

GeoAI Berbasis Machine Learning untuk Pemodelan Suhu Permukaan dan *Urban Heat Island* di Kota Cimahi

Dhanny Kurnia Kevin Karewur^{1*}, Rasoki Mintana Debara Daulay², Okyza Maherdy Prabowo³

^{1,2}Program Studi Sistem Informasi, STMIK AMIK BANDUNG, Bandung, Indonesia

³Program Studi Teknik Informatika, STMIK AMIK BANDUNG, Bandung, Indonesia

*Corresponding Author e-mail: dhany@stmik-amikbandung.ac.id

Email: rdaulay@stmik-amikbandung.ac.id, okyza@stmik-amikbandung.ac.id

Abstract: *Urban heat island (UHI) intensity in rapidly urbanizing Indonesian cities is commonly assessed through land surface temperature (LST) derived from satellite thermal sensors, yet fine-resolution, machine-learning-based spatial prediction for small and medium cities in the Bandung Raya region remains limited. This study applies a geospatial artificial intelligence (GeoAI) workflow to model and map LST in Kota Cimahi, West Java, using four cloud-screened Landsat 8/9 Collection 2 Level-2 thermal scenes from July–August 2025, resampled to the 10 m grid of Sentinel-2-derived NDVI, NDBI, and NDWI and Dynamic World built-up density and land-cover layers. Random Forest (RF) and Support Vector Regression (SVR) models were trained on 627,687 pixels and evaluated on 269,009 independent pixels. RF achieved a marginally higher test R^2 (0.528; RMSE 2.17 °C; MAE 1.63 °C) than SVR (R^2 0.525; RMSE 2.18 °C; MAE 1.61 °C). Built-up density and NDBI dominated under RF impurity-based importance, whereas NDVI dominated under SVR permutation importance, reflecting strong multicollinearity among the optical predictors. Spatial prediction confirmed a consistent thermal gradient, with the highest LST in the built-up southern core and the lowest in the vegetated northern highlands, although one acquisition date relied on cross-date gap-filling for over 90% of its pixels due to persistent cloud cover—a limitation reported transparently rather than concealed. The resulting maps offer local governments and urban planners a replicable, open-data basis for prioritizing heat-mitigation interventions, such as green-infrastructure siting, at the identified thermal hotspots*

Keywords: GeoAI; Land Surface Temperature; Random Forest; Support Vector Machine; Urban Heat Island

Abstrak: Intensitas pulau panas perkotaan (urban heat island/UHI) di kota-kota Indonesia yang berkembang pesat umumnya dikaji melalui suhu permukaan tanah (land surface temperature/LST) hasil penginderaan jauh termal, namun pemodelan spasial prediktif berbasis pembelajaran mesin dengan resolusi tinggi untuk kota berukuran kecil-menengah di kawasan Bandung Raya masih relatif terbatas. Penelitian ini menerapkan kerangka kerja Geospatial Artificial Intelligence (GeoAI) untuk memodelkan dan memetakan LST di Kota Cimahi, Jawa Barat, menggunakan empat skena termal Landsat 8/9 Collection 2 Level-2 (Juli–Agustus 2025) yang telah disaring dari piksel berawan dan diresampling ke grid 10 m mengikuti NDVI, NDBI, dan NDWI dari Sentinel-2 serta kerapatan terbangun dan kelas tutupan lahan dari Dynamic World. Model Random Forest (RF) dan Support Vector Regression (SVR) dilatih pada 627.687 piksel dan diuji pada 269.009 piksel independen. RF menghasilkan R^2 uji yang sedikit lebih tinggi (0,528; RMSE 2,17°C; MAE 1,63°C) dibandingkan SVR (R^2 0,525; RMSE 2,18°C; MAE 1,61°C). Kerapatan terbangun dan NDBI menjadi prediktor dominan berdasarkan importance bawaan RF, sementara NDVI dominan berdasarkan permutation importance SVR, mengindikasikan multikolinearitas kuat antarprediktor optik. Prediksi spasial mengonfirmasi gradien termal yang konsisten, dengan LST tertinggi terkonsentrasi di inti terbangun bagian selatan dan terendah di kawasan tervegetasi bagian utara, meskipun satu tanggal akuisisi mengandalkan penambalan data lintas-tanggal untuk lebih dari 90% pikselnya akibat tutupan awan—sebuah keterbatasan yang dilaporkan secara transparan, bukan disembunyikan. Peta yang dihasilkan dapat menjadi dasar berbasis data terbuka bagi pemerintah daerah dan perencana kota untuk memprioritaskan intervensi mitigasi panas, seperti penempatan infrastruktur hijau, pada titik-titik panas yang teridentifikasi

Kata Kunci: GeoAI; Suhu Permukaan Tanah; Random Forest; Support Vector Machine; Pulau Panas Perkotaan

How to Cite: Dhanny Kurnia Kevin Karewur, Rasoki Mintana Debara Daulay, Okyza Maherdy Prabowo, (2026). GeoAI Berbasis Machine Learning untuk Pemodelan Suhu Permukaan dan *Urban Heat Island* di Kota Cimahi. *Journal Transformation of Mandalika*, E-ISSN: 2745-5882, P-ISSN: 2962-2956, 4(8), 175-181. <https://doi.org/10.36312/10.36312/vol4iss1pp952-962>



<https://doi.org/10.36312/10.36312/vol4iss1pp952-962>

Copyright ©2026, Author (s)

This is an open-access article under the [CC-BY-SA License](https://creativecommons.org/licenses/by-sa/4.0/).



PENDAHULUAN

Urbanisasi yang berlangsung cepat di kota-kota Indonesia secara konsisten diasosiasikan dengan peningkatan suhu permukaan tanah (land surface temperature/LST) dan munculnya fenomena pulau panas perkotaan (urban heat island/UHI), yaitu kondisi area terbangun memiliki suhu yang secara sistematis lebih tinggi dibandingkan area vegetasi atau lahan terbuka di sekitarnya. Fenomena ini telah lama dikaji melalui penginderaan jauh termal karena kemampuannya memetakan variasi suhu permukaan secara spasial dan berulang pada area yang luas tanpa memerlukan jaringan stasiun pengukuran darat yang padat (Voogt & Oke, 2003). Di kawasan Bandung Raya, yang meliputi Kota Bandung, Kota Cimahi, dan sebagian Kabupaten Bandung, pola peningkatan LST akibat hilangnya tutupan vegetasi dan meluasnya area terbangun telah didokumentasikan sejak lebih dari satu dekade lalu (Ramdani & Setiani, 2014) dan dikonfirmasi pada kajian regional yang lebih baru yang membandingkan intensitas pulau panas permukaan (surface urban heat island intensity/SUHI) antara kawasan metropolitan Jakarta, kawasan Kota Bandung dan Kota Cimahi, serta Kota Sukabumi (Fajary et al., 2024).

