Argomento: Computer vision per la sicurezza ambientale

Corso: Machine Learning per applicazioni ambientali

Obiettivi di apprendimento

Al termine di questa unità, gli studenti saranno in grado di:

- Spiegare come la computer vision contribuisce alla sicurezza e al monitoraggio ambientale.
- Descrivere i concetti fondamentali del rilevamento di oggetti e della classificazione delle immagini in ambito ambientale.
- Comprendere come droni, dati satellitari e sensori vengano integrati per acquisire consapevolezza della situazione.
- Applicare un semplice modello di computer vision per classificare immagini satellitari o riprese da droni.
- Discutere come l'analisi automatizzata delle immagini supporti le decisioni ambientali e la mitigazione dei rischi (ad esempio rilevamento dell'inquinamento, monitoraggio degli incendi, individuazione di ordigni inesplosi e monitoraggio della biodiversità).

Introduzione

In questa lezione esamineremo la computer vision non come un concetto astratto di intelligenza artificiale tratto da un manuale di machine learning, ma come uno strumento pratico già impiegato per migliorare la sicurezza ambientale.

In termini semplici, la computer vision permette alle macchine di «vedere»: analizzare immagini satellitari, riprese di droni, fotografie aeree o flussi video ed estrarne informazioni significative. Non si tratta soltanto di riconoscere oggetti, ma anche di individuare cambiamenti, schemi ricorrenti e rischi su una scala impossibile da gestire manualmente.

Nelle applicazioni ambientali e di sicurezza, questa capacità è fondamentale. Molte aree da monitorare sono difficili o pericolose da raggiungere: zone industriali, foreste remote, territori interessati da conflitti o aree contaminate da ordigni inesplosi. In questi contesti, le ispezioni tradizionali sul campo sono lente, costose e spesso rischiose.

La computer vision, insieme al machine learning, consente il monitoraggio continuo di queste regioni attraverso dati visivi. I sistemi automatizzati possono elaborare grandi quantità di immagini

satellitari e da droni, individuando segnali precoci di minacce ambientali, come perdite di sostanze inquinanti, disboscamento illegale, focolai di incendi o danni strutturali, prima che la situazione peggiori.

Durante la lezione vedremo come funzionano nella pratica questi sistemi, quali dati utilizzano, quali attività di computer vision sono più importanti per il monitoraggio ambientale e come i risultati dell'analisi automatica delle immagini si traducano in decisioni concrete e interventi di mitigazione del rischio. La Figura 7.1 illustra la differenza tra visione artificiale e visione umana.

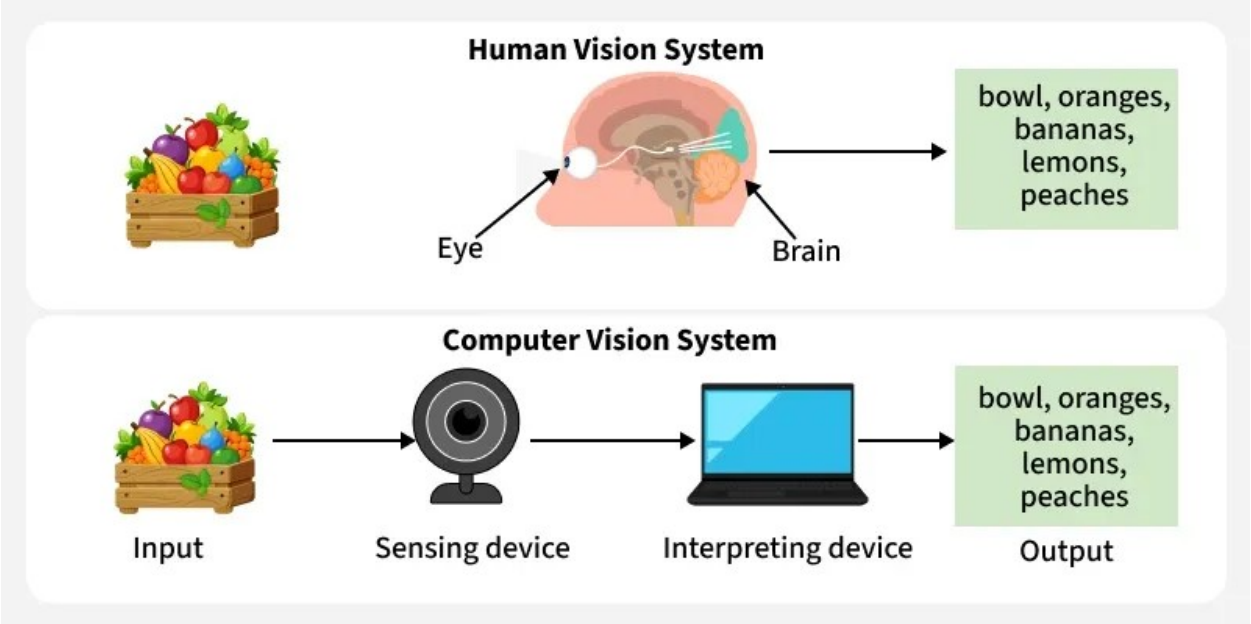

Figura 7.1 Schema della computer vision

Ruolo e importanza della computer vision

Quando si parla di computer vision nel monitoraggio ambientale, il concetto principale è la scalabilità. I metodi tradizionali si basano soprattutto sulle persone: ispettori, rilievi sul campo e misurazioni in loco. Questi approcci funzionano, ma sono difficili da applicare su larga scala e risultano spesso inadeguati proprio dove il monitoraggio è più necessario: aree molto estese, remote o pericolose.

La computer vision offre un'alternativa più scalabile e sistematica. Invece di basarci soltanto sull'osservazione umana, trasformiamo i pixel delle immagini in informazioni strutturate, analizzabili automaticamente e in modo coerente nel tempo.

Alla base della maggior parte dei sistemi di computer vision ambientale vi sono due attività fondamentali: classificazione delle immagini e rilevamento di oggetti. Sebbene vengano spesso citate insieme, rispondono a domande pratiche differenti.

La classificazione delle immagini riguarda ciò che è presente nell'immagine. Per esempio, un modello può stabilire se una scena satellitare raffigura una foresta, uno specchio d'acqua, un'area urbana o un terreno degradato. Questa analisi è particolarmente utile per monitorare territori estesi e seguirne i cambiamenti nel tempo.

Il rilevamento di oggetti, invece, riguarda il punto esatto in cui si trova qualcosa. Individua oggetti o elementi specifici e i relativi confini, come alberi caduti, accumuli di rifiuti nei fiumi o edifici danneggiati. Questo dettaglio è essenziale quando i risultati devono essere associati a posizioni precise per interventi sul campo o decisioni operative.

Combinando queste attività, i sistemi di computer vision forniscono un quadro della situazione quasi in tempo reale. I modelli possono imparare a riconoscere firme spettrali associate a sversamenti petroliferi, segnali di fumo dei primi focolai di incendio o modifiche strutturali visibili nelle immagini satellitari e radar.

L'importanza pratica consiste nella riduzione del tempo tra il cambiamento ambientale e la risposta. Invece di intervenire dopo che i danni sono visibili a terra, autorità e organizzazioni possono ricevere segnalazioni precoci e agire prima che la situazione peggiori.

Strategie di acquisizione e integrazione dei dati

L'efficacia della computer vision nel monitoraggio ambientale dipende direttamente dai dati disponibili. Nella pratica, nessuna fonte è sufficiente da sola: i sistemi per la sicurezza ambientale combinano diversi tipi di dati visivi, ciascuno con caratteristiche specifiche di scala, risoluzione e condizioni operative.

Le immagini satellitari costituiscono la base del monitoraggio su larga scala. Piattaforme come Sentinel e Landsat consentono di osservare continuamente territori molto estesi e per lunghi periodi. I dati multispettrali, soprattutto nelle bande del vicino infrarosso e dell'infrarosso a onde corte, permettono di valutare lo stato della vegetazione, rilevare la deforestazione e individuare cambiamenti nell'uso del suolo non visibili nelle normali immagini RGB.

I droni integrano i dati satellitari offrendo una risoluzione spaziale molto più elevata e una maggiore flessibilità di impiego. Sono generalmente utilizzati per ispezioni localizzate, come l'individuazione di piccole fonti di inquinamento o di ordigni inesplosi in luoghi dove l'accesso via terra non è sicuro, come mostrato nella Figura 7.2.

