GeoAI per la temperatura dell'aria in ambiente urbano: Random Forest multi-scala e SHAP su osservazioni MeteoTracker a Roma

Mattia Niccoli[1], Costanza Borghi[1,*], Elia Vangi[1], Giovanni D'Amico[1], Gioele Tiberi[2], Andrea Cecilia[3], Lorenzo Marinelli[3], Giampietro Casasanta[3], Juri Iurato[4], Stefania Argentini[3] e Gherardo Chirici[1,5]

[1] Università degli Studi di Firenze, Dipartimento di Scienze e Tecnologie Agrarie, Alimentari, Ambientali e Forestali (DAGRI), Via San Bonaventura 13, 50145 Firenze; mattia.niccoli@unifi.it, costanza.borghi@unifi.it, elia.vangi@unifi.it, giovanni.damico@unifi.it, gherardo.chirici@unifi.it

[2] Università degli Studi di Firenze, Dipartimento di Architettura (DIDA), Via della Mattonaia 8, 50121 Firenze; gioele.tiberi@unifi.it

[3] Consiglio Nazionale delle Ricerche, Istituto di Scienze dell'Atmosfera e del Clima (CNR-ISAC), Via Fosso del Cavaliere 100, 00133 Roma; andrea.cecilia@artov.isac.cnr.it, lorenzomarinelli@cnr.it, giampietro.casasanta@cnr.it, stefania.argentini@cnr.it

[4] Iotopon S.r.l., 09126 Cagliari; juri.iur@gmail.com

[5] Fondazione per il Futuro delle Città, Via Sardegna 49, 00187 Roma

[*] Autore corrispondente: costanza.borghi@unifi.it

Abstract. Oltre un milione di misure di temperatura dell'aria da sensori MeteoTracker su autobus (Roma, agosto 2024) sono analizzate con un flusso GeoAI: 140 predittori su buffer di 50–10.000 m, Random Forest orari validati con blocchi spaziali e interpretati con SHAP. Per ogni fattore emergono scala, ora e contributo in °C: impermeabilizzazione di notte a 1000–5000 m (2–2,4 °C), vegetazione e acqua di giorno a 2500–10.000 m (fino a circa 1 °C), distanza dal mare, di segno opposto tra notte e pomeriggio.

Parole chiave: GeoAI, Intelligenza artificiale interpretabile, Random Forest, SHAP, Sensori mobili, Isola di calore urbana.

1 Introduzione

La temperatura dell'aria (Tair) è la grandezza più direttamente legata al comfort termico e ai rischi per la salute in città, ma è difficile osservarla con la densità necessaria a descrivere l'isola di calore urbana (UHI) [1, 2]. Per misurare la Tair vengono solitamente utilizzate reti di stazioni fisse, spesso troppo rade o di qualità non controllata per descrivere la variabilità interna alla città a scala fine [3]. I sensori mobili, come i MeteoTracker (MT) montati sui mezzi pubblici, producono invece grandi quantità di osservazioni georeferenziate ad alta risoluzione spazio-temporale [4, 5]. Si tratta di dati eterogenei e difficili da trattare con i metodi tradizionali di analisi spaziale,

che si prestano invece ad approcci di intelligenza artificiale geospaziale (GeoAI) [6, 7], applicati all'analisi dell'isola di calore [8].

Il legame tra Tair e ambiente urbano cambia con la scala spaziale e con l'ora del giorno. I materiali impermeabili rilasciano di notte il calore accumulato durante il giorno e un basso *Sky View Factor* (SVF) rallenta il raffreddamento notturno, mentre la vegetazione agisce soprattutto di giorno e mare e corpi idrici intervengono con l'inerzia termica [1, 9]. Questi processi operano a scale diverse, descritte di solito con buffer di raggio crescente attorno ai punti di misura [10], e le relazioni tra forma urbana e Tair possono non essere lineari [11]. I modelli Random Forest (RF) [12], che non richiedono ipotesi a priori, sono infatti un riferimento per la mappatura di Tair a scala molto fine [10] e, su misure mobili, hanno fornito prestazioni superiori alla regressione lineare [11].

