GAP-SOLAR (GeoAI Photovoltaic Solar Mapping Piemonte) GeoAI e telerilevamento per la governance energetica: Mappatura automatizzata e monitoraggio continuo del parco fotovoltaico in Piemonte

Enrico Suozzi[1], Andrea Di Dio[1], Angelo Robotto[2], Elisa Guiot[3], Mario Ancilli[4], Stefano Campus[4], Gianbartolomeo Siletto[4]

1 [Staff della Direzione Ambiente, Energia e Territorio, Regione Piemonte, Torino, Italia] – [enrico.suozzi@regione.piemonte.it – andrea.didio@regione.piemonte.it]
2 [Direttore della Giunta Regionale Regione Piemonte, Torino, Italia] – [angelo.robotto@regione.piemonte.it]
3 [Settore A1616A – Sviluppo energetico sostenibile della Direzione Ambiente, Energia e Territorio, Regione Piemonte, Torino, Italia] – [elisa.guiot@regione.piemonte.it]
4 [Settore A1613B – Sistema informativo territoriale e ambientale della Direzione Ambiente, Energia e Territorio, Regione Piemonte, Torino, Italia] – [mario.ancilli@regione.piemonte.it – stefano.campus@regione.piemonte.it gianbartolomeo.siletto@regione.piemonte.it]

Abstract. La crescita rapida della potenza fotovoltaica installata mette in difficoltà gli enti territoriali, che devono monitorare gli impianti, pianificare l'energia e tenere aggiornati gli inventari regionali: su vaste aree i metodi di censimento tradizionali costano troppo e rendono poco. In questo lavoro presentiamo una pipeline GeoAI end-to-end e modulare, scritta in Python, che mappa, segmenta e georeferenzia in automatico gli impianti solari a partire da immagini telerilevate. A riconoscere gli impianti è lo strumento GeoAI Solar Panel Detection (OpenGeoAI), addestrato e validato con una libreria costruita da noi su 50 tipologie diverse di impianti fotovoltaici, individuate nelle ortofoto AGEA dell'intero territorio regionale. La pipeline è organizzata in quattro moduli: audit puntuale, scansione massiva comunale, spatial join e rilevamento di precisione. Negli impianti industriali più estesi il tiling frammenta e taglia i poligoni; per limitare il problema abbiamo messo a punto una strategia di inferenza multi-offset a croce, con cinque passaggi traslati (±100 m) e un'unione geometrica finale. I risultati preliminari mostrano un compromesso netto tra tempi e accuratezza. I moduli più rapidi rispondono in pochi secondi, ma con un'accuratezza del 60-80%; il modulo multi-offset supera il 90% (valore stimato) e riduce la frammentazione geometrica del 14%. Ne esce uno strumento operativo e scalabile per le pubbliche amministrazioni, che in futuro potrà accogliere dati satellitari multi-temporali (Sentinel, IRIDE).

Parole chiave: GeoAI, Solar Panel Detection, OpenGeoAI, Segmentazione Semantica, Deep Learning, Ortofoto AGEA, Multi-Offset Inference, GIS.

1 Introduzione

In Italia e nel resto dell'Unione Europea la transizione energetica ha fatto crescere in modo marcato la potenza fotovoltaica installata, tanto sui tetti delle case quanto negli impianti a terra di scala industriale. Per gli enti pubblici questo significa più lavoro: bisogna monitorare gli impianti, pianificare il territorio, valutarne l'impatto sul paesaggio e tenere aggiornate le basi dati. I metodi classici di censimento, cioè sopralluoghi e fotointerpretazione manuale, diventano troppo onerosi quando l'area da coprire è un comune, una provincia o un'intera regione.

Nel frattempo l'intelligenza artificiale applicata all'osservazione della Terra (GeoAI) è maturata, e i dati geospaziali ad alta risoluzione sono sempre più accessibili, sia in streaming tramite servizi Web Map Service (WMS) sia da archivi ortofotogrammetrici ufficiali come quello AGEA (Agenzia per le Erogazioni in Agricoltura). Oggi è quindi possibile individuare e vettorializzare i moduli fotovoltaici in automatico, con un'accuratezza compatibile con l'uso operativo. Da qui parte il nostro lavoro, che descrive progettazione, architettura e validazione preliminare di una pipeline GeoAI modulare per mappare e georeferenziare in automatico gli impianti solari.