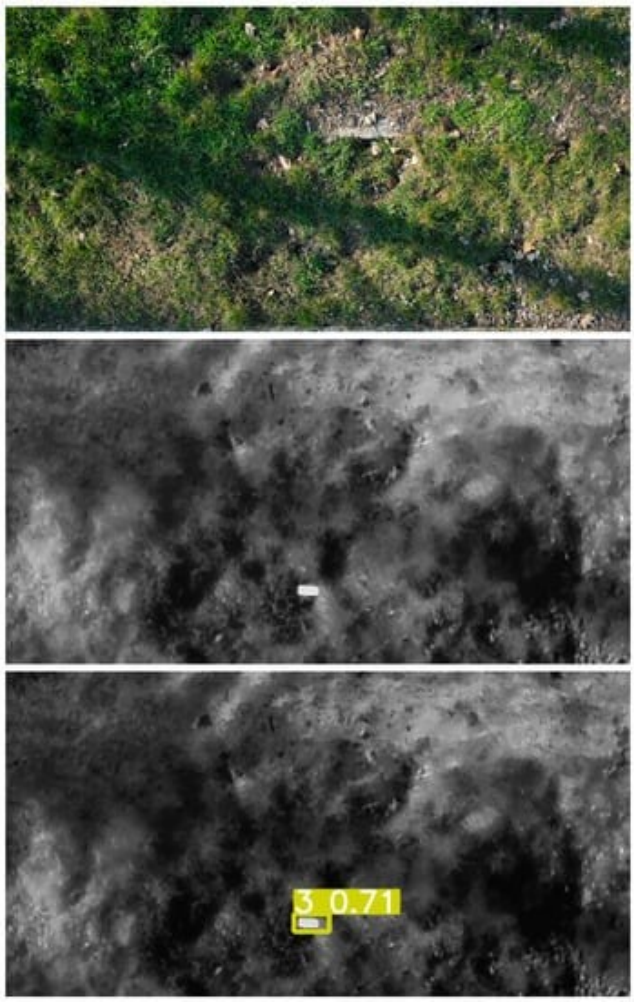

Figura 7.2 Drone dotato di computer vision

I sistemi radar, in particolare il radar ad apertura sintetica (SAR), superano alcuni limiti delle immagini ottiche. Poiché il SAR non dipende dalla luce solare e può osservare attraverso nuvole e fumo, consente un monitoraggio continuo indipendentemente dal meteo e dall'ora. I dati SAR sono particolarmente utili per rilevare cambiamenti strutturali e danni agli edifici. La Figura 7.3 mostra un esempio di immagine SAR.



Figura 7.3 Immagine SAR

Nella pratica, queste fonti vengono utilizzate congiuntamente. I risultati dei modelli di computer vision sono integrati nei sistemi informativi geografici (GIS), nei quali rischi e cambiamenti rilevati vengono rappresentati spazialmente. Questa integrazione trasforma le immagini grezze in informazioni utilizzabili per le decisioni ambientali e la mitigazione dei rischi.

Considerazioni etiche, di sicurezza e sulla gestione dei dati

Prima di approfondire modelli e metriche, è opportuno ricordare un aspetto pratico: la computer vision ambientale non è soltanto una questione tecnica. Le modalità di raccolta, conservazione e condivisione dei dati visivi possono comportare rischi concreti per l'etica e la sicurezza.

Il primo aspetto riguarda la privacy e la responsabilità nella gestione dei dati. La risoluzione delle immagini satellitari e dei droni continua a migliorare. Gli stessi dati utili per monitorare foreste, fiumi o impianti industriali possono così registrare involontariamente attività umane sensibili. La domanda non è solo «Possiamo rilevarlo?», ma anche «Dovremmo raccogliere o pubblicare queste informazioni con tale livello di dettaglio?».

Il secondo aspetto riguarda il rischio di uso duale. Si tende a considerare innocui i dati ambientali, ma non è sempre così. Per esempio, le posizioni esatte di specie minacciate o informazioni dettagliate sulle vulnerabilità delle infrastrutture possono essere sfruttate in modo improprio. Occorre quindi bilanciare trasparenza scientifica e misure di protezione.

Il messaggio fondamentale è semplice: una buona governance fa parte della buona progettazione. Controllo responsabile degli accessi, politiche attente di condivisione e

consapevolezza degli usi duali sono indispensabili affinché la computer vision rafforzi la resilienza ambientale senza creare nuovi rischi.

Concetti e metodi fondamentali

Quadro concettuale della computer vision per la sicurezza ambientale

Dopo aver esaminato i dati, la loro provenienza e i relativi limiti, possiamo descrivere come la computer vision estragga informazioni dalle immagini.

Nel monitoraggio ambientale l'obiettivo non è costruire il modello più complesso possibile, ma scegliere metodi robusti, interpretabili e coerenti con le caratteristiche dei dati.

La maggior parte delle pipeline di computer vision ambientale si basa su pochi concetti fondamentali. Questi metodi trasformano dati visivi grezzi - pixel satellitari, immagini di droni o segnali radar - in rappresentazioni strutturate dell'ambiente: mappe di copertura del suolo, oggetti individuati e indicatori di cambiamento.

La scelta del metodo deve dipendere dall'attività e dai dati, non dalle mode o dalla complessità del modello. Monitoraggio su vasta scala, rilevamento dei cambiamenti e applicazioni critiche per la sicurezza richiedono approcci stabili nel tempo e resistenti a rumore, etichette incomplete e dati di riferimento imperfetti.

Tenendo presente questo principio, esaminiamo le due attività di computer vision più comuni nella sicurezza ambientale: classificazione delle immagini e rilevamento di oggetti.

Classificazione delle immagini e rilevamento di oggetti a confronto

Nei sistemi ambientali, la maggior parte delle applicazioni si basa su due attività strettamente collegate: classificazione delle immagini e rilevamento di oggetti. Pur essendo spesso citate insieme, hanno scopi diversi e rispondono a domande differenti.

La classificazione delle immagini identifica ciò che è presente in una scena. Il modello assegna etichette all'intera immagine o a regioni predefinite, permettendo di riconoscere caratteristiche generali come il tipo di copertura del suolo, le condizioni della vegetazione o le aree danneggiate rispetto a quelle integre. Funziona particolarmente bene nel monitoraggio su larga scala, quando si vogliono seguire i cambiamenti nel tempo piuttosto che singoli oggetti. La Figura 7.4 illustra un esempio di segmentazione delle immagini.

Il rilevamento di oggetti individua invece il punto esatto in cui si trova qualcosa. Anziché assegnare etichette a intere regioni, il modello riconosce singoli oggetti e le loro posizioni precise.

Questo dettaglio è essenziale quando l'analisi deve tradursi in azioni concrete, come localizzare ordigni inesplosi, individuare accumuli di rifiuti o mappare edifici danneggiati. La Figura 7.5 mostra il rilevamento di automobili in un parcheggio.