Secara metodologis, kajian LST berbasis penginderaan jauh umumnya memanfaatkan kombinasi data termal dengan indeks spektral optik untuk menjelaskan variasi suhu permukaan, antara lain Normalized Difference Vegetation Index (NDVI) yang merepresentasikan kerapatan vegetasi (Tucker, 1979), Normalized Difference Built-up Index (NDBI) yang merepresentasikan tingkat keterbangunan lahan (Zha et al., 2003), dan Normalized Difference Water Index (NDWI) yang merepresentasikan kandungan air pada permukaan dan vegetasi (McFeeters, 1996). Ketiga indeks tersebut secara empiris terbukti berkorelasi kuat dengan LST pada berbagai studi UHI di Indonesia, termasuk di Surabaya (Kurniati & Nitivattananon, 2016) dan di kawasan Jawa bagian barat (Fajary et al., 2024), namun sebagian besar studi tersebut masih mengandalkan analisis regresi linier atau korelasi sederhana yang kurang mampu menangkap hubungan non-linier dan interaksi antarvariabel yang kompleks pada permukaan perkotaan yang heterogen.

Perkembangan kecerdasan buatan geospasial atau Geospatial Artificial Intelligence (GeoAI) membuka peluang untuk mengatasi keterbatasan tersebut. GeoAI didefinisikan sebagai bidang yang mengintegrasikan inovasi ilmu spasial dengan metode kecerdasan buatan dan pembelajaran mesin untuk menggali pengetahuan dari data spasial berskala besar (Janowicz et al., 2020; VoPham et al., 2018). Pada konteks pemodelan LST dan UHI, algoritma pembelajaran mesin seperti Random Forest (RF) dan Support Vector Machine (SVM) telah banyak diterapkan dan secara umum menunjukkan kinerja yang lebih baik dibandingkan regresi linier konvensional dalam menangkap hubungan non-linier antara tutupan lahan, morfologi perkotaan, dan suhu permukaan (Sheykhoumousa et al., 2020). Penerapan RF untuk pemodelan LST telah dilakukan antara lain di Beijing dengan memanfaatkan indikator morfologi dua dan tiga dimensi (He et al., 2025), di kawasan dataran tinggi Vietnam dengan kombinasi indeks spektral dan ukuran kekompakan geografis (Hoang, 2025), pada skala benua Afrika untuk empat kota yang berkembang pesat (Simwanda et al., 2019), serta pada konteks perubahan tutupan lahan jangka panjang di Italia (Rao et al., 2023) dan klasifikasi keparahan UHI di wilayah Midwest Amerika Serikat (Mansouri & Erfani, 2025). Secara umum, Random Forest juga telah ditunjukkan sebagai kerangka kerja generik yang andal untuk pemodelan prediktif variabel spasial dan spatio-temporal (Hengl et al., 2018). Perkembangan terkini menunjukkan tren ini terus berlanjut: kerangka GeoAI berbasis foundation model kini mulai digunakan untuk estimasi LST resolusi tinggi secara kontinu guna mendukung asesmen risiko panas dan kesehatan perkotaan (Johnson, 2026), studi terbaru di kota pesisir Asia Selatan mengintegrasikan lima algoritma pembelajaran mesin dengan persepsi publik untuk proyeksi dinamika UHI multi-tahun (Sarker et al., 2026), dan tinjauan sistematis terbaru mengonfirmasi bahwa metode pembelajaran mesin secara konsisten mengungguli pendekatan statistik konvensional dalam asesmen UHI (Gaur & Deb, 2026).

Meskipun kajian SUHI pada skala kawasan Bandung Raya telah tersedia (Fajary et al., 2024; Ramdani & Setiani, 2014), pemodelan spasial LST yang berbasis GeoAI secara khusus untuk Kota Cimahi, dengan resolusi spasial tinggi (10 meter), bersifat multi-tanggal, membandingkan lebih dari satu algoritma pembelajaran mesin, serta secara eksplisit melaporkan keterbatasan data akibat tutupan awan, masih jarang didokumentasikan dalam literatur yang dapat diakses publik. Ketersediaan data penginderaan jauh terbuka seperti Landsat Collection 2 Level-2 (Crawford et al., 2023), Sentinel-2 Surface Reflectance, dan Dynamic World (Brown et al., 2022) yang menyediakan kelas tutupan lahan dan kerapatan terbangun pada resolusi 10 meter secara hampir real-time, memungkinkan integrasi data tersebut ke dalam satu alur kerja GeoAI yang dapat direplikasi untuk kota-kota berukuran kecil-menengah di Indonesia.

Berdasarkan uraian tersebut, penelitian ini bertujuan untuk: (1) menerapkan pendekatan GeoAI guna memodelkan dan memetakan variasi spasial LST di Kota Cimahi melalui integrasi data termal Landsat 8/9 dengan data optik Sentinel-2 dan Dynamic World; (2) membandingkan kinerja algoritma Random Forest dan Support Vector Regression dalam memprediksi LST pada level piksel; (3) mengidentifikasi variabel prediktor yang paling berpengaruh terhadap variasi LST beserta implikasi multikolinearitas antarprediktor terhadap interpretasi tersebut; dan (4) melaporkan secara transparan keterbatasan data, khususnya proporsi piksel yang harus ditambal (gap-filled) akibat tutupan awan pada proses prediksi spasial, sebagai bagian dari praktik pelaporan ilmiah yang jujur dan dapat diperiksa ulang.

METODE PENELITIAN

Penelitian ini menggunakan desain kuantitatif dengan pendekatan GeoAI atau spatial machine learning, berupa studi kasus di Kota Cimahi, Provinsi Jawa Barat. Satuan analisis adalah piksel raster pada resolusi 10 meter di dalam batas area kajian (area of interest/AOI) Kota Cimahi, dengan koordinat batas grid pada sistem proyeksi UTM Zona 48S (EPSG:32748) berkisar pada $X = 778.105-784.945$ m dan $Y = 9.235.605-9.244.385$ m. Data dikumpulkan untuk musim kemarau tahun 2025; dari enam skena termal Landsat yang tersedia pada periode Juni–Agustus 2025, hanya empat

tanggal yang memiliki kelengkapan data Sentinel-2 dan Dynamic World secara simultan, yaitu 25 Juli, 2 Agustus, 10 Agustus, dan 26 Agustus 2025, sehingga keempat tanggal tersebut yang digunakan dalam pemodelan.

