruka

U svim tim primjenama uloga računalnog vida nije zamijeniti stručnjake za okoliš, nego proširiti njihove kapacitete. Automatizirana analiza čini praćenje bržim, sigurnijim i sustavnijim, omogućujući da se ljudska stručnost primijeni ondje gdje je najpotrebnija.

Izvori podataka i integracija za praćenje okoliša

U praksi se sustavi praćenja okoliša grade kao višeslojni pipelinei, a ne oslanjaju se na jedan izvor podataka.

Satelitske snimke pružaju gornji sloj - kontinuiranu pokrivenost velikih razmjera koja omogućuje dosljedno praćenje cijelih regija tijekom vremena. Taj je sloj odgovoran za ranu detekciju i analizu trendova.

Nakon što se prepoznaju područja od interesa, koriste se izvori podataka više rezolucije. Dronovi i zračne snimke pružaju detaljne, lokalizirane prikaze koji podupiru pregled, provjeru i precizno kartiranje.

Radarski podaci imaju komplementarnu ulogu osiguravanjem kontinuiteta. Kada optički podaci nisu dostupni zbog oblaka, dima ili mraka, SAR snimke omogućuju neprekidno praćenje.

Točka integracije za sve te tokove podataka jesu geografski informacijski sustavi. GIS pruža prostorni okvir koji usklađuje satelitska promatranja, dronske preglede i izlaze modela u jednu operativnu sliku.

Taj slojeviti pristup omogućuje sustavima praćenja okoliša uravnoteženje razmjera, detalja i pouzdanosti, pretvarajući heterogene podatke u djelotvornu situacijsku svijest.

Od detekcije do okolišne akcije

Primjena računalnog vida (CV) u sigurnosti okoliša pruža tehnički okvir za pretvaranje sirovih vizualnih podataka u djelotvornu prostornu inteligenciju. Automatiziranjem interpretacije digitalnih fotografija, satelitskih karata i dronskih snimki ti sustavi olakšavaju ranu detekciju ekoloških prijetnji, praćenje opasnih područja i unaprjeđenje podatkovno utemeljenog donošenja odluka. Prijelaz od vizualne identifikacije do ublažavanja uključuje sintezu umjetne inteligencije (AI), daljinskih istraživanja i geografskih informacijskih sustava (GIS) radi stvaranja automatiziranih petlji praćenja koje štede vrijeme i smanjuju ljudski rizik.

Identifikacija okolišnih i humanitarnih opasnosti

Modeli računalnog vida pružaju situacijsku svijest odgovaranjem na ključna pitanja o prisutnosti i lokaciji okolišnih rizika. Automatizirani sustavi primjenjuju se u različitim domenama radi prepoznavanja specifičnih prijetnji koje zahtijevaju intervenciju:

- Onečišćenje i otpad: Sustavi kamera opremljeni umjetnom inteligencijom i dronovi prate plastično onečišćenje u riječnim sustavima s prijavljenom visokom

točnošću detekcije u kontroliranim uvjetima. Ta tehnologija prepoznaje karakteristične spektralne vrhove apsorpcije plastike, što omogućuje detekciju oblaka kontaminacije.

- Ekološka degradacija: Automatizirana obrada multispektralnih snimki, kao što su podaci Sentinel-2, omogućuje detekciju deforestacije u zaštićenim šumama [6], [7], [8]. Sustavi koriste indekse kao što je NDVI za praćenje dinamike sječe i procjenu zdravlja vegetacije.
- Rizici povezani sa sukobima: U područjima u kojima je izravan pristup ograničen zbog sigurnosnih razloga, CV se koristi za prepoznavanje neeksplodiranih ubojnih sredstava (NUS) i kvantificiranje strukturnih oštećenja zgrada i infrastrukture [9].
- Sustavi ranog upozoravanja: Moderni AI okviri automatski analiziraju vizualne podatke radi rane detekcije dima šumskih požara ili industrijskih istjecanja, generirajući upozorenja za zajednice prije nego što ekološka šteta dosegne neupravljivu točku eskalacije.

Potpora strateškom oporavku i raspodjeli resursa

Integracija CV izlaza s GIS slojevima omogućuje dionicima vizualizaciju prostorne raspodjele rizika, što je ključno za strateško planiranje i određivanje prioriteta oporavka.

- Čišćenje i remedijacija: U scenarijima koji uključuju vodeno onečišćenje, automatizirano kartiranje omogućuje organizacijama prepoznavanje zona nakupljanja otpada u udaljenim područjima. Ti se prostorni podaci koriste za planiranje ciljanih ekspedicija čišćenja i aktivnosti uklanjanja.
- Infrastrukturna obnova: Sustavi za detekciju oštećenja zgrada daju procjene broja pogođenih struktura i predratne gustoće stanovništva u pojedinim zonama. Te „karte posrednika oštećenja“ pomažu spasilačkim operacijama i humanitarnim organizacijama u određivanju gdje su resursi najkritičnije potrebni.
- Identifikacija izvora: Georeferenciranjem oblaka onečišćenja i praćenjem njihova povratnog puta do primarnih izvora na karti, CV podupire industrijske inspekcije i provedbu propisa o zaštiti okoliša.