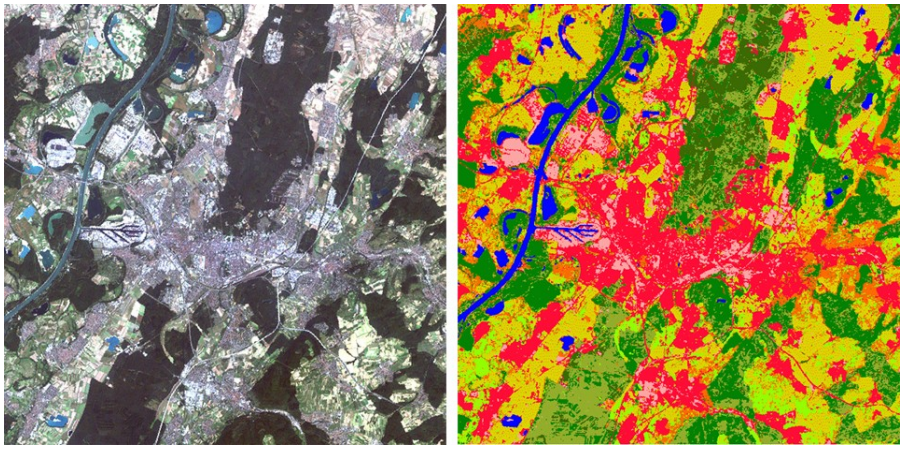

Figura 7.4 Esempio di segmentazione di un'immagine

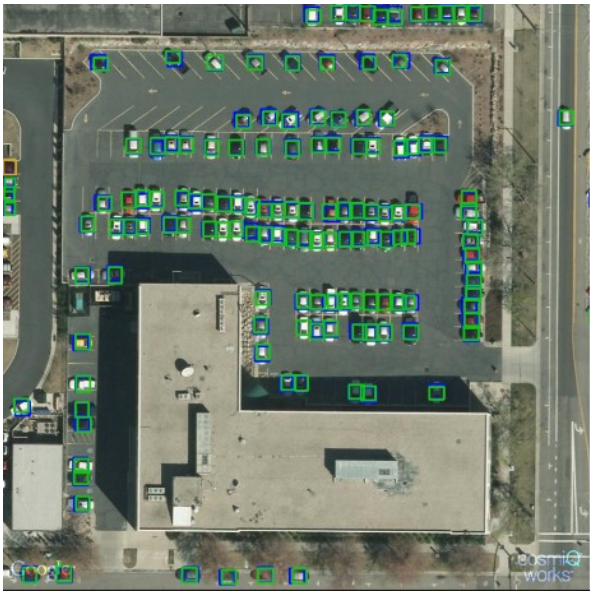

Figura 7.5 Rilevamento di oggetti

La differenza principale non è la complessità tecnica, bensì lo scopo. La classificazione consente di comprendere fenomeni su larga scala, mentre il rilevamento di oggetti permette interventi mirati. Molti sistemi reali combinano entrambi: prima classificano le aree di interesse, poi applicano il rilevamento per analizzarle in dettaglio.

Modelli di computer vision per la sicurezza ambientale

La domanda principale non è «Qual è l'architettura più avanzata?», ma «Che cosa possiamo impiegare in modo affidabile con i dati e i vincoli disponibili?». Le immagini ambientali sono rumorose, ottenere dati di riferimento è costoso e le condizioni cambiano nel tempo: stagioni, illuminazione, nuvole e sensori utilizzati.

Nella pratica, la scelta del modello dipende dal risultato desiderato: segmentazione oppure rilevamento.

Segmentazione: U-Net

Per mappare aree, come l'estensione di un'alluvione, i confini delle foreste o le zone danneggiate, la segmentazione è la scelta naturale. Un'architettura molto utilizzata è U-Net, progettata per produrre maschere a livello di pixel e acquisire sia i dettagli locali sia il contesto spaziale più ampio. La Figura 7.6 ne illustra la struttura. È utile quando è importante conoscere il confine e la dimensione dell'area interessata.

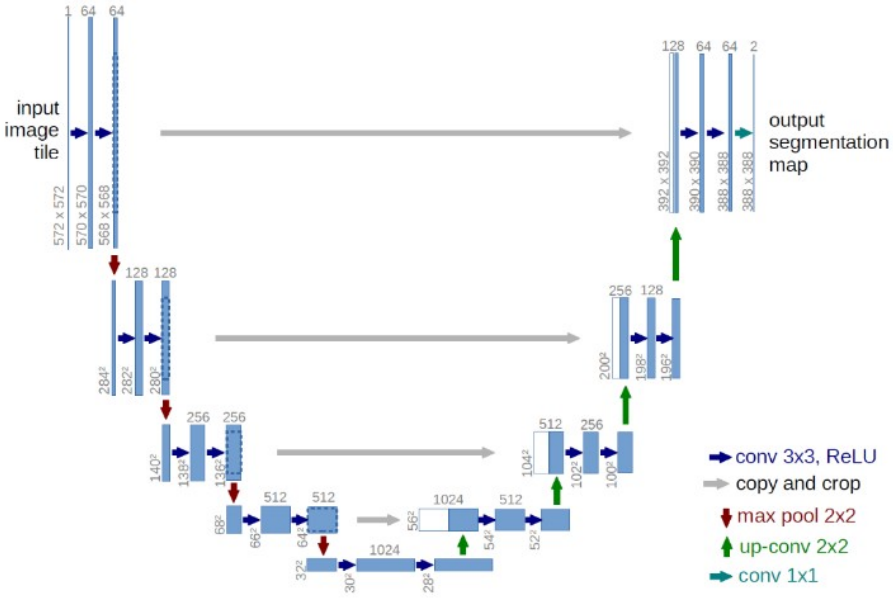

Figura 7.6 Architettura del modello U-Net

Rilevamento: MobileNet / YOLO-lite

Per individuare singoli oggetti - rifiuti, strutture danneggiate o possibili ordigni inesplosi - si usano generalmente modelli di object detection. In molti scenari operativi, soprattutto su droni o dispositivi edge, sono preferite architetture leggere come i rilevatori basati su MobileNet o YOLO-lite, che bilanciano velocità e accuratezza con risorse computazionali limitate.

Modelli preaddestrati e transfer learning

Una difficoltà ricorrente nella sicurezza ambientale è la scarsità di dati etichettati. In regioni pericolose o inaccessibili raccogliere e annotare immagini è costoso o impossibile. Per questo il transfer learning è molto diffuso: si parte da un modello preaddestrato su un grande dataset generale e lo si adatta a un dataset ambientale più piccolo, per esempio per riconoscere danni agli edifici o oggetti simili a ordigni inesplosi nelle riprese dei droni.

Combinazione di algoritmi complementari

Le pipeline ambientali combinano spesso approcci algoritmici diversi per aumentare la robustezza. Per esempio, Random Forest può ridurre il rumore «sale e pepe» nelle grandi regioni omogenee, utile nella classificazione della copertura del suolo. Modelli neurali più semplici come un MLP possono invece distinguere classi rare o poco rappresentate, come anomalie industriali poco evidenti o cambiamenti di piccola scala.

L'idea pratica è semplice: invece di affidarsi a un unico modello, si combinano metodi che tendono a commettere errori differenti.

Concetto chiave

Il modello non è quindi una singola architettura, ma una scelta di progettazione operativa. U-Net è una buona soluzione di partenza per la segmentazione, MobileNet e YOLO-lite sono opzioni pratiche per il rilevamento rapido e il transfer learning permette spesso di lavorare anche senza un grande dataset specifico iniziale.

Metriche statistiche delle prestazioni

Dopo aver definito gli obiettivi dei modelli — classificare regioni o individuare singoli oggetti — occorre valutarne le prestazioni. Nel monitoraggio ambientale, ciò è meno semplice di quanto possa sembrare.

Molti dataset ambientali sono fortemente sbilanciati: le zone danneggiate possono occupare soltanto una piccola parte di un territorio, mentre il resto rimane invariato. In questi casi la semplice accuratezza può trarre in inganno: un modello può ottenere un valore elevato pur non rilevando i fenomeni di interesse.

Per questo la computer vision ambientale utilizza metriche che riflettono meglio la sovrapposizione spaziale e la qualità del rilevamento.

Intersection over Union (IoU)

Una delle metriche più utilizzate per la segmentazione e l'analisi delle aree è l'Intersection over Union, o IoU.

La IoU misura quanto l'area prevista si sovrappone all'area di riferimento, o ground truth, come illustrato nella Figura 7.7.

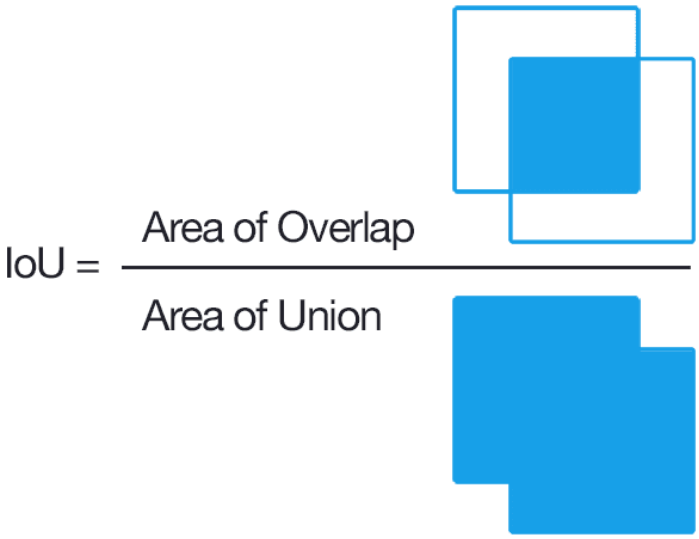

Figura 7.7 Illustrazione del calcolo dell'Intersection over Union

In termini intuitivi, la IoU risponde alla domanda: quanto si sovrappongono queste due aree? Un valore più elevato indica una maggiore concordanza spaziale fra la previsione e i dati etichettati dagli esperti. Nella mappatura della deforestazione o nella valutazione dei danni agli edifici, valori prossimi a uno indicano previsioni di alta qualità.

