Segmentazione delle chiome arboree da ortofoto RGB mediante deep learning per la modellazione dei servizi ecosistemici a scala di singolo albero: il caso di Firenze

Gioele Tiberi[1], Costanza Borghi[2,3,*], Mattia Niccoli[2], Elia Vangi[2], Giovanni D'Amico[2], Gherardo Chirici[2,3]

[1] Dipartimento di Architettura (DIDA), Università degli Studi di Firenze, Via della Mattonaia 8, 50121 Firenze, gioele.tiberi@unifi.it
[2] geoLAB – Laboratorio di Geomatica Forestale, Dipartimento di Scienze e Tecnologie Agrarie, Alimentari, Ambientali e Forestali (DAGRI), Università degli Studi di Firenze, Via San Bonaventura 13, 50145 Firenze, costanza.borghi@unifi.it, mattia.niccoli@unifi.it, elia.vangi@unifi.it, giovanni.damico@unifi.it, gherardo.chirici@unifi.it
[3] FFC – Fondazione per il Futuro delle Città, Firenze

Autore corrispondente: costanza.borghi@unifi.it

Abstract. Si presenta un flusso di lavoro GeoAI per delineare le singole chiome arboree (ITC) da ortofoto RGB regionali a 20 cm, con un rilevatore di deep learning e un filtro NDVI–CHM. In tre aree verdi di Firenze sono state delineate 645 chiome (55 specie): il rilevatore ne ha delineate correttamente l'83,4% (precisione 0,88, *recall* 0,83, F1 0,86), mentre le chiome contigue hanno richiesto correzione manuale. Gli attributi derivati hanno alimentato il modello AIRTREE a scala di singolo albero.

Parole chiave: GeoAI, Deep learning, Segmentazione, Ortofoto RGB, Foresta urbana

1 Introduzione

Gli alberi urbani forniscono servizi ecosistemici essenziali, tra cui la rimozione degli inquinanti atmosferici, l'assorbimento di carbonio e la mitigazione dell'isola di calore [1, 2]. La capacità di fornire tali servizi dipende in larga misura dalle dimensioni e dalla forma della chioma, oltre che da tratti specie-specifici [3]. L'informazione a scala di singolo albero proviene tradizionalmente da inventari rilevati in campo [4]: rilievi costosi e in genere limitati agli alberi pubblici [5]. Il telerilevamento e, più di recente, l'intelligenza artificiale geospaziale (GeoAI) offrono la possibilità di produrre la stessa informazione su aree estese, includendo anche la componente privata del verde urbano. Il rilevamento dei singoli alberi da LiDAR aereo è stato ampiamente indagato, soprattutto con metodi non supervisionati [6], mentre il rilevamento su ortofoto RGB ha ricevuto meno attenzione [7]. Le ortofoto RGB, prive di informazione tridimensionale diretta, sono però meno costose e più semplici da elaborare, e la crescente disponibilità di immagini ad altissima risoluzione potrebbe rendere disponibili dati per singolo albero su territori molto ampi [8, 9]. I primi metodi su immagini ottiche, basati su massimi locali di luminosità, *watershed* o regole geometriche [10], vanno calibrati su forme e dimensioni specifiche delle chiome e si trasferiscono con difficoltà all'eterogeneità urbana [7]. Il deep learning è oggi l'approccio di riferimento per

l'*object detection* su immagini RGB, ed è stato applicato con successo alla delineazione delle chiome [8, 11], fino alla scala metropolitana [9].
Gli studi di rilevamento, tuttavia, si fermano per lo più alla delineazione geometrica delle chiome [9, 11], mentre i modelli ecofisiologici per la stima dei servizi ecosistemici, come AIRTREE, sono di norma parametrizzati con dati di campo, valori medi per specie o dati aggregati per area [12, 13]. Le due linee di ricerca si sono quindi sviluppate in larga parte separatamente. Il presente lavoro, con un'attenzione prevalente alla componente GeoAI, si propone di: (i) implementare e valutare una procedura di deep learning per la delineazione delle singole chiome (*individual tree crown*, ITC) da ortofoto RGB regionali liberamente accessibili; (ii) derivare per ciascun albero gli attributi strutturali richiesti dalla modellazione, integrando LiDAR e machine learning; (iii) verificarne l'uso come input di un modello ecofisiologico multistrato.