Il contributo è di due tipi. Il primo è un'architettura a quattro moduli, ciascuno pensato per un caso d'uso preciso: audit puntuale, scansione massiva, integrazione con le ortofoto locali e rilevamento di precisione sui grandi impianti. Chi la usa può così scegliere l'equilibrio giusto tra accuratezza e tempo di calcolo. Il secondo è una strategia originale di inferenza multi-offset a croce, che serve a ridurre la troncatura dei poligoni ai bordi delle finestre di elaborazione della rete neurale, un problema ricorrente quando si segmentano oggetti di grandi dimensioni con il tiling.

2 Stato dell'arte

Nell'ultimo decennio il deep learning è stato usato sempre più spesso per estrarre infrastrutture energetiche dalle immagini di telerilevamento. I modelli di segmentazione semantica su immagini aeree e satellitari, in particolare, hanno permesso di monitorare in automatico gli impianti fotovoltaici, anche su aree estese grazie a strategie di mosaicking e finestre mobili. [1]

Mettere insieme sistemi informativi geografici (GIS), dati di osservazione della Terra e metodi multicriterio è utile per la pianificazione energetica sostenibile e per trovare i siti adatti agli impianti rinnovabili [2].

Dal punto di vista metodologico, la segmentazione semantica è uno degli approcci principali per estrarre oggetti planari da immagini raster. Minaee et al. ne hanno fatto una rassegna che ordina architetture, dataset e criteri di valutazione delle principali famiglie di modelli di deep learning [3]. Gli studi recenti sull'estrazione di array fotovoltaici da immagini ad alta risoluzione mostrano che distribuzione e scala delle feature, insieme al post-processing, incidono parecchio sulla continuità e sull'accuratezza delle geometrie estratte. Noi affrontiamo il problema con una strategia di inferenza multi-offset, pensata per attenuare gli effetti di bordo introdotti dal tiling [4].

Molti di questi lavori si concentrano soprattutto sull'ottimizzazione del modello di segmentazione. Il nostro invece si muove a livello di sistema: propone un'architettura operativa end-to-end, dalla scelta della ROI fino a output vettoriali georeferenziati, pensata per essere usata direttamente dagli enti territoriali.

3 Materiali e metodi

La pipeline è scritta interamente in Python. GeoPandas gestisce i dati vettoriali, Rasterio legge, scrive e georeferenzia i raster, Shapely si occupa delle operazioni geometriche. Il tutto lavora insieme a servizi Web Map Service conformi allo standard OGC WMS 1.3.0 e a un modello di deep learning per l'object detection e la segmentazione dei moduli fotovoltaici. L'operatore interagisce con il sistema tramite semplici interfacce grafiche basate su matplotlib.widgets.

3.1 Modello AI e costruzione del dataset di addestramento

Il cuore di intelligenza artificiale della pipeline si appoggia all'architettura e al flusso metodologico di GeoAI Solar Panel Detection (OpenGeoAI, https://opengeoai.org/examples/solar_panel_detection/). Il territorio piemontese è molto eterogeneo: per adattare il modello abbiamo costruito una libreria di ground truth su misura, a partire dalle ortofoto ad alta risoluzione dell'archivio AGEA.

Per addestrare e affinare il modello abbiamo selezionato, annotato e classificato 50 tipologie diverse di impianti e pannelli fotovoltaici presenti sul territorio regionale. Le tipologie cambiano per geometria, inclinazione, orientamento, materiale, colore di riflettanza e contesto di installazione (ad esempio coperture industriali, tetti residenziali, impianti a terra, agrivoltaico). Questa libreria è la base di conoscenza che permette alla rete neurale di generalizzare l'estrazione e la segmentazione dei moduli fotovoltaici in tutti i moduli operativi della pipeline, descritti qui sotto.

3.2 Architettura generale della pipeline

Il flusso di elaborazione ha quattro passi: acquisizione dei dati (WMS o raster locale) → grigliatura e spatial join tra centroide dei pannelli e grigliato AGEA → inferenza GeoAI → dissolve multi-offset. Come input usiamo servizi WMS interrogati alla risoluzione massima di 20 cm/pixel, oppure archivi offline in GeoTIFF con i relativi file di georeferenziazione TFW. Il risultato finale è un insieme di geometrie vettoriali in GeoJSON, accompagnate dal raster ritagliato e georeferenziato in GeoTIFF, che si importano direttamente in ambiente GIS.

