Tema: Računalniški vid za okoljsko varnost

Predmet: Strojno učenje za okoljske aplikacije

Učni izidi

Po zaključku te enote bodo študenti znali:

- Razložiti, kako računalniški vid prispeva k okoljski varnosti in spremljanju okolja.
- Opisati ključne koncepte zaznavanja objektov in razvrščanja slik v okoljskem kontekstu.
- Prepoznati, kako se droni, satelitski podatki in senzorji povezujejo za zagotavljanje zavedanja o razmerah.
- Uporabiti preprost model računalniškega vida za razvrščanje satelitskih posnetkov ali posnetkov z dronov.
- Razpravljati o tem, kako samodejna analiza slik podpira okoljsko odločanje in zmanjševanje tveganj (npr. zaznavanje onesnaženja, spremljanje požarov v naravi, zaznavanje neeksplodiranih ubojnih sredstev (UXO), spremljanje biotske raznovrstnosti).

Uvod

Danes bomo računalniški vid obravnavali ne kot abstrakten koncept umetne inteligence (AI) iz učbenika strojnega učenja, temveč kot praktično orodje, ki se že uporablja za podporo okoljski varnosti.

Preprosto povedano, pri računalniškem vidu gre za učenje strojev, da »vidijo« – da analizirajo satelitske posnetke, posnetke z dronov, posnetke iz zraka ali videotokove ter iz njih izluščijo smiselne informacije. Ne gre le za prepoznavanje objektov na sliki, temveč za zaznavanje sprememb, vzorcev in tveganj v obsegu, ki ga ročno ni mogoče obvladovati.

Pri okoljskih in varnostnih aplikacijah postane ta zmožnost ključna. Številna območja, ki jih moramo spremljati, so težko ali nevarno dostopna: industrijska območja, odročni gozdovi, območja, prizadeta zaradi konfliktov, ali območja, onesnažena z neeksplodiranimi ubojnimi sredstvi. Tradicionalni terenski pregledi so v takem okolju počasni, dragi in pogosto nevarni.

Računalniški vid nam v povezavi s strojnim učenjem omogoča neprekinjeno spremljanje teh območij z uporabo vizualnih podatkov. Avtomatizirani sistemi lahko obdelajo velike količine

satelitskih posnetkov in posnetkov z dronov ter odkrijejo zgodnje znake okoljskih nevarnosti – kot so izlitja onesnaževal, nezakonita sečnja, izbruhi požarov v naravi ali poškodbe objektov – veliko preden se razmere zaostrijo.

Med predavanjem bomo spoznali, kako ti sistemi delujejo v praksi: na katere vrste podatkov se opirajo, katere naloge računalniškega vida so najpomembnejše za spremljanje okolja ter kako se rezultati avtomatizirane analize slik pretvorijo v odločitve in ukrepe za zmanjševanje tveganj v resničnem svetu. Slika 7.1 prikazuje, kako se računalniški vid razlikuje od običajnega človeškega vida.

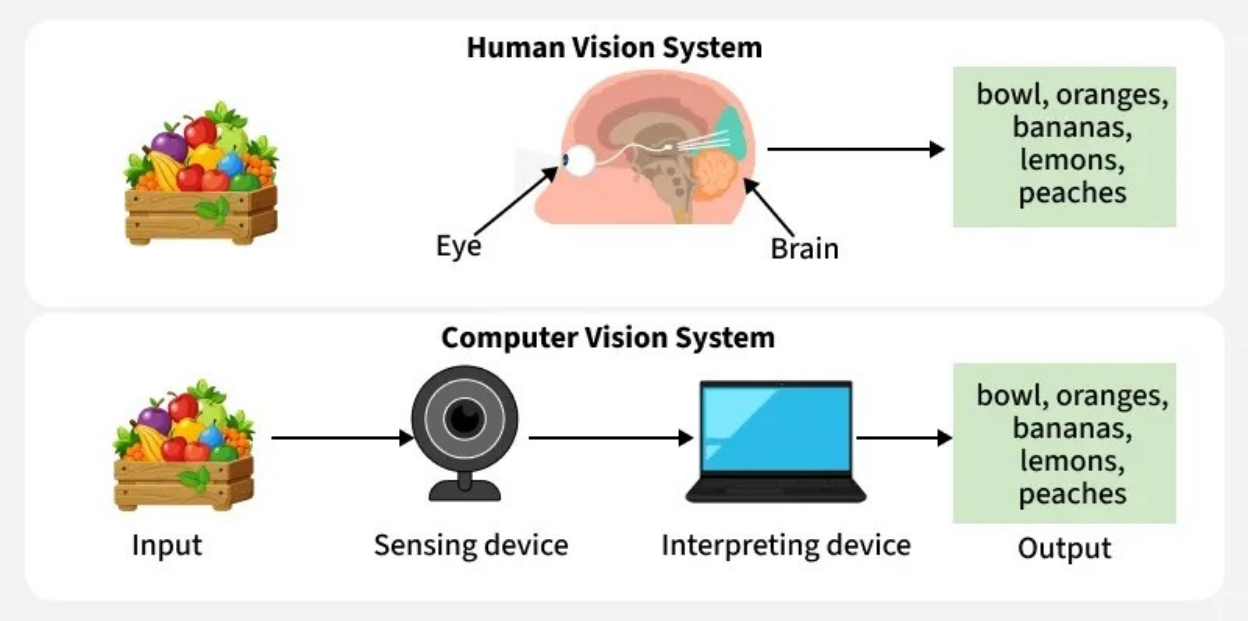

Slika 7.1 Shematski prikaz računalniškega vida

Prevod napisov na sliki: Sistem človeškega vida: oko, možgani in prepoznani predmeti (skleda, pomaranče, banane, limone in breskve). Sistem računalniškega vida: vhod, zaznavna naprava, naprava za interpretacijo in izhod.

Vloga in pomen računalniškega vida

Ko govorimo o vlogi računalniškega vida pri spremljanju okolja, je ključna zamisel razširljivost. Tradicionalne metode spremljanja so močno odvisne od ljudi – inšpektorjev, terenskih raziskav in meritev na kraju samem. Ti pristopi delujejo, vendar jih je težko razširiti in pogosto odpovejo prav tam, kjer je spremljanje najbolj potrebno: na velikih, odročnih ali nevarnih območjih.

Računalniški vid ponuja objektivnejšo rešitev, ki jo je mogoče lažje razširiti. Namesto da bi se zanašali na človeško opazovanje, neobdelane slikovne pike pretvorimo v strukturirane informacije, ki jih je mogoče skozi čas analizirati samodejno in dosledno.

V jedru večine okoljskih sistemov računalniškega vida sta dve temeljni nalogi: razvrščanje slik in zaznavanje objektov. Čeprav ju pogosto omenjamo skupaj, odgovarjata na različna praktična vprašanja.

Razvrščanje slik se osredotoča na to, *kaj je na sliki*. Model lahko na primer ugotovi, ali satelitski posnetek prikazuje gozd, vodo, urbano območje ali degradirano zemljišče. Ta vrsta analize je še posebej uporabna, kadar moramo spremljati velika območja in spremembe skozi čas.

Zaznavanje objektov pa se osredotoča na to, *kje natančno je nekaj*. Prepozna posamezne objekte ali značilnosti in njihove meje – na primer podrta drevesa, nakopičene odpadke v rekah ali poškodovane stavbe. Ta raven podrobnosti je nujna, kadar je treba rezultate povezati s konkretnimi lokacijami za ukrepanje na terenu ali odločanje.

Sistemi računalniškega vida z združevanjem teh nalog zagotavljajo zavedanje o razmerah skoraj v realnem času. Modele je mogoče naučiti prepoznavati spektralne vzorce, povezane z naftnimi madeži, značilnosti dima ob začetku požarov v naravi ali strukturne spremembe, vidne na satelitskih in radarskih posnetkih.

Praktični pomen tega pristopa je v tem, da skrajša čas med okoljsko spremembo in odzivom. Namesto da bi se odzvali šele, ko škoda postane vidna na terenu, lahko organi in organizacije prejmejo zgodnja opozorila ter ukrepajo, preden se razmere zaostrijo.

Strategije pridobivanja in povezovanja podatkov

Učinkovitost računalniškega vida pri spremljanju okolja je neposredno odvisna od podatkov, ki jih prejema. V praksi ne zadošča noben posamezen vir podatkov. Sistemi okoljske varnosti temeljijo na združevanju več vrst vizualnih podatkov, od katerih je vsaka prilagojena drugačnim omejitvam obsega, ločljivosti in pogojev delovanja.

Satelitski posnetki so temelj spremljanja velikih območij. Platforme, kot sta Sentinel in Landsat, omogočajo neprekinjeno opazovanje obsežnih ozemelj v daljših časovnih obdobjih. Večspektralni podatki, zlasti v bližnjem infrardečem in kratkovalovnem infrardečem pasu, omogočajo ocenjevanje zdravja vegetacije, zaznavanje krčenja gozdov in prepoznavanje sprememb rabe tal, ki na običajnih posnetkih RGB niso vidne.

Droni dopolnjujejo satelitske podatke, saj ponujajo veliko večjo prostorsko ločljivost in prilagodljivo uporabo. Navadno se uporabljajo za lokalne preglede, na primer za prepoznavanje

majhnih virov onesnaženja ali zaznavanje neeksplodiranih ubojnih sredstev na območjih, kjer dostop s tal ni varen, kot prikazuje slika 7.2.