Applicare questi modelli a misure mobili richiede però alcune cautele. Ogni osservazione combina un luogo e un'ora di acquisizione, e osservazioni consecutive distano pochi metri: la dipendenza spaziale che ne deriva porta una validazione casuale a sovrastimare le prestazioni dei modelli [13]. I predittori calcolati su buffer concentrici sono inoltre fortemente correlati, e questo rende instabile l'attribuzione dei contributi ai singoli predittori [14]. La letteratura sulla GeoAI indica poi, tra i limiti principali da superare, la scarsa attenzione alla scala spaziale e la natura di "scatola nera" dei modelli di *machine learning* [7, 8]. Su quest'ultimo punto, le *SHapley Additive exPlanations* (SHAP) [15], uno strumento dell'intelligenza artificiale interpretabile (*eXplainable AI*, XAI) [16], offrono interpretabilità ai risultati di RF e sono state applicate di recente ai fattori dell'UHI [17].

Poiché l'analisi congiunta di questi processi nello spazio e nel tempo ad alta risoluzione resta poco esplorata, il contributo propone un flusso di lavoro GeoAI multi-scala e interpretabile che affronta esplicitamente questi aspetti per capire quando e a quale scala spaziale (50–10.000 m) è più forte la relazione fra Tair, misurata a Roma nel mese di agosto 2024 (Fig. 1), e tre gruppi di fattori: (Q1) la morfologia urbana, o infrastruttura grigia; (Q2) la vegetazione, o infrastruttura verde; (Q3) il contesto geografico, cioè mare, acque interne e topografia. A strumenti di analisi *single-variable* (PCA e correlazioni) si affiancano RF orarie, validate con blocchi spaziali e interpretate con SHAP.

2 Dati e flusso di lavoro GeoAI

Il flusso di lavoro è riassunto in Fig. 2.

2.1 Osservazioni e regimi meteorologici

Quindici MT (IoTopon S.r.l.), installati su autobus ATAC nell'ambito del progetto TRAMS (ATAC S.p.A. e CNR-ISAC), hanno raccolto 1.063.267 osservazioni georeferenziate di Tair tra il 1° e il 31 agosto 2024, una ogni 5 secondi, lungo la rete stradale principale di Roma [5]. Il sensore registra solo con il mezzo in movimento e sopra i 7 km/h corregge l'errore radiativo, con un'accuratezza di ±0,3 °C [18]. Per

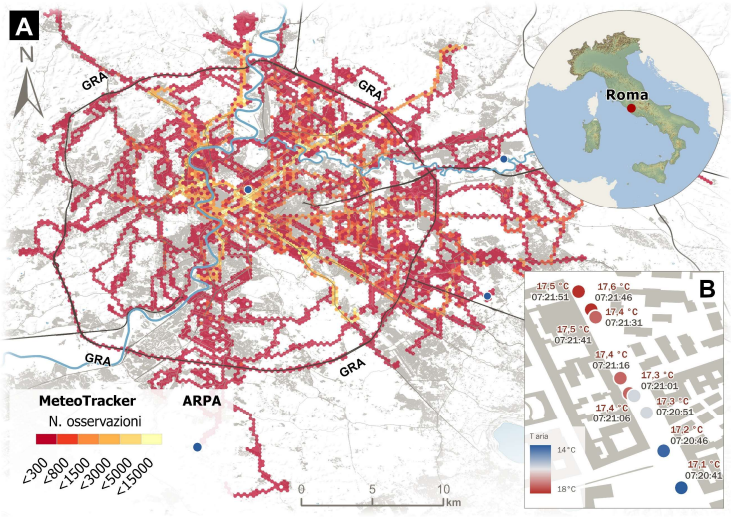

Fig. 1. (A) Densità delle osservazioni MeteoTracker raccolte a Roma nell'agosto 2024 (numero di osservazioni per esagono). Sono riportati anche il Grande Raccordo Anulare (GRA), la rete stradale principale, il reticolo idrografico e le stazioni ARPA Lazio. (B) Dettaglio di osservazioni MT lungo la rete stradale, colorate in base alla temperatura dell'aria: un esempio dell'elevata risoluzione spazio-temporale delle acquisizioni.