Data yang digunakan terdiri dari tiga kelompok. Pertama, data suhu permukaan (LST) diperoleh dari produk Landsat Collection 2 Level-2 (resolusi asli 30 meter), yang dihasilkan menggunakan algoritma suhu permukaan resmi United States Geological Survey (USGS) (Crawford et al., 2023). Kedua, indeks spektral optik NDVI, NDBI, dan NDWI dihitung dari band reflektansi permukaan Sentinel-2 (band 3, 4, 8, dan 11) pada resolusi 10 meter, mengikuti prinsip dasar masing-masing indeks (Tucker, 1979; Zha et al., 2003; McFeeters, 1996). Ketiga, kepadatan terbangun (Built_Density) dan kelas tutupan lahan (LandCover_Class) diperoleh dari produk Dynamic World, yaitu peta tutupan lahan global hampir real-time berbasis deep learning pada citra Sentinel-2 dengan sembilan kelas tutupan lahan dan resolusi 10 meter (Brown et al., 2022).

Praproses data dilakukan melalui beberapa tahap. Karena resolusi asli citra termal Landsat (30 meter) berbeda dengan resolusi Sentinel-2/Dynamic World (10 meter), data LST diresampling ke grid referensi NDVI menggunakan interpolasi bilinear, yang sesuai untuk data kontinu seperti suhu. Kesesuaian grid antarlayer diverifikasi sebelum proses penggabungan data (stacking). Seluruh layer kemudian diratakan (flatten) menjadi tabel piksel, menghasilkan 2.408.460 baris data (empat tanggal $\times$ 602.115 piksel per grid). Piksel yang bernilai kosong (NaN) pada salah satu layer baik karena berada di luar AOI maupun tertutup awan dihapus, menyisakan 901.839 baris data valid (37,4% dari total), dengan rincian per tanggal: 25 Juli sebanyak 321.297 piksel, 2 Agustus sebanyak 229.698 piksel, 10 Agustus sebanyak 29.543 piksel (jauh lebih rendah akibat tutupan awan yang sangat tebal pada tanggal tersebut), dan 26 Agustus sebanyak 321.301 piksel.

Kelas tutupan lahan Dynamic World dilabeli ulang ke dalam sembilan kategori: Water, Trees, Grass, Flooded_Vegetation, Crops, Shrub_Scrub, Built_Area, Bare_Ground, dan Snow_Ice. Perlu dicatat bahwa kemunculan kelas Snow_Ice sebanyak 247 piksel (0,03% dari data valid) secara fisik tidak masuk akal untuk wilayah dataran tropis seperti Cimahi, dan kemungkinan besar merupakan kesalahan klasifikasi algoritmik pada model Dynamic World misalnya akibat kesalahan deteksi pada atap logam atau bayangan awan yang sangat terang bukan kondisi aktual di lapangan. Demikian pula kelas Bare_Ground (511 piksel) dan Shrub_Scrub (266 piksel) memiliki ukuran sampel yang sangat kecil sehingga statistik LST pada kelas-kelas tersebut perlu diinterpretasikan dengan hati-hati.

Eksplorasi data dilakukan melalui statistik deskriptif, analisis korelasi Pearson antara LST dan keempat prediktor numerik, serta deteksi piksel outlier menggunakan z-score per tanggal dengan ambang $|z| > 3$, yang mengidentifikasi 5.143 piksel (0,57% dari data valid) sebagai outlier dan mengeluarkannya dari data pemodelan, menyisakan 896.696 baris data.

Pemodelan prediktif menggunakan lima variabel prediktor (NDVI, NDBI, NDWI, Built_Density, dan LandCover_Class) untuk memprediksi LST sebagai variabel target. Data dibagi menjadi data latih dan data uji dengan rasio 70:30 (random_state=42), menghasilkan 627.687 baris data latih dan 269.009 baris data uji. Dua algoritma diterapkan: (1) Random Forest Regressor dengan 300 pohon (n_estimators=300) dan minimum lima sampel per simpul daun (min_samples_leaf=5); dan (2) Support Vector Regression (SVR) dengan kernel radial basis function (RBF), parameter C=10, gamma='scale', dan epsilon=0,1, dengan fitur yang distandarisasi terlebih dahulu menggunakan StandardScaler. Karena pelatihan SVR pada lebih dari 600 ribu baris data tidak praktis secara komputasi, pelatihan SVR dilakukan pada subsampel terstratifikasi per tanggal sebanyak 99.998 baris yang diambil dari data latih (waktu pelatihan 6,7 menit), sementara evaluasi kedua model tetap dilakukan pada seluruh 269.009 baris data uji yang sama agar perbandingan kinerja tetap adil. Pemilihan nilai parameter awal (n_estimators=300 dan min_samples_leaf=5 untuk RF; C=10, gamma='scale', dan epsilon=0,1 untuk SVR) mengacu pada rentang nilai yang lazim digunakan pada studi pemodelan LST berbasis piksel sejenis (Hoang, 2025; Rao et al., 2023) serta uji coba awal pada subset data. Untuk menjawab kebutuhan validasi yang lebih formal, dilakukan pula hyperparameter tuning menggunakan RandomizedSearchCV dengan 5-fold cross-validation pada subsampel 100.000 baris data latih (25 kombinasi parameter untuk RF, 20 kombinasi untuk SVR), dengan model hasil tuning kemudian di-refit pada seluruh data latih (627.687 baris untuk RF; 99.998 baris subsampel untuk SVR) dan divalidasi ulang menggunakan 5-fold cross-validation formal. Hasil lengkap prosedur ini dilaporkan pada bagian Hasil dan Pembahasan.

Kinerja model dievaluasi menggunakan koefisien determinasi (R^2), root mean squared error (RMSE), dan mean absolute error (MAE) pada data latih maupun data uji. Tingkat kepentingan variabel (variable importance) dihitung menggunakan importance bawaan berbasis pengurangan impurity untuk Random Forest, serta permutation importance untuk SVR dengan 10 kali pengulangan, dievaluasi pada subsampel acak sebanyak 10.000 baris dari data uji mengingat biaya komputasi permutation importance yang tinggi. Model dengan R^2 uji tertinggi dipilih sebagai model terbaik untuk diterapkan pada prediksi spasial penuh.

Prediksi spasial dilakukan dengan menerapkan model terbaik ke seluruh piksel grid pada setiap tanggal. Untuk piksel yang fitur prediktornya kosong akibat tutupan awan, dilakukan penambalan (gap-filling) menggunakan nilai median komposit lintas-tanggal per fitur, yaitu nilai median dari piksel yang sama pada keempat tanggal yang tersedia, dengan mengabaikan nilai kosong (NaN). Kelas tutupan lahan tidak ditambal karena datanya sudah lengkap pada seluruh AOI. Proporsi piksel hasil tambalan dihitung dan dipetakan secara terpisah untuk setiap tanggal sebagai bagian dari upaya transparansi metodologis, sehingga pembaca dapat menilai sendiri tingkat keandalan peta prediksi pada setiap tanggal akuisisi. Seluruh pemrosesan data dilakukan menggunakan bahasa pemrograman Python dengan pustaka rasterio, scikit-learn, pandas, numpy, matplotlib, seaborn, dan folium.