3.3 Script 1 – Selettore interattivo WMS (Target Audit)

Il primo modulo serve per le verifiche puntuali e per il rapido scouting di singoli impianti. L'operatore sceglie la Regione di Interesse (ROI) da un'interfaccia grafica, selezionando Provincia e Comune. Lo script scarica il mosaico WMS di quell'area alla

risoluzione massima di 20 cm/pixel e passa il crop assemblato alla rete neurale, che restituisce un file GeoJSON con le geometrie individuate e un GeoTIFF georeferenziato dell'area analizzata.

3.4 Script 2 – Analisi comunale massiva (Bulk Scan)

Il secondo modulo scansiona in automatico interi territori comunali. Il territorio viene diviso in una maglia regolare di celle da 750 m di lato, e si elaborano solo le celle che intersecano il comune: così le chiamate API calano, secondo le nostre stime, del 40%. Su territori estesi il rischio è saturare la RAM o incorrere in timeout di rete, per questo l'architettura pulisce sistematicamente i dati temporanei e può riprendere il lavoro dallo stato salvato.

3.5 Script 3 – Spatial join e raccolta ortofoto AGEA

Il terzo modulo fa da ponte tra i poligoni preliminari trovati dagli Script 1 e 2 e le ortofoto ad alta risoluzione disponibili in locale (archivio AGEA). Per prima cosa controlla e allinea i sistemi di riferimento (CRS) dei due dataset, ad esempio riproiettando il layer AGEA nel sistema dei poligoni rilevati, con l'operazione riportata in (1).

gdf_agea = gdf_agea.to_crs(gdf_pannelli.crs) (1)

Poi esegue uno spatial join per associare i poligoni al grigliato ufficiale AGEA. Se alcune immagini hanno una georeferenziazione interna incompleta, il modulo ricostruisce la corretta matrice di trasformazione affine leggendo i file world (.tfw) associati: in questo modo raster e vettori restano coerenti nello spazio nelle analisi successive.

3.6 Script 4 – Analisi avanzata Multi-Offset

Nei grandi impianti fotovoltaici industriali le finestre di elaborazione della rete neurale (tiling) si incontrano spesso proprio sopra i pannelli, che finiscono troncati vicino ai bordi delle tile. Per ridurre sistematicamente l'errore, lo Script 4 esegue un crop centrato di 600×600 m e lo ripete in cinque passaggi traslati a croce: (i) crop centrato sul centroide esatto del poligono pre-rilevato; (ii) spostamento di +100 m verso Est; (iii) −100 m verso Ovest; (iv) +100 m verso Nord; (v) −100 m verso Sud.

Le predizioni dei cinque passaggi vengono poi fuse con un'unione geometrica non distruttiva (unary_union). Si ottiene così il contorno esatto del poligono, senza discontinuità né tagli residui dovuti al tiling.

3.7 Protocollo di valutazione

Abbiamo confrontato i moduli su accuratezza attesa, tempi di esecuzione e ambito d'uso. I valori della Sezione 4 vanno letti come stime preliminari, basate su verifiche empiriche.

4 Risultati

La Tabella 1 mette a confronto i tre moduli principali della pipeline: ambito di utilizzo, sorgente dei dati, gestione dell'overlap tra tile, tempi di esecuzione e accuratezza attesa.

Tabella 1. Confronto prestazionale tra i moduli della pipeline GeoAI.

Metrica / Parametro	**Script 1 (Target Audit)**	**Script 2 (Comune Bulk)**	**Script 4 (Multi-Offset)**
Ambito di utilizzo	Ispezione visiva interattiva	Inventario massivo comunale	Rilevamento geometrico di precisione
Sorgente immagini	WMS	WMS	Ortofoto locali GeoTIFF + TFW
Tecnica di overlap	Finestra standard (512×512 px)	Finestra standard (512×512 px)	5 passaggi a croce (±100 m)
Tempo di esecuzione	Pochi secondi	Da 2 Ore in su (in base al territorio)	Da minuti a ore
Accuratezza attesa*	70% – 80%	60% – 70%	> 90%

** Stima preliminare basata su verifiche empiriche; da consolidare con protocollo di validazione quantitativo (cfr. §3.6).*

I risultati mostrano un chiaro compromesso tra velocità e accuratezza geometrica. Lo Script 1 risponde in pochi secondi ed è ideale per le verifiche puntuali, ma la sua accuratezza attesa è più bassa (70–80%). Lo Script 2 copre l'intero territorio comunale e ha un'accuratezza attesa leggermente inferiore (60–70%); la causa più probabile è la maggiore eterogeneità del ricampionamento WMS su aree estese.

