Mappatura automatizzata degli impianti eolici in Italia mediante super-risoluzione di immagini Sentinel-2 e algoritmi di Machine Learning

Giulia Ronchetti [0000-0003-0951-0878], Matteo Gobbi Frattini [0009-0008-1390-8436] e Martina Aiello [0000-0002-4832-662X]

Dipartimento di Sviluppo Sostenibile e Fonti Energetiche, Ricerca sul Sistema Energetico – RSE S.p.A., via Rubattino 54, 20134 Milano, Italia;
giulia.ronchetti@rse-web.it, matteo.gobbifrattini@rse-web.it, martina.aiello@rse-web.it

Abstract. Si propone una metodologia automatizzata per la mappatura degli aerogeneratori in Italia, basata su immagini Sentinel-2, algoritmi di super-risoluzione e classificazione Random Forest. Sono confrontati dati alla risoluzione originale e immagini ricampionate a 5 e 2.5 m. I risultati mostrano un miglioramento del dettaglio visivo, ma variazioni limitate nell'accuratezza della classificazione pixel-based, suggerendo l'impiego di approcci object-based per valorizzare le informazioni geometriche degli impianti.

Parole chiave: Sentinel-2, Super-risoluzione, Impianti eolici.

1 Introduzione

Lo sviluppo dell'energia eolica rappresenta uno dei pilastri fondamentali della transizione energetica in Italia e del raggiungimento degli obiettivi nazionali di decarbonizzazione definiti dal PNIEC (Piano Nazionale Integrato Energia e Clima). In questo scenario, come richiamato dal D.Lgs. 199/2021 per la creazione della Piattaforma Aree Idonee, la disponibilità di dati geografici aggiornati, interoperabili e liberamente accessibili è un requisito imprescindibile per valutare l'uso del suolo e supportare la pianificazione territoriale delle amministrazioni regionali. Tuttavia, sussiste una costante difficoltà nel reperire dati geolocalizzati accurati e aggiornati sull'effettiva ubicazione degli impianti: le informazioni in possesso degli operatori di settore non sono generalmente di libero accesso e, anche quando rese pubbliche, tendono a diventare rapidamente obsolete di fronte alla rapida espansione e trasformazione del settore [1].

Le metodologie per la mappatura degli impianti eolici spaziano dall'uso di dati collaborativi al telerilevamento satellitare. In letteratura, la creazione di database geografici specifici per le fonti rinnovabili viene talvolta affidata a iniziative di *crowdsourcing* (come OpenStreetMap), mappatura volontaria o campagne di misura [2], [3]. Tuttavia, per un monitoraggio oggettivo, esteso e continuo, il telerilevamento satellitare costituisce la soluzione preferibile, pur scontrandosi con vincoli tecnici ed

economici, dovuti alla relazione tra la dimensione dell'area di indagine, la dimensione degli aerogeneratori stessi e la risoluzione delle immagini satellitari. Da un lato, l'impiego di immagini ad alta (< 5 m) o altissima risoluzione (< 1 m), derivanti da costellazioni commerciali come WorldView, RapidEye o PlanetScope, garantisce il livello di dettaglio spaziale necessario per identificare i singoli aerogeneratori, ma è limitato ad aree geografiche ristrette ed è fortemente condizionato dai costi elevati dei dati. Dall'altro lato, le immagini a media risoluzione spaziale (10 - 30 m), in particolare quelle fornite gratuitamente dalla costellazione Sentinel-2 (S2), consentono l'analisi di interi contesti regionali e nazionali. Tuttavia, a una risoluzione di 10 m non è possibile individuare la singola pala eolica, bensì soltanto la piazzola di montaggio (corrispondente a circa 1–5 pixel), la quale viene facilmente confusa con elementi territoriali spettralmente simili quali rocce nude o strade sterrate [4]. Questa sovrapposizione spettrale genera elevati livelli di incertezza e impone un gravoso sforzo di fotointerpretazione manuale per la rimozione dei falsi positivi, riducendo la replicabilità e l'automazione del processo di mappatura su vasta scala.