Politike utemeljene na dokazima i gospodarska potpora

Računalni vid služi kao objektivan alat za donošenje odluka na nacionalnoj razini, osobito kada je tradicionalno prikupljanje statističkih podataka otežano sukobom ili okolišnim katastrofama.

- Potpora poljoprivrednoj politici: Karte korištenja zemljišta visoke rezolucije koriste se za prepoznavanje neobrađenih ili napuštenih poljoprivrednih zemljišta. U regijama poput Ukrajine te su karte integrirane u nacionalne registre radi potpore vladinim odlukama, primjerice odobravanju poreznih oslobođenja poljoprivrednicima čije je zemljište kontaminirano ili se nalazi blizu bojišnice [4].
- Praćenje sigurnosti hrane: Dugoročno praćenje tipova usjeva i produktivnosti putem satelitskih snimki pomaže donositeljima politika u rješavanju izazova sigurnosti hrane prepoznavanjem promjena u poljoprivrednoj dinamici.
- Poslijeratna obnova: Kontinuirani podaci vremenskih nizova pružaju prostorni nacrt za pošumljavanje i obnovu u područjima koja se smatraju nesigurnima za ljudsku aktivnost [9].

Od detekcije do okolišne akcije: stvarni primjeri računalnog vida u sigurnosti okoliša

Kada računalo detektira okolišnu prijetnju, mora uslijediti djelovanje. Ovaj odjeljak razmatra kako računalni vid pretvara detekciju u stvarne okolišne odluke - kroz tri kritične faze: sprečavanje prijetnji prije eskalacije (prije događaja), praćenje dok se krize odvijaju (tijekom događaja) te procjena štete i planiranje oporavka (nakon događaja).

Faza 1: Detekcija prije događaja i rano upozoravanje

Praćenje kvalitete vode pomoću HydroVisiona

Zamislite da nadležna tijela žele znati je li riječna voda sigurna prije nego što se ljudi razbole. Tradicionalno ručno prikupljaju uzorke vode - skupo, sporo i često prekasno.

HydroVision je sustav koji analizira fotografije vode (snimljene dronovima ili satelitima) i otkriva kontaminaciju ili pogoršanje kvalitete vode. Traži boju, mutnoću i prisutnost algi - prepoznatljive znakove onečišćenja:

- Zelena voda = cvjetanje algi (potencijalno toksično)

- Smeđa mutnoća = suspendirana organska tvar (tvornički ispust)
- Anomalija boje = signal upozorenja

Umjesto jedne osobe na obali rijeke, sustav svakodnevno analizira stotine kilometara vodenih tijela. Primjenom dubokih konvolucijskih neuronskih mreža na RGB slike, HydroVision procjenjuje optički aktivne parametre kao što su koncentracija klorofila i obojena otopljena organska tvar (CDOM), koji služe kao posrednici za kvalitetu vode i trendove kontaminacije. Taj neinvazivni pristup smanjuje ovisnost o skupim spektralnim senzorima i ubrzava početnu identifikaciju prijetnji u različitim vodenim tijelima [12].

Praćenje bioraznolikosti i staništa

Računalni vid također podupire pripravnost prije događaja omogućujući automatizirano praćenje okoliša u velikim razmjerima - prepoznavanje obrazaca bioraznolikosti, praćenje distribucije vrsta i kartiranje stanja staništa. Sustavi temeljeni na vidu mogu detektirati promjene pokrova zemljišta, prisutnost vrsta i značajke staništa, pridonoseći širim naporima klimatskog djelovanja i zaštite bioraznolikosti. Te automatizirane detekcije pružaju važne temeljne skupove podataka koji otkrivaju dugoročne trendove koji bi inače mogli ostati neopaženi dok se ne manifestiraju kao akutne prijetnje [13].

Faza 2: Praćenje tijekom događaja u stvarnom vremenu

Praćenje u stvarnom vremenu tijekom šumskih požara

Slično načelo vrijedi tijekom šumskih požara:

- 🔥 Dronovi skeniraju područje, tražeći stupove dima i toplinske žarišne točke,
- 🗺️ Požar je lociran na rubu šume - može se zaustaviti prije širenja,
- 📊 Vatrogasci ne dobivaju informaciju „negdje postoji požar“, nego točne koordinate zapaljenja

Moderne arhitekture računalnog vida, osobito u kombinaciji sa senzorima Interneta stvari (IoT), omogućuju kontinuirani nadzor dinamičnih okolišnih događaja u stvarnom vremenu. Hibridni senzorski sustavi integriraju kamere s analitičkim modelima kako bi održali robusno praćenje i detekciju čak i u zahtjevnim uvjetima - promjenjivom osvjetljenju ili zaklonjenim pogledima - omogućujući učinkovitu detekciju promjena ili anomalija u ekosustavima pod stresom [14].

Detekcija plastičnog onečišćenja u vodama

Kada rijeke postanu zagušene plastičnim otpadom, računalni vid može precizno odrediti svaki komad koji pluta u vodi:

- 🎯 Automatska detekcija plastičnih boca u riječnim okruženjima,
- 📍 Precizne koordinate - točno gdje krhotine plutaju,
- ⏱️ Ažuriranja karata kontaminacije u stvarnom vremenu.