2 Materiali e metodi

2.1 Area di studio e dati di riferimento

La procedura è stata applicata a tre aree verdi del Comune di Firenze: due piazze del centro cittadino (Piazza d'Azeglio e Piazza dell'Indipendenza) e un parco urbano (Giardino Lippi). La città è caratterizzata da un clima sub-mediterraneo con estati calde e secche e da un'elevata stabilità atmosferica, che favorisce lo stress termico e l'accumulo di inquinanti [2]. Come dato di riferimento è stato utilizzato l'inventario arboreo pubblico del Comune di Firenze, disponibile sul portale Open Data della Regione Toscana (https://dati.toscana.it/dataset/42cd1073-521f-4040-9491-e993d03663a4): il dataset è costituito da punti georeferenziati rilevati con GPS e riporta, per ciascun albero, identificativo, sito, quartiere, specie botanica, nome comune e circonferenza del fusto.

2.2 Dati telerilevati

Per la delineazione delle chiome sono state utilizzate le ortofoto della campagna regionale OFC 2023, acquisite in volo estivo da CGR S.p.A. per conto della Regione Toscana, con risoluzione a terra (GSD) di 20 cm, quattro bande (RGB e NIR) e profondità radiometrica di 8 bit per canale, accessibili tramite servizio WMS dell'infrastruttura regionale Geoscopio (https://www.regione.toscana.it/-/geoscopio). Le bande RGB sono state impiegate per il rilevamento delle chiome, mentre la banda NIR ha consentito il calcolo dell'indice NDVI (*Normalized Difference Vegetation Index*). Il modello delle altezze della vegetazione (*Canopy Height Model*, CHM) è stato ricavato dal rilievo LiDAR 2023 del Comune di Firenze, i cui modelli digitali della superficie (DSM) e del terreno (DTM) sono pubblicati tramite servizio WMS comunale (strati DSM_Lidar_2023 e DTM_Lidar_2023), per differenza tra le due griglie:

$$\mathrm{CHM} = \mathrm{DSM} - \mathrm{DTM} \tag{1}$$

Il CHM è stato filtrato per rimuovere rumore, strutture non vegetali (edifici, linee elettriche) e valori negativi, ed è stato utilizzato sia come soglia strutturale per il rilevamento sia per derivare l'altezza totale di ciascun albero.

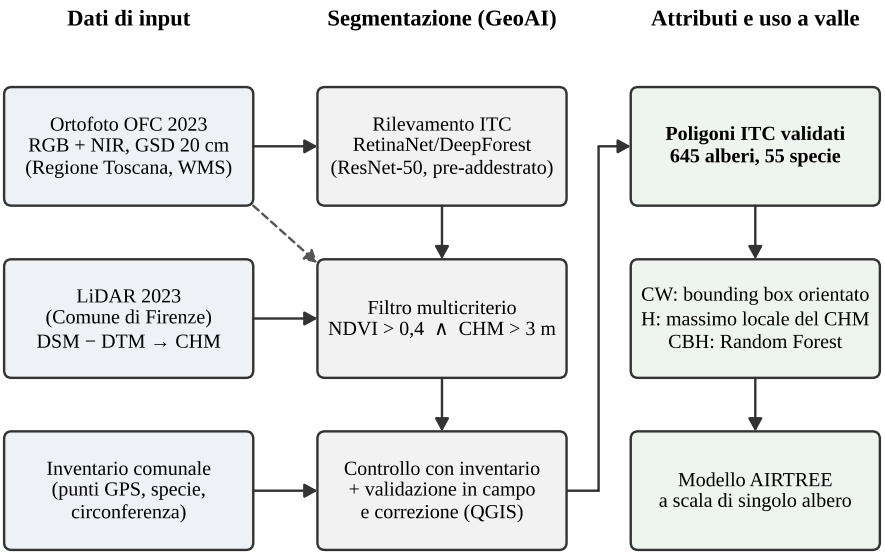

Fig. 1. Flusso di lavoro: dati di input, segmentazione delle singole chiome (ITC) con deep learning e filtro multicriterio, controllo con l'inventario e validazione in campo, derivazione degli attributi strutturali e loro uso nel modello AIRTREE.