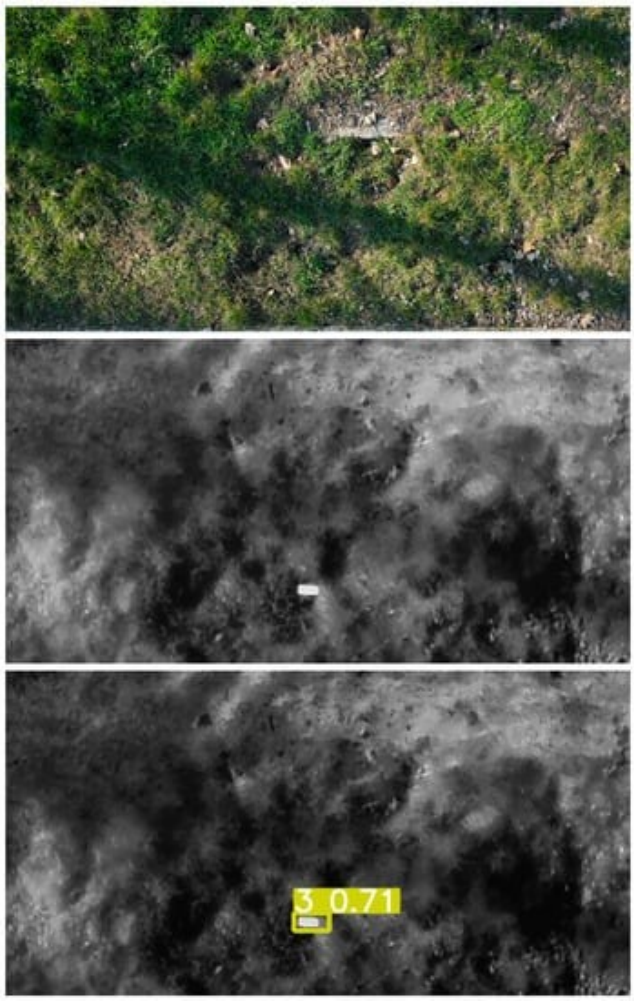

Slika 7.2 Dron z računalniškim vidom

Radarski sistemi, zlasti radar s sintetično odprtino, odpravljajo omejitve optičnih posnetkov. Ker SAR ni odvisen od sončne svetlobe ter lahko prodre skozi oblake in dim, omogoča neprekinjeno spremljanje ne glede na vreme ali čas dneva. Podatki SAR so še posebej dragoceni za zaznavanje strukturnih sprememb in poškodb stavb. Slika 7.3 prikazuje primer posnetka SAR.

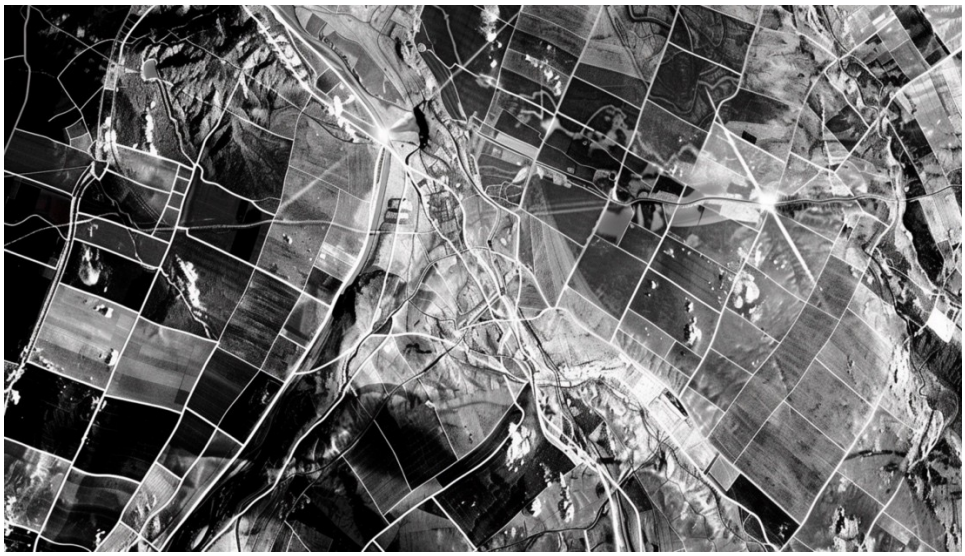

Slika 7.3 Posnetek SAR

V praksi se ti viri podatkov uporabljajo skupaj. Izhodi modelov računalniškega vida se vključijo v geografske informacijske sisteme, v katerih se zaznana tveganja in spremembe prostorsko kartirajo. S tem povezovanjem se neobdelani posnetki spremenijo v uporabne informacije, ki podpirajo okoljsko odločanje in zmanjševanje tveganj.

Etični, varnostni in podatkovni vidiki

Preden se podrobneje posvetimo modelom in metrikam, moramo upoštevati pomembno praktično dejstvo: računalniški vid za okoljske namene ni le tehnična tema. Način zbiranja, shranjevanja in izmenjave vizualnih podatkov lahko ustvari resnična etična in varnostna tveganja.

Prvo vprašanje zadeva zasebnost in odgovorno ravnanje s podatki. Ločljivost satelitskih posnetkov in posnetkov z droni se nenehno izboljšuje. To pomeni, da lahko iste podatkovne zbirke, ki so uporabne za spremljanje gozdov, rek ali industrijskih območij, nenamerno zajamejo tudi občutljive dejavnosti ljudi. Vprašanje torej ni le *»Ali lahko to zaznamo?«*, temveč tudi *»Ali bi morali podatke s tako ravnjo podrobnosti zbirati ali objaviti?«*

Drugo vprašanje je tveganje dvojne rabe. Okoljski podatki pogosto veljajo za nenevarne, vendar ni vedno tako. Natančne lokacije ogroženih vrst ali podrobne informacije o ranljivostih infrastrukture je na primer mogoče zlorabiti. Strokovnjaki morajo zato znanstveno preglednost uravnotežiti z zaščitnimi ukrepi, ki preprečujejo zlorabo.

Ključno sporočilo je preprosto: dobro upravljanje je sestavni del kakovostnega inženirskega dela. Odgovoren nadzor dostopa, premišljena pravila izmenjave in poznavanje scenarijev

dvojne rabe so nujni, če želimo z računalniškim vidom krepiti odpornost okolja, ne pa ustvarjati novih tveganj.

Temeljni koncepti in metode

Konceptualni okvir računalniškega vida pri okoljski varnosti

Zdaj ko smo si ogledali podatke – od kod izvirajo in kakšne omejitve imajo –, lahko obravnavamo, kako računalniški vid dejansko izlušči informacije iz teh slik.

Pri spremljanju okolja cilj računalniškega vida ni izdelati najkompleksnejšega možnega modela. Gre za izbiro metod, ki so robustne, razložljive in dobro usklajene z lastnostmi podatkov.

Večina delovnih postopkov okoljskega računalniškega vida temelji na majhnem naboru osrednjih zamisli. Na splošno te metode sprejmejo neobdelane vizualne vhodne podatke – satelitske slikovne pike, posnetke z dronov ali radarske signale – ter jih pretvorijo v strukturirane predstavitve okolja: zemljevide pokrovnosti tal, zaznane objekte ali kazalnike sprememb.

Pomembno je, da izbiro metode narekujejo naloga in podatki, ne moda ali kompleksnost modela. Spremljanje velikih območij, zaznavanje sprememb in varnostno kritične aplikacije zahtevajo pristope, ki so skozi čas stabilni ter odporni proti šumu, nepopolnim oznakam in netočnim referenčnim podatkom.

Ob upoštevanju tega si lahko zdaj ogledamo dve najpogostejši nalogi računalniškega vida na področju okoljske varnosti: razvrščanje slik in zaznavanje objektov.

Razvrščanje slik v primerjavi z zaznavanjem objektov

V okoljskem računalniškem vidu večina praktičnih sistemov temelji na dveh tesno povezanih nalogah: razvrščanju slik in zaznavanju objektov. Čeprav ju pogosto omenjamo skupaj, imata različne namene in odgovarjata na različna vprašanja.

Razvrščanje slik se osredotoča na to, *kaj je na sliki*. Model dodeli oznake celotni sliki ali vnaprej določenim območjem, s čimer lahko razumemo splošne vzorce – na primer vrste pokrovnosti tal, stanje vegetacije ali poškodovana in nepoškodovana območja. Ta pristop je še posebej učinkovit pri spremljanju velikih območij, kjer je cilj spremljati spremembe skozi čas in ne posameznih objektov. Slika 7.4 prikazuje primer pristopa segmentacije slik.

Zaznavanje objektov pa se osredotoča na to, *kje natančno je nekaj*. Namesto označevanja območij model prepozna posamezne objekte in njihove natančne položaje. Ta raven

podrobnosti postane nujna, kadar je treba analizo povezati s konkretnimi ukrepi na terenu – na primer določiti lokacije neeksplodiranih ubojnih sredstev, prepoznati posamezne kupe odpadkov ali kartirati posamične poškodovane stavbe. Slika 7.5 prikazuje rezultat algoritma za zaznavanje objektov, uporabljenega za avtomobile na parkirišču.

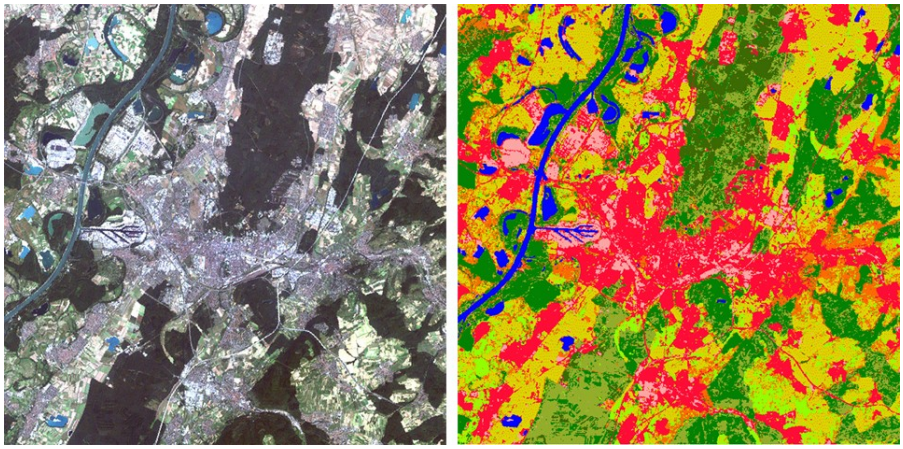

Slika 7.4 Primer segmentacije slik

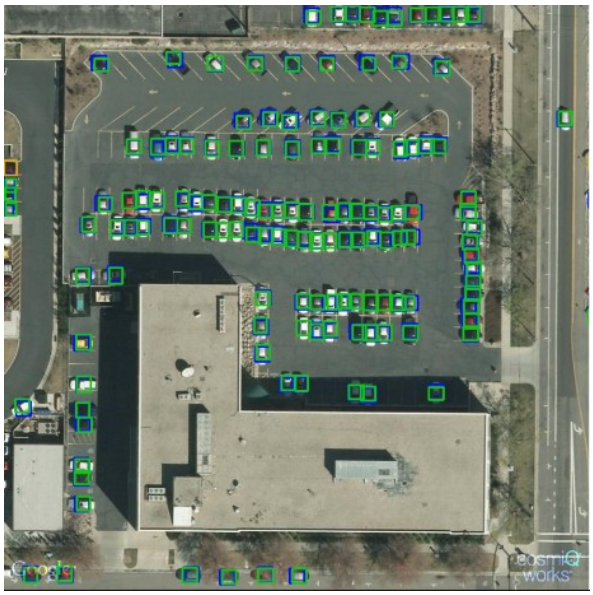

Slika 7.5 Zaznavanje objektov

Ključna razlika med tema pristopoma ni tehnična kompleksnost, temveč namen. Razvrščanje nam pomaga razumeti vzorce na velikih območjih, zaznavanje objektov pa omogoča ciljno ukrepanje. V številnih dejanskih sistemih za spremljanje okolja se obe metodi združujeta: razvrščanje se uporablja za prepoznavanje območij zanimanja, zaznavanje objektov pa za njihovo podrobno analizo.

