

Komparasi Metode Klasifikasi Tersupervisi untuk Pemetaan Lahan Terbangun dan NonTerbangun Menggunakan Landsat 8 OLI dan Google Earth Engine (Studi Kasus: Kota Malang)

RS. Sianturi

Departemen Sistem Informasi, Fakultas Ilmu Komputer, Universitas Brawijaya

e-mail: rsianturi@ub.ac.id

Abstrak—Pertumbuhan kota Malang telah berdampak pada peningkatan lahan terbangun dan pengurangan lahan nonterbangun. Dinamika lahan terbangun dan nonterbangun tersebut mempengaruhi interaksi manusia dengan lingkungan dan keadaan ekonomi dan sosial masyarakat kota Malang. Oleh karena itu, informasi distribusi dan luasan lahan terbangun dan nonterbangun diperlukan untuk dapat membantu pengambilan berbagai keputusan perencanaan kota dan wilayah. Sayangnya, belum banyak penelitian terkait distribusi lahan terbangun dan nonterbangun di kota Malang. Penelitian ini bertujuan untuk memetakan distribusi lahan terbangun dan nonterbangun dengan Landsat 8 OLI dan Google Earth Engine (GEE) di kota Malang. Indeks spektral yang dihasilkan dari Landsat 8 OLI seperti NDVI, EVI, BU (NDBI-NDVI), LSWI, dan MNDWI serta titik ketinggian (*elevation*) dan tingkat kelerengan (*slope*) yang diturunkan dari ALOS DSM 30m digunakan sebagai masukan untuk klasifikasi tersupervisi. Ragam teknik klasifikasi tersupervisi seperti Support Vector Machine (SVM), Random Forest (RF), Minimum Distance (MD), Gradient Tree Boost (GTB), dan Classification And Regression Tree (CART) digunakan untuk memetakan distribusi lahan terbangun dan nonterbangun. Random Forest menunjukkan akurasi tertinggi dalam memetakan lahan terbangun dan nonterbangun di kota Malang dengan *Overall Accuracy* 0,96 dan *Kappa Coefficient* 0,91. Luas area terbangun diestimasi sebesar ~55%-61% dan nonterbangun sebesar ~39%-45% dari total luas kota Malang.

Kata Kunci— Google Earth Engine, lahan terbangun, lahan nonterbangun, landsat 8 OLI, kota Malang

I. PENDAHULUAN

URBANISASI menyebabkan penambahan lahan terbangun dan berkurangnya lahan tidak terbangun secara tidak terencana yang berujung pada pengembangan wilayah yang tidak berkelanjutan [1]. Lahan nonterbangun, seperti lahan terbuka, area pertanian, dan hutan, dianggap memiliki nilai ekonomi yang lebih rendah dan seringkali lebih mudah dikonversi menjadi lahan terbangun[2]. Lahan terbangun adalah struktur buatan seperti jalan, area industri, kawasan perkantoran, yang ditutup oleh ragam material yang cenderung dapat menghalangi infiltrasi air ke dalam tanah, seperti aspal, atap, dan tanah yang diperkeras [3]. Pertambahan lahan terbangun dan pengurangan lahan nonterbangun yang tidak terkendali dapat mengubah dinamika ekosistem, meningkatkan konflik sosial, menambah polusi dan timbulan sampah, dan mempercepat pemanasan global [1]. Informasi distribusi lahan terbangun

dan nonterbangun juga diperlukan untuk pemodelan aliran air permukaan dan *urban heat island*, pengelolaan lingkungan, dan perencanaan transportasi [4][5][6]. Oleh karena itu, persebaran lahan terbangun dan nonterbangun perlu untuk dipantau secara berkala.

Citra penginderaan jauh dapat membantu memetakan permukaan terbangun pada area luas dengan biaya yang relatif murah dibandingkan dengan survei terestrial [7]. Berbagai kajian, seperti tata kota dan perubahan penggunaan lahan [8][9]. Sebagai contoh, citra Landsat yang tersedia lebih dari 30 tahun telah memungkinkan pemantauan terhadap dinamika lahan terbangun di permukaan bumi [10]

Berbagai penelitian telah merekomendasikan metode untuk memetakan permukaan terbangun, seperti indeks spektral [10] dan klasifikasi tersupervisi [11]. Indeks spektral dihasilkan dengan mengkombinasikan dua atau lebih band citra satelit penginderaan jauh. Indeks spektral dapat menonjolkan karakteristik penutup lahan tertentu sehingga memudahkan proses pengidentifikasian dan interpretasi [12]. Oleh karena itu, indeks spektral sering digunakan untuk memonitor perubahan alami penutupan lahan atau dinamika lahan terbangun sebagai salah satu bentuk intervensi manusia terhadap lingkungan [13][14]. Selanjutnya, indeks spektral dapat digunakan sebagai data masukan berbagai teknik klasifikasi tersupervisi untuk mendeteksi permukaan terbangun apabila didukung *training sample* yang memadai [15].