Radnici i volonteri na čišćenju točno znaju gdje tražiti - bez uzaludnog rada naslijepo. Istraživači su razvili modele koji automatski detektiraju plastične boce u riječnim okruženjima treniranjem na opsežnim skupovima podataka vodenih snimki. Ti modeli mogu s visokom preciznošću prepoznati i lokalizirati plastične krhotine u složenim prirodnim scenama. Takve sposobnosti omogućuju nadležnim tijelima i okolišnim organizacijama kontinuirano praćenje žarišta onečišćenja, poboljšanje situacijske svijesti tijekom epizoda onečišćenja te informiranje taktika čišćenja i raspodjele resursa gotovo u stvarnom vremenu [15].

Faza 3: Procjena nakon događaja i oporavak

Kartiranje opožarenih područja nakon šumskih požara

Nakon šumskog požara, poplave ili oluje, nadležna tijela trebaju znati:

- Gdje je točno gorjelo? (Koja područja zahtijevaju ograničen pristup?)
- Koliko je ozbiljno? (Jesu li stabla samo siva i bez lišća ili su pougljenjena?)
- Koliko je resursa potrebno za oporavak? (Osoblje, oprema, vrijeme?)

Tradicionalno su ljudi mjesecima pješačili kroz šume, ručno mjerili i savjetovali se s lokalnim stanovništvom - sporo i skupo.

Modeli dubokog učenja na satelitskim snimkama završavaju taj posao u danima. Modeli dubokog učenja primijenjeni na satelitske snimke, poput U-Neta i drugih konvolucijskih arhitektura, omogućuju automatizirano kartiranje opožarenih područja nakon šumskih požara. Ti sustavi koriste Sentinel-2 snimke prije i nakon požara za klasifikaciju jačine izgaranja i ocrtavanje požarnih ožiljaka s visokom točnošću, pružajući objektivne i ponovljive procjene ključne za planiranje strategija rehabilitacije i raspodjelu resursa za obnovu [16].

Izlaz uključuje:

- 📍 Karte opožarenosti: točno gdje je gorjelo/gori
- 🎨 Označena ozbiljnost bojama: žuta = mala, narančasta = umjerena, crna = teška
- 📊 Izvješća: kvantitativne procjene šumskog područja koje zahtijeva oporavak

Procjena štete nakon katastrofe

Isti pristup funkcionira za poplave, oluje i druge katastrofe:

- 🏘️ Koje su zgrade poplavljene?
- 🛣️ Koje su ceste blokirane?
- 👥 Koje su populacije izložene riziku?

Računalni vid pridonosi široj okolišnoj evaluaciji nakon katastrofe, gdje duboki CNN modeli detektiraju i kategoriziraju obrasce štete u prirodnom i izgrađenom okolišu neposredno nakon oluja, poplava ili drugih ekoloških poremećaja. Analizom velikih količina zračnih snimki nakon događaja ti modeli podupiru brzu klasifikaciju pogođenih zona, omogućujući brže donošenje odluka i bolju koordinaciju između okolišnih agencija, hitnih službi i programa obnove [17].

Studija slučaja: Procjena zdravlja vegetacije pomoću NDVI-ja iz podataka Sentinel-2

Kontekst

U ovoj studiji slučaja multispektralne satelitske snimke korištene su za procjenu zdravlja vegetacije i analizu prostornih obrazaca okolišne degradacije. Analiza se temeljila na normaliziranom diferencijskom vegetacijskom indeksu (Normalized Difference Vegetation Index, NDVI), dobro poznatom spektralnom pokazatelju izvedenom iz crvenog i bliskog infracrvenog (NIR) pojasa snimki Sentinel-2.

Studija slučaja osmišljena je kako bi pokazala kako relativno jednostavne tehnike računalnog vida i daljinskih istraživanja mogu proizvesti djelotvorne okolišne uvide kada se primijene na stvarne satelitske podatke.

Okolišna relevantnost

Analiza temeljena na NDVI-ju široko je prihvaćena u primjenama sigurnosti okoliša, uključujući praćenje deforestacije, procjenu korištenja poljoprivrednog zemljišta, analizu utjecaja suše i okolišnu evaluaciju nakon poremećaja. Uporaba spektralnih indeksa izvedenih iz satelitskih podataka omogućila je promatranja velikih razmjera koja se mogu ponavljati tijekom duljih vremenskih razdoblja.

Taj je pristup osobito učinkovit u regijama u kojima su izravna terenska mjerenja ograničena zbog sigurnosnih ograničenja ili izazova pristupačnosti. Oslanjanjem na orbitalne podatke održava se kontinuirano praćenje okoliša bez fizičke prisutnosti u potencijalno opasnim područjima.

Podaci i spektralni ulazi

Analiza se temeljila na multispektralnim snimkama Sentinel-2. Od dostupnih spektralnih kanala odabrani su crveni (B4) i bliski infracrveni (B8) pojas zbog njihove osjetljivosti na svojstva refleksije vegetacije.