Precision, recall e F1-score

Passando dalla segmentazione di aree al rilevamento di oggetti, diventano importanti ulteriori metriche.

La precision indica quale proporzione degli oggetti rilevati è effettivamente corretta. È cruciale nelle applicazioni di sicurezza, nelle quali i falsi positivi possono provocare interventi inutili o perfino pericolosi.

La recall misura quanti oggetti rilevanti vengono individuati dal modello. Non rilevare un ordigno inesploso o il fumo iniziale di un incendio può avere conseguenze gravi.

L'F1-score combina precision e recall in un unico valore, bilanciando falsi positivi e falsi negativi. È particolarmente utile nelle applicazioni ambientali, dove le classi sono spesso sbilanciate e sono importanti entrambi i tipi di errore.

Perché queste metriche sono importanti nella pratica?

Nel monitoraggio ambientale le metriche non servono soltanto a confrontare modelli: influenzano le decisioni reali.

Per esempio, aumentare la soglia di rilevamento può migliorare la precision ma diminuire la recall. L'equilibrio più appropriato dipende dall'attività: nelle applicazioni di sicurezza ambientale spesso si privilegia la riduzione dei mancati rilevamenti, accettando qualche falso allarme.

Comprendere questi compromessi è essenziale per adottare i sistemi di computer vision in modo responsabile ed efficace.

Fattori che influenzano le prestazioni misurate

Nel discutere le metriche di prestazione bisogna ricordare che l'efficacia misurata di un sistema di computer vision non dipende soltanto dal modello.

Nel monitoraggio ambientale, le prestazioni sono fortemente influenzate dalle caratteristiche dei dati e dalle condizioni in cui vengono acquisiti.

Differenze di risoluzione spaziale

Un limite frequente deriva dalle differenze di risoluzione spaziale. Le etichette di riferimento sono spesso ricavate da immagini ad altissima risoluzione o dall'interpretazione manuale, mentre i modelli possono utilizzare dati satellitari a risoluzione moderata.

Di conseguenza, anche un buon modello raramente ottiene una sovrapposizione perfetta con i dati di riferimento. Ciò non implica necessariamente un errore del modello, ma può dipendere dal confronto tra informazioni acquisite a scale spaziali differenti.

Rumore ambientale e condizioni atmosferiche

Le immagini ottiche sono molto sensibili al rumore ambientale. Nuvole, ombre, fumo e cambiamenti nell'illuminazione possono alterare la qualità delle immagini e ridurre le prestazioni del modello.

I dati radar, come quelli SAR, superano alcune di queste limitazioni offrendo osservazioni indipendenti dalle condizioni meteorologiche. Introducono però altre difficoltà, tra cui maggiore rumore del segnale e schemi visivi meno intuitivi, che possono complicare l'individuazione dei contorni e la classificazione.

Stabilità temporale ed effetti stagionali

Un altro fattore importante è la variabilità temporale. Le condizioni ambientali cambiano nel tempo a causa delle stagioni, dei fenomeni meteorologici e delle dinamiche di uso del suolo.

Per aumentare la stabilità del monitoraggio a lungo termine si usano spesso indici di differenza normalizzata. Questi riducono l'influenza delle variazioni di illuminazione e della stagionalità, facilitando il riconoscimento di cambiamenti ambientali significativi rispetto a fluttuazioni temporanee.

Concetto chiave

Le metriche devono essere sempre interpretate nel loro contesto. Nella computer vision ambientale, valori più bassi non indicano automaticamente un modello scadente: spesso riflettono i limiti dei dati reali.

La comprensione di questi fattori aiuta a definire aspettative realistiche e a progettare sistemi di monitoraggio robusti, anziché ottimizzati soltanto in condizioni artificiali.

Applicazioni nella mitigazione dei rischi ambientali

Dopo aver discusso dati, metodi, metriche e limiti, possiamo affrontare la domanda più pratica: come si utilizza la computer vision per ridurre concretamente i rischi ambientali?

Negli scenari reali, l'analisi automatica delle immagini supporta le decisioni individuando precocemente rischi su grandi territori e spesso in luoghi dove un'ispezione diretta è difficile o pericolosa.

Monitoraggio dell'inquinamento e dei rifiuti

Una delle applicazioni più comuni è il monitoraggio dell'inquinamento. I modelli di computer vision possono rilevare sversamenti di petrolio sulle superfici acquatiche o identificare discariche abusive lungo fiumi e in zone remote.

Il vantaggio principale è la scala: grandi territori possono essere monitorati continuamente, permettendo alle autorità di concentrare ispezioni e interventi di bonifica nei luoghi più critici anziché basarsi su segnalazioni sporadiche [7].

Individuazione di ordigni inesplosi (UXO)

Nelle regioni colpite da conflitti e in quelle postbelliche, la computer vision contribuisce direttamente alla sicurezza delle persone. Analizzando immagini di droni e dati satellitari ad alta risoluzione, i modelli aiutano a individuare aree potenzialmente contaminate da ordigni inesplosi.

Questi sistemi non sostituiscono gli esperti di sminamento, ma riducono il rischio delimitando le aree da esaminare e dando priorità alle zone che richiedono attenzione immediata.

Rilevamento di incendi boschivi e fumo

La computer vision è impiegata anche per il rilevamento precoce degli incendi boschivi. I modelli riconoscono configurazioni del fumo o anomalie termiche prima che gli incendi diventino estesi e incontrollabili.

Anche piccoli miglioramenti nei tempi di rilevamento possono avere un impatto importante, riducendo danni ambientali, costi degli interventi e rischi per le comunità vicine.

Valutazione dei danni agli edifici

Un'altra applicazione fondamentale è la valutazione dei danni dopo disastri naturali o durante conflitti armati.

I sistemi radar, in particolare SAR, sono molto utili in questi scenari perché funzionano indipendentemente dal meteo e dall'illuminazione. I danni strutturali causano variazioni misurabili nella riflessione dei segnali radar, consentendo di riconoscerli anche quando non sono disponibili immagini ottiche. Le Figure 7.8 e 7.9 illustrano esempi di visualizzazione dei danni.



Figura 7.8 Valutazione dei danni agli edifici dopo il terremoto in Turchia



Figura 7.9 Danni nella città di Rubižne (Ucraina) dovuti alle operazioni belliche

Questi risultati vengono generalmente integrati in piattaforme GIS, dove supportano gli interventi di emergenza, la pianificazione degli aiuti umanitari e l'individuazione delle priorità di ricostruzione [9].

Monitoraggio della deforestazione e della biodiversità

Rischi ambientali a lungo termine, come la deforestazione e la perdita di biodiversità, vengono monitorati confrontando immagini satellitari acquisite in momenti diversi.

La computer vision consente di rilevare in maniera coerente e ripetibile cambiamenti graduali nella copertura del suolo, a sostegno della conservazione e delle politiche pubbliche, soprattutto nelle regioni dove il monitoraggio continuo sul campo non è possibile [6], [7], [8]. Un esempio è mostrato nella Figura 7.10.