Koncepti modelov računalniškega vida za okoljsko varnost

Ko govorimo o modelih okoljskega računalniškega vida, glavno vprašanje ni »katera arhitektura je najnaprednejša«, temveč »kaj lahko glede na podatke in omejitve, ki jih imamo, zanesljivo uvedemo«. Okoljski posnetki vsebujejo šum, pridobivanje referenčnih podatkov je drago, razmere pa se skozi čas spreminjajo – letni časi, osvetlitev, oblačnost in celo vrste senzorjev.

V praksi izbiro modela narekuje izhod, ki ga potrebujemo: segmentacija ali zaznavanje

Segmentacija: U-Net

Če je cilj kartirati *območja* – na primer obseg poplavljenega območja, meje gozdov ali poškodovana območja –, je segmentacija naravna izbira.

Pri tem se pogosto uporablja arhitektura U-Net, saj je zasnovana za ustvarjanje mask na ravni slikovnih pik ter zajemanje lokalnih podrobnosti in širšega prostorskega konteksta. Slika 7.6 jasno prikazuje, zakaj se imenuje U-Net. Pri spremljanju okolja je zato uporabna vedno, kadar sta pomembna *položaj meje* in *velikost prizadetega območja*.

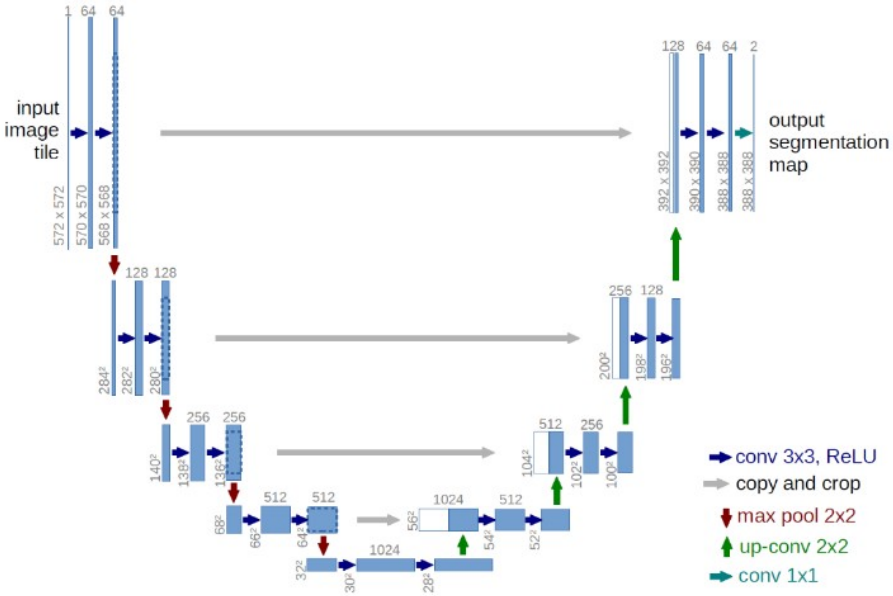

Slika 7.6 Arhitektura modela U-Net

Prevod napisov na sliki: Vhodni slikovni izrez; izhodna segmentacijska karta; konvolucija 3 × 3 in ReLU; kopiranje in obrezovanje; maksimalno združevanje 2 × 2; navzgornja konvolucija 2 × 2; konvolucija 1 × 1.

Zaznavanje: MobileNet / YOLO-lite

Če je cilj poiskati *posamezne objekte* – kot so kosi odpadkov, posamezne poškodovane konstrukcije ali morebitna neeksplodirana ubojna sredstva (UXO) –, običajno uporabimo modele za zaznavanje objektov.

V številnih operativnih okoljih, zlasti na dronih ali robnih napravah, imajo prednost lahke arhitekture, kot so detektorji na osnovi MobileNet ali YOLO-lite, saj uravnotežujejo hitrost in točnost ter lahko delujejo z omejenimi računskimi zmogljivostmi.

Predhodno naučeni modeli in prenosno učenje

Ponavljajoči se izziv na področju okoljske varnosti je omejena količina označenih podatkov. Na nevarnih ali nedostopnih območjih je zbiranje in označevanje posnetkov drago ali nemogoče.

Zato je prenosno učenje tako pogosto: začnemo z modelom, ki je bil predhodno naučen na veliki splošni podatkovni zbirki, nato pa ga dodatno učimo na manjši zbirki okoljskih podatkov – na primer model za mestne posnetke prilagodimo za prepoznavanje določenih vzorcev poškodb stavb ali detektor za prepoznavanje predmetov, podobnih neeksplodiranim ubojnim sredstvom (UXO), na posnetkih z dronov.

Združevanje dopolnjujočih se algoritmov

Okoljski delovni postopki pogosto združujejo več algoritemskih pristopov, da izboljšajo robustnost.

Modeli Random Forest lahko na primer zmanjšajo šum tipa »sol in poper« na velikih homogenih območjih, kar je uporabno pri razvrščanju pokrovnosti tal. Preprostejši nevronski modeli, kot je MLP, pa lahko včasih ločijo manjše ali redke razrede, ki so v podatkih preslabo zastopani – na primer komaj opazne industrijske anomalije ali manjše spremembe, ki se izgubijo v širših razredih.

Praktična zamisel je preprosta: namesto da bi vse stavili na en model, združimo metode, ki odpovedujejo na različne načine.

Ključno sporočilo

Tukajšnji »koncept« modela torej ni posamezna arhitektura, temveč odločitev o operativni zasnovi. U-Net je dobra privzeta izbira za zemljevide segmentacije, MobileNet / YOLO-lite sta praktični izbiri za hitro zaznavanje, prenosno učenje pa pogosto pomeni razliko med »to lahko izdelamo« in »nimamo podatkovne zbirke, s katero bi lahko začeli«.

Statistične metrike uspešnosti

Ko opredelimo, kaj naj bi naši modeli počeli – razvrščali območja ali zaznavali posamezne objekte –, se pojavi naslednje vprašanje: kako ocenimo njihovo uspešnost. Pri spremljanju okolja to ni tako preprosto, kot se morda zdi.

Številne zbirke okoljskih podatkov so izrazito neuravnotežene. Poškodovana območja lahko na primer pokrivajo le majhen del obsežnega območja, medtem ko večina ostane nespremenjena. V takih primerih je lahko sama točnost zavajajoča, saj lahko model doseže visoko točnost, vendar ne zazna pojavov, ki nas dejansko zanimajo.

Zato se okoljski računalniški vid opira na metrike, ki bolje odražajo prostorsko ujemanje in kakovost zaznavanja.

Razmerje preseka nad unijo (IoU)

Ena najpogosteje uporabljenih metrik za segmentacijo in analizo območij je razmerje preseka nad unijo oziroma IoU.

IoU meri, kako dobro se napovedano območje prekriva z referenčnim območjem oziroma območjem dejanskega stanja, kot prikazuje slika 7.7.

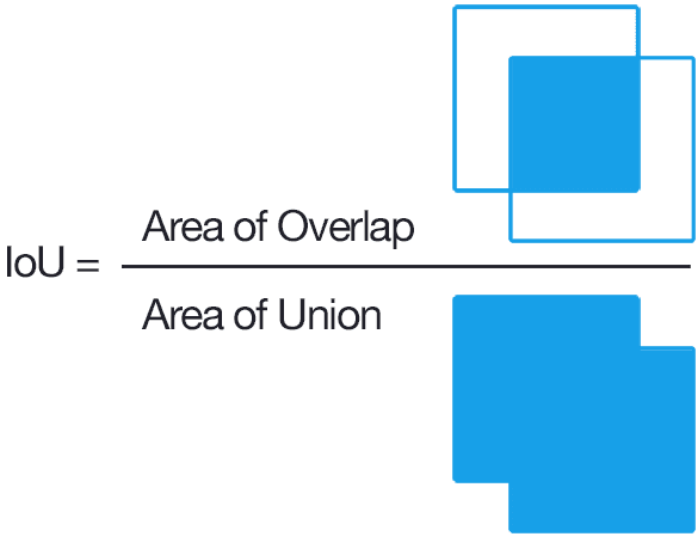

Slika 7.7 Ponazoritev izračuna razmerja preseka nad unijo

Prevod napisov na sliki: IoU = ploščina prekrivanja / ploščina unije.

Intuitivno IoU odgovarja na preprosto vprašanje: *kolikšno je prekrivanje teh dveh območij?* Višja vrednost IoU pomeni boljše prostorsko ujemanje med izhodom modela in podatki, ki so jih označili strokovnjaki. Pri nalogah, kot sta kartiranje krčenja gozdov ali ocenjevanje poškodb stavb, vrednosti IoU blizu 1 pomenijo visokokakovostne napovedi.

Preciznost, priklic in mera F1

Ko od segmentacije območij preidemo k zaznavanju objektov, postanejo pomembne dodatne metrike.

Preciznost pove, kolikšen delež zaznav je pravilen. To je ključnega pomena pri varnostnih nalogah, pri katerih lahko lažno pozitivne zaznave povzročijo nepotrebna ali celo nevarna posredovanja.