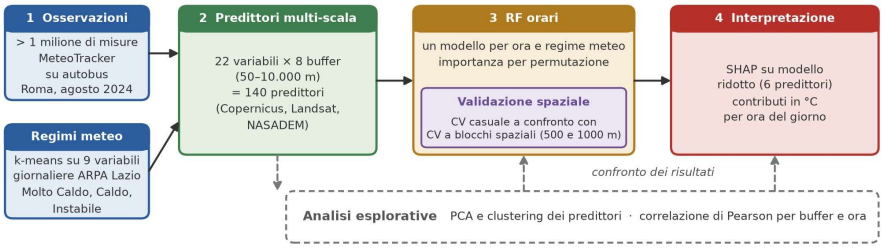

Fig. 2. Schema del flusso di lavoro: dalle osservazioni MeteoTracker e dai regimi meteorologici, attraverso i predittori geospaziali multi-scala, ai modelli Random Forest orari, verificati con la validazione spaziale e interpretati con SHAP. Le analisi esplorative (PCA e correlazione), esterne al flusso GeoAI, utilizzano gli stessi predittori e i loro risultati sono confrontati con l'importanza dei predittori nei modelli RF e con i valori SHAP.

confrontare giorni con condizioni sinottiche simili, i giorni sono stati classificati con il k-means (k = 3, *Elbow Method*) in base alle medie giornaliere standardizzate di nove variabili misurate da tre stazioni ARPA Lazio. Ne risultano tre regimi meteo: Molto Caldo (VH, 16 giorni), Caldo (H, 11) e Instabile (U, 3). I risultati riportati riguardano il regime VH, quello in cui l'UHI è più intensa [9].

Poiché i percorsi degli autobus determinano i luoghi campionati, è stata verificata la stabilità del campionamento nel corso della giornata: le mappe orarie delle osservazioni sono simili tra loro (correlazione di Spearman mediana 0,65 su una griglia di 500 m) e

gli ambienti campionati coprono la stessa gamma di condizioni urbane a tutte le ore, anche di notte, quando il servizio è ridotto. Le differenze tra i modelli orari riflettono quindi l'ora del giorno più che uno spostamento dei luoghi campionati.

2.2 Predittori geospaziali multi-scala

Per ogni osservazione MT sono state estratte 22 variabili entro otto buffer concentrici (50, 100, 200, 500, 1000, 2500, 5000 e 10.000 m) [10], per un totale di 140 predittori. Impermeabilizzazione [19], altezza degli edifici [20], Sky View Factor (SVF), copertura arborea [21], altezza degli alberi [22] e NDVI sono descritti da media e deviazione standard; superfici sigillate, forestali, erbacee e d'acqua dalla proporzione di pixel [23]. Distanza dal mare e dalle acque interne, quota, pendenza ed esposizione [24], sei bande Landsat e LST entrano invece come valori puntuali. In questo modo la scala spaziale diventa una dimensione dell'insieme dei predittori: la scala a cui ogni variabile è più informativa emerge dal modello, invece di essere fissata a priori. La letteratura GeoAI distingue i modelli *spatially explicit*, che incorporano lo spazio nella propria formulazione o nei dati di input [6, 7]. Nel flusso proposto lo spazio entra attraverso i buffer, cioè gli intorni a più scale di ciascuna osservazione MT, e attraverso la validazione a blocchi spaziali, mentre l'algoritmo RF non utilizza direttamente coordinate o relazioni di vicinato.

2.3 Analisi esplorative, modelli RF e SHAP

Come analisi esplorative, la struttura dei predittori è stata descritta con l'analisi delle componenti principali (PCA) e con il clustering gerarchico, e la correlazione di Pearson ha misurato l'associazione tra ciascun predittore e Tair per ogni buffer e ogni ora.