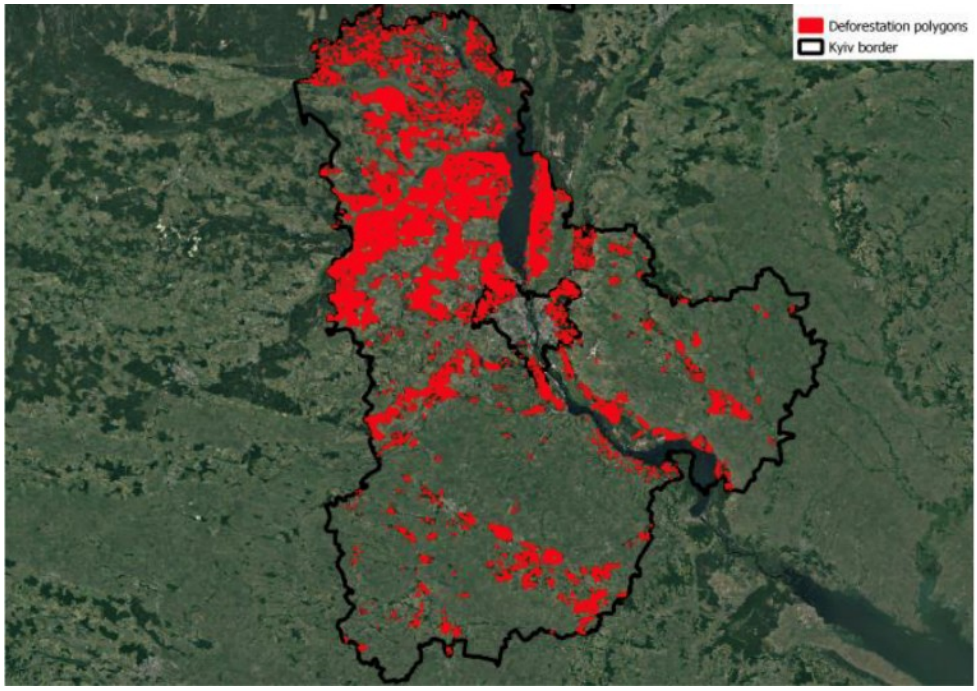

Figura 7.10 Visualizzazione del rilevamento della deforestazione

Concetto chiave

In tutte queste applicazioni, la computer vision non intende sostituire gli esperti ambientali, ma ampliarene le capacità. L'analisi automatizzata rende il monitoraggio più rapido, sicuro e sistematico, consentendo agli esperti di concentrarsi sulle attività nelle quali il loro contributo è più importante.

Fonti e integrazione dei dati per il monitoraggio ambientale

Nella pratica, i sistemi di monitoraggio ambientale sono organizzati in pipeline a più livelli anziché fare affidamento su un'unica fonte di dati.

Le immagini satellitari costituiscono il livello superiore: offrono una copertura continua su vasta scala e permettono di osservare intere regioni nel tempo. Questo livello è responsabile del rilevamento precoce e dell'analisi delle tendenze.

Dopo aver individuato le aree di interesse, si usano fonti a risoluzione più elevata. Droni e fotografie aeree forniscono viste dettagliate e localizzate per ispezioni, verifiche e mappature precise.

I dati radar svolgono un ruolo complementare garantendo continuità: quando nuvole, fumo o oscurità rendono indisponibili i dati ottici, le immagini SAR consentono di proseguire il monitoraggio.

Il punto di integrazione dei flussi di dati è rappresentato dai sistemi informativi geografici. I GIS forniscono il riferimento spaziale che unifica osservazioni satellitari, ispezioni con droni e risultati dei modelli in un unico quadro operativo.

Questo approccio stratificato bilancia estensione, dettaglio e affidabilità, trasformando dati eterogenei in informazioni concrete per comprendere la situazione.

Dal rilevamento all'azione ambientale

L'impiego della computer vision (CV) nella sicurezza ambientale offre un quadro tecnico per trasformare dati visivi grezzi in informazioni spaziali utilizzabili. Automatizzando l'interpretazione di fotografie digitali, mappe satellitari e immagini da droni, questi sistemi favoriscono il rilevamento precoce delle minacce ecologiche, il monitoraggio di regioni pericolose e il miglioramento delle decisioni basate sui dati. Il passaggio dall'identificazione all'intervento combina intelligenza artificiale (AI), telerilevamento e sistemi informativi geografici (GIS), creando cicli di monitoraggio automatici che fanno risparmiare tempo e riducono i rischi umani.

Identificazione dei rischi ambientali e umanitari

I modelli di computer vision aiutano a comprendere la situazione rispondendo a domande cruciali sulla presenza e la localizzazione dei rischi ambientali. I sistemi automatici sono impiegati in ambiti diversi per individuare minacce specifiche che richiedono un intervento:

- **Inquinamento e rifiuti: sistemi di telecamere dotati di AI e droni monitorano l'inquinamento da plastica nei corsi d'acqua, con accuratezze di rilevamento elevate riportate in condizioni controllate. La tecnologia riconosce caratteristici picchi di assorbimento spettrale delle plastiche, consentendo di individuare pennacchi di contaminazione.**
- **Degrado ecologico: l'elaborazione automatica di immagini multispettrali, come i dati Sentinel-2, permette di rilevare la deforestazione nelle aree protette [6], [7], [8]. Gli indici come NDVI sono utilizzati per seguire l'abbattimento degli alberi e valutare lo stato della vegetazione.**
- **Rischi legati ai conflitti: nelle aree in cui l'accesso diretto è limitato per motivi di sicurezza, la CV viene usata per identificare ordigni inesplosi (UXO) e quantificare danni strutturali a edifici e infrastrutture [9].**
- **Sistemi di allerta precoce: gli strumenti moderni di AI analizzano automaticamente dati visivi per individuare precocemente il fumo degli incendi o**

perdite industriali, generando avvisi alle comunità prima che i danni ecologici diventino incontrollabili.

Supporto alla ricostruzione strategica e all'allocazione delle risorse

L'integrazione dei risultati della CV con i livelli GIS permette di visualizzare la distribuzione spaziale dei rischi, essenziale per la pianificazione strategica e la definizione delle priorità di recupero.

- **Pulizia e bonifica: nei casi di inquinamento acquatico, la mappatura automatizzata aiuta a individuare zone di accumulo di rifiuti in luoghi remoti. Questi dati spaziali servono a pianificare interventi mirati di pulizia e rimozione.**
- **Ripristino delle infrastrutture: i sistemi di rilevamento dei danni agli edifici forniscono stime del numero di strutture colpite e della densità della popolazione precedente al conflitto in determinate zone. Queste «mappe proxy dei danni» aiutano soccorritori e organizzazioni umanitarie a individuare le aree che necessitano maggiormente di risorse.**
- **Identificazione delle fonti: georeferenziando i pennacchi di inquinamento e risalendo alle possibili sorgenti su una mappa, la computer vision supporta le ispezioni industriali e l'applicazione delle normative ambientali.**

Politiche basate su evidenze e sostegno economico

La computer vision rappresenta uno strumento oggettivo per le decisioni a livello nazionale, soprattutto quando la raccolta tradizionale di dati statistici è ostacolata da conflitti o disastri ambientali.

- **Sostegno alle politiche agricole: mappe ad alta risoluzione dell'uso del suolo sono impiegate per identificare terreni agricoli incolti o abbandonati. In regioni come l'Ucraina, queste mappe sono state integrate nei registri nazionali per supportare decisioni pubbliche, come l'esenzione fiscale per agricoltori con terreni contaminati o vicini alla linea del fronte [4].**
- **Monitoraggio della sicurezza alimentare: l'osservazione a lungo termine dei tipi di colture e della produttività mediante immagini satellitari aiuta i decisori ad affrontare problemi di sicurezza alimentare individuando variazioni nelle dinamiche agricole.**

- **Ricostruzione postbellica: serie temporali continue forniscono una base spaziale per pianificare la riforestazione e la ricostruzione nelle aree considerate pericolose per l'attività umana [9].**

Dal rilevamento all'azione ambientale: esempi reali di computer vision per la sicurezza ambientale

Quando un sistema informatico rileva una minaccia ambientale, devono seguire azioni concrete. Questa sezione esamina come la computer vision trasformi il rilevamento in decisioni ambientali nelle tre fasi fondamentali: prevenzione prima dell'emergenza, monitoraggio durante l'evento e valutazione dei danni con pianificazione del recupero dopo l'evento.

Fase 1: rilevamento preventivo e allerta precoce

Monitoraggio della qualità dell'acqua con HydroVision

Immaginiamo che le autorità vogliano sapere se l'acqua di un fiume è sicura prima che le persone si ammalino. Tradizionalmente raccolgono campioni manualmente: un processo costoso, lento e spesso tardivo.