Priklic meri, koliko ustreznih objektov model uspešno zazna. Spregled objekta, kot je neeksplodirano ubojno sredstvo ali dim ob začetku požara v naravi, ima lahko resne posledice.

Mera F1 združuje preciznost in priklic v eno vrednost ter uravnoteži lažno pozitivne in lažno negativne zaznave. Zato je še posebej uporabna pri okoljskih aplikacijah, kjer je neravnotežje med razredi pogosto in sta pomembni obe vrsti napak.

Zakaj so te metrike pomembne v praksi?

Pri spremljanju okolja metrike niso le številke za primerjanje modelov. Vplivajo na odločitve v resničnem svetu.

Povečanje pragov zaznavanja lahko na primer izboljša preciznost, vendar zmanjša priklic. Ustrezno ravnovesje je odvisno od naloge: aplikacije na področju okoljske varnosti pogosto dajejo prednost zmanjšanju števila spregledanih primerov, tudi če je zato nekaj lažnih alarmov več.

Razumevanje teh kompromisov je bistveno za odgovorno in učinkovito uvajanje sistemov računalniškega vida.

Dejavniki, ki vplivajo na izmerjeno učinkovitost

Pri obravnavi metrik uspešnosti modela je pomembno razumeti ključno dejstvo: izmerjene učinkovitosti sistema računalniškega vida ne določa samo model.

Pri spremljanju okolja na uspešnost močno vplivajo lastnosti podatkov in razmere, v katerih so ti podatki zbrani.

Razlike v prostorski ločljivosti

Ena pogostih omejitev izhaja iz razlik v prostorski ločljivosti.
Referenčne oznake so pogosto ustvarjene z uporabo posnetkov zelo visoke ločljivosti ali z ročno interpretacijo, modeli pa lahko delujejo na satelitskih podatkih srednje ločljivosti.

Zato tudi dobro delujoč model le redko doseže popolno prekrivanje z referenčnimi podatki. To ni nujno napaka pri modeliranju, temveč posledica primerjanja informacij, zajetih v različnih prostorskih merilih.

Okoljski šum in atmosferske razmere

Optični posnetki so zelo občutljivi na okoljski šum. Oblaki, sence, dim in različne svetlobne razmere lahko vplivajo na kakovost slike in zmanjšajo uspešnost modela.

Radarski podatki, kot so podatki SAR, pomagajo odpraviti nekatere od teh omejitev, saj omogočajo opazovanje ne glede na vremenske razmere. Vendar radarski posnetki prinašajo svoje izzive, med drugim več signalnega šuma in manj intuitivne vizualne vzorce, zaradi česar je lahko določanje meja objektov in njihovo razvrščanje zahtevnejše.

Časovna stabilnost in sezonski vplivi

Drug pomemben dejavnik je časovna spremenljivost. Okoljske razmere se skozi čas spreminjajo zaradi letnih časov, vremenskih vzorcev in dinamike rabe zemljišč.

Za izboljšanje stabilnosti pri dolgoročnem spremljanju se pogosto uporabljajo tehnike, kot so normalizirani diferenčni indeksi. Ti indeksi zmanjšajo vpliv razlik v osvetlitvi in sezonskih nihanj, zato je lažje zaznati pomembne okoljske spremembe namesto začasnih odstopanj.

Ključno sporočilo

Glavno sporočilo je, da je treba metrike uspešnosti vedno razlagati v ustreznem kontekstu. Pri okoljskem računalniškem vidu nižje vrednosti metrik ne pomenijo samodejno slabe kakovosti modela – pogosto odražajo omejitve podatkov iz resničnega sveta.

Razumevanje teh dejavnikov strokovnjakom pomaga postaviti realistična pričakovanja in zasnovati sisteme spremljanja, ki so robustni, namesto da bi bili umetno optimizirani.

Uporaba pri zmanjševanju okoljskih tveganj

Po obravnavi podatkov, metod, metrik in njihovih omejitev se lahko osredotočimo na najpomembnejše praktično vprašanje: *kako se računalniški vid dejansko uporablja za zmanjševanje okoljskih tveganj?*

V resničnih razmerah avtomatizirana analiza slik podpira odločanje z zgodnjim zaznavanjem tveganj na velikih območjih in pogosto na krajih, kjer je neposredni pregled na terenu težaven ali nevaren.

Spremljanje onesnaženja in odpadkov

Ena najpogostejših uporab je spremljanje onesnaženja. Modeli računalniškega vida lahko zaznajo naftne madeže na vodnih površinah ali prepoznajo nezakonito odlaganje odpadkov v rekah in na odročnih območjih.

Ključna prednost je obseg. Obsežna ozemlja je mogoče spremljati neprekinjeno, kar pristojnim organom omogoča, da preglede in čiščenje usmerijo na najbolj kritične lokacije, namesto da bi se zanašali na občasna poročila s terena [7].

Zaznavanje neeksplodiranih ubojnih sredstev (UXO)

Na območjih, ki jih je prizadel konflikt, in pokonfliktnih območjih računalniški vid neposredno prispeva k varnosti ljudi. Z analizo posnetkov z dronov in satelitskih podatkov visoke ločljivosti lahko modeli pomagajo prepoznati območja, na katerih bi lahko bila neeksplodirana ubojna sredstva.

Ti sistemi ne nadomeščajo strokovnjakov za razminiranje. Namesto tega zmanjšujejo tveganje z omejevanjem območij iskanja in prednostno obravnavo območij, ki zahtevajo takojšnjo pozornost.

Zaznavanje požarov v naravi in dima

Računalniški vid se uporablja tudi za zgodnje zaznavanje požarov v naravi. Modeli lahko prepoznajo vzorce dima ali toplotne anomalije, preden požari postanejo veliki in neobvladljivi.

Že majhno skrajšanje časa do zaznave lahko pomembno vpliva na zmanjšanje okoljske škode, stroškov odziva in tveganj za bližnje skupnosti.

Ocenjevanje poškodb stavb

Druga ključna uporaba je ocenjevanje poškodb po naravnih nesrečah ali med oboroženimi spopadi.

Radarski sistemi, zlasti SAR, so v teh primerih še posebej dragoceni, ker delujejo neodvisno od vremenskih in svetlobnih razmer. Poškodbe konstrukcij povzročijo merljive spremembe v odbojih radarskega signala, zato jih je mogoče zaznati tudi, kadar optični posnetki niso na voljo. Sliki 7.8 in 7.9 ponazarjata, kako je mogoče vizualizirati ocenjevanje poškodb.



Slika 7.8 Ocena poškodb stavb po potresu v Turčiji

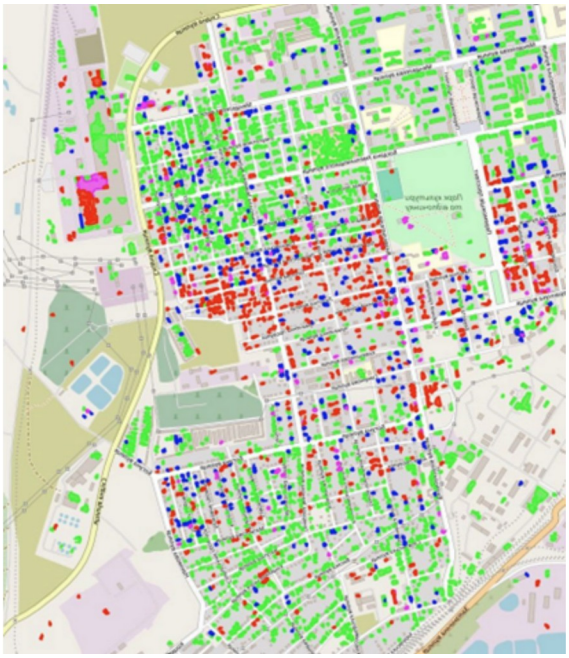

Slika 7.9 Poškodbe mesta Rubižne (Ukrajina) zaradi bojnih operacij

Ti rezultati se navadno vključijo v platforme GIS, kjer podpirajo odzivanje ob nesrečah, načrtovanje humanitarne pomoči in določanje prednostnih nalog pri obnovi [9].

Spremljanje krčenja gozdov in biotske raznovrstnosti

Dolgoročna okoljska tveganja, kot sta krčenje gozdov in izguba biotske raznovrstnosti, spremljamo s primerjanjem satelitskih posnetkov skozi čas.

Računalniški vid omogoča dosledno in ponovljivo zaznavanje postopnih sprememb pokrovnosti tal ter tako podpira naravovarstvena prizadevanja in oblikovanje politik – zlasti v regijah, kjer stalno spremljanje na terenu ni izvedljivo [6], [7], [8]. Rezultat takšnega spremljanja je prikazan na sliki 7.10.

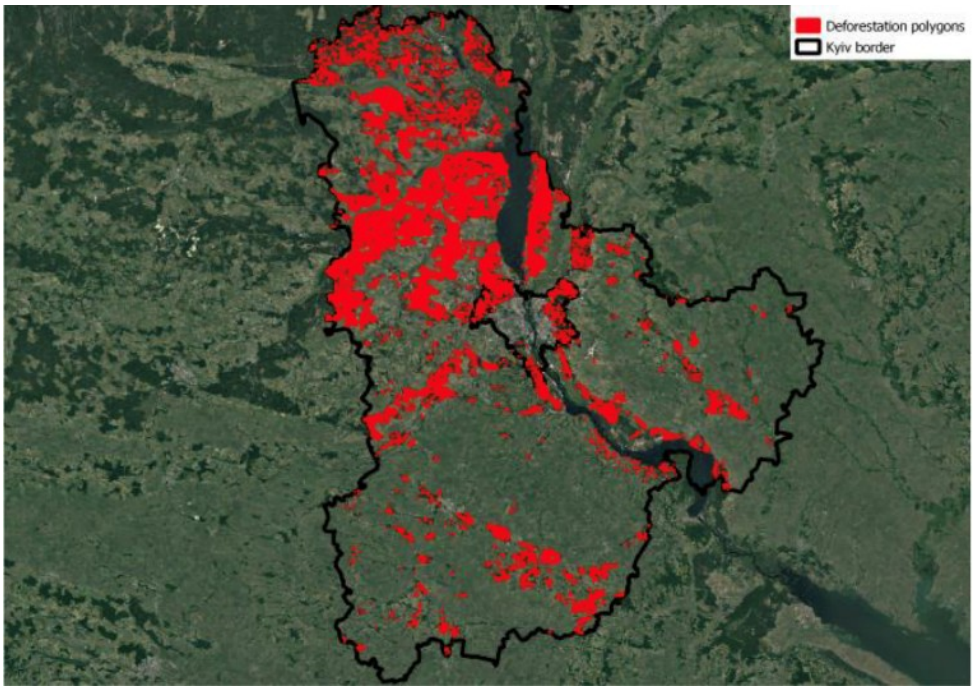

Slika 7.10 Prikaz zaznavanja krčenja gozdov

Prevod napisov na sliki: Poligoni krčenja gozdov; meja Kijeva.