Saat ini, semakin banyak penelitian yang memanfaatkan Google Earth Engine (GEE) untuk melakukan pemetaan lahan terbangun dan nonterbangun di permukaan bumi, [16], [17]. GEE adalah platform komputasi awan yang menyediakan akses terhadap beragam data spasial, termasuk citra satelit penginderaan jauh [18]. GEE memungkinkan pengguna untuk melakukan analisa dan visualisasi terhadap beragam data spasial secara gratis. Sebagai fitur dan kemudahan yang disediakan oleh GEE membantu para peneliti untuk lebih fokus pada analisa dan interpretasi data.

Kota Malang terletak di tengah-tengah wilayah Kabupaten Malang. Kota Malang terletak 445-526 meter di atas permukaan air laut. Sebagai salah satu tujuan wisata, kota Malang terletak pada posisi 112.06° - 112.07° Bujur Timur dan 7.06° - 8.02° Lintang Selatan [19]. Perekonomian kota Malang tumbuh dengan pesat karena oleh didukung sektor

pendidikan dan perdagangan dan jasa. Pertumbuhan kota Malang telah berdampak pada peningkatan lahan terbangun dan pengurangan lahan nonterbangun yang tentu saja mengubah dinamika ekosistem dan iklim lokal di kota Malang.

Penelitian sebelumnya telah memanfaatkan ragam citra penginderaan jauh untuk memetakan lahan terbangun di berbagai kota di dunia [20], [21]. Namun, belum banyak penelitian yang melakukan pemetaan lahan terbangun dengan citra Landsat 8 OLI di kota Malang. Penelitian ini bertujuan untuk memetakan lahan terbangun dan nonterbangun di Kota Malang dengan memanfaatkan citra Landsat 8 OLI dan Google Earth Engine. Hasil penelitian ini diharapkan dapat menjadi referensi terkait distribusi dan luas lahan terbangun dan nonterbangun serta menjadi masukan dalam pengambilan berbagai keputusan, misalnya terkait pengelolaan lingkungan hidup yang secara langsung ataupun tidak langsung berkontribusi bagi penataan ruang di Kota Malang.

II. MATERIAL DAN METODE

A. Landsat 8 OLI

Landsat 8 memiliki dua sensor yaitu sensor Operational Land Imager (OLI) dan Thermal Infrared Sensor (TIRS) [22]. Landsat 8 memiliki 4 *visible bands*, 1 *near-infrared (NIR) bands*, 2 *short-wave infrared (SWIR) bands* yang diproses menjadi reflektansi permukaan terortorektifikasi dan 2 *thermal infrared (TIR) bands* yang diproses ke suhu kecerahan terortorektifikasi [22]. Rincian band 1-7 pada sensor Landsat 8 OLI dan potensi pemanfaatannya, antara lain Band 1 Coastal/Aerosol (0.435 – 0.451 μm , 30m) cocok untuk studi kepesisiran dan aerosol; Band 2 Blue (0.452 – 0.512 μm , 30 m) cocok untuk pemetaan batimetri dan membedakan tanah dari vegetasi; Band 3 Green (0.533 – 0.590 μm , 30 m) dapat menekankan tanaman sehat; Band 4 Red (0.636 – 0.673 μm , 30 m) mampu mendeteksi lereng vegetasi (*vegetation slope*); Band 5 Near-Infrared (0.851 – 0.879 μm , 30 m) dapat menekankan kandungan biomassa dan garis pantai; dan Band 6 SWIR-1 (Short Wave Infrared-1) (1.566 – 1.651 μm , 30 m) dan Band 7 SWIR-2 (2.107 – 2.294 μm , 30 m) cocok untuk membedakan kadar air vegetasi dan tanah. Landsat 8 memiliki orbit *Sun-Synchronous* pada ketinggian 705 km dan resolusi temporal 16 hari [22].

Citra Landsat 8 OLI Surface Reflectance (SR) Tier 1 periode Januari 2021 hingga Desember 2021 diakses dari platform GEE. Landsat 8 SR merupakan reflektansi permukaan yang dikoreksi secara atmosferik dari sensor Landsat 8 OLI/TIRS. Citra ini dapat langsung digunakan untuk mendukung analisa spasial tanpa perlu melakukan koreksi geometrik dan radiometrik.

Citra Digital Surface Model (DSM) Global ALOS 3D resolusi spasial 30m (AW3D30) juga diakses dengan GEE. AW3D30 adalah dataset *global digital surface model (DSM)* dengan resolusi horisontal sekitar 30 meter (1 *arcsec mesh*) [23]. Elevasi AW3D30 dihitung dengan proses pencocokan citra (*image matching*) yang menggunakan sepasang stereo gambar optik. Awan, salju, dan es secara otomatis diidentifikasi selama pemrosesan. Namun, upaya ini tidak menutup kemungkinan masih terdapat titik yang tidak cocok terutama di sekitar (atau di tepi) awan, salju, dan area es, yang menyebabkan beberapa kesalahan ketinggian pada citra DSM akhir [24].

Data sekunder, seperti dokumen pemerintah dan *shapefiles (.shp)* dikumpulkan dan digunakan untuk mendukung pencapaian tujuan penelitian. Sebagai contoh, batas administrasi kota Malang diperoleh dari pemerintah provinsi Jawa Timur. Dokumen terkait profil kota Malang diperoleh dari website Badan Pusat Statistik (BPS) kota Malang [19].