2.3 Segmentazione delle singole chiome

La delineazione delle chiome (Fig. 1) è stata eseguita sulle ortofoto estive a 20 cm con un modello di deep learning pre-addestrato (Esri Deep Learning Model Package basato sull'architettura RetinaNet/DeepForest). Il modello implementa il flusso semi-supervisionato proposto da Weinstein et al. [7], che combina un pre-addestramento non supervisionato basato su dati LiDAR con un numero limitato di annotazioni manuali. Il rilevatore è una rete RetinaNet con estrattore di caratteristiche ResNet-50, che individua le chiome candidate come riquadri (*bounding box*), successivamente trattati come poligoni ITC.

Per eliminare falsi positivi, superfici non vegetate e vegetazione bassa, è stato applicato un filtro spaziale multicriterio che combina una soglia spettrale (NDVI > 0,4) e una strutturale (CHM > 3 m). La soglia NDVI separa la vegetazione attiva da superfici impermeabili, suolo nudo e ombre senza escludere porzioni di chioma in stress idrico estivo o auto-ombreggiate, condizioni che portano spesso l'NDVI delle latifoglie urbane sotto 0,6 [14]; la soglia di 3 m elimina prati e arbusti bassi ad alto NDVI.

Il risultato è stato sottoposto a un controllo di qualità in due fasi: nella prima, l'inventario comunale è stato usato come riferimento per individuare i poligoni contenenti più punti-albero, indicatori di possibile sotto-segmentazione (fusione di chiome adiacenti); nella seconda, ogni poligono ITC è stato verificato in campo e, dove necessario, corretto in ambiente QGIS. Ciascun poligono è stato quindi classificato come correttamente delineato o da correggere, e il dataset finale costituisce un insieme di chiome interamente validato, utilizzabile come verità a terra.

L'accuratezza è stata valutata confrontando l'output grezzo del rilevatore con i poligoni validati e corretti, assunti come riferimento. Per ciascun sito, i poligoni grezzi

e quelli di riferimento sono stati abbinati uno-a-uno massimizzando l'*Intersection over Union* (IoU) complessiva (algoritmo ungherese); seguendo Weinstein et al. [7], le coppie con IoU ≥ 0,5 sono state considerate veri positivi (TP), i poligoni grezzi non abbinati falsi positivi (FP) e le chiome di riferimento non abbinate falsi negativi (FN), da cui sono state calcolate precisione, *recall* e F1. A Giardino Lippi sono stati esclusi 57 poligoni grezzi relativi ad alberi più bassi di 3 m o abbattuti dopo il 2023, esterni al dataset di riferimento. Gli errori sono stati classificati come sotto-segmentazione (un poligono grezzo contiene due o più chiome di riferimento) o sovra-segmentazione (una chioma di riferimento è coperta da due o più poligoni grezzi, ciascuno per almeno il 20% della sua area). Infine, per le coppie TP, larghezza (§ 2.4) e area di proiezione della chioma sono state confrontate tramite bias, RMSE, RMSE% e R^2, per stimare come l'errore di segmentazione si propaghi agli input di AIRTREE.

2.4 Attributi strutturali

Larghezza della chioma. Per tenere conto della geometria irregolare delle chiome, a ciascun poligono ITC è stato adattato un rettangolo orientato di area minima (*Oriented Bounding Box*, OBB), libero di ruotare secondo la direzione principale di sviluppo della chioma. Dai due assi ortogonali del rettangolo, maggiore (W_{max}) e minore (W_{min}), la larghezza media della chioma è stata calcolata come media aritmetica, in analogia con la stima su due direzioni perpendicolari adottata nella segmentazione da telerilevamento [6]:

$$CW = (W_{max} + W_{min}) / 2 \quad (2)$$

Altezza totale e altezza di inserzione della chioma. L'altezza totale (H) è stata assunta pari al massimo locale del CHM all'interno di ciascun poligono, mentre il diametro a petto d'uomo (DBH) è stato ricavato dalla circonferenza riportata nell'inventario. L'altezza di inserzione della chioma (*Crown Base Height*, CBH), non osservabile da immagini aeree, è stata stimata con un modello Random Forest (RF). I dati di addestramento provengono dal dataset di Borghi et al. [15]: 4.507 alberi misurati in 180 aree di saggio circolari (r = 13 m) distribuite lungo un gradiente urbano–periurbano in 12 parchi di tre città italiane (Firenze, Roma e Campobasso). Il modello usa come predittori DBH, H e specie; il dataset è stato suddiviso casualmente in un insieme di addestramento (70%) e uno di test indipendente (30%), su cui sono stati calcolati coefficiente di determinazione (R^2), errore quadratico medio (RMSE) e RMSE relativo (RMSE%).

2.5 Il modello AIRTREE

Per verificarne l'utilizzabilità, gli attributi derivati sono stati usati come input di AIRTREE, un modello ecofisiologico multistrato che stima gli scambi di CO_2, O_3, NO_2, CO e particolato tra foglie e atmosfera [12, 16]. Il modello lavora separatamente per ciascuno dei 645 alberi, assegnando i parametri ecofisiologici dal database specie-specifico di Zappitelli et al. [13] (integrato con il database TRY), con forzanti meteorologiche GLDAS e concentrazioni di fondo CAMS EAC4 coerenti con l'anno di acquisizione.

3 Risultati

3.1 Accuratezza della segmentazione

La validazione in campo ha interessato tutti i 645 poligoni: 538 chiome (83,4%) erano correttamente delineate dal rilevatore, mentre le restanti 107 (16,6%) sono state ridisegnate manualmente e 71 poligoni falsi sono stati eliminati. Sugli individui isolati la delineazione è risultata affidabile e il filtro multicriterio ha rimosso efficacemente strutture non vegetali, arbusti e prati; gli errori si sono concentrati nelle chiome contigue.

Rispetto al riferimento validato in campo, l'output grezzo del rilevatore ha raggiunto, con IoU ≥ 0,5, una precisione complessiva di 0,88, una *recall* di 0,83 e un F1 di 0,86 (538 TP, 71 FP e 107 FN; Tab. 1). L'accuratezza è stata massima a Piazza dell'Indipendenza e Giardino Lippi (F1 = 0,92 in entrambi i siti), dove le chiome sono per lo più isolate o regolarmente distanziate, e minima a Piazza d'Azeglio (F1 = 0,69), dove la *recall* è scesa a 0,62. La sotto-segmentazione è stata l'errore prevalente: 24 poligoni grezzi hanno fuso 54 chiome di riferimento, e 19 di questi poligoni (44 chiome) si trovano a Piazza d'Azeglio, dove le grandi chiome mature di *Platanus* × *acerifolia* e *Celtis australis* sono contigue; la sovra-segmentazione ha interessato 28 chiome, 17 delle quali a Piazza d'Azeglio. Le chiome correttamente rilevate sono state delineate con elevata concordanza geometrica (IoU medio = 0,90): per queste, la larghezza della chioma ricavata dai poligoni grezzi differisce dal riferimento con un bias di −0,11 m e un RMSE di 0,59 m (RMSE% = 8,6%; R^2 = 0,98), e l'area di proiezione con un RMSE di 9,3 m^2 (RMSE% = 20,3%; R^2 = 0,96). Dove il rilevatore isola correttamente una chioma, la larghezza che ne deriva può quindi essere usata direttamente come input di AIRTREE.

Tab. 1. Accuratezza dell'output grezzo del rilevatore rispetto alle chiome di riferimento validate in campo (IoU ≥ 0,5). Grezzi = poligoni prodotti dal rilevatore; Rif. = chiome di riferimento; Prec. = precisione; IoU = IoU medio delle chiome correttamente rilevate; RMSE CW = RMSE (m) della larghezza delle chiome correttamente rilevate. * Esclusi 57 poligoni relativi ad alberi più bassi di 3 m o abbattuti dopo il 2023.