Ključno sporočilo

Pri vseh teh uporabah računalniški vid ne nadomešča okoljskih strokovnjakov, temveč povečuje njihove zmožnosti. Samodejna analiza omogoča hitrejše, varnejše in bolj sistematično spremljanje, zato se lahko človeško strokovno znanje uporabi tam, kjer je najpomembnejše.

Viri in povezovanje podatkov za spremljanje okolja

Sistemi za spremljanje okolja so v praksi zasnovani kot večplastni delovni postopki in se ne zanašajo na en sam vir podatkov.

Satelitski posnetki zagotavljajo vrhnjo plast – neprekinjeno pokritost velikih območij, ki omogoča dosledno spremljanje celotnih regij skozi čas. Ta plast je namenjena zgodnjemu zaznavanju in analizi trendov.

Ko so območja zanimanja določena, se uporabijo viri podatkov z višjo ločljivostjo. Droni in zračni posnetki zagotavljajo podrobne lokalne prikaze, ki podpirajo pregledovanje, preverjanje in natančno kartiranje.

Radarski podatki imajo dopolnilno vlogo, saj zagotavljajo neprekinjenost. Kadar optični podatki zaradi oblakov, dima ali teme niso na voljo, posnetki SAR omogočajo neprekinjeno spremljanje.

Točka povezovanja vseh teh podatkovnih tokov so geografski informacijski sistemi. GIS zagotavlja prostorski okvir, ki satelitska opazovanja, preglede z droni in rezultate modelov združuje v enotno operativno sliko.

Ta večplastni pristop sistemom za spremljanje okolja omogoča uravnoteženje obsega, podrobnosti in zanesljivosti ter pretvarja raznovrstne podatke v uporabno situacijsko zavedanje.

Od zaznavanja do okoljskega ukrepanja

Uporaba računalniškega vida (CV) na področju okoljske varnosti zagotavlja tehnični okvir za pretvarjanje neobdelanih vizualnih podatkov v uporabne prostorske informacije. Ti sistemi s samodejnim razlaganjem digitalnih fotografij, satelitskih zemljevidov in posnetkov z droni omogočajo zgodnje zaznavanje ekoloških groženj, spremljanje nevarnih območij in izboljšanje postopkov odločanja na podlagi podatkov. Prehod od vizualnega prepoznavanja do blaženja posledic vključuje povezovanje umetne inteligence (AI), daljinskega zaznavanja in geografskih informacijskih sistemov (GIS) v samodejne zanke spremljanja, ki prihranijo čas in zmanjšajo tveganje za ljudi.

Prepoznavanje okoljskih in humanitarnih nevarnosti

Modeli računalniškega vida zagotavljajo situacijsko zavedanje, saj odgovarjajo na ključna vprašanja o prisotnosti in lokaciji okoljskih tveganj. Samodejni sistemi se uporabljajo na različnih področjih za prepoznavanje določenih groženj, ki zahtevajo ukrepanje:

- **Onesnaževanje in odpadki:** Sistemi kamer in droni, opremljeni z umetno inteligenco (AI), spremljajo onesnaževanje rečnih sistemov s plastiko, pri čemer po poročilih v nadzorovanih razmerah dosegajo visoko točnost zaznavanja. Ta tehnologija prepozna značilne absorpcijske vrhove plastike, kar omogoča zaznavanje oblakov onesnaženja.

- **Ekološka degradacija:** Samodejna obdelava večspektralnih posnetkov, kot so podatki Sentinel-2, omogoča zaznavanje krčenja gozdov v zavarovanih gozdovih [6], [7], [8]. Sistemi uporabljajo indekse, kot je NDVI, za spremljanje dinamike sečnje in ocenjevanje zdravja vegetacije.
- **Tveganja, povezana s konflikti:** Na območjih, kjer je neposreden dostop zaradi varnostnih razlogov omejen, se CV uporablja za prepoznavanje neeksplodiranih ubojnih sredstev (UXO) ter količinsko ocenjevanje poškodb stavb in infrastrukture [9].
- **Sistemi zgodnjega opozarjanja:** Sodobni okviri umetne inteligence (AI) samodejno analizirajo vizualne podatke za zgodnje zaznavanje dima požarov v naravi ali iztekanj iz industrijskih objektov ter ustvarjajo opozorila za skupnosti, preden ekološka škoda doseže neobvladljivo stopnjo.

Podpora strateški obnovi in razporejanju virov

Povezovanje rezultatov CV s plastmi GIS deležnikom omogoča prikaz prostorske porazdelitve tveganj, ki je bistven za strateško načrtovanje in določanje prednostnih nalog pri obnovi.

- **Čiščenje in sanacija:** Pri onesnaženju vodnega okolja samodejno kartiranje organizacijam omogoča prepoznavanje območij kopičenja odpadkov na odročnih lokacijah. Ti prostorski podatki se uporabljajo za načrtovanje ciljno usmerjenih čistilnih odprav in odstranjevanja odpadkov.
- **Obnova infrastrukture:** Sistemi za zaznavanje poškodb stavb zagotavljajo ocene števila prizadetih objektov in gostote prebivalstva pred vojno na posameznih območjih. Ti »zemljevidi približne ocene škode« (Damage Proxy Maps) pomagajo reševalnim službam in organizacijam za humanitarno pomoč določiti, kje so viri najnujneje potrebni.
- **Prepoznavanje virov:** CV z georeferenciranjem oblakov onesnaženja in njihovim sledenjem nazaj do primarnih virov na zemljevidu podpira industrijske inšpekcijske preglede in uveljavljanje okoljskih predpisov.

Na dokazih temelječa politika in gospodarska podpora

Računalniški vid je objektivno orodje za odločanje na državni ravni, zlasti kadar je tradicionalno zbiranje statističnih podatkov oteženo zaradi konfliktov ali okoljskih nesreč.

- **Podpora kmetijski politiki:** Zemljevidi rabe tal z visoko ločljivostjo se uporabljajo za prepoznavanje neobdelanih ali opuščenih kmetijskih zemljišč. V regijah, kot je

Ukrajina, so bili ti zemljevidi vključeni v državne registre kot podpora vladnim odločitvam, na primer odobritvi davčnih oprostitev kmetom, katerih zemljišča so onesnažena ali blizu frontne črte [4].

- **Spremljanje prehranske varnosti:** Dolgoročno spremljanje vrst poljščin in produktivnosti s satelitskimi posnetki oblikovalcem politik pomaga reševati izzive prehranske varnosti, saj omogoča prepoznavanje sprememb v kmetijski dinamiki.
- **Povojna obnova:** Neprekinjeni podatki časovnih vrst zagotavljajo prostorski načrt za pogozdovanje in obnovo na območjih, ki veljajo za nevarna za človekovo dejavnost [9].

Od zaznavanja do okoljskega ukrepanja: primeri uporabe računalniškega vida za okoljsko varnost v resničnem svetu

Ko računalniški sistem zazna okoljsko grožnjo, mora slediti ukrepanje. Ta razdelek obravnava, kako računalniški vid zaznavanje pretvori v dejanske okoljske odločitve v treh ključnih fazah: preprečevanje groženj, preden se stopnjujejo (*pred dogodkom*), spremljanje med potekom kriz (*med dogodkom*) ter ocenjevanje škode in načrtovanje obnove (*po dogodku*).

1. faza: zaznavanje pred dogodkom in zgodnje opozarjanje

Spremljanje kakovosti vode s sistemom HydroVision

Predstavljajte si, da želijo pristojni ugotoviti, ali je rečna voda varna, preden ljudje zbolijo. Običajno vzorce vode zbirajo ročno, kar je drago, počasno in pogosto prepozno.

HydroVision je sistem, ki analizira fotografije vode (posnete z droni ali sateliti) in razkriva onesnaženje ali poslabšanje kakovosti vode. Išče barvne značilnosti, motnost in prisotnost alg – značilne znake onesnaženja:

- Zelena voda = cvetenje alg (lahko strupeno)
- Rjava motnost = suspendirane organske snovi (industrijski izpust)
- Barvna anomalija = opozorilni znak

Namesto enega človeka na rečnem bregu sistem vsak dan analizira stotine kilometrov vodnih teles. HydroVision z uporabo globokih konvolucijskih nevronskih mrež na posnetkih RGB ocenjuje optično aktivne parametre, kot sta koncentracija klorofila in obarvana raztopljena organska snov (CDOM), ki se uporabljajo kot posredni kazalniki kakovosti vode in trendov onesnaženja. Ta neinvazivni pristop zmanjšuje odvisnost od dragih spektralnih senzorjev in pospešuje začetno prepoznavanje groženj v različnih vodnih telesih [12].

Spremljanje biotske raznovrstnosti in habitatov

Računalniški vid podpira tudi pripravljenost pred dogodkom, saj omogoča obsežno samodejno spremljanje okolja – prepoznavanje vzorcev biotske raznovrstnosti, spremljanje razširjenosti vrst in kartiranje stanja habitatov. Sistemi računalniškega vida lahko zaznavajo spremembe pokrovnosti tal, prisotnost vrst in značilnosti habitatov ter tako prispevajo k širšim prizadevanjem za podnebno ukrepanje in varstvo biotske raznovrstnosti. Ta samodejna zaznavanja zagotavljajo pomembne izhodiščne podatkovne nabore, ki razkrivajo dolgoročne trende. Ti bi sicer lahko ostali neopaženi, dokler se ne izrazijo kot neposredne nevarnosti [13].