Per ogni ora e regime meteo è stato poi addestrato un modello RF sui 140 predittori, usando solo le osservazioni di quell'ora; l'importanza per permutazione di ciascun predittore, calcolata per ogni buffer e ogni ora, indica la scala e il momento in cui è più rilevante. Le prestazioni sono state stimate con una validazione incrociata (CV) casuale a 10 fold e con una CV a blocchi spaziali, in cui celle quadrate di 500 e 1000 m sono assegnate per intero a uno dei dieci fold, così che osservazioni vicine non finiscano sia nell'insieme di addestramento sia in quello di verifica [13].

I valori SHAP, calcolati con TreeSHAP [25], attribuiscono a ogni osservazione il contributo in °C di ciascun predittore alla Tair stimata. Poiché i buffer concentrici di una stessa variabile sono fortemente correlati [14], SHAP è stato applicato a un modello ridotto con sei predittori, ciascuno al buffer di massima importanza media e fisso nelle 24 ore: impermeabilizzazione (2500 m), SVF (5000 m), copertura arborea (5000 m), superfici d'acqua (10.000 m), distanza dal mare e quota. La scala rilevante in ogni ora si legge quindi dall'importanza del modello completo, mentre SHAP ne quantifica segno e intensità alla scala scelta.

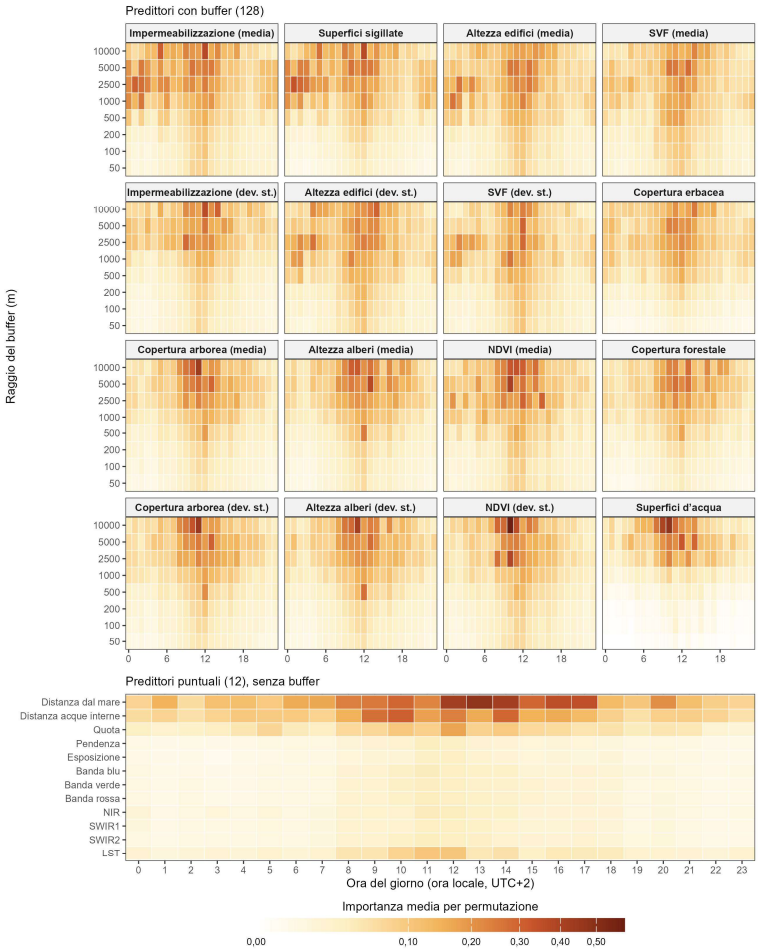

Fig. 3. Importanza media per permutazione dei 140 predittori nei modelli RF orari del regime VH: i 128 predittori con buffer, per raggio e ora (in alto), e i 12 predittori puntuali (in basso), con la stessa scala di colore.