Sito	Grezzi (n)	Rif. (n)	TP	FP	FN	Prec.	Recall	F1	IoU	RMSE CW
Giardino Lippi	279*	278	256	23	22	0,92	0,92	0,92	0,88	0,48
Piazza d'Azeglio	150	187	116	34	71	0,77	0,62	0,69	0,93	0,83
Piazza dell'Indipendenza	180	180	166	14	14	0,92	0,92	0,92	0,92	0,55
Totale	**609**	**645**	**538**	**71**	**107**	**0,88**	**0,83**	**0,86**	**0,90**	**0,59**

Il dataset finale comprende 645 alberi appartenenti a 55 specie, per una superficie di chioma complessiva di 27.386 m^2 (2,7 ha). Composizione e struttura variano sensibilmente tra i tre siti: Giardino Lippi (278 alberi, 49 specie) presenta il maggior numero di alberi e la maggiore ricchezza specifica, con individui giovani (DBH raramente > 60 cm, H < 20 m); Piazza d'Azeglio (187 alberi, 15 specie) è caratterizzata da latifoglie mature (DBH fino a 125 cm, H fino a circa 30 m); Piazza dell'Indipendenza (180 alberi, 6 specie) presenta la massima uniformità, con netta prevalenza di *Tilia* × *europaea* (H max 18–20 m, DBH fino a 100 cm). Nel complesso, la struttura è dominata

da quattro latifoglie: *Tilia* × *europaea*, *Celtis australis*, *Platanus* × *acerifolia* e *Quercus ilex*.

3.2 Attributi strutturali

Il modello RF per la CBH (500 alberi decisionali), addestrato su 3.154 alberi e valutato su un insieme di test indipendente di 1.353 alberi, ha ottenuto R^2 = 0,53, RMSE = 1,97 m e RMSE% = 39,4%, con una varianza spiegata *out-of-bag* del 57,1%. L'altezza totale è risultata il predittore più importante, seguita da DBH e specie.

3.3 Uso del prodotto nella modellazione a scala di singolo albero

L'esecuzione di AIRTREE albero per albero ha messo in evidenza il peso degli attributi derivati dalla segmentazione. A parità di specie e sito, l'individuo più grande e quello più piccolo differiscono di 50–70 volte: in Piazza d'Azeglio il *Platanus* × *acerifolia* più grande (DBH 104 cm, area di chioma 258 m^2) raggiunge una produzione primaria netta (NPP) di 3,12 kg CO_2 d^{-1}, contro 0,06 kg CO_2 d^{-1} di un individuo giovane della stessa specie (DBH 4,5 cm, 5 m^2); in Piazza dell'Indipendenza la NPP di *Tilia* × *europaea* varia da 0,01 a 0,68 kg CO_2 d^{-1}. L'area e la larghezza della chioma, ossia le grandezze prodotte dalla segmentazione, condizionano quindi direttamente le stime: un errore di delineazione si trasferisce senza attenuazione al servizio stimato per il singolo albero.

4 Discussione

Il comportamento del rilevatore, affidabile su chiome isolate e soggetto a sotto-segmentazione su chiome contigue, non è un artefatto dell'implementazione ma una proprietà documentata dell'approccio. Weinstein et al. [7], che hanno sviluppato il flusso semi-supervisionato qui adottato, riportano in un bosco aperto di querce e pini una *recall* di 0,69 e una precisione di 0,61 (IoU ≥ 0,5), con una sotto-segmentazione crescente al crescere della complessità della copertura; in ambito urbano, Ventura et al. [9] ottengono su circa 43,5 milioni di alberi in otto città californiane una precisione del 73,6% e una *recall* del 73,3%, con errori concentrati nelle coperture dense. I valori ottenuti qui (F1 = 0,86), pur su un'area molto più limitata, sono superiori e confermano lo stesso schema: gli errori si concentrano dove le chiome sono contigue, come a Piazza d'Azeglio. Né il problema si risolve con una maggiore accuratezza a livello di pixel: la segmentazione semantica della copertura arborea urbana raggiunge F1 superiori al 91% [17], ma separa la chioma dal resto dell'immagine, non una chioma dall'altra.