Radi potpore transparentnosti i ponovljivosti, međukoraci obrade dokumentirani su izravno unutar analitičkog tijeka rada.

Isječak koda: učitavanje i predobrada pojaseva Sentinel-2

```
images = (ee.ImageCollection('COPERNICUS/S2_SR_HARMONIZED')
        .filterBounds(aoi)
        .filterDate(start_date, end_date)
        .median()
        .clip(ai))
```

Pregled metode

Vrijednosti NDVI-ja izračunate su standardnom formulacijom normalizirane razlike:

Ta je formulacija naglasila kontrast između površina prekrivenih vegetacijom i područja bez vegetacije iskorištavanjem različitog ponašanja refleksije klorofila u crvenom i bliskom infracrvenom dijelu spektra.

Isječak koda: izračun NDVI-ja

```
def addNDVI(image):
    ndvi = image.normalizedDifference(['B8', 'B4']).rename('NDVI')
    return ndvi.copyProperties(image, ['system:time_start'])
```

Vizualizacija i prostorni prikaz

Nakon izračuna generirane su NDVI karte radi vizualizacije prostornih varijacija u stanju vegetacije.

Na tim su kartama niske vrijednosti NDVI-ja (obično ispod ~0,1) prikazane crvenim ili smeđim tonovima i odgovarale su površinama bez vegetacije, kao što su vodena tijela, golo tlo ili izgrađena područja. Srednje vrijednosti NDVI-ja (približno 0,1-0,3), vizualizirane žutim ili narančastim tonovima, označavale su rijetku ili stresom pogođenu vegetaciju, često povezanu s prijelaznim tipovima pokrova zemljišta ili sezonskim učincima. Visoke vrijednosti NDVI-ja (iznad ~0,3), prikazane zelenim tonovima, predstavljale su gustu i zdravu vegetaciju, odražavajući područja s visokom fotosintetskom aktivnošću.

Ti su vizualni prikazi služili kao primarno sučelje za okolišnu interpretaciju, omogućujući brzo prepoznavanje anomalnih ili degradiranih zona. Slika 7.11 prikazuje primjer vizualizacije NDVI karte.

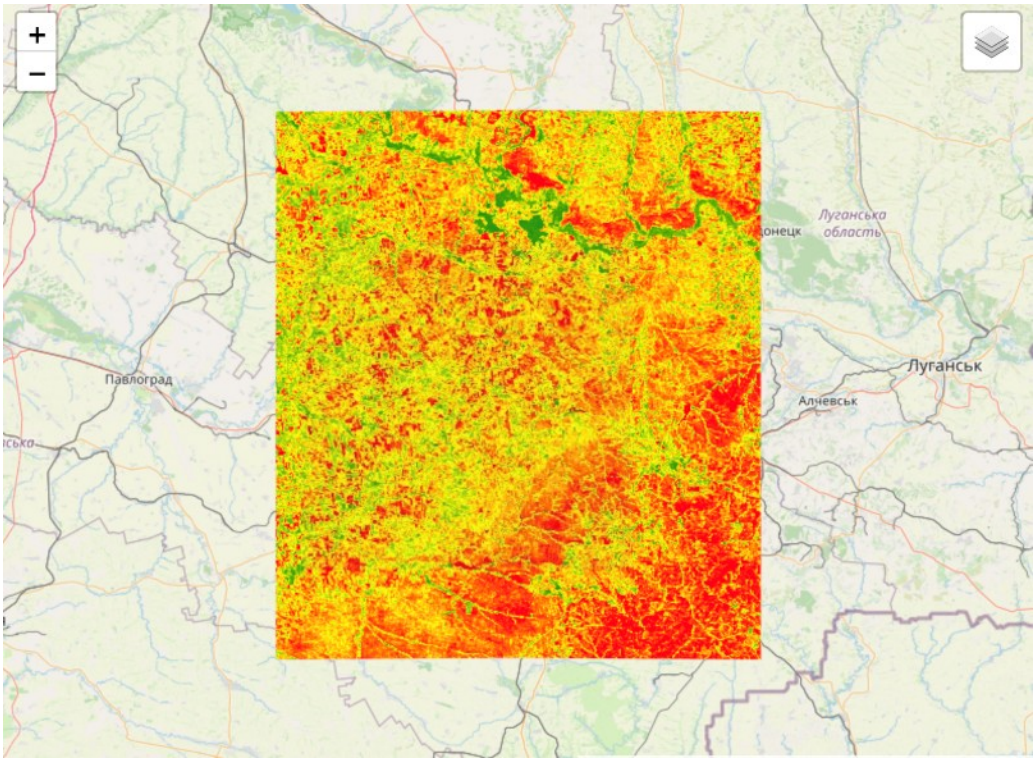

Slika 7.11 Vizualizacija NDVI karte

Interpretacija NDVI obrazaca

Interpretacija temeljena na pragovima primijenjena je za kategorizaciju stanja vegetacije:

- Vrijednosti NDVI-ja ispod približno 0,1 povezane su s vodenim tijelima, golim tlom ili izrazito degradiranim zemljištem,
- Srednje vrijednosti NDVI-ja (približno 0,1-0,3) označavale su rijetku ili stresom pogođenu vegetaciju,
- Više vrijednosti NDVI-ja odgovarale su gustom i zdravom vegetacijskom pokrovu.