3 Risultati

3.1 Analisi esplorative

Le prime due componenti principali spiegano il 56% della varianza dei predittori: la PC1 (33,5%) è legata soprattutto ad altezza degli edifici, SVF e impermeabilizzazione, la PC2 (22,5%) a copertura e altezza degli alberi, NDVI e copertura forestale. Il clustering gerarchico sulla PCA distingue quattro gruppi: l'infrastruttura grigia;

vegetazione e acqua a scala ampia (2500–10.000 m); vegetazione e acqua a scala piccola e media (50–1000 m); gli indicatori di apertura (SVF medio e copertura erbacea). Le correlazioni anticipano gli schemi che emergono dai modelli: l'impermeabilizzazione è fortemente correlata con Tair di notte e al primo mattino ($r \approx 0,7$), con un massimo tra 2500 e 5000 m; la copertura arborea è correlata negativamente, di notte soprattutto a scala piccola e media e al mattino e nel tardo pomeriggio a scala ampia; la distanza dal mare ha correlazione negativa tra le 02:00 e le 10:00 e positiva tra le 13:00 e le 20:00.

3.2 Modelli RF: prestazioni, scale e ore rilevanti

Applicando una CV casuale, l'RMSE mediano dei 24 modelli orari è 0,87 °C ($R^2 = 0,49$); con blocchi spaziali di 500 e 1000 m sale a 0,97 e 1,01 °C, un aumento vicino o inferiore all'accuratezza dei sensori, mentre l'R^2 scende a 0,34. Le prestazioni sono migliori di notte e il modello ridotto a sei predittori mantiene gran parte della capacità predittiva (RMSE mediano 0,90 °C con la CV casuale e 1,02 e 1,07 °C con blocchi di 500 e 1000 m).

Quasi a ogni ora l'importanza dei predittori con buffer si concentra sui raggi di 1000 m e oltre, ma le scale coinvolte cambiano nel corso della giornata (Fig. 3). Di notte impermeabilizzazione e superfici sigillate sono più rilevanti tra 1000 e 5000 m. Vegetazione e acqua raggiungono la massima importanza tra le 08:00 e le 14:00, a 2500–10.000 m. Tra i predittori puntuali, la distanza dal mare è il più importante quasi a ogni ora tra le 12:00 e le 17:00. Raggruppando i predittori secondo i gruppi della PCA, di notte la morfologia urbana ha una quota di importanza pari a 1,5–1,9 volte quella attesa in base al numero di predittori del gruppo, mentre vegetazione e acqua a scala ampia arrivano a circa il doppio dell'atteso tra le 08:00 e le 11:00 e tra le 18:00 e le 20:00: gli stessi momenti e le stesse scale indicati dalle correlazioni.

3.3 Contributi dei predittori stimati con SHAP

SHAP traduce queste associazioni in contributi espressi in °C (Fig. 4). Tra le 00:00 e le 04:00 il contributo mediano del quartile più impermeabilizzato supera di circa 2–2,4 °C quello del quartile meno impermeabilizzato, con una dispersione delle singole osservazioni fino a circa 4 °C durante le ore notturne; il contrasto si attenua di giorno e torna a crescere dopo le 21:00. La copertura arborea ha contributi modesti di notte e negativi alle 08:00–09:00 e alle 18:00–19:00 (contrasto mediano 0,2–0,5 °C, fino a circa −2 °C per singole osservazioni). Le superfici d'acqua mostrano un segnale netto e crescente tra il primo mattino e la tarda mattinata, con un massimo intorno alle 10:00: aree con una maggiore superficie blu sono associate a temperature più fresche rispetto a zone meno ricche d'acqua, fino a 1 °C considerando gli SHAP mediani e fino a 3 °C sulle singole osservazioni. Per la distanza dal mare il segno si inverte: tra le 03:00 e le 10:00 le località più interne mostrano temperature più basse di circa 0,5 °C sui valori mediani e fino a 3 °C sulle singole osservazioni rispetto a quelle costiere, dalle 13:00 alle 22:00 superiori di 0,2–1,1 °C (valori mediani), con un massimo verso le 16:00.