Per superare questo collo di bottiglia e coniugare il dettaglio dell'alta risoluzione con la copertura gratuita e periodica di S2, la ricerca si è orientata verso l'uso di algoritmi di super-risoluzione (SR). Un algoritmo di SR è una tecnica computazionale che consente di aumentare la risoluzione spaziale di un'immagine, ovvero di migliorarne il livello di dettaglio. Questi algoritmi ricostruiscono informazioni ad alta definizione a partire da immagini a media/bassa risoluzione, utilizzando metodi basati su modelli statistici, apprendimento automatico o Deep Learning. Nello specifico dei dati S2, la letteratura si articola in due filoni principali: il primo mira a omogeneizzare le bande spettrali a minore risoluzione (20 m e 60 m) uniformandole alla risoluzione di 10 m [5], [6]; il secondo si focalizza invece sull'incremento del dettaglio spaziale delle bande RGBNIR a 10 m per portarle a risoluzioni di 5 m, 3 m o fino a 2 m [7]. Quest'ultimo approccio impiega sia metodi interpolativi tradizionali (es. interpolazione bicubica) sia modelli complessi quali Reti Neurali Convoluzionali (CNN) [8] e Reti Generative Avversarie (GAN) [9], addestrate su coppie di immagini ad alta (es. WorldView, RapidEye o costellazione Dove) e media risoluzione acquisite sulla stessa area, fino a soluzioni avanzate di *data fusion* e serie multitemporali, come l'algoritmo *DeepSent* [10]. Sebbene tali modelli siano stati applicati con successo in diverse applicazioni, principalmente in ambito di classificazione del territorio [11], attualmente non risultano in letteratura studi che abbiano applicato algoritmi di super-risoluzione a immagini Sentinel-2 per la mappatura e il riconoscimento specifico degli aerogeneratori eolici.

Per colmare questo divario, il presente lavoro propone una metodologia innovativa e automatizzata per il riconoscimento degli aerogeneratori sul territorio italiano, integrando l'uso di immagini Sentinel-2, algoritmi di super-risoluzione e modelli di Machine Learning. La procedura si articola in tre fasi principali: 1) l'applicazione della super-risoluzione alle bande RGBNIR delle immagini Sentinel-2 per aumentarne il livello di dettaglio spaziale; 2) la classificazione supervisionata tramite Machine Learning per l'identificazione automatica degli aerogeneratori; 3) la validazione dei risultati ottenuti attraverso il confronto con i database di riferimento esistenti. L'obiettivo principale è superare i vincoli di risoluzione delle immagini S2 e ridurre gli interventi manuali per la mappatura degli impianti eolici in Italia, sviluppando uno

strumento replicabile, scalabile e basato su dati ad accesso libero. Questo contributo intende così fornire un supporto concreto e continuo al monitoraggio del territorio, alla pianificazione energetica regionale e all'aggiornamento delle banche dati nazionali sulle fonti energetiche rinnovabili.

2 Materiali e metodi

2.1 Aree di studio

La metodologia proposta in questo studio è stata sviluppata a partire da 16 differenti aree di studio, posizionate nel sud Italia, in una zona ricca di impianti eolici, tra le regioni Molise, Campania, Puglia, Basilicata e Sicilia. Tra queste aree, 7 sono state selezionate come aree di training per addestrare l'algoritmo di classificazione (rappresentate in arancione in **Fig. 1**) e le rimanenti 9 come aree di test (in color ciano in **Fig. 1**).

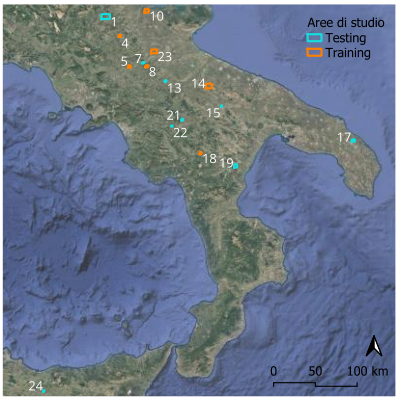

Fig. 1. Aree di studio e relativo utilizzo nella fase di training o testing dell'algoritmo.

Per ciascuna di queste aree di studio è stata selezionata una immagine della costellazione Sentinel-2, in una range temporale tra gli anni 2018 e 2024, in vari mesi dell'anno.

2.2 Metodologia

La metodologia proposta si divide in tre fasi principali, schematizzate nel *workflow* di **Fig. 2**. La prima fase della metodologia è dedicata alla super-risoluzione delle immagini S2 selezionate, limitatamente alle bande spettrali RGBNIR, con un fattore di scala da 2 a 4 volte, raggiungendo quindi un dettaglio da 5 m fino a 2.5 m. Considerando il livello raggiunto dalla comunità scientifica nello sviluppo di metodi di super-risoluzione per immagini S2, si è scelto di utilizzare algoritmi già disponibili in letteratura, dai meno complessi (es. *bicubic interpolation*) ai più avanzati (es. *deep learning*), con l'intento di mantenere la metodologia semplice e facilmente replicabile.