Sampel lahan terbangun dan nonterbangun dikumpulkan untuk mendukung klasifikasi tersupervisi dengan menggunakan analisis visual terhadap *spectral signature* lahan terbangun (n=360) dan nonterbangun (n=225). Gambar 1 menunjukkan rerata *spectral signature* kelas lahan terbangun dan nonterbangun dari *band* Landsat 8 OLI di kota Malang. Secara visual, kedua *spectral signature* ini selaras dengan penelitian sebelumnya [25][26]. Selain itu, citra Google Map juga digunakan untuk membantu memilih kelas penggunaan lahan. Penggunaan lahan yang termasuk kelas lahan terbangun antara lain bangunan permukiman, perkantoran, industri, dan jalan. Penggunaan lahan yang termasuk lahan nonterbangun antara lain sawah, lapangan rumput, hutan, tutupan vegetasi, lahan kosong, dan tubuh air.

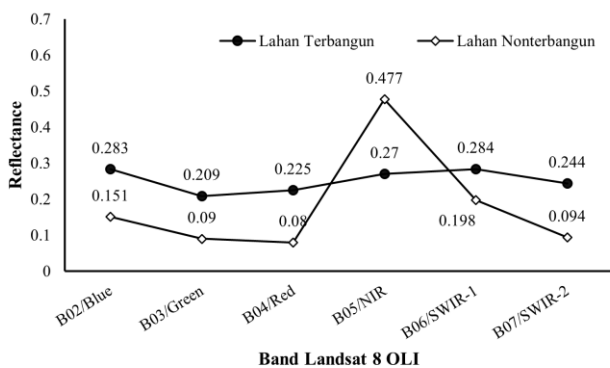
B. Indeks spektral

Beberapa indeks spektral, seperti *Normalized Difference Vegetation Index (NDVI)* [27], *Enhanced Vegetation Index (EVI)* [28], *Built-up Index (BU)* yang dibuat dari selisih antara NDBI (*Normalized Difference Built-up Index*) dan NDVI [29], *Land Surface Water Index (LSWI)* [30], *Modified Normalized Difference Water Index (MNDWI)* [31] dihasilkan dari citra Landsat 8 OLI (Tabel 1). NDVI dan EVI menonjolkan tutupan vegetasi dan memberikan informasi tentang kondisi vegetasi dengan memanfaatkan perbedaan refleksi pada band *visible* atau tampak (VIS) dan *Near-Infrared (NIR)*. Selanjutnya, NDBI dapat membantu untuk mendeteksi area terbangun. Kawasan perkotaan memiliki reflektansi yang lebih tinggi pada band SWIR daripada band NIR. Kemudian, LSWI dan MNDWI cenderung menonjolkan tubuh air dan nontubuh air. LSWI menggunakan SWIR dan NIR. Cahaya cenderung diserap kuat oleh tubuh air pada band SWIR. LSWI sensitif terhadap jumlah total air di vegetasi dan latar belakang tanah disekitarnya [30]. MNDWI lebih cocok untuk menonjolkan tubuh air disekitar lahan terbangun daripada *Normalized Difference Water Index (NDWI)* dikarenakan MNDWI dapat secara efisien mengurangi dan bahkan menghilangkan gangguan refleksi yang disebabkan lahan terbangun [31]. Terakhir, BU merupakan selisih NDBI dan NDVI. Area terbangun memiliki nilai BU yang besar sedangkan area nonterbangun cenderung memiliki nilai BU yang kecil [29].


C. Klasifikasi tersupervisi

Klasifikasi tersupervisi digunakan untuk memetakan lahan terbangun dan nonterbangun berdasarkan *training sample* yang telah dikumpulkan. Indeks spektral dan band 1-7 Landsat 8 OLI digunakan sebagai data masukan untuk klasifikasi tersupervisi. Data ketinggian (*elevation*) dan tingkat kelerengan (*slope*) yang dihasilkan dari ALOS DSM juga digunakan sebagai masukan klasifikasi tersupervisi. GEE telah menyediakan lebih dari 20 fungsi yang dapat digunakan untuk melakukan klasifikasi tersupervisi [18]. Penelitian ini membandingkan algoritma klasifikasi