HASIL DAN PEMBAHASAN

Statistik deskriptif variabel numerik pada 901.839 piksel valid disajikan pada Tabel 1. Rata-rata LST pada wilayah kajian adalah 36,78°C dengan rentang 26,43–48,80°C, mencerminkan variasi suhu permukaan yang besar dalam satu kota berukuran relatif kecil. Tingkat retensi data valid yang hanya 37,4% dari total piksel yang distack menegaskan besarnya gangguanutupan awan pada citra optik dan termal di wilayah tropis seperti Cimahi, suatu kendala umum dalam pemanfaatan data optik untuk pemantauan UHI berkelanjutan di Indonesia.


Tabel 1. Statistik Deskriptif Variabel pada 901.839 Piksel Valid

Variabel	Rata-rata	Std. Dev.	Min	Median	Maks
LST (°C)	36,78	3,22	26,43	37,49	48,80
NDVI	0,340	0,236	-0,282	0,257	0,976
NDBI	0,033	0,180	-0,752	0,074	0,790
NDWI	-0,364	0,180	-0,969	-0,325	0,680
Built_Density	0,639	0,199	0,022	0,727	0,796

Variasi LST antartanggal akuisisi (Tabel 2) menunjukkan bahwa 10 Agustus 2025 memiliki rata-rata LST terendah (34,33°C) sekaligus jumlah piksel valid yang jauh lebih kecil (29.543 piksel) dibandingkan tanggal lain. Temuan ini perlu dibaca secara kritis: rata-rata yang lebih rendah pada tanggal tersebut sangat mungkin bukan mencerminkan pendinginan kota secara menyeluruh, melainkan bias seleksi (selection bias) akibat sebagian besar piksel yang bebas awan pada tanggal itu justru terletak di area tervegetasi/perbukitan bagian utara yang secara inheren lebih sejuk, sementara area perkotaan terbangun di bagian selatan sebagian besar tertutup awan dan tidak terwakili dalam perhitungan rata-rata tersebut.


Tabel 2. Jumlah Piksel Valid dan Statistik LST per Tanggal Akuisisi

Tanggal	N Piksel Valid	Rata-rata LST (°C)	Std. Dev. (°C)
25 Juli 2025	321.297	36,50	3,56
2 Agustus 2025	229.698	37,83	2,40
10 Agustus 2025	29.543	34,33	2,17
26 Agustus 2025	321.301	36,53	3,22



Gambar 1. Distribusi Keseluruhan LST (kiri) dan Distribusi LST per Tanggal Akuisisi (kanan)

Analisis korelasi Pearson (Gambar 2) menunjukkan bahwa NDBI memiliki korelasi positif terkuat dengan LST ($r = 0,630$), diikuti Built_Density ($r = 0,618$) dan NDWI ($r = 0,588$), sementara NDVI berkorelasi negatif ($r = -0,616$). Arah korelasi ini konsisten dengan teori dan temuan empiris UHI bahwa area terbangun cenderung lebih panas sedangkan vegetasi cenderung lebih sejuk (Zha et al., 2003; Voogt & Oke, 2003). Namun, matriks korelasi yang sama juga memperlihatkan multikolinearitas yang sangat kuat antarprediktor itu sendiri NDVI dan NDWI berkorelasi negatif sebesar $r = -0,960$, NDBI dan NDWI berkorelasi positif sebesar $r = 0,803$, dan NDVI dengan NDBI berkorelasi negatif sebesar $r = -0,871$. Tingkat multikolinearitas seperti ini perlu menjadi perhatian utama dalam menafsirkan kepentingan setiap variabel secara individual, karena beberapa indeks pada dasarnya membawa informasi yang sangat tumpang tindih.




Gambar 2. Matriks Korelasi antara LST dan Variabel Prediktor

Pola LST menurut kelas tutupan lahan (Tabel 3 dan Gambar 3) menegaskan kontras termal klasik antara area terbangun dan vegetasi: kelas Built_Area memiliki rata-rata LST tertinggi (37,40°C), sedangkan kelas Trees memiliki rata-rata terendah (31,07°C), selisih sekitar 6,3°C. Pola ini sejalan dengan temuan pada kajian SUHI di kawasan Bandung Raya (Fajary et al., 2024) maupun di kota-kota tropis lain (Simwanda et al., 2019). Kelas Snow_Ice, Bare_Ground, dan Shrub_Scrub memiliki rata-rata LST pada kisaran menengah (34,7–35,9°C), tetapi mengingat ukuran sampelnya yang sangat kecil (masing-masing 247, 511, dan 266 piksel) dan, khususnya untuk kelas Snow_Ice, indikasi kuat sebagai artefak kesalahan klasifikasi, nilai-nilai tersebut tidak dapat dianggap representatif dan tidak digunakan sebagai dasar kesimpulan substantif dalam penelitian ini.

Tabel 3. Rata-rata dan Standar Deviasi LST per Kelas Tutupan Lahan

Kelas Tutupan Lahan	N Piksel	Rata-rata LST (°C)	Std. Dev. (°C)
Built_Area	808.087	37,40	2,63
Bare_Ground	511	35,87	4,10
Water	1.156	35,51	1,74
Grass	3.758	35,07	1,42
Shrub_Scrub	266	35,03	3,09
Snow_Ice*	247	34,75	2,63
Crops	8.786	32,18	2,70
Trees	79.028	31,07	2,70

*Kelas Snow_Ice kemungkinan besar merupakan kesalahan klasifikasi algoritmik Dynamic World, bukan kondisi aktual di Kota Cimahi yang beriklim tropis; nilai pada baris ini tidak diinterpretasikan secara substantif.



Gambar 3. Distribusi LST per Kelas Tutupan Lahan

Sebanyak 5.143 piksel (0,57% dari data valid) teridentifikasi sebagai outlier berdasarkan z-score per tanggal dan dikeluarkan sebelum pemodelan, menyisakan 896.696 baris data untuk pelatihan dan pengujian model.

Perbandingan kinerja kedua algoritma pembelajaran mesin disajikan pada Tabel 4. Random Forest menghasilkan R^2 uji sebesar 0,5284 (RMSE = 2,1710°C; MAE = 1,6324°C), sementara SVR menghasilkan R^2 uji sebesar 0,5245 (RMSE = 2,1800°C; MAE = 1,6064°C). Selisih R^2 uji antara kedua model hanya sebesar 0,0039, yang secara praktis dapat dikatakan setara (comparable) dan tidak mencerminkan keunggulan Random Forest yang substansial atas SVR untuk konfigurasi fitur ini meskipun Random Forest tetap dipilih sebagai model terbaik untuk prediksi spasial karena R^2 ujinya yang sedikit lebih tinggi. Perlu dicatat pula bahwa R^2 train Random Forest (0,7732) jauh lebih tinggi daripada R^2 ujinya (0,5284), mengindikasikan tingkat overfitting yang moderat, sedangkan SVR menunjukkan R^2 train dan uji yang hampir identik (0,5268 dan 0,5245), konsisten dengan kapasitas SVR yang lebih dibatasi oleh proses subsampling dan regularisasi parameter C.