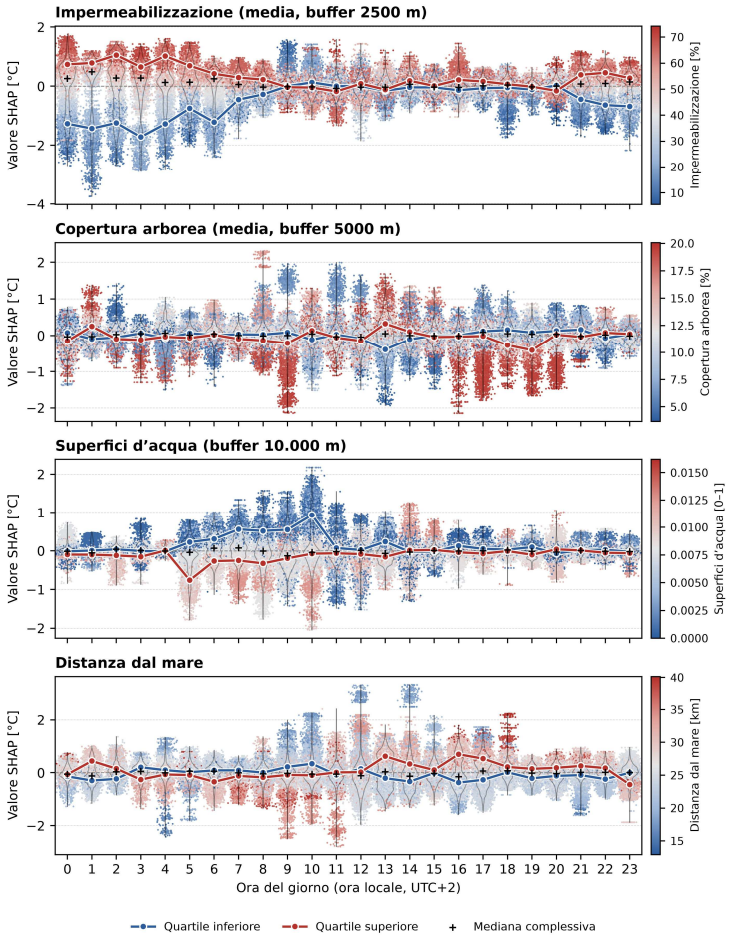

Fig. 4. Valori SHAP orari nel regime VH per impermeabilizzazione, copertura arborea, superfici d'acqua e distanza dal mare. Ogni punto è una singola osservazione MT, colorata in base al valore del predittore (rosso: alto, blu: basso); le linee indicano la mediana oraria di SHAP nel quartile inferiore (blu) e superiore (rosso) del predittore.

4 Discussione e conclusioni

Il flusso GeoAI associa a ogni fattore una combinazione caratteristica di scala e ora. La morfologia urbana prevale di notte, a buffer di 1000–5000 m, in modo coerente con l'accumulo di calore nei materiali impermeabili durante il giorno e con il minore raffreddamento radiativo dei tessuti compatti; l'ordine di grandezza dei contrasti è in linea con l'UHI notturna di 3–4 °C stimata a Roma con la stessa rete [5]. Vegetazione e superfici d'acqua a scala ampia sono associate a temperature più basse soprattutto al

mattino e, per la vegetazione, nel tardo pomeriggio, quando ombreggiamento ed evapotraspirazione diventano i processi principali. La distanza dal mare inverte invece il segno della propria associazione tra notte e pomeriggio, in accordo con l'effetto di mitigazione del mare e con l'esposizione alla brezza [26].