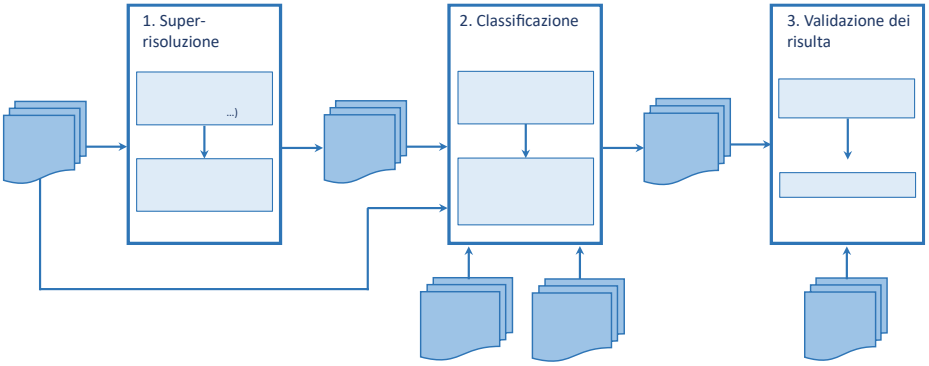

Fig. 2. Diagramma di flusso rappresentante le tre fasi principali della metodologia qui proposta.

Nella seconda fase della metodologia, si procede con la mappatura degli aerogeneratori mediante algoritmi di *machine learning* dedicati alla classificazione, in particolare l'algoritmo di classificazione supervisionato *Random Forest* [12]. In questo studio, è stata implementata una classificazione a 4 classi, comprendente: 1. WTG; 2. Aree agricole; 3. Aree naturali e bosco; 4. Strade. Per ciascuna classe sono stati utilizzati da 200 (per le classi meno presenti nelle aree di studio, WTG e aree naturali) a 400 (per le classi più presenti nelle aree di studio, aree agricole e strade) campioni per la fase di addestramento dell'algoritmo. Per ovviare allo sbilanciamento tra le classi, tra i parametri del *Random Forest* è stato selezionato "*balanced subsample*". A seguito della classificazione, i risultati sono stati post-processati con algoritmo *Sieve* per rimuovere rumore ed effetto sale e pepe nelle mappe e, come nel precedente studio [4], per ridurre il rischio di falsi positivi, la classificazione delle immagini è stata limitata esclusivamente alle aree in cui è alta la probabilità di installazione di impianti eolici, escludendo a priori aree tecnicamente non idonee (es. zone umide, corpi idrici, superfici urbane, etc.) o aree soggette a vincoli ambientali tramite l'uso di cartografia di base. Infine, la terza fase della metodologia consiste nella validazione delle mappe prodotte attraverso il calcolo della matrice di confusione, e delle relative accuratezze, tramite confronto degli aerogeneratori riconosciuti con un dataset che rappresenta la verità a terra opportunamente campionato. Per verificare l'efficacia della super-risoluzione sulle classificazioni finali, le mappe, la matrice di confusione e le metriche di accuratezza sono calcolate a partire dalla classificazione delle immagini ricampionate tramite le due metodologie, ma anche a partire dalle immagini alla risoluzione originale.
Algoritmi di super-risoluzione. Per incrementare il livello di dettaglio spaziale delle immagini Sentinel-2 (S2), sono stati applicati due algoritmi di super-risoluzione, caratterizzati da differenti fattori di scala.

1. Interpolazione bicubica (fattore 2): applicata mediante la libreria Python *rasterio* [13], consente di portare la risoluzione spaziale delle bande originali da 10 m a 5 m, attraverso una ricampionatura basata sull'interpolazione dei pixel vicini.
2. ESA OpenSR (fattore 4): utilizza il modello *Latent Diffusion Super-Resolution for Sentinel-2* (LDSR-S2), basato sulla diffusione latente, per ricostruire le bande

RGBNIR a una risoluzione spaziale di 2.5 m. Il modello impiega il campionamento DDIM (*Denoising Diffusion Implicit Models*), condizionato alle osservazioni originali a 10 m, per generare dettagli e texture mantenendo la coerenza con la struttura della scena [14].

L'impiego dei due approcci consente di confrontare una tecnica di ricampionamento convenzionale con un metodo basato su *deep learning* generativo.