Il modulo Multi-Offset (Script 4) supera il 90% di accuratezza attesa, ma richiede tempi più lunghi. In particolare, i cinque passaggi traslati a croce riducono del 14% la frammentazione delle geometrie nei grandi impianti industriali, rispetto alla griglia standard a finestra singola. È una conferma dell'efficacia della strategia contro la troncatura ai bordi delle tile discussa in letteratura [4].

5 Discussione

5.1 Implicazioni operative

Grazie alla struttura modulare la pipeline si adatta a scenari diversi: dal controllo su un singolo impianto, utile nelle fasi di verifica, fino al censimento sistematico a scala comunale o regionale, che serve alla pianificazione energetica del territorio. Lo Script 4 è più oneroso dal punto di vista computazionale, ma la sua alta accuratezza lo rende adatto soprattutto all'inventario dei grandi impianti industriali.

5.2 Limiti dello studio

Il limite principale è la disomogeneità temporale tra le campagne di acquisizione: le variazioni stagionali e il tempo trascorso tra la ripresa e oggi possono creare disallineamenti rispetto allo stato reale del territorio. Il secondo limite è che al momento manca un protocollo di validazione quantitativo standardizzato, basato su ground truth indipendente.

5.3 Sviluppi futuri

In futuro vorremmo sviluppare pipeline dedicate alla ricucitura (temporal stitching) dei vuoti temporali tra voli ortofotogrammetrici consecutivi, e integrare costellazioni satellitari a media-alta risoluzione, come Sentinel e la nuova costellazione italiana IRIDE, insieme a piattaforme cloud come Google Earth Engine. L'obiettivo è ampliare la copertura temporale e spaziale della pipeline.

6 Conclusioni

Abbiamo descritto l'architettura e la validazione preliminare di una pipeline GeoAI modulare per mappare e georeferenziare in automatico gli impianti fotovoltaici, che unisce sorgenti WMS e ortofoto AGEA ad alta risoluzione con modelli di deep learning per la segmentazione. I quattro moduli permettono di bilanciare velocità di elaborazione e accuratezza geometrica, mentre la strategia multi-offset a croce si è rivelata efficace nel ridurre la frammentazione delle geometrie nei grandi impianti industriali.

I risultati preliminari sono incoraggianti, ma prima di considerarli definitivi serve una validazione quantitativa più rigorosa, con dataset di ground truth indipendenti. I prossimi passi sono l'integrazione di dati satellitari multi-temporali e la standardizzazione del protocollo di valutazione.

7 Riferimenti bibliografici

1. Soudani, K., et al.: Remote sensing for monitoring photovoltaic solar plants in Brazil using deep semantic segmentation. Energies 14(10), 2960 (2021). https://doi.org/10.3390/en14102960
2. Spyridonidou, S., Sismani, G., Loukogeorgaki, E., Vagiona, D. G., Ulanovsky, H., Madar, D.: Sustainable spatial energy planning of large-scale wind and PV farms in Israel: A collaborative and participatory planning approach. Energies 14(3), 551 (2021). https://doi.org/10.3390/en14030551
3. Minaee, S., Boykov, Y. Y., Porikli, F., Plaza, A. J., Kehtarnavaz, N., Terzopoulos, D.: Image segmentation using deep learning: A survey. IEEE Transactions on Pattern Analysis and Machine Intelligence 44(7), 3523–3542 (2022). https://doi.org/10.1109/TPAMI.2021.3059968
4. Li, D., et al.: Impact of deep convolutional neural network structure on photovoltaic array extraction from high spatial resolution remote sensing images. Remote Sensing 15(18), 4554 (2023). https://doi.org/10.3390/rs15184554
5. Gillies, S., et al.: Rasterio: Geospatial raster I/O for Python programmers. GitHub repository. https://github.com/rasterio/rasterio
6. Jordahl, K., et al.: GeoPandas: Python tools for geographic data. Zenodo (2020).
7. Open Geospatial Consortium: Web Map Service Implementation Specification, Version 1.3.0. OGC 06-042 (2006). https://www.ogc.org/standards/wms/