Le analisi esplorative, pur non appartenendo alla GeoAI, convergono con RF e SHAP sugli stessi schemi, e questo rafforza l'interpretazione dei modelli. La validazione a blocchi spaziali, un aspetto centrale nella GeoAI per via della dipendenza tra osservazioni vicine, mostra che le prestazioni sono sovrastimate solo in misura modesta in termini di RMSE e fornisce la stima più prudente della trasferibilità dei modelli alle parti della città non campionate. I buffer concentrici permettono di far emergere la scala dal modello, ma obbligano a usare un modello ridotto per SHAP, che descrive ogni predittore a una sola scala fissa. Lo studio presenta alcuni limiti: la sovrapposizione tra spazio e tempo, attenuata ma non eliminata dall'aggregazione oraria; la limitazione ai corridoi stradali serviti dagli autobus; l'assenza di descrittori della ventilazione; il riferimento a una sola città e a un solo mese.

Sviluppi futuri potrebbero rendere il flusso più esplicitamente spaziale, ad esempio con varianti di RF che tengono conto dell'eterogeneità spaziale delle relazioni o con estensioni di SHAP che trattano la posizione come un predittore [8], e utilizzarlo per produrre mappe continue di Tair. Il rilevamento mobile ad alta densità, unito a modelli di *machine learning* validati spazialmente e interpretabili, permette di indicare dove e quando concentrare gli interventi di mitigazione del calore.

Ringraziamenti

Questo contributo è la versione estesa in italiano di un articolo in revisione presso *Sustainable Cities and Society*. Si ringraziano i progetti LIFE17 CCA/GR/000108, LIFE-SIRIUS (LIFE21-GIE-EL-LIFE), PRIN 2022 RESTART (Prot. 2022KZ2AJE) e Space It Up (ASI e MUR, Contratto n. 2024-5-E.0, CUP I53D24000060005), ATAC S.p.A. per la flotta di autobus della campagna TRAMS, l'Ufficio Clima di Roma Capitale, ed in particolare la persona di Alessandro Conidi, e Iotopon S.r.l., produttore dei MeteoTracker.

Riferimenti bibliografici

1. Oke, T.R., Mills, G., Christen, A., Voogt, J.A.: Urban Climates. Cambridge University Press, Cambridge (2017).
2. Good, E.J.: An in situ-based analysis of the relationship between land surface "skin" and screen-level air temperatures. Journal of Geophysical Research: Atmospheres 121 (15), 8801–8819 (2016).
3. Napoly, A., Grassmann, T., Meier, F., Fenner, D.: Development and application of a statistically-based quality control for crowdsourced air temperature data. Frontiers in Earth Science 6, 118 (2018).
4. Zanetti, C., Rubert, L., De Marchi, M., Pappalardo, S.E.: Bridging the gap: matching data from low-cost mobile sensors and satellite for urban heat island research. A case study in