Prostorni klasteri trajno niskih vrijednosti NDVI-ja interpretirani su kao potencijalni pokazatelji okolišnog stresa, antropogenog poremećaja ili promjene u korištenju zemljišta.

Rezultati i okolišne implikacije

Dobiveni NDVI izlazi otkrili su jasne prostorne obrasce zdravlja vegetacije u promatranom području. Proširena područja smanjene vegetacijske aktivnosti upućivala su na moguću deforestaciju, napuštanje zemljišta ili ekološku degradaciju nakon poremećaja.

Dokumentiranjem međurezultata i vizualnih izlaza uz računalne korake, studija slučaja pokazala je kako spektralna analiza može poduprijeti transparentnu procjenu okoliša i ponovljive analitičke pipelinee.

Praktična vježba

Cilj

Steći praktično iskustvo s analizom satelitskih snimki i razumjeti kako se NDVI može koristiti za sigurnost i praćenje okoliša: izračunati NDVI kartu, vizualizirati obrasce zdravlja vegetacije i interpretirati rezultate u okolišnom kontekstu.

Vodič korak po korak: kako pokrenuti bilježnicu

Priložena bilježnica „ML_CV_NDVI.ipynb“ cjelovit je, potpuno funkcionalan tijek rada spreman za pokretanje. Unaprijed je konfigurirana za pristup podacima Sentinel-2 putem Google Earth Enginea, izračun NDVI kompozita, vizualizaciju prostornih obrazaca stanja vegetacije i izvođenje vremenskih usporedbi. Nakon pokretanja bilježnica automatski proizvodi interaktivne karte i vizualne izlaze. Za reprodukciju rezultata nije potrebno dodatno programiranje, iako se parametri poput područja interesa i vremenskog raspona mogu mijenjati radi istraživačke analize.

Koristit ćemo Google Colab za pokretanje priložene bilježnice u preglednickom okruženju (nije potrebna lokalna instalacija), slijedeći isti tijek „učitaj → pokreni sve → interpretiraj izlaze“ kao u predlošku kolegija.

Objašnjenje strukture bilježnice:

1. Konfiguracija i biblioteke. Ovaj odjeljak inicijalizira računalno okruženje. Uvoze se potrebne Python biblioteke, a parametri eksperimenta definiraju se u pododjeljcima:

1a: Područje interesa (AOI) definira se pomoću formata GeoJSON. Zadano je to područje jugoistočne Ukrajine, regija koja je nažalost zahvaćena aktivnim borbenim djelovanjima.

1b: Konfigurira se pristup Google Earth Engineu.

1c: Postavite konfiguracijske parametre eksperimenta:

- NDVI vremenski prozor (NDVI_START_DATE i NDVI_END_DATE) koji predstavlja trenutačno razdoblje analize.
- NDVI povijesno referentno razdoblje (NDVI_HISTORICAL_START_DATE i NDVI_HISTORICAL_END_DATE) koje se koristi za usporedbu.
- Parametri vizualizacije NDVI_VISUALIZATION_PARAMS.
- Parametri vizualizacije za NDVI razliku DIFF_VISUALIZATION_PARAMS.

2. Pomoćne funkcije. Ovaj odjeljak sadrži ponovno upotrebljive pomoćne funkcije koje obuhvaćaju temeljne operacije kao što su:
   - izgradnja interaktivnih Folium karata,
   - izračun NDVI-ja iz snimki Sentinel-2,
   - generiranje NDVI kompozita,
   - i potpora logici vizualizacije.
3. Vizualizacija NDVI kompozita. U ovom odjeljku generira se medijanski NDVI kompozit za odabrano područje interesa i vremensko razdoblje. Dobivena NDVI karta pruža prostorni pregled stanja vegetacije i služi kao referentni prikaz zdravlja vegetacije tijekom odabrane sezone.
4. Vremenska usporedba NDVI-ja. Ovaj odjeljak provodi detekciju vremenskih promjena usporedbom NDVI kompozita iz dvaju različitih vremenskih razdoblja. Diferenciranje NDVI-ja koristi se za prepoznavanje područja poboljšanja ili degradacije vegetacije, omogućujući detekciju dugoročnih okolišnih promjena, a ne izoliranih opažanja.
5. Pitanja za refleksiju. Završni odjeljak usmjeren je na kvalitativnu interpretaciju. Studente se vodi da razmisle o opaženim prostornim i vremenskim obrascima,

razmotre okolišne pokretače promjene vegetacije te rasprave o ograničenjima i nesigurnosti satelitske analize.

Preduvjet: postavljanje Google Earth Enginea

Ova praktična vježba oslanja se na Google Earth Engine za pristup i obradu satelitskih snimki Sentinel-2. Prije pokretanja bilježnice pristup Earth Engineu mora biti omogućen za vaš Google račun. Detaljne upute pronaći ćete u datoteci bilježnice u odjeljku 1b. Google Earth project setup.