2. faza: spremljanje v realnem času med dogodkom

Spremljanje v realnem času med požari v naravi

Podobno načelo velja med požari v naravi:

- 🔥 Droni pregledujejo območje in iščejo oblake dima ter toplotna žarišča,
- 🗺️ Požar je na robu gozda – mogoče ga je ustaviti, preden se razširi,
- 📊 Gasilci ne prejmejo sporočila »nekje gori«, temveč natančne koordinate vžiga

Sodobne arhitekture računalniškega vida, zlasti v povezavi s senzorji interneta stvari (IoT), omogočajo neprekinjen nadzor dinamičnih okoljskih dogodkov v realnem času. Hibridni senzorski sistemi povezujejo kamere z analitičnimi modeli ter zagotavljajo robustno sledenje in zaznavanje tudi v zahtevnih razmerah – pri spremenljivi osvetlitvi ali zakritem pogledu – in tako omogočajo učinkovito zaznavanje sprememb ali anomalij v obremenjenih ekosistemih [14].

Zaznavanje onesnaženja vodnega okolja s plastiko

Ko reke preplavijo plastični odpadki, lahko računalniški vid natančno določi vsak kos, ki plava v vodi:

- 🎯 Samodejno zaznavanje plastenk v rečnem okolju,
- 📍 Natančne koordinate – točna lokacija plavajočih odpadkov,
- ⏱️ Sprotno posodabljanje zemljevidov onesnaženja.

Delavci in prostovoljci, ki sodelujejo pri čiščenju, natančno vedo, kje iskati, zato ne izgubljajo časa z iskanjem na slepo. Raziskovalci so z uporabo obsežnih naborov posnetkov vodnega okolja razvili modele za samodejno zaznavanje plastenk v rekah. Ti modeli lahko z visoko preciznostjo prepoznajo in locirajo plastične odpadke v zapletenih naravnih prizorih. Takšne zmogljivosti pristojnim organom in okoljskim organizacijam omogočajo stalno spremljanje žarišč onesnaženja, izboljšujejo situacijsko zavedanje med dogodki onesnaženja ter skoraj v realnem času podpirajo taktiko čiščenja in razporejanje virov [15].

3. faza: ocenjevanje in obnova po dogodku

Kartiranje pogorelih območij po požarih v naravi

Po požaru v naravi, poplavi ali neurju morajo pristojni ugotoviti:

- Kje natančno je gorelo? (Katera območja zahtevajo omejen dostop?)
- Kako hude so posledice? (Ali so drevesa le siva in brez listov ali so zoglenela?)
- Koliko virov je potrebnih za obnovo? (Osebje, oprema, čas?)

Običajno so ljudje več mesecev hodili po gozdovih, ročno merili in se posvetovali z domačini, kar je bilo počasno in drago.

Modeli globokega učenja takšno delo s satelitskimi posnetki opravijo v nekaj dneh. Modeli globokega učenja, uporabljeni na satelitskih posnetkih, kot so U-Net in druge konvolucijske arhitekture, omogočajo samodejno kartiranje pogorelih območij po požarih v naravi. Ti sistemi uporabljajo posnetke Sentinel-2 pred požarom in po njem za razvrščanje stopnje ožganosti ter določanje meja požarišč z visoko točnostjo, s čimer zagotavljajo objektivne in ponovljive ocene, bistvene za načrtovanje sanacijskih strategij in razporejanje virov za obnovo [16].

Rezultati vključujejo:

- 📍 Zemljevide požarov: natančne lokacije, kjer je gorelo oziroma gori
- 🎨 Barvno označena stopnja resnosti: rumena = blaga, oranžna = zmerna, črna = huda
- 📊 Poročila: količinske ocene gozdnih površin, ki jih je treba obnoviti

Ocenjevanje škode po nesrečah

Enak pristop deluje pri poplavah, neurjih in drugih nesrečah:

- 🏘️ Katere stavbe so poplavljene?
- 🛣️ Katere ceste so blokirane?
- 👥 Katere skupine prebivalstva so ogrožene?

Računalniški vid prispeva k širšemu ocenjevanju okolja po nesrečah, pri katerem globoke konvolucijske nevronske mreže (CNN) takoj po neurjih, poplavah ali drugih ekoloških motnjah zaznajo in razvrstijo vzorce škode v naravnem in grajenem okolju. Z analizo velikih količin zračnih posnetkov po dogodku ti modeli podpirajo hitro razvrščanje prizadetih območij, omogočajo hitrejše odločanje ter izboljšujejo usklajevanje med okoljskimi organi, reševalnimi službami in programi obnove [17].

Študija primera: ocenjevanje zdravja vegetacije z uporabo NDVI iz podatkov Sentinel-2

Ozadje

V tej študiji primera so bili večspektralni satelitski posnetki uporabljeni za ocenjevanje zdravja vegetacije in analizo prostorskih vzorcev okoljske degradacije. Analiza je temeljila na normaliziranem diferencialnem vegetacijskem indeksu (NDVI), uveljavljenem spektralnem kazalniku, izpeljanem iz rdečega in bližnjega infrardečega (NIR) pasu posnetkov Sentinel-2.

Študija primera je bila zasnovana tako, da pokaže, kako lahko razmeroma preproste tehnike računalniškega vida in daljinskega zaznavanja pri obdelavi dejanskih satelitskih podatkov zagotovijo uporabna okoljska spoznanja.

Pomen za okolje

Analiza na podlagi NDVI se pogosto uporablja pri zagotavljanju okoljske varnosti, med drugim za spremljanje krčenja gozdov, ocenjevanje rabe kmetijskih zemljišč, analizo posledic suše in ocenjevanje okolja po motnjah. Uporaba spektralnih indeksov, izpeljanih iz satelitskih podatkov, omogoča obsežna in ponovljiva opazovanja v daljših časovnih obdobjih.

Ta pristop je še posebej učinkovit v regijah, kjer so neposredne terenske meritve omejene zaradi varnostnih razlogov ali težavne dostopnosti. Z uporabo orbitalnih podatkov je mogoče ohranjati neprekinjeno spremljanje okolja brez fizične prisotnosti na potencialno nevarnih območjih.

Podatki in spektralni vhodi

Analiza temelji na večspektralnih posnetkih Sentinel-2. Iz razpoložljivih spektralnih kanalov sta bila zaradi občutljivosti na odbojne lastnosti vegetacije izbrana rdeči (B4) in bližnji infrardeči (B8) pas.

Za podporo preglednosti in ponovljivosti so bili vmesni koraki obdelave dokumentirani neposredno v analitičnem delovnem poteku.

Izsek kode: nalaganje in predobdelava pasov Sentinel-2

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

Pregled metode

Vrednosti NDVI so bile izračunane s standardno formulo normalizirane razlike:

$$NDVI = \frac{NIR - Red}{NIR + Red}$$

Ta formula poudari razliko med površinami, prekritimi z vegetacijo, in območji brez vegetacije, tako da izkoristi različne odbojne lastnosti klorofila v rdečem in bližnjem infrardečem delu spektra.

Izsek kode: izračun NDVI

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

Vizualizacija in prostorski prikaz

Po izračunu so bili ustvarjeni zemljevidi NDVI za prikaz prostorskih razlik v stanju vegetacije.

Na teh zemljevidih so **nizke vrednosti NDVI** (navadno pod ~0.1) prikazane z rdečimi ali rjavimi odtenki in ustrezajo **površinam brez vegetacije**, kot so vodna telesa, gola tla ali pozidana območja. **Srednje vrednosti NDVI** (približno 0.1–0.3), prikazane z rumenimi ali oranžnimi odtenki, kažejo na **redko ali obremenjeno vegetacijo**, pogosto povezano s prehodnimi vrstami pokrovnosti tal ali sezonskimi vplivi. **Visoke vrednosti NDVI** (nad ~0.3), prikazane z zelenimi odtenki, predstavljajo **gosto in zdravo vegetacijo** ter kažejo na območja z visoko fotosintetsko aktivnostjo.

Ti vizualni prikazi so glavna podlaga za okoljsko razlago, saj omogočajo hitro prepoznavanje neobičajnih ali degradiranih območij. Slika 7.11 prikazuje primer vizualizacije zemljevida NDVI.

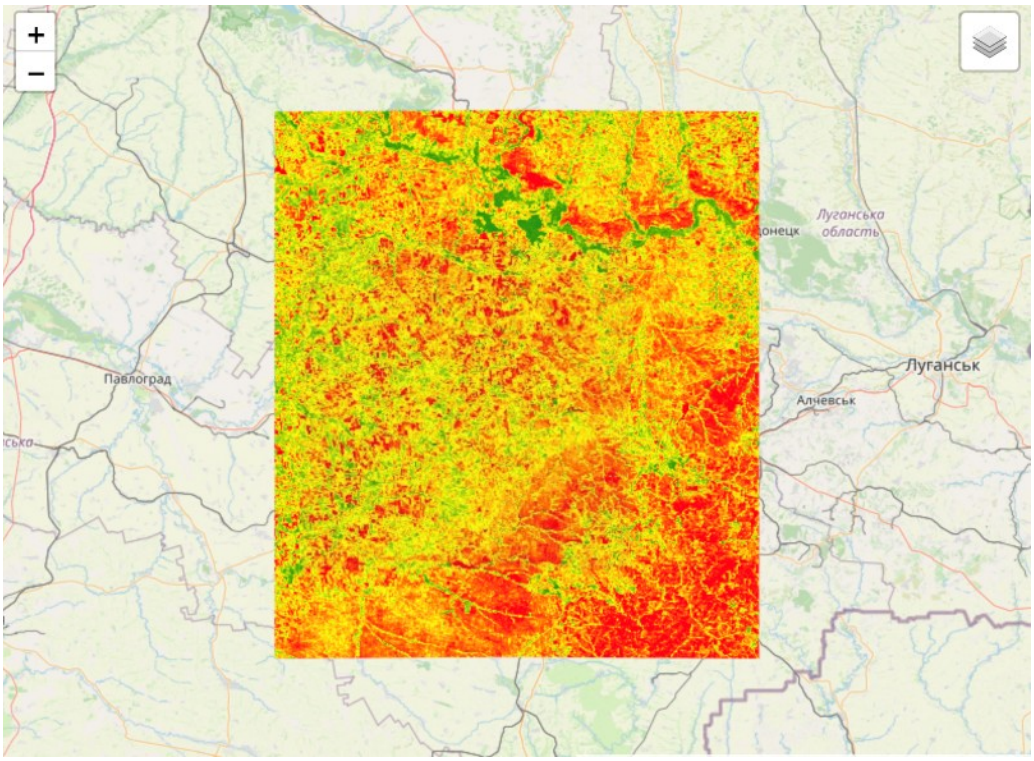

Slika 7.11 Vizualizacija zemljevida NDVI

Razlaga vzorcev NDVI

Za razvrščanje stanja vegetacije je bila uporabljena razlaga na podlagi pragov:

- Vrednosti NDVI pod približno 0.1 so bile povezane z vodnimi telesi, golimi tlemi ali močno degradiranimi zemljišči,
- Srednje vrednosti NDVI (približno 0.1–0.3) so kazale na redko ali obremenjeno vegetacijo,
- Višje vrednosti NDVI so ustrezale gosti in zdravi vegetacijski odeji.