tersupervisi, antara lain Support Vector Machine (SVM) [32], Random Forest (RF) [33], Minimum Distance [34], Gradient Tree Boost [35], dan Classification and Regression Tree (CART) [36] dalam memetakan distribusi lahan terbangun dan nonterbangun di kota Malang. Tabel 2 menunjukkan parameter-parameter dari algoritma klasifikasi tersupervisi yang terpilih untuk meningkatkan akurasi klasifikasi tersupervisi. Sebagai tambahan, penelitian ini tidak berfokus pada pembahasan formula algoritma klasifikasi tersupervisi yang digunakan dikarenakan ingin menekankan keunggulan penggunaan GEE. Selain terhadap data spasial dalam jumlah yang besar, GEE memberikan kemudahan akses dalam penggunaan fungsi matematika sederhana hingga operasi geostatistik, pembelajaran mesin, dan pemrosesan gambar yang kompleks [18]. GEE terus berupaya meningkatkan akses terhadap data spasial, daya komputasi, dan teknik analisis canggih, namun dalam format yang mudah digunakan. Peneliti dapat memanfaatkan algoritma pembelajaran mesin tersupervisi dan non-supervisi yang sudah ada dan disediakan tim pengembang GEE tanpa perlu melakukan *coding* fungsi matematika dari awal. Fasilitasi ini dimaksudkan agar peneliti dapat memanfaatkan data spasial tanpa mengeluarkan sumberdaya yang besar, seperti waktu untuk data preprocessing yang lama, kemampuan komputasi mesin yang tinggi, dan ruang penyimpanan data yang besar. Peneliti diharapkan dapat fokus pada penyelidikan ilmiah dan pengembangan kerangka berpikir sesuai dengan disiplin ilmunya untuk menjawab permasalahan sosial, ekonomi, dan lingkungan. Penelitian selanjutnya yang ingin melakukan eksplorasi lebih dalam terkait klasifikasi tersupervisi yang digunakan dalam penelitian ini didorong untuk dapat merujuk pada berbagai literatur yang relevan [37][38][39][40][41]. Selanjutnya, luas lahan terbangun dan nonterbangun diperoleh dari masing-masing teknik klasifikasi tersupervisi yang digunakan.



Gambar 1. Rerata Spectral Signature Landsat 8 OLI kelas lahan terbangun (n=360) dan nonterbangun (n=225) di Kota Malang



Gambar 2. Batas Administrasi Kota Malang

D. Lokasi Penelitian

Kota Malang berbatasan dengan kecamatan-kecamatan Kabupaten Malang. Kecamatan Singosari dan Karangploso merupakan batas disebelah utara, Kecamatan Pakis dan Tumpang disebelah timur, Kecamatan Tajinan dan Pakisaji disebelah Selatan, dan Kecamatan Wagir dan Dau disebelah Barat (Gambar 2). Kota Malang terbagi dalam lima kecamatan yaitu Kecamatan Kedungkandang, Sukun, Klojen, Blimbing dan Lowokwaru. Kecamatan dengan luas tertinggi adalah Kedungkandang (36,24%) dan luas terendah adalah Klojen (8,02%).

E. Accuracy Assessment

Penilaian akurasi dilakukan untuk menilai hasil klasifikasi tersupervisi. Tujuan analisis dari penelitian ini adalah klasifikasi. Beberapa metrik digunakan untuk menilai hasil klasifikasi lahan terbangun dan lahan tidak terbangun, antara lain Overall Accuracy (OA), Producer's Accuracy (PA), dan User's Accuracy (UA), dan Kappa Coefficient [42]. Penelitian ini tidak menampilkan detail lokasi *sampling* yang digunakan untuk validasi dikarenakan data untuk *training* dan *validasi* diperoleh secara acak dari total sampel data. Gambar 3a menunjukkan seluruh sample titik koordinat (n=585) untuk merepresentasikan lahan terbangun dan nonterbangun. Data yang digunakan untuk *training* dan *validasi* hasil klasifikasi memiliki proporsi 70% (n=406) dan 30% (n=179). Selain itu, penelitian ini juga tidak mendaftarkan detail lokasi *sampling* yang digunakan untuk validasi untuk alasan keterbatasan ruang pada artikel. Selanjutnya, penelitian ini juga tidak melakukan cek lapangan tambahan untuk validasi hasil klasifikasi dikarenakan data validasi (30%) berasal dari total sampel lahan terbangun dan nonterbangun yang telah dikumpulkan. Penelitian ini berupaya menjamin kualitas sampel dengan memilih titik sampel pada lokasi dengan *mixed pixel* rendah (bantuan Google Map) dan karakteristik *spectral signature* lahan terbangun dan non terbangun.

III. HASIL DAN PEMBAHASAN

A. Indeks Spektral

Indeks Spektral digunakan sebagai masukan untuk klasifikasi tersupervisi lahan terbangun dan nonterbangun. Gambar 3 menunjukkan ragam spasial data yang digunakan, mencakup NDVI, EVI, MNDWI, LSWI, Built-Up Index (NDVI-NDBI) yang diturunkan dari Landsat 8 OLI dan Citra *elevation* dan *slope* yang dihasilkan dari ALOS DSM.