La scelta metodologica adottata, la validazione integrale di ogni poligono, rende esplicito il compromesso tra estensione e accuratezza: le stime ottenute sono svincolate dall'errore di segmentazione, ma la procedura non è ancora trasferibile alla scala comunale senza intervento manuale. Il confronto tra output grezzo e dataset corretto (Tab. 1) mostra che la correzione manuale incide soprattutto sul numero e sull'identità delle chiome nelle coperture contigue, più che sulla geometria di quelle isolate (RMSE della larghezza = 0,59 m). Proprio per questo il dataset prodotto può costituire un riferimento per validare e confrontare metodi di segmentazione completamente automatici in contesto urbano.

Quanto agli attributi strutturali, l'RMSE ottenuto per la CBH (1,97 m) rientra nell'intervallo riportato in letteratura, compreso tra 1,59 e 2,51 m [18, 19], sebbene quei modelli riguardino popolamenti forestali. In ambito urbano la CBH è raramente stimata da telerilevamento ed è più spesso assunta o sostituita da valori medi per specie [13]: la stima tramite RF fornisce invece un descrittore verticale specifico per ciascun albero.

Prospettive GeoAI. L'automazione della segmentazione delle chiome contigue richiede di passare dal rilevamento per *bounding box* alla segmentazione a livello di istanza (ad es. Mask R-CNN o architetture *promptable*), di integrare nuvole di punti LiDAR ad alta densità e di sfruttare immagini multi-temporali, in cui l'asincronia fenologica tra individui adiacenti fornisce la discontinuità spettrale che una singola acquisizione estiva non offre. Un secondo limite riguarda la specie, qui ottenuta dall'inventario comunale e quindi nota solo per gli alberi pubblici: una mappa delle chiome di Firenze esiste già [20], ma è orientata alla classificazione delle specie e non fornisce altezza e CBH, per cui l'estensione al verde privato richiede una classificazione delle specie da dati multi- o iperspettrali.

5 Conclusioni

Il lavoro ha mostrato che ortofoto RGB regionali a 20 cm, elaborate con un rilevatore di deep learning pre-addestrato e un filtro multicriterio NDVI–CHM, consentono di delineare le singole chiome urbane con buona affidabilità sugli individui isolati (F1 = 0,92 a Giardino Lippi e Piazza dell'Indipendenza), mentre le chiome contigue richiedono ancora una revisione in campo (F1 = 0,69 a Piazza d'Azeglio). Integrando LiDAR e Random Forest, l'output è stato usato come input di un modello ecofisiologico alla scala del singolo albero, la stessa a cui le amministrazioni decidono abbattimenti, sostituzioni e scelta delle specie. Il dataset validato, disponibile su richiesta, può servire come riferimento per il confronto di approcci di segmentazione automatica; segmentazione a livello di istanza e classificazione delle specie sono i passi necessari per estendere la procedura all'intera città.

Ringraziamenti

Studio parzialmente finanziato dai progetti europei FORWARDS (n. 101084481), MONIFUN (n. 101134991), NextGenCarbon (n. 101184989) e NextBON (n. 101287608) e dal progetto Space It Up! (ASI–MUR, n. 2024-5-E.0, CUP I53D24000060005).

Riferimenti bibliografici

1. Nowak, D.J., Crane, D.E., Stevens, J.C.: Air pollution removal by urban trees and shrubs in the United States. Urban Forestry & Urban Greening 4(3–4), 115–123 (2006).
2. Bottalico, F., Chirici, G., Giannetti, F., De Marco, A., Nocentini, S., Paoletti, E., et al.: Air pollution removal by green infrastructures and urban forests in the city of Florence. Agriculture and Agricultural Science Procedia 8, 243–251 (2016).
3. Grote, R., Samson, R., Alonso, R., Amorim, J.H., Cariñanos, P., Churkina, G., et al.: Functional traits of urban trees: air pollution mitigation potential. Frontiers in Ecology and the Environment 14(10), 543–550 (2016).