Padua, Italy. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XLVIII-4/W10-2024, 205–211 (2024).
5. Cecilia, A., Marinelli, L., Borghi, C., Casasanta, G., Chirici, G., et al.: The impact of tree canopy cover and imperviousness on air temperature during summer using low cost sensors on public transportation in Rome, Italy. Urban Climate 66, 102832 (2026).
6. Janowicz, K., Gao, S., McKenzie, G., Hu, Y., Bhaduri, B.: GeoAI: spatially explicit artificial intelligence techniques for geographic knowledge discovery and beyond. International Journal of Geographical Information Science 34 (4), 625–636 (2020).
7. Liu, P., Biljecki, F.: A review of spatially-explicit GeoAI applications in Urban Geography. International Journal of Applied Earth Observation and Geoinformation 112, 102936 (2022).
8. Mai, G., Xie, Y., Jia, X., Lao, N., Rao, J., et al.: Towards the next generation of Geospatial Artificial Intelligence. International Journal of Applied Earth Observation and Geoinformation 136, 104368 (2025).
9. Masson, V., Lemonsu, A., Hidalgo, J., Voogt, J.: Urban climates and climate change. Annual Review of Environment and Resources 45, 411–444 (2020).
10. Venter, Z.S., Brousse, O., Esau, I., Meier, F.: Hyperlocal mapping of urban air temperature using remote sensing and crowdsourced weather data. Remote Sensing of Environment 242, 111791 (2020).
11. Tian, L., Hao, T., He, X., Chan, I., Niu, J., et al.: Examining the non-linear relationship between urban form and air temperature at street level: a case of Hong Kong. Building and Environment 264, 111884 (2024).
12. Breiman, L.: Random forests. Machine Learning 45 (1), 5–32 (2001).
13. Ploton, P., Mortier, F., Réjou-Méchain, M., Barbier, N., Picard, N., et al.: Spatial validation reveals poor predictive performance of large-scale ecological mapping models. Nature Communications 11, 4540 (2020).
14. Aas, K., Jullum, M., Løland, A.: Explaining individual predictions when features are dependent: more accurate approximations to Shapley values. Artificial Intelligence 298, 103502 (2021).
15. Lundberg, S.M., Lee, S.-I.: A unified approach to interpreting model predictions. In: Advances in Neural Information Processing Systems 30 (NIPS 2017). Curran Associates (2017).
16. Longo, L., Brcic, M., Cabitza, F., Choi, J., Confalonieri, R., et al.: Explainable Artificial Intelligence (XAI) 2.0: a manifesto of open challenges and interdisciplinary research directions. Information Fusion 106, 102301 (2024).
17. Hong, T., Yim, S.H.L., Heo, Y.: Interpreting complex relationships between urban and meteorological factors and street-level urban heat islands: application of random forest and SHAP method. Sustainable Cities and Society 126, 106353 (2025).
18. Barbano, F., Brattich, E., Cintolesi, C., Ghafoor Nizamani, A., Di Sabatino, S., et al.: Performance evaluation of MeteoTracker mobile sensor for outdoor applications. Atmospheric Measurement Techniques 17 (10), 3255–3278 (2024).
19. Copernicus Land Monitoring Service: Imperviousness Density 2018 (raster 10 m), Europe, 3-yearly, https://doi.org/10.2909/3bf542bd-eebd-4d73-b53c-a0243f2ed862, ultimo accesso 2026/10/12.
20. Copernicus Land Monitoring Service: Urban Atlas Building Height 2012 (raster 10 m), Europe, version 3, https://doi.org/10.2909/42690e05-edf4-43fc-8020-33e130f62023, ultimo accesso 2026/10/12.
21. Copernicus Land Monitoring Service: Tree Cover Density 2018–present (raster 10 m), Europe, yearly, https://doi.org/10.2909/e677441e-fb94-431c-b4f9-304f10e4dfd8, ultimo accesso 2026/10/12.

22. Tolan, J., Yang, H.-I., Nosarzewski, B., Couairon, G., Vo, H.V., et al.: Very high resolution canopy height maps from RGB imagery using self-supervised vision transformer and convolutional decoder trained on aerial lidar. Remote Sensing of Environment 300, 113888 (2024).
23. Copernicus Land Monitoring Service: CLCplus Backbone 2021 (raster 10 m), Europe, 3-yearly, https://doi.org/10.2909/71fc9d1b-479f-4da1-aa66-662a2fff2cf7, ultimo accesso 2026/10/12.
24. NASA JPL: NASADEM Merged DEM Global 1 arc second V001. NASA Land Processes Distributed Active Archive Center, https://www.earthdata.nasa.gov/data/catalog/lpcloud-nasadem-hgt-001, ultimo accesso 2026/10/12.
25. Lundberg, S.M., Erion, G., Chen, H., DeGrave, A., Prutkin, J.M., et al.: From local explanations to global understanding with explainable AI for trees. Nature Machine Intelligence 2 (1), 56–67 (2020).
26. Potgieter, J., Nazarian, N., Lipson, M.J., Hart, M.A., Ulpiani, G., et al.: Combining high-resolution land use data with crowdsourced air temperature to investigate intra-urban microclimate. Frontiers in Environmental Science 9, 720323 (2021).