Tabel 4. Perbandingan Kinerja Model Random Forest dan SVR

Model	N Latih	R^2 Latih	R^2 Uji	RMSE Uji (°C)	MAE Uji (°C)
Random Forest	627.687	0,7732	0,5284	2,1710	1,6324
SVR (subsampel)	99.998	0,5268	0,5245	2,1800	1,6064

Tingkat R^2 uji sekitar 0,52–0,53 pada penelitian ini tergolong moderat, dan perlu ditempatkan secara proporsional dibandingkan studi sejenis. Sebagai pembanding, He et al. (2025) melaporkan R^2 uji hingga 0,81 untuk pemodelan RF terhadap LST di Beijing, namun model tersebut menggunakan indikator morfologi perkotaan dua dan tiga dimensi yang teragregasi pada grid 600 meter, bukan nilai spektral mentah per piksel 10 meter seperti pada penelitian ini; agregasi spasial pada skala yang lebih kasar secara umum mengurangi noise piksel-ke-piksel sehingga R^2 yang dihasilkan cenderung lebih tinggi. Hoang (2025) dan Rao et al. (2023) yang juga memodelkan LST berbasis piksel dengan indeks spektral melaporkan tingkat akurasi yang bervariasi tergantung wilayah kajian dan kombinasi fitur yang digunakan. Dengan demikian, R^2 sebesar 0,53 pada penelitian ini dapat dipahami sebagai konsekuensi dari penggunaan fitur spektral piksel-demi-piksel pada citra yang menggabungkan dua sensor berbeda (Landsat 8 dan Landsat 9) dan empat tanggal akuisisi dengan kondisi atmosfer yang berbeda-beda tanpa fitur tanggal/sensor secara eksplisit, bukan indikasi kegagalan pendekatan GeoAI itu sendiri.


Untuk memvalidasi kestabilan hasil di atas secara lebih formal, dilakukan hyperparameter tuning menggunakan RandomizedSearchCV dengan 5-fold cross-validation (Tabel 6). Parameter terbaik untuk Random Forest yang ditemukan adalah $n_estimators=400$, $max_depth=10$, $min_samples_split=2$, $min_samples_leaf=5$, dan $max_features='log2'$ (mean R^2 cross-validation pada subsampel tuning = 0,5346), sementara untuk SVR adalah kernel RBF dengan $C=10$, $gamma=0,1$, dan $epsilon=0,5$ (mean R^2 cross-validation = 0,4479). Setelah model dengan parameter terbaik tersebut di-refit pada seluruh data latih dan dievaluasi pada data uji yang sama, Random Forest hasil tuning menghasilkan R^2 uji sebesar 0,5350 (RMSE = 2,1558°C; MAE = 1,6229°C), naik tipis sebesar 0,0066 dibandingkan parameter awal (0,5284), sedangkan SVR hasil tuning menghasilkan R^2 uji sebesar 0,5238 (RMSE = 2,1816°C; MAE = 1,6141°C), turun tipis sebesar 0,0007 dibandingkan parameter awal (0,5245) selisih yang secara praktis dapat diabaikan. Cross-validation formal 5-fold pada model hasil tuning juga menunjukkan hasil yang stabil dan konsisten dengan evaluasi data uji tunggal: Random Forest memperoleh $R^2 = 0,5349 \pm 0,0043$, RMSE = $2,1576 \pm 0,0086^\circ\text{C}$, dan MAE = $1,6238 \pm 0,0052^\circ\text{C}$; SVR memperoleh $R^2 = 0,5239 \pm 0,0037$, RMSE = $2,1928 \pm 0,0128^\circ\text{C}$, dan MAE = $1,6205 \pm 0,0108^\circ\text{C}$. Simpangan baku antarfold yang kecil (di bawah 0,005 untuk R^2) mengindikasikan bahwa performa kedua model tidak sensitif terhadap

pembagian data latih/uji tertentu, sehingga R^2 uji sebesar $\sim 0,53$ yang dilaporkan pada Tabel 4 dapat dipandang sebagai estimasi kinerja model yang cukup stabil, bukan hasil kebetulan dari satu split data.

Tabel 6. Hasil Hyperparameter Tuning dan 5-Fold Cross-Validation

Model	R^2 Uji	RMSE Uji ($^{\circ}\text{C}$)	MAE Uji ($^{\circ}\text{C}$)	R^2 CV 5-Fold (mean $\pm$ SD)	Parameter Terbaik
Random Forest (default)	0,5284	2,1710	1,6324	–	n_estimators=300, min_samples_leaf=5
Random Forest (tuned)	0,5350	2,1558	1,6229	$0,5349 \pm 0,0043$	n_estimators=400, max_depth=10, min_samples_split=2, min_samples_leaf=5, max_features='log2'
SVR (default, subsampel)	0,5245	2,1800	1,6064	–	C=10, gamma='scale', epsilon=0,1
SVR (tuned, subsampel)	0,5238	2,1816	1,6141	$0,5239 \pm 0,0037$	kernel='rbf', C=10, gamma=0,1, epsilon=0,5


Karena peningkatan R^2 uji Random Forest hasil tuning (+0,0066) berada dalam rentang simpangan baku hasil cross-validation ($\pm 0,0043$), peningkatan tersebut tergolong marginal dan tidak mengubah kesimpulan utama penelitian ini: Random Forest dan SVR menghasilkan kinerja yang secara praktis setara untuk konfigurasi fitur yang digunakan, dan model Random Forest dengan parameter default (Tabel 4) tetap dipertahankan sebagai model yang digunakan untuk prediksi spasial pada Gambar 7, mengingat selisih kinerja terhadap versi tuned tidak cukup besar untuk membenarkan pengulangan seluruh proses prediksi spasial dan pemetaan Folium.




Gambar 4. Perbandingan LST Aktual dan Prediksi pada Data Uji: Random Forest (kiri) dan SVR (kanan)

Pola pada Gambar 4 memperlihatkan fenomena kompresi rentang (range compression) pada kedua model: nilai LST aktual yang sangat tinggi ($>43^{\circ}\text{C}$) maupun sangat rendah ($<29^{\circ}\text{C}$) cenderung diprediksi mendekati nilai rata-rata, bukan nilai ekstremnya. Pola ini merupakan karakteristik umum model regresi berbasis ensemble pohon maupun kernel pada data dengan rentang nilai yang lebar, dan memiliki implikasi praktis penting: peta prediksi LST pada penelitian ini lebih andal digunakan sebagai indikator relatif pola spasial suhu (misalnya untuk membandingkan area mana yang relatif lebih panas atau lebih sejuk) dibandingkan sebagai pembacaan suhu absolut pada titik-titik ekstrem, seperti pusat industri atau kawasan hijau yang sangat rapat.