4. Nielsen, A.B., Östberg, J., Delshammar, T.: Review of urban tree inventory methods used to collect data at single-tree level. Arboriculture & Urban Forestry 40(2), 96–111 (2014).
5. Wallace, L., Sun, Q.C., Hally, B., Hillman, S., Both, A., Hurley, J., Saldias, D.S.M.: Linking urban tree inventories to remote sensing data for individual tree mapping. Urban Forestry & Urban Greening 61, 127106 (2021).
6. Yun, T., Jiang, K., Li, G., Eichhorn, M.P., Fan, J., Liu, F., Chen, B., An, F., Cao, L.: Individual tree crown segmentation from airborne LiDAR data using a novel Gaussian filter and energy function minimization-based approach. Remote Sensing of Environment 256, 112307 (2021).
7. Weinstein, B.G., Marconi, S., Bohlman, S., Zare, A., White, E.: Individual tree-crown detection in RGB imagery using semi-supervised deep learning neural networks. Remote Sensing 11(11), 1309 (2019).
8. Weinstein, B.G., Marconi, S., Bohlman, S.A., Zare, A., White, E.P.: Cross-site learning in deep learning RGB tree crown detection. Ecological Informatics 56, 101061 (2020).
9. Ventura, J., Pawlak, C., Honsberger, M., Gonsalves, C., Rice, J., Love, N.L.R., et al.: Individual tree detection in large-scale urban environments using high-resolution multispectral imagery. International Journal of Applied Earth Observation and Geoinformation 130, 103848 (2024).
10. Ardila, J.P., Bijker, W., Tolpekin, V.A., Stein, A.: Context-sensitive extraction of tree crown objects in urban areas using VHR satellite images. International Journal of Applied Earth Observation and Geoinformation 15, 57–69 (2012).
11. Zamboni, P., Junior, J.M., Silva, J.D.A., Miyoshi, G.T., Matsubara, E.T., Nogueira, K., Gonçalves, W.N.: Benchmarking anchor-based and anchor-free state-of-the-art deep learning methods for individual tree detection in RGB high-resolution images. Remote Sensing 13(13), 2482 (2021).
12. Fares, S., Conte, A., Alivernini, A., Chianucci, F., Grotti, M., Zappitelli, I., et al.: Testing removal of carbon dioxide, ozone, and atmospheric particles by urban parks in Italy. Environmental Science & Technology 54(23), 14910–14922 (2020).
13. Zappitelli, I., Conte, A., Alivernini, A., Finardi, S., Fares, S.: Species-specific contribution to atmospheric carbon and pollutant removal: case studies in two Italian municipalities. Atmosphere 14(2), 285 (2023).
14. Alonzo, M., Bookhagen, B., Roberts, D.A.: Urban tree species mapping using hyperspectral and lidar data fusion. Remote Sensing of Environment 148, 70–83 (2014).
15. Borghi, C., Versace, S., Di Pirro, E., Travaglini, D., Chirici, G., Lasserre, B., et al.: A dataset on forest stand structures, deadwood, and tree-related microhabitats along an urban-periurban gradient in Central Italy. Data in Brief 60, 111561 (2025).
16. Bosso, L., Alivernini, A., Zappitelli, I., Conte, A., Fares, S.: AIRTREE v2.0: predicting ecosystem services provided by Italian urban parks under climate change scenarios. Journal of Environmental Management 416, 130738 (2026).
17. Martins, J.A.C., Nogueira, K., Osco, L.P., Gomes, F.D.G., Furuya, D.E.G., Gonçalves, W.N., et al.: Semantic segmentation of tree-canopy in urban environment with pixel-wise deep learning. Remote Sensing 13(16), 3054 (2021).
18. Allensworth, E., Temesgen, H., Frank, B., Gray, A.: Imputation to predict height to crown base for trees with predicted heights. Forest Ecology and Management 498, 119574 (2021).
19. Yang, Z., Yang, H., Zhou, Z., Wan, X., Zhang, H., Duan, G.: LiDAR-based modeling of individual tree height to crown base in Picea crassifolia Kom. in northern China: comparing Bayesian, Gaussian process, and random forest approaches. Forests 15(11), 1940 (2024).
20. Sicard, P., Coulibaly, F., Lameiro, M., Araminiene, V., De Marco, A., Sorrentino, B., et al.: Object-based classification of urban plant species from very high-resolution satellite imagery. Urban Forestry & Urban Greening 81, 127866 (2023).