Prostorski skupki trajno nizkih vrednosti NDVI so veljali za možne kazalnike okoljske obremenitve, antropogenih motenj ali sprememb rabe tal.

Rezultati in okoljske posledice

Dobljeni rezultati NDVI so razkrili izrazite prostorske vzorce zdravja vegetacije na opazovanem območju. Obsežna območja zmanjšane vegetacijske aktivnosti so nakazovala morebitno krčenje gozdov, opuščanje zemljišč ali ekološko degradacijo po motnjah.

Študija primera je pokazala, kako lahko spektralna analiza podpira pregledno okoljsko presojo in ponovljive analitične delovne poteke, saj je poleg računskih korakov dokumentirala tudi vmesne rezultate in vizualne prikaze.

Praktična vaja

Cilj

Pridobiti praktične izkušnje z analizo satelitskih posnetkov in razumeti uporabo NDVI za okoljsko varnost in spremljanje okolja: izračunati zemljevid NDVI, vizualizirati vzorce zdravja vegetacije in rezultate razložiti v okoljskem kontekstu.

Vodnik po korakih: kako zagnati zvezek

Priloženi zvezek “ML_CV_NDVI.ipynb” je celovit, popolnoma delujoč delovni potek, pripravljen za zagon. Vnaprej je nastavljen za **dostop do podatkov Sentinel-2 prek Google Earth Engine**, izračun kompozitov NDVI, vizualizacijo prostorskih vzorcev stanja vegetacije in izvajanje časovnih primerjav. Po izvedbi zvezek **samodejno ustvari interaktivne zemljevide in vizualne rezultate**. Za poustvaritev rezultatov ni potrebno dodatno programiranje, parametre, kot sta območje zanimanja (Area of Interest) in časovno obdobje, pa je mogoče spremeniti za raziskovalno analizo.

Za zagon priloženega zvezka v brskalniškem okolju bomo uporabili Google Colab (lokalna namestitev ni potrebna) in sledili enakemu poteku »nalaganje → Run all → razlaga rezultatov« kot v predlogi predmeta.

Razlaga zgradbe zvezka:

1. *Konfiguracija in knjižnice*. V tem razdelku se inicializira računsko okolje. Uvozijo se potrebne knjižnice Python, parametri poskusa pa se določijo v podrazdelkih:

   1a: območje zanimanja (AOI) je določeno v obliki GeoJSON. Privzeto je to ozemlje jugovzhodne Ukrajine, ki ga žal zajemajo aktivni spopadi.

   1b: nastavi se dostop do Google Earth Engine.

   1c: nastavite konfiguracijske parametre poskusa:

   - Časovno obdobje NDVI (NDVI_START_DATE in NDVI_END_DATE), ki predstavlja trenutno obdobje analize.

- Zgodovinsko referenčno obdobje NDVI (NDVI_HISTORICAL_START_DATE in NDVI_HISTORICAL_END_DATE), ki se uporablja za primerjavo.
- Parametri vizualizacije NDVI_VISUALIZATION_PARAMS.
- Parametri vizualizacije razlike NDVI DIFF_VISUALIZATION_PARAMS.

2. *Pomožne funkcije*. Ta razdelek vsebuje funkcije za večkratno uporabo, ki zajemajo temeljne postopke, kot so:
   - izdelava interaktivnih zemljevidov Folium,
   - izračun NDVI iz posnetkov Sentinel-2,
   - ustvarjanje kompozitov NDVI,
   - in podpora logiki prikaza.
3. *Prikaz kompozita NDVI*. V tem razdelku se za izbrano območje AOI in časovno obdobje ustvari medianski kompozit NDVI. Nastali zemljevid NDVI omogoča prostorski pregled stanja vegetacije in je izhodiščni prikaz njenega zdravja v izbrani sezoni.
4. *Časovna primerjava NDVI*. V tem razdelku se spremembe skozi čas zaznavajo s primerjavo kompozitov NDVI iz dveh različnih časovnih obdobij. Z izračunom razlike NDVI prepoznamo območja izboljšanja ali poslabšanja stanja vegetacije, kar omogoča zaznavanje dolgoročnih okoljskih sprememb namesto posameznih opazovanj.
5. *Vprašanja za razmislek.* Zadnji razdelek je namenjen kvalitativni razlagi. Študente usmerja k razmisleku o opaženih prostorskih in časovnih vzorcih, okoljskih dejavnikih sprememb vegetacije ter omejitvah in negotovosti satelitske analize.

Predpogoj: nastavitev Google Earth Engine

Ta praktična vaja upora**b**lja Google Earth Engine za dostop do satelitskih posnetkov Sentinel-2 in njihovo obdelavo. Pred zagonom zvezka mora biti za vaš račun Google omogočen dostop do Earth Engine. Podrobna navodila so v datoteki zvezka v razdelku **1**b. **Nastavitev projekta Google Earth**.

Ko je projekt pripravljen, posodobite spremenljivko EE_PROJECT, kot prikazuje slika 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 Opredelitev spremenljivke EE_PROJECT

Prevod napisov na sliki: Identifikator projekta Google Earth Engine; projekt mora biti omogočen v konzoli Google Cloud in povezan s prijavljenim Googlovim računom, da omogoča izvajanje operacij Earth Engine; tukaj nastavite identifikator svojega projekta.

Izvajanje zvezka

Ko dokončate nastavitev projekta Google Earth Engine, nadaljujte z izvajanjem zvezka.

1. Odprite Google Colab.
2. Naložite datoteko zvezka.
3. Zaženite zvezek: **Runtime** → **Run all**.
4. Med izvajanjem celic se pomikajte po rezultatih. Prikazati bi se morali vmesni rezultati in končni prikazi NDVI.
   - V razdelku **3. Prikaz kompozita NDVI** boste videli prikaz NDVI za določeno datumsko obdobje, kot prikazuje slika 7.13. Zelena območja vsebujejo zdravo in gosto vegetacijo, medtem ko je na rdečih območjih vegetacije manj, golih tal pa več.

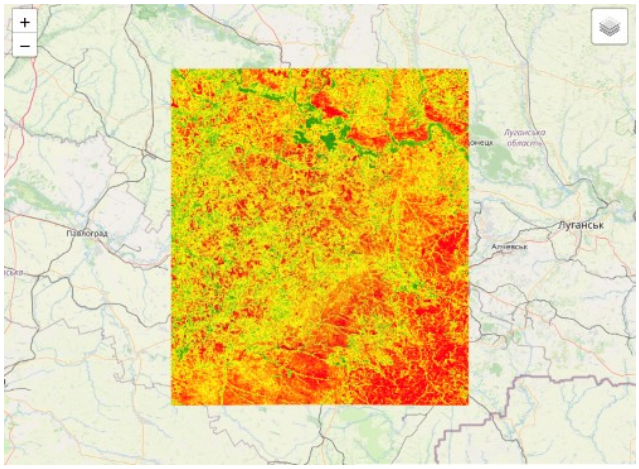

Slika 7.13 Prikaz kompozita NDVI

   - V razdelku **4. Časovna primerjava NDVI** je prikazana tudi razlika NDVI med izbranim in zgodovinskim datumskim obdobjem. Zelena območja pomenijo izboljšanje stanja vegetacije glede na zgodovinsko obdobje, rdeča območja pa zmanjšanje njene gostote. Slika 7.14 prikazuje primer časovne primerjave NDVI.

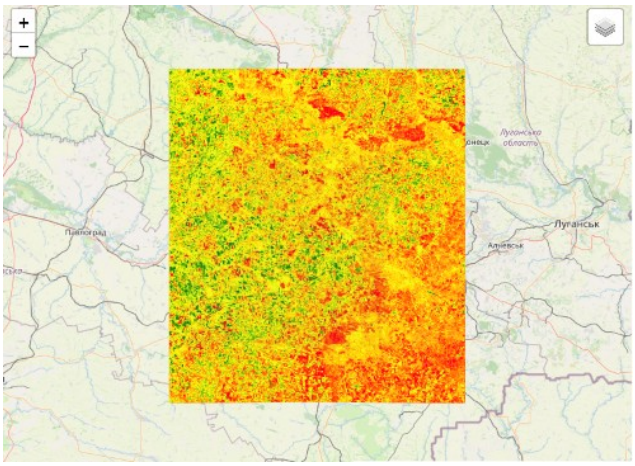

Slika 7.14 Časovna primerjava NDVI

Opomba: če Colab prikaže opozorilo (»Author not trusted«), kliknite Run anyway.

Vir podatkov

Vaja uporablja večspektralne posnetke Sentinel-2. NDVI se izračuna iz rdečega pasu (B4) in bližnjega infrardečega pasu (B8).

Podatki se naložijo iz zbirke Copernicus Sentinel-2 SR (npr. *COPERNICUS/S2_SR_HARMONIZED*), filtrirajo po območju in datumu ter nato združijo za analizo.

Naloge

1. naloga: zagon in preverjanje izhodiščnega rezultata

- Odprite in zaženite priloženi zvezek.
- Preverite, ali se podatki Sentinel-2 pravilno naložijo za izbrano območje AOI in datumsko obdobje.
- Izračunajte sloj NDVI in izrišite zemljevid NDVI.

Vprašanja:

- Kje znotraj območja AOI opazite skupke nizkih in visokih vrednosti NDVI?
- Katere vrste pokrovnosti tal so najverjetneje povezane s temi skupki (npr. vodna telesa, gola tla, urbana območja, gosta vegetacija)?
- Ali so vzorci NDVI prostorsko povezani ali pa so na ravni slikovnih pik razdrobljeni in polni šuma?