Tabel 1. Indeks Spektral yang diturunkan dari Landsat 8 OLI

Indeks Spektral	Formula	Referensi
a	b	c
Normalized Difference Vegetation Index (NDVI)	$(NIR - Red) / (NIR + Red)$	[27]
Enhanced Vegetation Index (3 band) (EVI)	$2.5 \times (NIR - Red) / (NIR + 6 \times Red - 7.5 \times Blue + 1)$	[28]
Normalized Difference Built-up Index (NDBI)	$(SWIR - NIR) / (SWIR + NIR)$	[29]
Built-up Index	$NDBI - NDVI$	[29]
Land Surface Water Index (LSWI)	$(NIR - SWIR) / (NIR + SWIR)$	[30]
Modified Normalized Difference Water Index (MNDWI)	$(Green - SWIR) / (Green + SWIR)$	[31]

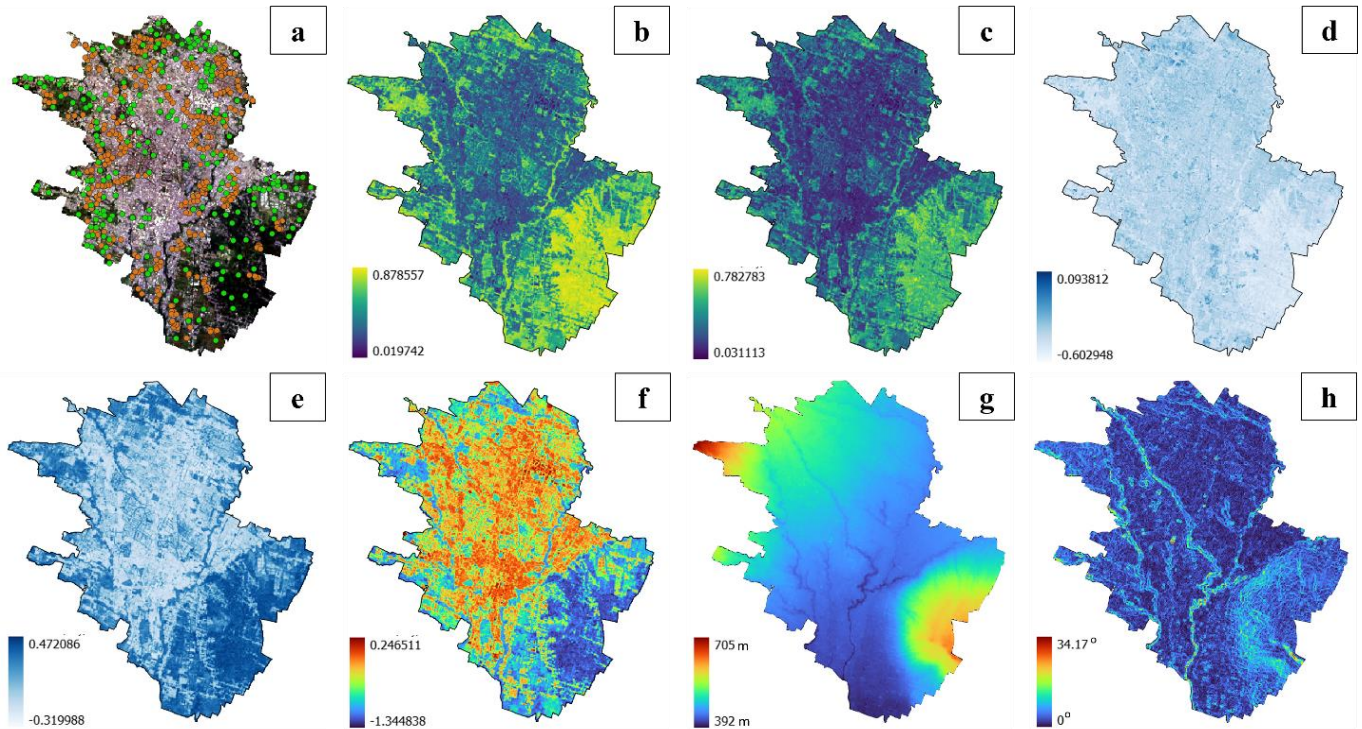
Tabel 2. Parameter algoritma klasifikasi tersupervisi

Teknik Klasifikasi	Parameter Landsat 8 OLI
a	b
Support Vector Machine (SVM)	decisionProcedure: <i>Voting</i> ; svmType: <i>C_SVC</i> ; kernelType: <i>RBF</i> ; shrinking: <i>true</i> ; degree: <i>null</i> ; gamma: <i>0,1</i> ; coef0: <i>null</i> ; cost: <i>30</i> ; nu: <i>null</i> ; terminationEpsilon: <i>null</i> ; lossEpsilon: <i>null</i> ; oneClass: <i>null</i>
Random Forest (RF)	numberOfTrees: <i>20</i> ; variablesPerSplit: <i>null</i> ; minLeafPopulation: <i>1</i> ; bagFraction: <i>0,6</i> ; variablesPerSplit: <i>5</i> ; maxNodes: <i>null</i> ; seed: <i>0</i>
Minimum Distance	metric: <i>mahalanobis</i> ; kNearest: <i>1</i>
Gradient Tree Boost	numberOfTrees: <i>90</i> ; shrinkage: <i>0,005</i> ; samplingRate: <i>0,8</i> ; maxNodes: <i>null</i> ; loss: <i>LeastSquares</i> ; seed: <i>0</i>
Classification and Regression Tree (CART)	maxNodes: <i>null</i> ; minLeafPopulation: <i>1</i>