Nel seguito dell'articolo, i risultati ottenuti dalle immagini alla risoluzione originale, sottoposte a super-risoluzione bicubica e a super-risoluzione tramite ESA OpenSR saranno identificati, rispettivamente, dai suffissi 1x, 2x e 4x.

3 Risultati

3.1 Immagini post super-risoluzione

In questo paragrafo sono mostrati alcuni esempi delle immagini originali e delle rispettive immagini sottoposte a super-risoluzione bicubica e ESA OpenSR (**Fig. 3**). All'aumentare del fattore di scala, si nota un miglioramento effettivo nel riconoscimento visivo dei dettagli dell'immagine, rendendo la scena stessa più intelleggibile anche per l'utente.

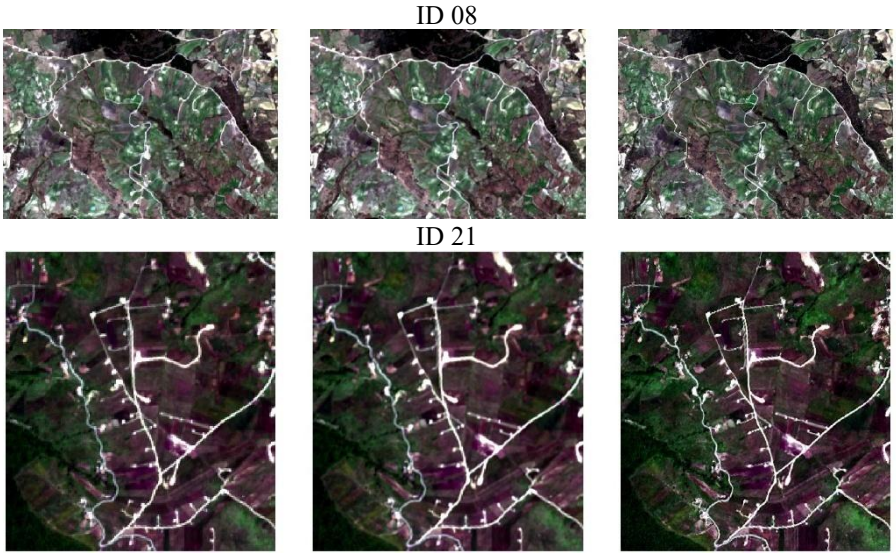

Fig. 3. Rappresentazione RGB per le immagini delle aree di studio ID 08 e ID 21, al variare della risoluzione: 1x (a sinistra), 2x (al centro), 4x (a destra).

Inoltre, viene mantenuta coerenza spettrale tra le bande alle diverse risoluzioni, come rappresentato dagli istogrammi dei valori dei pixel in **Fig. 4** (limitatamente alle immagini sull'area ID 21, per esigenze di spazio). In **Fig. 4**, gli istogrammi dei valori per i tre fattori di scala risultano praticamente sovrapposti, dimostrando che l'informazione spettrale rimane invariata al variare della risoluzione.

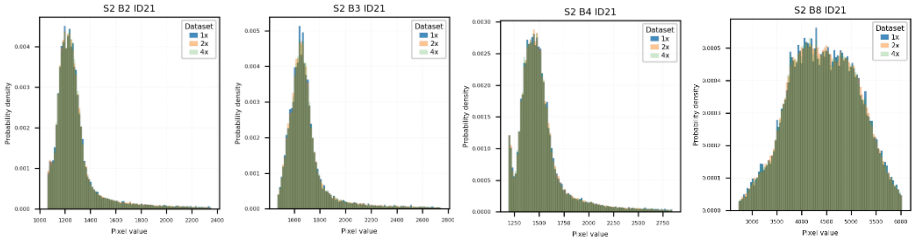

Fig. 4. Istogrammi dei valori per le 4 bande delle immagini relative all'area ID 21.

3.2 Mappe di WTGs

In **Fig. 5** vengono mostrate le mappature prodotte per alcune aree di studio utilizzate in fase di test (per esigenze di spazio). Nelle mappe, le 4 classi sono rappresentate rispettivamente con questi colori: *WTG* in rosso, *Aree agricole* in verde chiaro, *Aree naturali e bosco* in verde scuro, *Strade* in grigio.