Nakon što je projekt spreman, ažurirajte varijablu EE_PROJECT kao što je prikazano na Slici 7.12.

```
# Google Earth Engine project ID.
# This project must be enabled in Google Cloud Console and linked
# to the authenticated Google account to allow Earth Engine operations.
EE_PROJECT = "ml-cv-class-2026" # set your project ID here
```

Slika 7.12 Definicija varijable EE_PROJECT

Izvršavanje bilježnice

Kada završite s postavljanjem projekta Google Earth Engine, prijeđite na izvršavanje bilježnice.

1. Otvorite Google Colab.
2. Učitajte datoteku bilježnice.
3. Pokrenite bilježnicu: Runtime → Run all.
4. Pomičite se kroz izlaze dok se ćelije izvršavaju. Trebali biste vidjeti međurezultate i završne NDVI vizualizacije.
    - Vidjet ćete NDVI vizualizaciju za definirani raspon datuma u odjeljku 3. NDVI Composite Visualization, kao što je prikazano na Slici 7.13. Zelena područja sadrže zdravu i gustu vegetaciju, dok crvena područja imaju manje vegetacije i više golog tla.

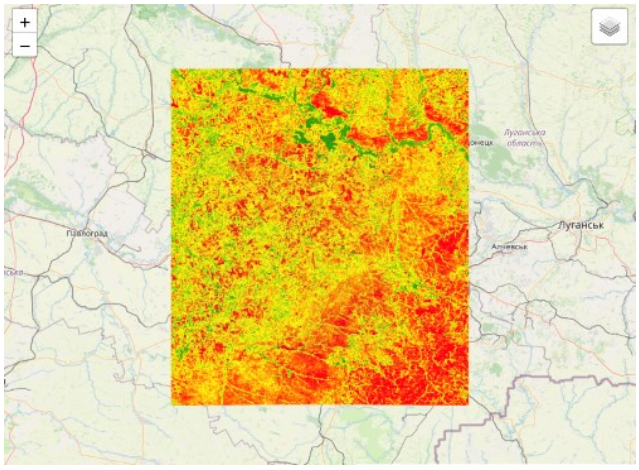

Slika 7.13 Vizualizacija NDVI kompozita

- Također ćete vidjeti NDVI razliku između definiranog raspona datuma i povijesnog raspona datuma u odjeljku 4. NDVI Temporal Comparison. Ovdje zelena područja predstavljaju pozitivnu promjenu vegetacije u usporedbi s povijesnim rasponom datuma, a crvena područja predstavljaju smanjenje gustoće vegetacije. Slika 7.14 prikazuje primjer vremenske usporedbe NDVI-ja.

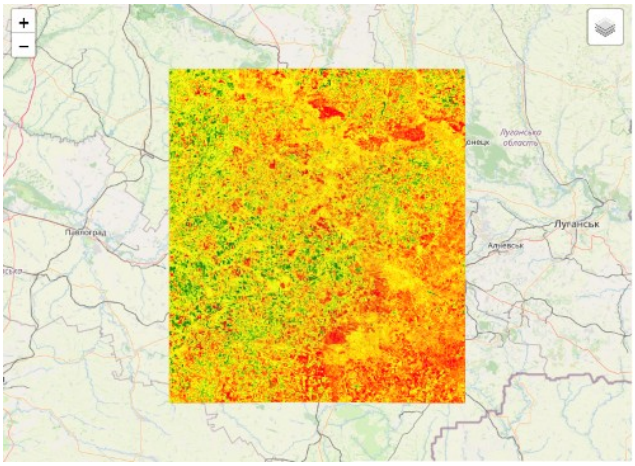

Slika 7.14 Vremenska usporedba NDVI-ja

Napomena: Ako Colab prikaže upozorenje (“Author not trusted”), kliknite Run anyway.

Izvor podataka

Ova vježba koristi multispektralne snimke Sentinel-2. NDVI se izračunava iz crvenog pojasa (B4) i bliskog infracrvenog pojasa (B8).

Podaci se učitavaju iz zbirke Copernicus Sentinel-2 SR (npr. COPERNICUS/S2_SR_HARMONIZED), filtriraju prema području i datumu, a zatim agregiraju za analizu.

Zadaci

Zadatak 1: Pokrenite i provjerite osnovni izlaz

- Otvorite i pokrenite priloženu bilježnicu.
- Potvrdite da se podaci Sentinel-2 ispravno učitavaju za odabrani AOI i raspon datuma.
- Izračunajte NDVI sloj i prikažite NDVI kartu.

Pitanja:

- Gdje unutar AOI-ja opažate klastere niskih i visokih vrijednosti NDVI-ja?
- Koji su tipovi pokrova zemljišta najvjerojatnije povezani s tim klasterima (npr. vodena tijela, golo tlo, urbana područja, gusta vegetacija)?
- Djeluju li NDVI obrasci prostorno koherentno ili su fragmentirani i šumoviti na razini piksela?
- Koja se početna okolišna interpretacija može izvesti na temelju prostorne raspodjele vrijednosti NDVI-ja?