HydroVision è un sistema che analizza fotografie dell'acqua (riprese da droni o satelliti) e segnala contaminazione o degrado della qualità. Esamina colore, torbidità e presenza di alghe, possibili indicatori di inquinamento:

- Acqua verde = proliferazione algale (potenzialmente tossica)
- Torbidità marrone = materiali organici in sospensione (possibili scarichi industriali)
- Anomalia cromatica = segnale di allarme

Invece di affidarsi a una sola persona sulla riva, il sistema può analizzare ogni giorno centinaia di chilometri di corsi d'acqua. Attraverso reti neurali convoluzionali profonde applicate a immagini RGB, HydroVision stima parametri otticamente attivi come la concentrazione di clorofilla e la materia organica disciolta colorata (CDOM), utilizzati come indicatori indiretti dello stato della qualità dell'acqua.

Monitoraggio della biodiversità e degli habitat

La computer vision sostiene anche la preparazione preventiva, consentendo il monitoraggio ambientale automatizzato su vasta scala: individuazione di pattern di biodiversità, studio della distribuzione delle specie e mappatura degli habitat. I sistemi visivi possono riconoscere cambiamenti nella copertura del suolo, presenza di specie e caratteristiche degli habitat, contribuendo a valutazioni ecologiche e strategie di conservazione.

Fase 2: monitoraggio in tempo reale durante l'evento

Monitoraggio in tempo reale degli incendi boschivi

Un principio simile si applica durante gli incendi:

- 🔥 I droni sorvolano la regione alla ricerca di colonne di fumo e punti caldi.
- 🗺️ Il fuoco viene localizzato ai margini della foresta, dove può essere fermato prima di propagarsi.
- 📊 I vigili del fuoco ricevono coordinate precise del focolaio, non un'indicazione generica della presenza dell'incendio.

Le architetture moderne di computer vision, soprattutto se combinate con sensori dell'Internet delle cose (IoT), permettono un'osservazione continua degli eventi ambientali dinamici. Sistemi di rilevamento ibridi integrano telecamere e modelli analitici per mantenere affidabili il monitoraggio e il rilevamento anche in condizioni difficili, come variazioni di illuminazione, rumore e ostacoli alla visibilità.

Rilevamento dell'inquinamento da plastica in acqua

Quando i fiumi accumulano rifiuti di plastica, la computer vision può localizzare i singoli oggetti galleggianti:

- 🎯 Rilevamento automatico di bottiglie di plastica negli ambienti fluviali.
- 📍 Coordinate precise dei punti in cui i rifiuti si spostano.
- ⏱️ Aggiornamenti in tempo reale delle mappe di contaminazione.

Gli addetti alla pulizia e i volontari sanno dove intervenire, evitando ricerche inutili. I ricercatori hanno sviluppato modelli capaci di riconoscere automaticamente bottiglie di plastica nei fiumi mediante addestramento su ampie raccolte di immagini acquatiche. Questi modelli individuano e localizzano i rifiuti in scenari naturali complessi, supportando gli interventi di rimozione.

Fase 3: valutazione e recupero dopo l'evento

Mappatura delle aree bruciate dopo gli incendi boschivi

Dopo un incendio, un'alluvione o una tempesta, le autorità devono sapere:

- Dove sono esattamente le aree bruciate? (Quali zone richiedono restrizioni di accesso?)
- Quanto sono gravi i danni? (Gli alberi sono soltanto spogli o completamente carbonizzati?)

- Quali risorse servono per il recupero? (Personale, attrezzature, tempo?)

Tradizionalmente questi rilievi richiedevano mesi di sopralluoghi, misurazioni manuali e consultazioni con la popolazione locale, con costi elevati e tempi lunghi.

I modelli di deep learning applicati alle immagini satellitari possono completare queste analisi in pochi giorni. Architetture convoluzionali come U-Net consentono di mappare automaticamente le aree bruciate dopo gli incendi, usando immagini Sentinel-2 precedenti e successive all'evento per classificare la gravità dei danni e riconoscere le zone colpite.

I risultati comprendono:

- 📍 Mappe delle aree bruciate: dove il fuoco è passato o è ancora attivo.
- 🎨 Gravità rappresentata con colori: giallo = lieve, arancione = moderata, nero = grave.
- 📊 Rapporti: stime quantitative della superficie forestale che richiede interventi di ripristino.

Valutazione dei danni dopo i disastri

Lo stesso approccio vale per alluvioni, tempeste e altre catastrofi:

- 🏘️ Quali edifici sono allagati?
- 🛣️ Quali strade sono bloccate?
- 👥 Quali popolazioni sono esposte al rischio?

La computer vision contribuisce alla valutazione ambientale dopo i disastri: modelli CNN profondi rilevano e classificano danni all'ambiente naturale e costruito subito dopo tempeste, alluvioni o altri eventi. Analizzando grandi quantità di immagini aeree successive all'evento, questi modelli supportano una rapida valutazione dei danni e le priorità di risposta.

Caso di studio: valutazione dello stato della vegetazione mediante NDVI da dati Sentinel-2

Contesto

In questo caso di studio vengono utilizzate immagini satellitari multispettrali per valutare lo stato della vegetazione e analizzare i pattern spaziali di degrado ambientale. L'analisi si basa sull'Indice di vegetazione della differenza normalizzata (NDVI), un indicatore spettrale consolidato derivato dalle bande del rosso e del vicino infrarosso (NIR).

Il caso di studio mostra come tecniche relativamente semplici di computer vision e telerilevamento possano produrre informazioni ambientali utili quando vengono applicate a dati satellitari reali.

Rilevanza ambientale

L'analisi basata sull'NDVI è ampiamente utilizzata nella sicurezza ambientale, per monitorare la deforestazione, valutare l'uso agricolo del suolo, analizzare gli effetti della siccità e stimare le condizioni ambientali dopo eventi di disturbo. Gli indici spettrali derivati da satellite permettono osservazioni ripetibili su larga scala e nel tempo.

Questo approccio è particolarmente efficace nelle regioni in cui le misurazioni dirette sul campo sono limitate da problemi di sicurezza o accessibilità. Grazie ai dati orbitali è possibile mantenere il monitoraggio continuo senza entrare fisicamente in aree potenzialmente pericolose.

Dati e bande spettrali di ingresso

L'analisi utilizza immagini multispettrali Sentinel-2. Tra le bande disponibili vengono selezionate quella del rosso (B4) e quella del vicino infrarosso (B8), per la loro sensibilità alle proprietà di riflettanza della vegetazione.

Per garantire trasparenza e riproducibilità, i passaggi intermedi di elaborazione sono documentati direttamente nel flusso di analisi.

Estratto di codice: caricamento e pre-elaborazione delle bande Sentinel-2

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

Panoramica del metodo

I valori NDVI sono calcolati mediante la formula standard della differenza normalizzata:

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

Questa formula evidenzia il contrasto tra superfici vegetate e non vegetate sfruttando il diverso comportamento di riflettanza della clorofilla nelle bande del rosso e del vicino infrarosso.

Estratto di codice: calcolo dell'NDVI

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

Visualizzazione e rappresentazione spaziale

Dopo il calcolo vengono generate mappe NDVI che illustrano la variazione spaziale delle condizioni della vegetazione.

Nelle mappe, valori NDVI bassi (generalmente inferiori a circa 0,1) sono rappresentati in rosso o marrone e corrispondono a superfici prive di vegetazione, come acque, suolo nudo o aree edificate. Valori intermedi (circa 0,1–0,3), visualizzati in giallo o arancione, indicano vegetazione rada o stressata. Valori elevati, rappresentati in verde, indicano copertura vegetale densa e in buone condizioni.

Queste rappresentazioni costituiscono l'interfaccia principale per interpretare le condizioni ambientali e consentono una rapida individuazione delle aree anomale o degradate. La Figura 7.11 mostra un esempio di mappa NDVI.