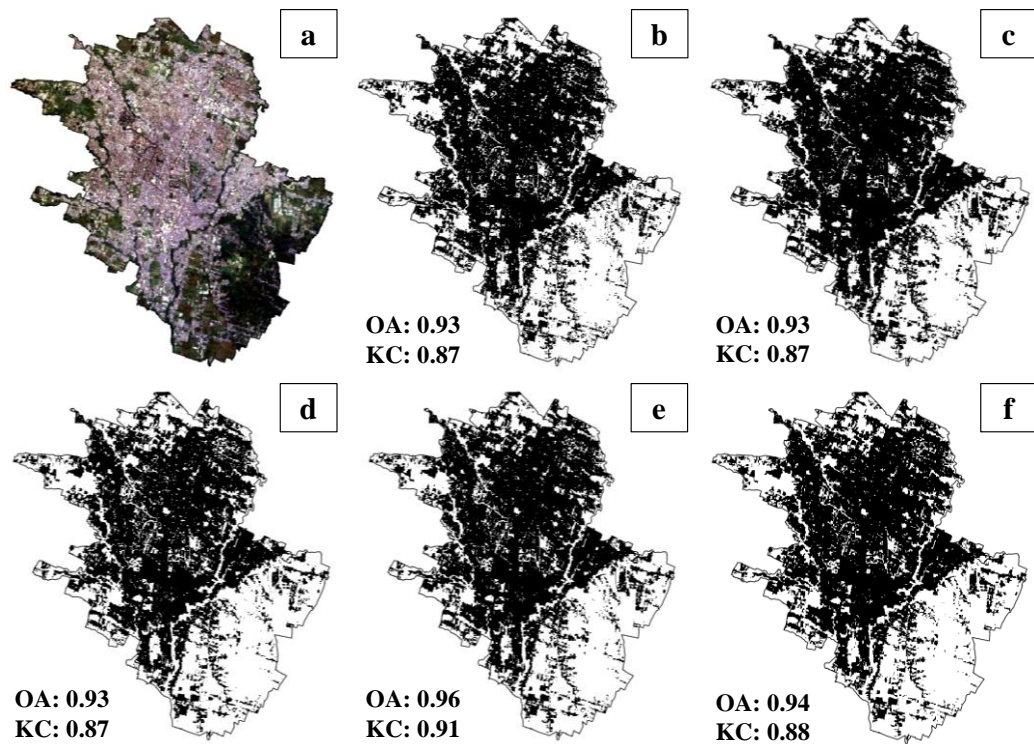
B. Lahan terbangun dan nonterbangun

Distribusi lahan terbangun dan nonterbangun dapat diketahui dengan menggunakan klasifikasi tersupervisi. Gambar 4 menunjukkan hasil klasifikasi lahan terbangun dan nonterbangun di kota Malang menggunakan Support Vector Machine (SVM), Random Forest (RF), Minimum Distance (MD), Gradient Tree Boost (GTB), dan Classification and Regression Tree (CART). Random Forest menunjukkan nilai validasi hasil klasifikasi tertinggi dengan skor *Overall Accuracy* 0.96 dan *Kappa Coefficient* 0.91 (**Error! Reference source not found.**).

Selanjutnya, hasil klasifikasi tersupervisi digunakan untuk melakukan estimasi luas area terbangun dan nonterbangun di kota Malang (Tabel 4). Ragam teknik klasifikasi tersupervisi menunjukkan bahwa luas lahan terbangun sekitar ~55%-61% dan lahan nonterbangun berkisar ~39%-45% dari total luas kota Malang. Sementara itu, Random Forest mengestimasi luas lahan terbangun dan nonterbangun di



Gambar 3. Landsat 8 OLI: a) True Color Composite dengan area terbangun (bulatan jingga) dan tidak terbangun (bulatan hijau); b) NDVI; c) EVI; d) MNDWI; e) LSWI; f) Built-Up Index (NDVI-NDBI); ALOS Digital Surface Model (DSM); g) elevation (meter); h) slope (degree)



Gambar 4. Landsat 8 a) True Color Composite; classification results of b) Classification and Regression Trees; c) Gradient Tree Boost; d) Minimum Distance; e) Random Forest; f) Support Vector Machine.

Tabel 3. Akurasi klasifikasi lahan terbangun dan nonterbangun di Kota Malang

Alg.	Akurasi					OA	KC
	terbangun		nonterbangun				
	CA	PA	CA	PA			
a	b	c	d	e	f	g	
SVM	0.9444	0.9622	0.9436	0.9178	0.9441	0.8838	
RF	0.9626	0.9716	0.9583	0.9452	0.9608	0.91	
MD	0.96	0.93	0.9	0.94	0.93	0.87	
GTB	0.9279	0.9716	0.9558	0.8904	0.9385	0.8713	
CART	0.9523	0.9433	0.9189	0.9315	0.9385	0.8730	

SVM: Support Vector Machine; RF: Random Forest; MD: Minimum Distance; GTB: Gradient Tree Boost; CART: Classification and Regression Tree; CA: Consumer's accuracy; PA: Producer's accuracy; OA: Overall accuracy; KC.: Kappa Coefficient.