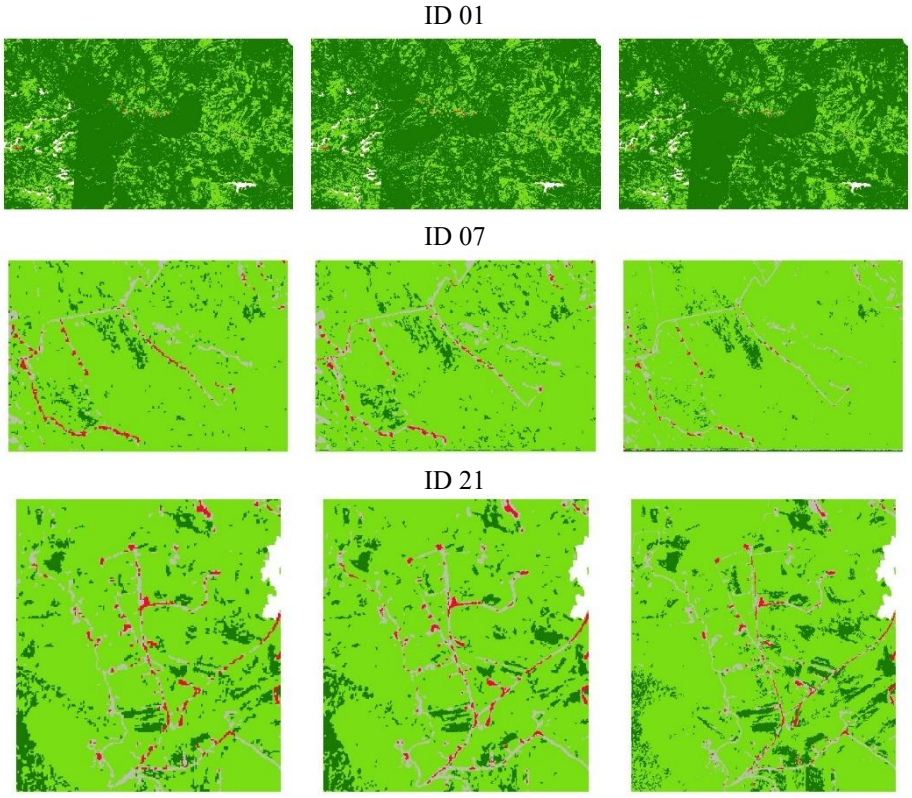

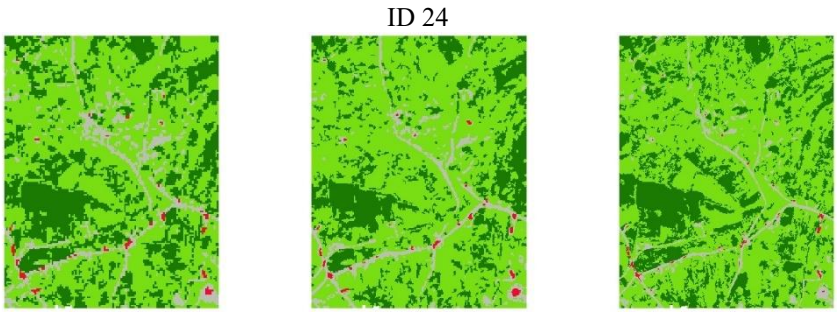

Fig. 5. Mappature generate per alcune delle aree di studio utilizzate in fase test, al variare della risoluzione: 1x (a sinistra), 2x (al centro), 4x (a destra).

3.3 Metriche di accuratezza

In

Table 1, sono mostrate le metriche di accuratezza ricavate tramite il calcolo delle matrici di confusione per le mappe generate su tutte le aree di studio test, specificatamente per la classe degli aerogeneratori.

In

Table 1: TP = *True Positive*; FP = *False Positive*; FN = *False Negative*; TN = *True Negative*.

Table 1. Metriche di accuratezza al variare della risoluzione delle immagini.

Mappa	TP	FP	FN	TN	Recall	Precision	F1-score	IoU
1x	114	91	50	934	69.5%	55.6%	61.8%	44%
2x	116	97	48	928	70.7%	54.5%	61.5%	44%
4x	109	78	55	947	66.5%	58.3%	62.1%	45%

4 Conclusioni

In questo studio sono stati testati algoritmi di super-risoluzione applicati alle immagini Sentinel-2 per la mappatura degli aerogeneratori (WTG) in alcune aree di studio italiane. Gli algoritmi mantengono la coerenza spettrale tra le bande RGBNIR alle diverse risoluzioni, migliorando al contempo il dettaglio e l'interpretabilità visiva delle immagini. Nell'ambito della classificazione pixel-based, basata sulle caratteristiche spettrali, non sono emersi miglioramenti significativi all'aumentare della risoluzione, ad eccezione di una lieve riduzione dei falsi positivi. Il maggiore dettaglio geometrico suggerisce tuttavia di esplorare approcci object-based, basati sulla segmentazione delle immagini e sul riconoscimento di forme e geometrie degli oggetti target, integrando così l'informazione spaziale e morfologica con quella spettrale.