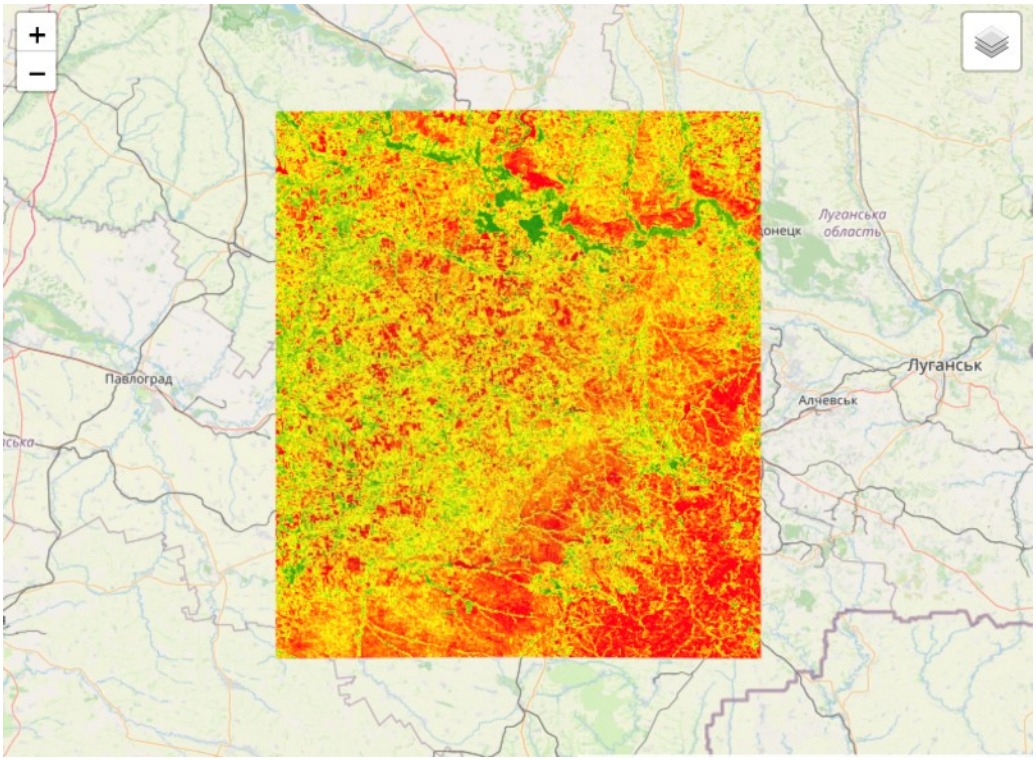

Figura 7.11 Visualizzazione di una mappa NDVI

Interpretazione dei pattern NDVI

Per classificare le condizioni della vegetazione vengono utilizzate soglie NDVI:

- Valori inferiori a circa 0,1 sono associati a corpi idrici, suolo nudo o terreni fortemente degradati.
- Valori intermedi (circa 0,1–0,3) indicano vegetazione rada o stressata.
- Valori più elevati corrispondono a una copertura vegetale densa e in buone condizioni.

Raggruppamenti spaziali di valori NDVI persistentemente bassi possono essere interpretati come possibili indicatori di stress ambientale, alterazioni antropiche o cambiamenti d'uso del suolo.

Risultati e implicazioni ambientali

Le mappe NDVI mostrano pattern spaziali distinti nelle condizioni della vegetazione dell'area osservata. Zone estese con attività vegetativa ridotta possono suggerire deforestazione, abbandono dei terreni o degrado ecologico successivo a eventi perturbativi.

Documentando risultati intermedi e rappresentazioni visive accanto ai passaggi di calcolo, il caso di studio illustra come l'analisi spettrale supporti valutazioni ambientali trasparenti e procedure riproducibili.

Esercitazione pratica

Obiettivo

Acquisire esperienza pratica nell'analisi di immagini satellitari e comprendere come utilizzare l'NDVI per sicurezza e monitoraggio ambientale: calcolare una mappa NDVI, visualizzare le condizioni della vegetazione e interpretare i risultati in un contesto ambientale.

Guida passo passo: esecuzione del notebook

Il notebook fornito, «ML_CV_NDVI.ipynb», contiene una procedura completa e funzionante pronta per l'esecuzione. È configurato per accedere ai dati Sentinel-2 tramite Google Earth Engine, calcolare compositi NDVI, visualizzare i pattern spaziali della vegetazione ed eseguire confronti temporali. Produce mappe interattive e risultati utilizzabili per l'interpretazione ambientale.

Utilizzeremo Google Colab per eseguire il notebook nel browser, senza installazione locale, seguendo la sequenza «carica → esegui tutto → interpreta i risultati» già utilizzata nel corso.

Struttura del notebook:

1. *Configurazione e librerie. Questa sezione inizializza l'ambiente di calcolo, importa le librerie Python necessarie e definisce i parametri dell'esperimento nelle sottosezioni seguenti:*

   1a: l'Area di interesse (AOI) è definita nel formato GeoJSON. Per impostazione predefinita comprende il territorio dell'Ucraina sudorientale, purtroppo interessato da operazioni belliche attive.

   1b: configurazione dell'accesso a Google Earth Engine.

   1c: impostazione dei parametri dell'esperimento:

   - Intervallo temporale NDVI (NDVI_START_DATE e NDVI_END_DATE), relativo al periodo di analisi corrente.
   - Periodo storico di riferimento dell'NDVI (NDVI_HISTORICAL_START_DATE e NDVI_HISTORICAL_END_DATE), utilizzato per il confronto.
   - Parametri di visualizzazione NDVI_VISUALIZATION_PARAMS.
   - Parametri di visualizzazione della differenza NDVI DIFF_VISUALIZATION_PARAMS.

2. *Funzioni di utilità. Questa sezione include funzioni riutilizzabili che racchiudono operazioni fondamentali come:*
   - creazione di mappe interattive Folium;
   - calcolo dell'NDVI dalle immagini Sentinel-2;
   - generazione dei compositi NDVI;
   - supporto alla logica di visualizzazione.
3. *Visualizzazione del composito NDVI. Viene generato un composito mediano dell'NDVI per l'AOI e il periodo scelti. La mappa risultante mostra la distribuzione spaziale delle condizioni della vegetazione.*
4. *Confronto temporale dell'NDVI. Questa sezione rileva cambiamenti nel tempo confrontando compositi NDVI relativi a due periodi distinti. La differenza permette di individuare aree con aumento o diminuzione dell'attività vegetativa.*
5. *Domande di riflessione. La sezione finale guida l'interpretazione qualitativa dei pattern spaziali e temporali osservati, esaminando possibili cause ambientali e i limiti dell'analisi.*

Prerequisito: configurazione di Google Earth Engine

L'esercitazione utilizza Google Earth Engine per accedere alle immagini Sentinel-2 ed elaborarle. Prima di eseguire il notebook, occorre abilitare l'accesso a Earth Engine per il proprio account e predisporre il progetto richiesto.