- Kakšno začetno okoljsko razlago lahko oblikujete na podlagi prostorske porazdelitve vrednosti NDVI?

2. naloga: razlaga na podlagi pragov (okoljsko sklepanje)

Uporabite pragove za razlago NDVI in območje AOI razvrstite v kategorije »nizka/srednja/visoka stopnja zdravja vegetacije«:

- NDVI < ~0.1
- NDVI ~0.1–0.3
- NDVI > ~0.3

Vprašanja:

- Katera stopnja zdravja vegetacije na podlagi NDVI (nizka, srednja ali visoka) prevladuje na območju AOI in zakaj?
- Ali so območja z nizkim NDVI prostorsko združena v skupke ali razpršena? Kaj to nakazuje o morebitnih okoljskih obremenitvah ali vzorcih rabe tal?
- Kateri naravni ali antropogeni dejavniki bi lahko verjetno pojasnili prisotnost območij z nizkim NDVI v tej regiji?

3. naloga: preverjanje občutljivosti (čas in lokacija)

Spreminjajte **po eno spremenljivko naenkrat**, znova zaženite postopek in primerjajte rezultate:

- Spremenite **datumsko obdobje** (npr. pomlad v primerjavi s poznim poletjem).
- Za **AOI** izberite svojo domačo regijo ali regijo, ki jo želite analizirati (npr. mestno obrobje v primerjavi s kmetijsko regijo)

Vprašanja:

- Kako se vzorci NDVI spremenijo, ko spremenite obdobje opazovanja?
- Katere spremembe je mogoče pojasniti s sezonsko dinamiko vegetacije in katere bi lahko nakazovale trajnejše strukturne spremembe?
- Kako sprememba območja AOI vpliva na razlago rezultatov NDVI, zlasti pri primerjavi mestnega obrobja in kmetijskih regij?

Preverjanje znanja

Kakšna je glavna vloga računalniškega vida pri zagotavljanju okoljske varnosti?

A) Nadomeščanje okoljskih strokovnjakov s popolnoma avtomatiziranimi sistemi

B) Izboljšanje vizualne kakovosti satelitskih posnetkov
C) Samodejno pridobivanje uporabnih informacij iz velikih količin vizualnih podatkov
D) Ročno označevanje okoljskih slik

Katera naloga računalniškega vida je najprimernejša za določanje natančne lokacije nezakonitih odlagališč odpadkov ob reki?

A) Razvrščanje slik
B) Zaznavanje objektov
C) Izboljšanje slik
D) Normalizacija podatkov

Zakaj se pri sistemih za spremljanje okolja brezpilotni letalniki pogosto uporabljajo skupaj s satelitskimi posnetki?

A) Brezpilotni letalniki odpravijo potrebo po satelitskih podatkih
B) Brezpilotni letalniki zagotavljajo lokalna opazovanja z višjo ločljivostjo, ki dopolnjujejo obsežno satelitsko pokritost
C) Brezpilotni letalniki odpravijo potrebo po modelih računalniškega vida
D) Satelitskih posnetkov ni mogoče uporabljati za spremljanje okolja

Katero vrsto okoljskih informacij najpogosteje razberemo iz visokih vrednosti NDVI?

A) Gostota mestne infrastrukture
B) Prisotnost oblakov ali dima
C) Gosta in zdrava vegetacija
D) Območja, ki so jih prizadele poplave

Zakaj je radar s sintetično odprtino (Synthetic Aperture Radar, SAR) še posebej pomemben za spremljanje nesreč, kot so poplave ali poškodbe stavb?

A) Zagotavlja višjo barvno ločljivost
B) Zaznava samo spremembe vegetacije
C) Deluje neodvisno od vremenskih razmer in dnevne svetlobe
D) Ne zahteva povezovanja z GIS

Katera kombinacija tehnologij je najučinkovitejša za zagotavljanje zavedanja o razmerah v sistemih okoljske varnosti?

A) Samo modeli računalniškega vida
B) Satelitski posnetki brez strojnega učenja
C) Računalniški vid + satelitski podatki/podatki brezpilotnih letalnikov + povezovanje z GIS
D) Ročno pregledovanje slik z napravami GPS

Literatura / dodatno branje

[1] R. Szeliski, *Computer Vision: Algorithms and Applications*, 2. izd. Cham, Švica: Springer International Publishing, 2022. doi: 10.1007/978-3-030-34372-9. [splet]. Dostopno na: https://szeliski.org/Book/, dostopano: 15. dec. 2025.

[2] S. J. D. Prince, *Computer Vision: Models, Learning, and Inference*. Cambridge, Združeno kraljestvo: Cambridge University Press, 2012. [splet]. Dostopno na: https://raw.githubusercontent.com/udlbook/cvbook/main/book.pdf, dostopano: 15. dec. 2025.

[3] H. J. Escalante *et al.* (ur.), *Explainable and Interpretable Models in Computer Vision and Machine Learning*. Cham, Švica: Springer International Publishing, 2018. doi: 10.1007/978-3-319-98131-4. [splet]. Dostopno na: https://link.springer.com/book/10.1007/978-3-319-98131-4, dostopano: 15. dec. 2025.

[4] N. Kussul, A. Shelestov, B. Yailymov, H. Yailymova, G. Lemoine in 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*, let. 140, str. 104551, 2025. [splet]. Dostopno na: https://linkinghub.elsevier.com/retrieve/pii/S1569843225001980, dostopano: 15. dec. 2025.

[5] J. Song, A. Pashazadeh, S. Wu, V. R. Greene, K. O. Hallee, A. M. Tannehill, T. M. Saxon, M. Potter in Z. Beneke, »Advances in microplastic detection and interception: A state-of-the-art review«, *Cleaner Water*, let. 4, str. 100141, 2025. [splet]. Dostopno na: https://doi.org/10.1016/j.clwat.2025.100141, dostopano: 15. dec. 2025.

[6] O. Ballinger, »A New Tool Allows Researchers to Track Damage in Gaza«, *Bellingcat*, 15. nov. 2023. [splet]. Dostopno na: https://www.bellingcat.com/resources/2023/11/15/a-new-tool-allows-researchers-to-track-damage-in-gaza/, dostopano: 15. dec. 2025.

[7] L. Shumilo, M. Lavreniuk, N. Kussul in B. Shevchuk, »Automatic Deforestation Detection based on the Deep Learning in Ukraine«, v *Proceedings of the 11th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems (IDAACS)*, 2021. doi: 10.1109/IDAACS53288.2021.9661008. [splet]. Dostopno na: https://doi.org/10.1109/IDAACS53288.2021.9661008, dostopano: 15. dec. 2025.

[8] D. Mozghovyi, V. Korchynskyi in D. Svynarenko, »Methodology of satellite monitoring of deforestation based on Sentinel-2A/B data«, *Challenges and Issues of Modern Science*, let. 3, 2024. [splet]. Dostopno na: https://cims.fti.dp.ua/j/article/view/252/207, dostopano: 15. dec. 2025.

[9] O. Rumiantsev, Y. Oliinyk in L. Oliinyk, »Damage Detection Based on Satellite Image Analysis«, v *Lecture Notes in Data Engineering, Computational Intelligence, and Decision-Making*, let. 2, *Lecture Notes on Data Engineering and Communications Technologies*, let. 244, ur. S. Babichev in V. Lytvynenko. Cham, Švica: Springer International Publishing, 2025, str. 177–189. doi: 10.1007/978-3-031-88483-2. [splet]. Dostopno na: https://link.springer.com/book/10.1007/978-3-031-88483-2, dostopano: 15. dec. 2025.

[10] European Space Agency, *Copernicus Sentinel-2* [podatkovni niz Level-2A], 2026. [splet]. Dostopno na: https://dataspace.copernicus.eu/, dostopano: 15. dec. 2025.

[11] U.S. Geological Survey, *Landsat 8–9 OLI/TIRS Level-2, Collection 2* [podatkovni niz]. Earth Resources Observation and Science (EROS) Center, 2026. doi: 10.5066/P9OGBGM6. [splet]. Dostopno na: https://doi.org/10.5066/P9OGBGM6, dostopano: 15. dec. 2025.

[12] S. L. Deshmukh, M. Wilchek in F. A. Batarseh, »HydroVision: Predicting optically active parameters in surface water using computer vision«, *predobjava arXiv*, 2025. [splet]. Dostopno na: https://arxiv.org/abs/2509.01882, dostopano: 15. dec. 2025.

[13] L. K. Jamili, K. Wu, K. Natarajan, A. K. Singh, M. Tee in M. Jindal, »Computer vision in environmental monitoring: Automated detection for biodiversity and climate action«, *International Journal of Environmental Sciences*, let. 11, št. 19s, str. 870–878, 2025. doi: 10.64252/a24f9536. [splet]. Dostopno na: https://doi.org/10.64252/a24f9536, dostopano: 15. dec. 2025.

[14] A. V. Voloshko in 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. [splet]. Dostopno na: https://doi.org/10.31673/2786-8362.2024.010202, dostopano: 15. dec. 2025.

[15] A. Heller, M. Jacobs, G. Acosta-González, *et al.*, »Plastic water bottle detection model using computer vision in aquatic environments«, *Scientific Reports*, let. 15, str. 24851, 2025. doi: 10.1038/s41598-025-09300-8. [splet]. Dostopno na: https://doi.org/10.1038/s41598-025-09300-8, dostopano: 15. dec. 2025.

[16] A. Singh, A. Sengupta in P. Venkoparao, »Deep learning-based burned area mapping using pre- and post-fire Sentinel-2 imagery«, *Remote Sensing Applications: Society and Environment*, let. 24, str. 100614, 2021. doi: 10.1016/j.rsase.2021.100614. [splet]. Dostopno na: https://doi.org/10.1016/j.rsase.2021.100614, dostopano: 15. dec. 2025.

[17] S. Aksoy, V. Yilmaz in S. Öztürk, »Deep convolutional networks for post-disaster environmental damage assessment using aerial imagery«, *Scientific Reports*, let. 12, str. 1883, 2022. doi: 10.1038/s41598-022-06067-1. [splet]. Dostopno na: https://doi.org/10.1038/s41598-022-06067-1, dostopano: 15. dec. 2025.