Hasil analisis kepentingan variabel menunjukkan perbedaan yang mencolok antara kedua model (Gambar 5 dan Gambar 6). Berdasarkan importance bawaan Random Forest, Built_Density merupakan prediktor paling dominan ($0,540$), diikuti NDBI ($0,224$), NDVI ($0,109$), NDWI ($0,095$), dan LandCover_Class ($0,032$). Sebaliknya, berdasarkan permutation importance SVR yang dievaluasi pada subsampel 10.000 data uji, NDVI justru menjadi prediktor paling dominan secara meyakinkan ($0,950 \pm 0,020$), diikuti Built_Density ($0,302 \pm 0,006$), LandCover_Class ($0,216 \pm 0,006$), NDBI ($0,205 \pm 0,005$), dan NDWI ($0,184 \pm 0,008$).



Gambar 5. Feature Importance Random Forest




Gambar 6. Permutation Importance SVR (dievaluasi pada 10.000 sampel uji)

Perbedaan urutan kepentingan variabel antara kedua metode tersebut bukan merupakan kesalahan komputasi, melainkan konsekuensi langsung dari multikolinearitas kuat yang telah diidentifikasi pada Gambar 2 dan dari perbedaan mekanisme kedua metode importance itu sendiri. Importance berbasis impurity pada Random Forest cenderung membagi kontribusi secara tidak proporsional di antara variabel yang saling berkorelasi tinggi, tergantung urutan pemilihan split secara greedy pada setiap pohon, sehingga satu variabel (dalam hal ini Built_Density) dapat tampak jauh lebih dominan meskipun variabel lain yang berkorelasi dengannya (NDBI, NDWI) sebenarnya membawa informasi yang sangat mirip. Sebaliknya, permutation importance pada SVR mengukur penurunan akurasi ketika nilai satu variabel diacak secara independen; karena NDVI berkorelasi sangat kuat dengan NDWI ($r = -0,960$) dan NDBI ($r = -0,871$), pengacakan NDVI secara efektif merusak informasi yang juga terkandung pada variabel-variabel lain tersebut, sehingga dampaknya terhadap akurasi tampak besar. Sheykhmousa et al. (2020) dalam meta-analisis mereka terhadap 251 studi klasifikasi penginderaan jauh juga mencatat bahwa perilaku Random Forest dan SVM dapat berbeda signifikan tergantung struktur dan redundansi fitur input, sejalan dengan temuan pada penelitian ini. Implikasi praktisnya, kesimpulan tentang variabel mana yang 'paling penting' bagi LST di Cimahi sebaiknya tidak digantungkan pada satu metode importance saja, melainkan dipahami sebagai secara kolektif kombinasi sinyal keterbangunan (Built_Density dan NDBI) versus sinyal vegetasi/kelembapan (NDVI dan NDWI) yang keduanya valid namun saling tumpang tindih secara informasi.

Hasil prediksi spasial menggunakan model Random Forest (Gambar 7) menunjukkan pola yang konsisten pada keempat tanggal: suhu permukaan tertinggi terkonsentrasi pada klaster di bagian selatan AOI, yang secara konsisten dengan peta tutupan lahan dan kerapatan terbangun mengindikasikan kawasan terbangun padat/inti perkotaan, sementara suhu terendah terdapat pada pita di bagian utara AOI yang secara topografis dan tutupan lahan berasosiasi dengan kawasan bervegetasi/perbukitan. Pola spasial ini konsisten dengan struktur ruang Kota Cimahi yang menempatkan kawasan permukiman dan kegiatan ekonomi padat di bagian tengah-selatan, sementara bagian utara relatif lebih hijau. Perbandingan visual antara baris 'Aktual' dan 'Prediksi' pada Gambar 7 juga memperjelas kembali fenomena kompresi rentang yang telah

dibahas sebelumnya peta prediksi terlihat lebih halus (smooth) dan kurang ekstrem dibandingkan peta aktual, terutama pada klaster terpanas di bagian selatan.




Gambar 7. Peta LST Aktual (baris atas) dan Prediksi Setelah Penambalan Data (baris bawah) per Tanggal Akuisisi

Aspek yang secara khusus ditonjolkan dalam penelitian ini adalah transparansi mengenai proporsi piksel hasil penambalan (gap-filling) pada peta prediksi (Tabel 5 dan Gambar 8). Pada tanggal 25 Juli dan 26 Agustus 2025, hampir seluruh piksel prediksi (0,0%) berasal dari fitur asli tanggal tersebut, sehingga kedua peta tanggal ini dapat dianggap sebagai representasi yang relatif independen dan andal. Sebaliknya, pada 2 Agustus 2025 sebanyak 28,5% piksel merupakan hasil tambalan, dan pada 10 Agustus 2025 proporsi piksel hasil tambalan melonjak hingga 90,8% artinya hampir seluruh peta prediksi untuk tanggal tersebut sebenarnya dibangun dari nilai median fitur lintas-tanggal, bukan dari observasi citra tanggal itu sendiri. Implikasinya, peta LST untuk 10 Agustus 2025 sebaiknya tidak diperlakukan sebagai potret kondisi suhu pada hari tunggal tersebut, melainkan sebagai estimasi terkompisit (composited estimate) yang sebagian besar mencerminkan kondisi rata-rata keempat tanggal yang tersedia. Kegagalan untuk melaporkan proporsi ini secara eksplisit berisiko menyesatkan pembaca yang menganggap seluruh peta time-series memiliki tingkat keandalan yang sama, padahal pada kenyataannya tidak demikian.

Temuan gradien termal utara-selatan pada Gambar 7 memiliki implikasi langsung bagi kebijakan mitigasi UHI di Kota Cimahi dan kota-kota sejenis di Indonesia. Klaster suhu tertinggi yang secara konsisten terkonsentrasi di inti terbangun bagian selatan menunjukkan area prioritas bagi intervensi infrastruktur hijau, seperti penambahan tutupan pohon jalan, taman kota, dan atap/dinding hijau, serta bagi kebijakan pengendalian kepadatan bangunan dan proporsi ruang terbuka hijau dalam rencana tata ruang wilayah (RTRW). Sebaliknya, kawasan bervegetasi di bagian utara berfungsi sebagai "pendingin alami" kota dan perlu dipertahankan melalui kebijakan perlindungan lahan hijau agar tidak terkonversi menjadi area terbangun. Karena alur kerja GeoAI pada penelitian ini dibangun dari data penginderaan jauh terbuka (Landsat, Sentinel-2, Dynamic World), pendekatan yang sama berpotensi direplikasi secara relatif murah oleh dinas terkait di kota-kota kecil-menengah lain di Indonesia untuk pemetaan awal titik panas sebagai dasar perencanaan mitigasi UHI, sebelum dilengkapi dengan validasi lapangan sebagaimana diuraikan pada bagian Rekomendasi.