Quando il progetto è pronto, aggiornare la variabile EE_PROJECT come mostrato nella Figura 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
```

Figura 7.12 Definizione della variabile EE_PROJECT

Esecuzione del notebook

Una volta completata la configurazione del progetto Google Earth Engine, procedere all'esecuzione del notebook.

1. Aprire Google Colab.
2. Caricare il file del notebook.
3. Eseguire il notebook: Runtime → Run all.
4. Scorrere i risultati man mano che vengono eseguite le celle. Dovrebbero comparire i risultati intermedi e le visualizzazioni NDVI finali.
    - Nella sezione 3, «Visualizzazione del composito NDVI», apparirà una rappresentazione relativa all'intervallo di date impostato, come nella Figura 7.13. Le aree verdi indicano vegetazione sana e densa, mentre i colori più caldi indicano vegetazione rada o assente.

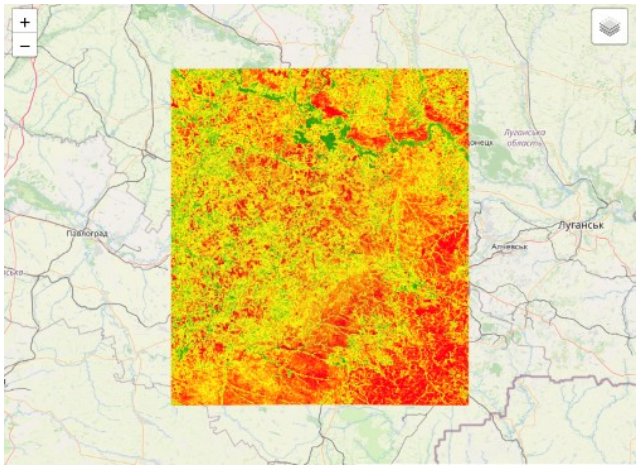

Figura 7.13 Visualizzazione del composito NDVI

- Nella sezione 4, «Confronto temporale dell'NDVI», comparirà la differenza tra il periodo scelto e quello storico. Le aree verdi rappresentano variazioni positive della vegetazione rispetto al riferimento storico, mentre quelle rosse rappresentano diminuzioni.

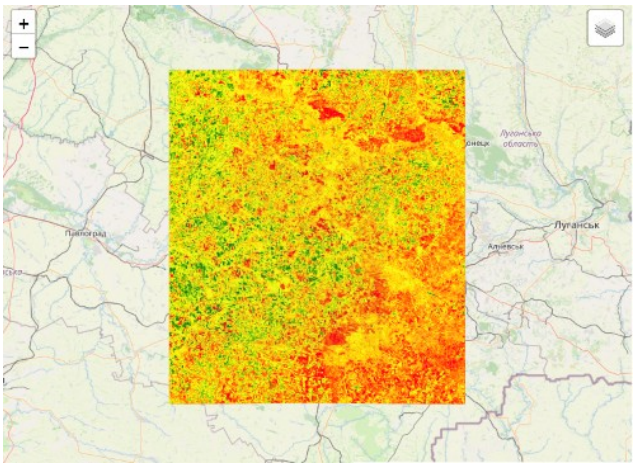

Figura 7.14 Confronto temporale dell'NDVI

Nota: se Colab mostra l'avviso «Author not trusted», selezionare «Run anyway».

Fonte dei dati

L'esercitazione utilizza immagini multispettrali Sentinel-2. L'NDVI è calcolato dalla banda del rosso (B4) e dalla banda del vicino infrarosso (B8).

I dati sono caricati dalla raccolta Copernicus Sentinel-2 SR (ad esempio COPERNICUS/S2_SR_HARMONIZED), filtrati per area e data e quindi aggregati per l'analisi.

Attività

Attività 1: eseguire e verificare il risultato di riferimento

- Aprire ed eseguire il notebook fornito.
- Verificare che i dati Sentinel-2 siano caricati correttamente per l'AOI e l'intervallo di date selezionati.
- Calcolare il livello NDVI e visualizzare una mappa NDVI.

Domande:

- Dove si osservano raggruppamenti di valori NDVI bassi e alti nell'AOI?
- Quali tipi di copertura del suolo sono più probabilmente associati a questi raggruppamenti (ad esempio acqua, suolo nudo, aree urbane, vegetazione densa)?
- I pattern NDVI sono spazialmente coerenti o frammentati e rumorosi a livello di pixel?
- Quale prima interpretazione ambientale può essere ricavata dalla distribuzione spaziale dell'NDVI?

Attività 2: interpretazione basata su soglie (ragionamento ambientale)

Utilizzare le soglie di interpretazione NDVI e classificare l'AOI in tre livelli di salute della vegetazione: basso, medio e alto:

- NDVI < circa 0,1
- NDVI circa 0,1–0,3
- NDVI > circa 0,3

Domande:

- Quale categoria di salute della vegetazione basata sull'NDVI (bassa, media o alta) prevale nell'AOI e perché?
- Le aree con NDVI basso sono raggruppate o disperse? Che cosa suggerisce ciò sul possibile stress ambientale o sui pattern di uso del suolo?
- Quali fattori naturali o antropici possono spiegare la presenza di zone a basso NDVI in questa regione?

Attività 3: analisi di sensibilità (tempo e localizzazione)

Modificare una variabile alla volta, eseguire nuovamente il notebook e confrontare i risultati:

- Modificare l'intervallo di date (per esempio primavera rispetto a fine estate).
- Modificare l'AOI scegliendo la propria regione o un'altra area di interesse (per esempio la periferia urbana rispetto a una zona agricola).

Domande:

- Come cambiano i pattern NDVI quando si modifica il periodo di osservazione?
- Quali cambiamenti sono spiegabili con le dinamiche stagionali della vegetazione e quali possono indicare trasformazioni strutturali più persistenti?
- Come influisce la modifica dell'AOI sull'interpretazione dell'NDVI, soprattutto confrontando aree periurbane e agricole?

Valutazione

1. Qual è il ruolo principale della computer vision nelle applicazioni di sicurezza ambientale?
   A) Sostituire gli esperti ambientali con sistemi completamente automatizzati
   B) Migliorare la qualità visiva delle immagini satellitari
   C) Estrarre automaticamente informazioni utilizzabili da grandi volumi di dati visivi
   D) Etichettare manualmente le immagini ambientali

2. Quale attività di computer vision è più adatta a localizzare con precisione accumuli illegali di rifiuti lungo un fiume?
   A) Classificazione delle immagini
   B) Rilevamento di oggetti
   C) Miglioramento delle immagini
   D) Normalizzazione dei dati

3. Perché i droni vengono spesso utilizzati insieme alle immagini satellitari nei sistemi di monitoraggio ambientale?
   A) I droni eliminano la necessità di dati satellitari
   B) I droni forniscono osservazioni localizzate a risoluzione più elevata che integrano la copertura satellitare su larga scala
   C) I droni eliminano la necessità dei modelli di computer vision
   D) Le immagini satellitari non possono essere utilizzate per il monitoraggio ambientale

4. Quale informazione ambientale è più frequentemente associata a valori NDVI elevati?
   A) Elevata densità di infrastrutture urbane

B) Presenza di nuvole o fumo
C) Vegetazione densa e in buone condizioni
D) Aree interessate da inondazioni

5. Perché il radar ad apertura sintetica (SAR) è particolarmente importante per monitorare disastri come alluvioni o danni agli edifici?
   A) Offre una risoluzione cromatica superiore
   B) Rileva esclusivamente i cambiamenti della vegetazione
   C) Funziona indipendentemente dalle condizioni meteorologiche e dalla luce diurna
   D) Non richiede integrazione con GIS

6. Quale combinazione di tecnologie è più efficace per costruire un quadro della situazione nei sistemi di sicurezza ambientale?
   A) Soltanto modelli di computer vision
   B) Immagini satellitari senza machine learning
   C) Computer vision + dati satellitari/da droni + integrazione GIS
   D) Ispezione manuale delle immagini con dispositivi GPS

Riferimenti bibliografici e ulteriori letture

[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]. Available: https://szeliski.org/Book/, Accessed: Dec. 15, 2025.

[2] S. J. D. Prince, *Computer Vision: Models, Learning, and Inference*. Cambridge, UK: Cambridge University Press, 2012. [Online]. Available: https://raw.githubusercontent.com/udlbook/cvbook/main/book.pdf, Accessed: Dec. 15, 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]. Available: https://link.springer.com/book/10.1007/978-3-319-98131-4, Accessed: Dec. 15, 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]. Available: https://linkinghub.elsevier.com/retrieve/pii/S1569843225001980, Accessed: Dec. 15, 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]. Available: https://doi.org/10.1016/j.clwat.2025.100141, Accessed: Dec. 15, 2025.

[6] O. Ballinger, "A New Tool Allows Researchers to Track Damage in Gaza," *Bellingcat*, Nov. 15, 2023. [Online]. Available: https://www.bellingcat.com/resources/2023/11/15/a-new-tool-allows-researchers-to-track-damage-in-gaza/, Accessed: Dec. 15, 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]. Available: https://doi.org/10.1109/IDAACS53288.2021.9661008, Accessed: Dec. 15, 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]. Available: https://cims.fti.dp.ua/j/article/view/252/207, Accessed: Dec. 15, 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]. Available: https://link.springer.com/book/10.1007/978-3-031-88483-2, Accessed: Dec. 15, 2025.

[10] European Space Agency, *Copernicus Sentinel-2* [Level-2A data set], 2026. [Online]. Available: https://dataspace.copernicus.eu/, Accessed: Dec. 15, 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]. Available: https://doi.org/10.5066/P9OGBGM6, Accessed: Dec. 15, 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]. Available: https://arxiv.org/abs/2509.01882, Accessed: Dec. 15, 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]. Available: https://doi.org/10.64252/a24f9536, Accessed: Dec. 15, 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]. Available: https://doi.org/10.31673/2786-8362.2024.010202, Accessed: Dec. 15, 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]. Available: https://doi.org/10.1038/s41598-025-09300-8, Accessed: Dec. 15, 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]. Available: https://doi.org/10.1016/j.rsase.2021.100614, Accessed: Dec. 15, 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]. Available: https://doi.org/10.1038/s41598-022-06067-1, Accessed: Dec. 15, 2025.