Tabel 4. Perbandingan luas lahan terbangun dan nonterbangun (km²) hasil klasifikasi tersupervisi

Algoritma klasifikasi	Luas (km ²)			
	Terbangun	%	nonterbangun	%
a	b	c	d	e
SVM	62.96	56.45	48.1	43.12
RF	64.16	57.52	46.9	42.05
MD	61.07	54.75	49.99	44.82
GTB	67.69	60.69	43.38	38.89
CART	64.39	57.73	46.67	41.84
Total Lahan Terbangun + Nonterbangun: 111.54 km ²				

SVM: Support Vector Machine; RF: Random Forest; MD: Minimum Distance; GTB: Gradient Tree Boost; CART: Classification and Regression Tree.

Tabel 5. Luas Lahan Terbangun dan Nonterbangun (km²) di Kota Malang berdasarkan klasifikasi Random Forest Landsat 8 OLI

Kecamatan	Luas (km ²)				
	Terbangun	%	Non Terbangun	%	Total (a + b)
a	b	c	d	e	f
Lowokwaru	15.66	66.78	7.79	33.22	23.45
Blimbing	13.82	77.68	3.97	22.32	17.79
Klojen	8.63	87.88	1.19	12.12	9.82
Kedungkandang	13.28	33.38	26.50	66.62	39.78
Sukun	12.78	63.14	7.46	36.86	20.24
Total	64.17		46.91		111.08

kota Malang sebesar ~64.16 km² dan ~46.9 km² secara berurutan. Tabel 5 menunjukkan luas lahan terbangun dan nonterbangun di lima kecamatan di Kota Malang. Luas lahan terbangun tertinggi berada di kecamatan Klojen (~87.88%) dan terendah berada di kecamatan Kedungkandang (~33.38%) dan luas lahan nonterbangun tertinggi berada di kecamatan Kedungkandang (~66.62%) dan terendah berada di kecamatan Klojen (~12.12%). Informasi ini tentu memberikan gambaran awal akan pentingnya perencanaan pengembangan kota mengingat pentingnya fungsi jasa ekosistem lahan nonterbangun ditengah pesatnya perkembangan kota Malang.

Kota Malang memiliki ragam penggunaan lahan yang mempengaruhi kehidupan sosial ekonomi masyarakat. Ragam penggunaan lahan ini dapat dikategorikan menjadi lahan terbangun dan nonterbangun. Walaupun pengkategorian ini memberikan generalisasi pada dinamika fenomena spasial dan mengurangi potensi manfaat luaran dalam bidang tata ruang, unit analisis ini dapat dengan mudah menggambarkan seberapa besar intervensi manusia terhadap lingkungan dan dapat menjadi masukan untuk penelitian atau pemodelan selanjutnya, misalnya terkait interaksi manusia dan lingkungan.

IV. KESIMPULAN

Dengan mengambil kasus di kota Malang, penelitian ini menunjukkan bahwa Landsat 8 OLI dapat dimanfaatkan untuk memetakan lahan terbangun dan nonterbangun. Google Earth Engine terbukti dapat memudahkan proses pemetaan tersebut dan membantu pengambil keputusan dalam memantau dinamika lahan terbangun dan nonterbangun. Teknik klasifikasi tersupervisi Random Forest menunjukkan akurasi terbaik dalam memetakan lahan terbangun dan nonterbangun di kota Malang dengan nilai *Overall Accuracy* 0,96 dan *Kappa Coefficient* 0,91. Luas area terbangun adalah sebesar ~55%-61% dan nonterbangun adalah sebesar ~39%-45% dari total luas kota Malang. Hasil klasifikasi Random Forest menunjukkan bahwa luas lahan terbangun tertinggi (~87.88%) dan lahan nonterbangun terendah (~12.12%) berada di kecamatan Klojen. Sementara itu, luas lahan nonterbangun tertinggi (~66.62%) dan lahan terbangun terendah (~33.38%) berada di kecamatan Kedungkandang. Walaupun hanya berfokus pada klasifikasi lahan terbangun dan non terbangun

dan tidak berfokus secara spesifik pada analisa *time-series* dan klasifikasi penggunaan lahan, hasil penelitian ini telah memberikan rekomendasi teknik klasifikasi tersupervisi yang dapat digunakan oleh penelitian selanjutnya untuk melakukan analisa *time-series* perubahan penggunaan lahan di kota Malang. Penelitian ini merekomendasikan kajian lanjutan terkait monitoring dinamika lahan terbangun dan nonterbangun antar waktu dalam konteks perambatan kota di sekitar Malang Raya.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Fakultas Ilmu Komputer yang telah menyediakan ruang kerja dan fasilitasnya untuk menyelesaikan artikel ini. Terima kasih kepada tim pengembang Google Earth Engine yang telah menyediakan akses terhadap data spasial dan Integrated Development Environment (IDE).