Tabel 5. Proporsi Piksel Hasil Penambalan (Gap-Filling) pada Peta Prediksi per Tanggal

Tanggal	N Piksel Diprediksi	N Piksel Tambalan	Persentase Tambalan
25 Juli 2025	321.397	4	0,0%
2 Agustus 2025	321.397	91.616	28,5%
10 Agustus 2025	321.397	291.792	90,8%
26 Agustus 2025	321.301	0	0,0%



Gambar 8. Peta Sumber Piksel Prediksi (Merah = Fitur Asli, Biru = Hasil Tambalan Lintas-Tanggal)

KESIMPULAN

Kontribusi ilmiah utama penelitian ini adalah menghadirkan alur kerja GeoAI multi-tanggal, multi-algoritma, dan resolusi tinggi (10 meter) untuk pemodelan LST yang secara eksplisit melaporkan proporsi data hasil penambalan (gap-filling) sebagai ukuran keandalan suatu praktik pelaporan yang masih jarang ditemukan pada kajian UHI di kota kecil-menengah Indonesia. Penelitian ini menunjukkan bahwa pendekatan tersebut, yang mengintegrasikan data termal Landsat 8/9 dengan data optik Sentinel-2 dan Dynamic World, dapat digunakan untuk memodelkan dan memetakan variasi spasial LST di Kota Cimahi pada resolusi 10 meter. Random Forest dan Support Vector Regression menghasilkan kinerja yang secara praktis setara (R^2 uji 0,5284 dan 0,5245; RMSE 2,17°C dan 2,18°C), dengan Random Forest dipilih sebagai model terbaik karena R^2 uji yang sedikit lebih tinggi, meskipun selisihnya tidak besar. Kestabilan hasil ini diperkuat oleh hyperparameter tuning dan 5-fold cross-validation formal, yang menunjukkan simpangan baku R^2 antarfold di bawah 0,005 untuk kedua model dan peningkatan performa pasca-tuning yang hanya marginal (+0,0066 untuk RF; -0,0007 untuk SVR) mengonfirmasi bahwa performa $\sim 0,53$ bukan hasil kebetulan dari satu pembagian data latih/uji. Kerapatan terbangun, NDBI, dan NDVI secara konsisten teridentifikasi sebagai prediktor utama LST, menegaskan kontras termal klasik antara area terbangun dan area bervegetasi yang juga didokumentasikan pada kajian-kajian SUHI di kawasan Bandung Raya, namun urutan dominasi antarprediktor berbeda antara metode importance Random Forest dan SVR akibat multikolinearitas yang kuat di antara indeks spektral optik yang digunakan, sehingga interpretasi kepentingan variabel tunggal perlu dilakukan secara hati-hati. Pola spasial LST di Kota Cimahi secara jelas dibentuk oleh gradien tutupan lahan utara-selatan: bagian utara yang bervegetasi relatif lebih sejuk, sedangkan bagian selatan yang terbangun padat relatif lebih panas. Keterbatasan penting yang dilaporkan secara transparan dalam penelitian ini adalah ketergantungan yang sangat besar pada penambalan data lintas-tanggal untuk skena 10 Agustus 2025 (90,8% piksel), yang secara substansial membatasi nilai tanggal tersebut sebagai observasi independen, serta fenomena kompresi rentang pada kedua model yang membuat peta prediksi lebih sesuai digunakan sebagai indikator pola spasial relatif dibandingkan pembacaan suhu absolut pada nilai ekstrem.

REKOMENDASI

Beberapa rekomendasi diajukan untuk penelitian lanjutan. Pertama, penelitian selanjutnya disarankan menambah jumlah akuisisi termal bebas awan atau melibatkan sensor tambahan seperti ECOSTRESS atau ASTER, maupun komposit Sentinel-3 SLSTR dengan frekuensi revisit yang lebih tinggi, untuk mengurangi ketergantungan pada penambalan data lintas-tanggal seperti yang teridentifikasi pada skena 10 Agustus 2025. Kedua, memasukkan tanggal akuisisi atau sensor (Landsat 8 versus Landsat 9) sebagai fitur kategorikal eksplisit, atau melatih model terpisah per tanggal, berpotensi memisahkan variabilitas LST yang bersifat atmosferik/sensor dari variabilitas yang benar-benar mencerminkan kondisi permukaan. Ketiga, mengingat tingkat multikolinearitas yang tinggi antara NDVI, NDBI, dan NDWI pada penelitian ini, langkah seleksi fitur atau reduksi dimensi misalnya melalui variance inflation factor (VIF) atau principal component analysis (PCA) serta penggunaan metode interpretasi yang lebih robust seperti SHAP (SHapley Additive exPlanations) disarankan sebelum menarik simpulan kausal dari satu metode importance saja; hyperparameter tuning dan cross-validation formal yang telah dilakukan pada penelitian ini (lihat Tabel 6) menunjukkan bahwa penyetelan parameter saja tidak cukup untuk mengatasi keterbatasan performa yang bersumber dari multikolinearitas fitur, sehingga langkah reduksi dimensi menjadi prioritas lebih tinggi untuk penelitian lanjutan dibandingkan tuning lebih jauh. Keempat, validasi lapangan terhadap data suhu udara atau suhu permukaan in-situ di Kota Cimahi diperlukan untuk menilai akurasi absolut produk LST Landsat itu sendiri, terlepas dari model regresi yang dibangun di atasnya. Kelima, perluasan kajian ke rangkaian waktu multi-tahun akan memungkinkan penilaian tren UHI yang sesungguhnya, mengingat penelitian ini hanya merupakan potret pada satu musim kemarau. Keenam, eksplorasi algoritma gradient boosting atau deep learning (misalnya XGBoost atau pendekatan downscaling berbasis convolutional neural network) dapat dipertimbangkan pada penelitian mendatang, dengan tetap mempertahankan standar pelaporan ketidakpastian yang transparan seperti yang diterapkan dalam penelitian ini. Ketujuh, bagi pemerintah daerah dan dinas terkait di Kota Cimahi maupun kota-kota berukuran sejenis, peta LST dan titik panas yang dihasilkan disarankan digunakan sebagai salah satu masukan awal (bukan satu-satunya dasar) dalam penyusunan atau revisi rencana tata ruang wilayah dan program mitigasi UHI, seperti penentuan prioritas lokasi ruang terbuka hijau dan infrastruktur hijau, dengan tetap mempertimbangkan keterbatasan metodologis khususnya kompresi rentang nilai ekstrem dan ketergantungan tinggi pada data tambalan untuk skena 10 Agustus 2025 yang telah diuraikan pada bagian Hasil dan Pembahasan.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada STMIK AMIK BANDUNG atas dukungan institusional dalam penyusunan penelitian ini. Penelitian ini tidak menerima pendanaan eksternal dari pihak mana pun.