Zadatak 2: Interpretacija temeljena na pragovima (okolišno zaključivanje)

Upotrijebite pragove za interpretaciju NDVI-ja i klasificirajte AOI u kategorije "nisko / srednje / visoko zdravlje vegetacije":

- NDVI < ~0,1
- NDVI ~0,1-0,3
- NDVI > ~0,3

Pitanja:

- Koja kategorija zdravlja vegetacije temeljena na NDVI-ju (niska, srednja ili visoka) dominira u AOI-ju i zašto?
- Jesu li područja niskog NDVI-ja prostorno klasterirana ili raspršena? Što to sugerira o potencijalnom okolišnom stresu ili obrascima korištenja zemljišta?

- Koji prirodni ili antropogeni čimbenici mogu uvjerljivo objasniti prisutnost zona niskog NDVI-ja u ovoj regiji?

Zadatak 3: Provjera osjetljivosti (vrijeme i lokacija)

Promijenite jednu varijablu odjednom, ponovno pokrenite i usporedite izlaze:

- Promijenite raspon datuma (npr. proljeće naspram kasnog ljeta).
- Promijenite AOI na svoju matičnu regiju ili regiju koju želite analizirati (npr. rub urbanog područja naspram poljoprivredne regije)

Pitanja:

- Kako se NDVI obrasci mijenjaju kada se promijeni razdoblje promatranja?
- Koje se promjene mogu objasniti sezonskom dinamikom vegetacije, a koje mogu upućivati na trajniju strukturnu promjenu?
- Kako promjena AOI-ja utječe na interpretaciju NDVI rezultata, osobito pri usporedbi ruba urbanog područja i poljoprivrednih regija?

Provjera znanja

Koja je glavna uloga računalnog vida u primjenama sigurnosti okoliša?

A) Zamjena stručnjaka za okoliš potpuno automatiziranim sustavima
B) Poboljšanje vizualne kvalitete satelitskih snimki
C) Automatsko izdvajanje djelotvornih informacija iz velikih količina vizualnih podataka
D) Ručno označavanje okolišnih slika

Koji je zadatak računalnog vida najprikladniji za prepoznavanje točne lokacije nezakonitih hrpa otpada uz rijeku?

A) Klasifikacija slika
B) Detekcija objekata
C) Poboljšanje slike
D) Normalizacija podataka

Zašto se dronovi često koriste zajedno sa satelitskim snimkama u sustavima praćenja okoliša?

A) Dronovi zamjenjuju potrebu za satelitskim podacima
B) Dronovi pružaju lokalizirana opažanja više rezolucije koja nadopunjuju satelitsku pokrivenost velikih razmjera
C) Dronovi uklanjaju potrebu za modelima računalnog vida
D) Satelitske snimke ne mogu se koristiti za praćenje okoliša

Koja se vrsta okolišnih informacija najčešće izvodi iz visokih vrijednosti NDVI-ja?

A) Gustoća urbane infrastrukture
B) Prisutnost oblaka ili dima
C) Gusta i zdrava vegetacija
D) Područja pogođena poplavama

Zašto je radar sa sintetičkom aperturom (SAR) posebno važan za praćenje katastrofa kao što su poplave ili oštećenja zgrada?

A) Pruža višu rezoluciju boja
B) Detektira samo promjene vegetacije
C) Radi neovisno o vremenskim uvjetima i dnevnoj svjetlosti
D) Ne zahtijeva integraciju s GIS-om

Koja je kombinacija tehnologija najučinkovitija za izgradnju situacijske svijesti u sustavima sigurnosti okoliša?

A) Samo modeli računalnog vida
B) Satelitske snimke bez strojnog učenja
C) Računalni vid + satelitski/dronski podaci + GIS integracija
D) Ručna inspekcija slika s GPS uređajima

Reference / dodatna literatura

[1] R. Szeliski, Computer Vision: Algorithms and Applications, 2nd ed. Cham, Switzerland: Springer International Publishing, 2022. doi: 10.1007/978-3-030-34372-9. [Online]. Dostupno: https://szeliski.org/Book/, pristupljeno: 15. prosinca 2025.

[2] S. J. D. Prince, Computer Vision: Models, Learning, and Inference. Cambridge, UK: Cambridge University Press, 2012. [Online]. Dostupno: https://raw.githubusercontent.com/udlbook/cvbook/main/book.pdf, pristupljeno: 15. prosinca 2025.

[3] H. J. Escalante et al. (eds.), Explainable and Interpretable Models in Computer Vision and Machine Learning. Cham, Switzerland: Springer International Publishing, 2018. doi: 10.1007/978-3-319-98131-4. [Online]. Dostupno: https://link.springer.com/book/10.1007/978-3-319-98131-4, pristupljeno: 15. prosinca 2025.

[4] N. Kussul, A. Shelestov, B. Yailymov, H. Yailymova, G. Lemoine, and K. Deininger, “Assessment of war-induced agricultural land use changes in Ukraine using machine learning applied to Sentinel satellite data,” International Journal of Applied Earth Observation and Geoinformation, vol. 140, p. 104551, 2025. [Online]. Dostupno: https://linkinghub.elsevier.com/retrieve/pii/S1569843225001980, pristupljeno: 15. prosinca 2025.