Riferimenti bibliografici

[1] G. Ronchetti, I. Galbiati, and E. Garofalo, 'Analyzing wind and photovoltaic plant development toward the energy transition in Italy', *Next Energy*, vol. 8, p. 100265, Jul. 2025, doi: 10.1016/j.nxener.2025.100265.

[2] S. Dunnett, A. Sorichetta, G. Taylor, and F. Eigenbrod, 'Harmonised global datasets of wind and solar farm locations and power', *Sci Data*, vol. 7, no. 1, p. 130, Apr. 2020, doi: 10.1038/s41597-020-0469-8.

[3] R. Peters, J. Berlekamp, K. Tockner, and C. Zarfl, 'RePP Africa – a georeferenced and curated database on existing and proposed wind, solar, and hydropower plants', *Sci Data*, vol. 10, no. 1, p. 16, Jan. 2023, doi: 10.1038/s41597-022-01922-1.

[4] M. Aiello, D. Airoldi, and E. Garofalo, 'Mapping onshore wind turbine generators in Italy from Sentinel-2 data', *GEOmedia*, vol. 26, no. 1, Art. no. 1, Apr. 2022.

[5] C. Lanaras, J. Bioucas-Dias, S. Galliani, E. Baltsavias, and K. Schindler, 'Super-resolution of Sentinel-2 images: Learning a globally applicable deep neural network', *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 146, pp. 305–319, Dec. 2018, doi: 10.1016/j.isprsjprs.2018.09.018.

[6] S. E. Armannsson, M. O. Ulfarsson, and J. Sigurdsson, 'A Learned Reduced-Rank Sharpening Method for Multiresolution Satellite Imagery', *Remote Sensing*, vol. 17, no. 3, Art. no. 3, Jan. 2025, doi: 10.3390/rs17030432.

[7] M. Galar, R. Sesma, C. Ayala, and C. Aranda, 'SUPER-RESOLUTION FOR SENTINEL-2 IMAGES', *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. XLII-2-W16, pp. 95–102, Sep. 2019, doi: 10.5194/isprs-archives-XLII-2-W16-95-2019.

[8] M. Galar, R. Sesma, C. Ayala, L. Albizua, and C. Aranda, 'Super-Resolution of Sentinel-2 Images Using Convolutional Neural Networks and Real Ground Truth Data', *Remote Sensing*, vol. 12, no. 18, Art. no. 18, Jan. 2020, doi: 10.3390/rs12182941.

[9] L. Salgueiro Romero, J. Marcello, and V. Vilaplana, 'Super-Resolution of Sentinel-2 Imagery Using Generative Adversarial Networks', *Remote Sensing*, vol. 12, no. 15, Art. no. 15, Jan. 2020, doi: 10.3390/rs12152424.

[10] T. Tarasiewicz *et al.*, 'Multitemporal and multispectral data fusion for super-resolution of Sentinel-2 images', *IEEE Trans. Geosci. Remote Sensing*, vol. 61, pp. 1–19, 2023, doi: 10.1109/TGRS.2023.3311622.

[11] M. Chanev, I. Kamenova, P. Dimitrov, and L. Filchev, 'Evaluation of Sentinel-2 Deep Resolution 3.0 Data for Winter Crop Identification and Organic Barley Yield Prediction', *Remote Sensing*, vol. 17, no. 6, Art. no. 6, Jan. 2025, doi: 10.3390/rs17060957.

[12] L. Breiman, 'Random Forests', *Machine Learning*, vol. 45, no. 1, pp. 5–32, Oct. 2001, doi: 10.1023/A:1010933404324.

[13] 'Rasterio: access to geospatial raster data — rasterio 1.4.4 documentation'. Accessed: Oct. 13, 2026. [Online]. Available: https://rasterio.readthedocs.io/en/stable/

[14] S. Donike, C. Aybar, L. Gómez-Chova, and F. Kalaitzis, 'Trustworthy Super-Resolution of Multispectral Sentinel-2 Imagery With Latent Diffusion', *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 18, pp. 6940–6952, 2025, doi: 10.1109/JSTARS.2025.3542220.