REFERENSI

1. Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
2. Brown, C. F., Brumby, S. P., Guzder-Williams, B., Birch, T., Hyde, S. B., Mazzariello, J., Czerwinski, W., Pasquarella, V. J., Haertel, R., Ilyushchenko, S., Schwehr, K., Weisse, M., Stolle, F., Hanson, C., Guinan, O., Moore, R., & Tait, A. M.

- (2022). Dynamic World, near real-time global 10 m land use land cover mapping. *Scientific Data*, 9, 251. <https://doi.org/10.1038/s41597-022-01307-4>
3. Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297. <https://doi.org/10.1007/BF00994018>
 4. Crawford, C. J., Roy, D. P., Arab, S., Barnes, C., Vermote, E., Hulley, G., Gerace, A., Choate, M., Engebretson, C., Micijevic, E., Schmidt, G. L., Anderson, C., Anderson, M., Bouchard, M., Cook, B., Dittmeier, R., Howard, D., Jenkerson, C., Kim, M., ... Zahn, S. G. (2023). The 50-year Landsat collection 2 archive. *Science of Remote Sensing*, 8, 100103. <https://doi.org/10.1016/j.srs.2023.100103>
 5. Drucker, H., Burges, C. J. C., Kaufman, L., Smola, A. J., & Vapnik, V. (1997). Support vector regression machines. In *Advances in Neural Information Processing Systems* 9 (pp. 155–161). MIT Press.
 6. Fajary, F. R., Lee, H. S., Kubota, T., Bhanage, V., Pradana, R. P., Nimiya, H., & Putra, I. D. G. A. (2024). Comprehensive spatiotemporal evaluation of urban growth, surface urban heat island, and urban thermal conditions on Java island of Indonesia and implications for urban planning. *Heliyon*, 10(13), e33708. <https://doi.org/10.1016/j.heliyon.2024.e33708>
 7. Gaur, A., & Deb, C. (2026). Machine learning methods and approaches for urban heat island (UHI) assessment: A comprehensive review. *Renewable and Sustainable Energy Reviews*, 234, 116903.
 8. He, R., Wang, J., & Liu, D. (2025). Assessing the impact of urban spatial form on land surface temperature using Random Forest taking Beijing as a case study. *Land*, 14(8), 1639. <https://doi.org/10.3390/land14081639>
 9. Hengl, T., Nussbaum, M., Wright, M. N., Heuvelink, G. B. M., & Gräler, B. (2018). Random forest as a generic framework for predictive modeling of spatial and spatio-temporal variables. *PeerJ*, 6, e5518. <https://doi.org/10.7717/peerj.5518>
 10. Hoang, N.-D. (2025). Machine learning approaches for geospatial modeling of urban land surface temperature: Assessing geographical compactness, interpretability, and causal inference. *Sensors*, 25(17), 5380. <https://doi.org/10.3390/s25175380>
 11. Janowicz, K., Gao, S., McKenzie, G., Hu, Y., & Bhaduri, B. (2020). GeoAI: Spatially explicit artificial intelligence techniques for geographic knowledge discovery and beyond. *International Journal of Geographical Information Science*, 34(4), 625–636. <https://doi.org/10.1080/13658816.2019.1684500>
 12. Johnson, D. P. (2026). A foundation-model GeoAI framework for continuous heat and health risk mapping. *Frontiers in Environmental Science*, 14, 1770260. <https://doi.org/10.3389/fenvs.2026.1770260>
 13. Kurniati, A. C., & Nitivattananon, V. (2016). Factors influencing urban heat island in Surabaya, Indonesia. *Sustainable Cities and Society*, 27, 99–105. <https://doi.org/10.1016/j.scs.2016.07.006>
 14. Mansouri, A., & Erfani, A. (2025). Machine learning prediction of urban heat island severity in the Midwestern United States. *Sustainability*, 17(13), 6193. <https://doi.org/10.3390/su17136193>
 15. McFeeters, S. K. (1996). The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, 17(7), 1425–1432. <https://doi.org/10.1080/01431169608948714>
 16. Ramdani, F., & Setiani, P. (2014). Spatio-temporal analysis of urban temperature in Bandung City, Indonesia. *Urban Ecosystems*, 17(2), 473–487. <https://doi.org/10.1007/s11252-013-0332-1>
 17. Rao, P., Tassinari, P., & Torreggiani, D. (2023). Exploring the land-use urban heat island nexus under climate change conditions using machine learning approach: A spatio-temporal analysis of remotely sensed data. *Heliyon*, 9(8), e18423. <https://doi.org/10.1016/j.heliyon.2023.e18423>
 18. Sarker, S., Kauser, M. R. H., Saha, A. K., Azad, A., & Wang, X. (2026). Integrating geospatial technique, machine learning algorithm, and public perceptions for advancing urban heat island dynamics assessment. *ISPRS International Journal of Geo-Information*, 15(5), 192. <https://doi.org/10.3390/ijgi15050192>
 19. Sheykhoumousa, M., Mahdianpari, M., Ghanbari, H., Mohammadimanesh, F., Ghamisi, P., & Homayouni, S. (2020). Support vector machine versus random forest for remote sensing image classification: A meta-analysis and systematic review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 6308–6325. <https://doi.org/10.1109/JSTARS.2020.3026724>
 20. Simwanda, M., Ranagalage, M., Estoque, R. C., & Murayama, Y. (2019). Spatial analysis of surface urban heat islands in four rapidly growing African cities. *Remote Sensing*, 11(14), 1645. <https://doi.org/10.3390/rs11141645>
 21. Sobrino, J. A., Jiménez-Muñoz, J. C., & Paolini, L. (2004). Land surface temperature retrieval from LANDSAT TM 5. *Remote Sensing of Environment*, 90(4), 434–440. <https://doi.org/10.1016/j.rse.2004.02.003>
 22. Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8(2), 127–150.
 23. VoPham, T., Hart, J. E., Laden, F., & Chiang, Y.-Y. (2018). Emerging trends in geospatial artificial intelligence (geoAI): Potential applications for environmental epidemiology. *Environmental Health*, 17(1), 1–6.
 24. Voogt, J. A., & Oke, T. R. (2003). Thermal remote sensing of urban climates. *Remote Sensing of Environment*, 86(3), 370–384. [https://doi.org/10.1016/S0034-4257\(03\)00079-8](https://doi.org/10.1016/S0034-4257(03)00079-8)
 25. Zha, Y., Gao, J., & Ni, S. (2003). Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *International Journal of Remote Sensing*, 24(3), 583–594. <https://doi.org/10.1080/01431160304987>