[5] J. Song, A. Pashazadeh, S. Wu, V. R. Greene, K. O. Hallee, A. M. Tannehill, T. M. Saxon, M. Potter, and Z. Beneke, “Advances in microplastic detection and interception: A state-of-the-art review,” Cleaner Water, vol. 4, p. 100141, 2025. [Online]. Dostupno: https://doi.org/10.1016/j.clwat.2025.100141, pristupljeno: 15. prosinca 2025.

[6] O. Ballinger, “A New Tool Allows Researchers to Track Damage in Gaza,” Bellingcat, 15. studenoga 2023. [Online]. Dostupno: https://www.bellingcat.com/resources/2023/11/15/a-new-tool-allows-researchers-to-track-damage-in-gaza/, pristupljeno: 15. prosinca 2025.

[7] L. Shumilo, M. Lavreniuk, N. Kussul, and B. Shevchuk, “Automatic Deforestation Detection based on the Deep Learning in Ukraine,” in Proceedings of the 11th IEEE

International Conference on Intelligent Data Acquisition and Advanced Computing Systems (IDAACS), 2021. doi: 10.1109/IDAACS53288.2021.9661008. [Online]. Dostupno: https://doi.org/10.1109/IDAACS53288.2021.9661008, pristupljeno: 15. prosinca 2025.

[8] D. Mozghovyi, V. Korchynskyi, and D. Svynarenko, “Methodology of satellite monitoring of deforestation based on Sentinel-2A/B data,” Challenges and Issues of Modern Science, vol. 3, 2024. [Online]. Dostupno: https://cims.fti.dp.ua/j/article/view/252/207, pristupljeno: 15. prosinca 2025.

[9] O. Rumiantsev, Y. Oliinyk, and L. Oliinyk, “Damage Detection Based on Satellite Image Analysis,” in Lecture Notes in Data Engineering, Computational Intelligence, and Decision-Making, vol. 2, Lecture Notes on Data Engineering and Communications Technologies, vol. 244, S. Babichev and V. Lytvynenko, Eds. Cham, Switzerland: Springer International Publishing, 2025, pp. 177–189. doi: 10.1007/978-3-031-88483-2. [Online]. Dostupno: https://link.springer.com/book/10.1007/978-3-031-88483-2, pristupljeno: 15. prosinca 2025.

[10] European Space Agency, Copernicus Sentinel-2 [Level-2A data set], 2026. [Online]. Dostupno: https://dataspace.copernicus.eu/, pristupljeno: 15. prosinca 2025.

[11] U.S. Geological Survey, Landsat 8–9 OLI/TIRS Level-2, Collection 2 [data set]. Earth Resources Observation and Science (EROS) Center, 2026. doi: 10.5066/P9OGBGM6. [Online]. Dostupno: https://doi.org/10.5066/P9OGBGM6, pristupljeno: 15. prosinca 2025.

[12] S. L. Deshmukh, M. Wilchek, and F. A. Batarseh, “HydroVision: Predicting optically active parameters in surface water using computer vision,” arXiv preprint, 2025. [Online]. Dostupno: https://arxiv.org/abs/2509.01882, pristupljeno: 15. prosinca 2025.

[13] L. K. Jamili, K. Wu, K. Natarajan, A. K. Singh, M. Tee, and M. Jindal, “Computer vision in environmental monitoring: Automated detection for biodiversity and climate action,” International Journal of Environmental Sciences, vol. 11, no. 19s, pp. 870–878, 2025. doi: 10.64252/a24f9536. [Online]. Dostupno: https://doi.org/10.64252/a24f9536, pristupljeno: 15. prosinca 2025.

[14] A. V. Voloshko and A. O. Makarenko, “Using sensor devices combined with computer vision algorithms to improve motion-tracking systems,” Scientific Notes of the State

University of Telecommunications, 2024. doi: 10.31673/2786-8362.2024.010202. [Online]. Dostupno: https://doi.org/10.31673/2786-8362.2024.010202, pristupljeno: 15. prosinca 2025.

[15] A. Heller, M. Jacobs, G. Acosta-González, et al., “Plastic water bottle detection model using computer vision in aquatic environments,” Scientific Reports, vol. 15, p. 24851, 2025. doi: 10.1038/s41598-025-09300-8. [Online]. Dostupno: https://doi.org/10.1038/s41598-025-09300-8, pristupljeno: 15. prosinca 2025.

[16] A. Singh, A. Sengupta, and P. Venkoparao, “Deep learning-based burned area mapping using pre- and post-fire Sentinel-2 imagery,” Remote Sensing Applications: Society and Environment, vol. 24, p. 100614, 2021. doi: 10.1016/j.rsase.2021.100614. [Online]. Dostupno: https://doi.org/10.1016/j.rsase.2021.100614, pristupljeno: 15. prosinca 2025.

[17] S. Aksoy, V. Yilmaz, and S. Öztürk, “Deep convolutional networks for post-disaster environmental damage assessment using aerial imagery,” Scientific Reports, vol. 12, p. 1883, 2022. doi: 10.1038/s41598-022-06067-1. [Online]. Dostupno: https://doi.org/10.1038/s41598-022-06067-1, pristupljeno: 15. prosinca 2025.