DAFTAR PUSTAKA

- [1] UN, *World Urbanization Prospects - The 2018 Revision*. UN, Department of Economic and Social Affairs Population Division, 2018. [Online]. Available: <https://population.un.org/wup/Publications/Files/WUP2018-Report.pdf>
- [2] M. Rondhi, P. A. Pratiwi, V. T. Handini, A. F. Sunartomo, and S. A. Budiman, "Agricultural Land Conversion, Land Economic Value, and Sustainable Agriculture: A Case Study in East Java, Indonesia," *Land (Basel)*, vol. 7, no. 4, 2018, doi: 10.3390/land7040148.
- [3] C. L. Arnold and C. J. Gibbons, "Impervious Surface Coverage: The Emergence of a Key Environmental Indicator," *Journal of the American Planning Association*, vol. 62, no. 2, pp. 243–258, Jun. 1996, doi: 10.1080/01944369608975688.
- [4] M. L. Imhoff, P. Zhang, R. E. Wolfe, and L. Bounoua, "Remote sensing of the urban heat island effect across biomes in the continental USA," *Remote Sens Environ*, vol. 114, no. 3, pp. 504–513, 2010, doi: <https://doi.org/10.1016/j.rse.2009.10.008>.
- [5] A. R. Shahtahmassebi *et al.*, "How do modern transportation projects impact on development of impervious surfaces via new urban area and urban intensification? Evidence from Hangzhou Bay Bridge, China," *Land use policy*, vol. 77, pp. 479–497, 2018, doi: <https://doi.org/10.1016/j.landusepol.2018.05.059>.
- [6] E. Brabec, S. Schulte, and P. L. Richards, "Impervious Surfaces and Water Quality: A Review of Current Literature and Its Implications for Watershed Planning," *J Plan Lit*, vol. 16, no. 4, pp. 499–514, May 2002, doi: 10.1177/088541202400903563.
- [7] J. Cihlar, "Land cover mapping of large areas from satellites: Status and research priorities," *Int J Remote Sens*, vol. 21, no. 6–7, pp. 1093–1114, Jan. 2000, doi: 10.1080/014311600210092.
- [8] K. Islam, M. Jashimuddin, B. Nath, and T. K. Nath, "Land use classification and change detection by using multi-temporal remotely sensed imagery: The case of Chunati wildlife sanctuary, Bangladesh," *The Egyptian Journal of Remote Sensing and Space Science*, vol. 21, no. 1, pp. 37–47, 2018, doi: <https://doi.org/10.1016/j.ejrs.2016.12.005>.
- [9] Z. Deng, X. Zhu, Q. He, and L. Tang, "Land use/land cover classification using time series Landsat 8 images in a heavily urbanized area," *Advances in Space Research*, vol. 63, no. 7, pp. 2144–2154, 2019, doi: <https://doi.org/10.1016/j.asr.2018.12.005>.
- [10] W. Cao, Y. Zhou, R. Li, X. Li, and H. Zhang, "Monitoring long-term annual urban expansion (1986–2017) in the largest archipelago of China," *Science of The Total Environment*, vol. 776, p. 146015, Jul. 2021, doi: 10.1016/J.SCIOTENV.2021.146015.
- [11] Q. Zhang, B. Li, D. Thau, and R. Moore, "Building a better Urban picture: Combining day and night remote sensing imagery," *Remote Sens (Basel)*, vol. 7, no. 9, pp. 11887–11913, 2015, doi: 10.3390/RS70911887.
- [12] M. Boschetti, F. Nutini, G. Manfron, P. A. Brivio, and A. Nelson, "Comparative Analysis of Normalised Difference Spectral Indices Derived from MODIS for Detecting Surface Water in Flooded Rice Cropping Systems," *PLoS One*, vol. 9, no. 2, pp. e88741–, Feb. 2014, [Online]. Available: <https://doi.org/10.1371/journal.pone.0088741>
- [13] R. Kaur and P. Pandey, "A review on spectral indices for built-up area extraction using remote sensing technology," *Arabian Journal of Geosciences*, vol. 15, no. 5, p. 391, 2022, doi: 10.1007/s12517-022-09688-x.
- [14] J. C. Valdiviezo-N, A. Téllez-Quiñones, A. Salazar-Garibay, and A. A. López-Caloca, "Built-up index methods and their applications for urban extraction from Sentinel 2A satellite data: discussion," *Journal of the Optical Society of America A*, vol. 35, no. 1, pp. 35–44, 2018, doi: 10.1364/JOSAA.35.000035.
- [15] D. Lu and Q. Weng, "A survey of image classification methods and techniques for improving classification performance," *Int J Remote Sens*, vol. 28, no. 5, pp. 823–870, Mar. 2007, doi: 10.1080/01431160600746456.
- [16] N. N. Patela *et al.*, "Multitemporal settlement and population mapping from landsat using google earth engine," *International Journal of Applied Earth Observation and Geoinformation*, vol. 35, no. PB, pp. 199–208, 2015, doi: 10.1016/j.jag.2014.09.005.
- [17] X. Zhang *et al.*, "Development of a global 30m impervious surface map using multisource and multitemporal remote sensing datasets with the Google Earth Engine platform," *Earth Syst Sci Data*, vol. 12, no. 3, pp. 1625–1648, Jul. 2020, doi: 10.5194/ESSD-12-1625-2020.
- [18] N. Gorelick, M. Hancher, M. Dixon, S. Ilyushchenko, D. Thau, and R. Moore, "Google Earth Engine: Planetary-scale geospatial analysis for everyone," *Remote Sens Environ*, vol. 202, pp. 18–27, Dec. 2017, doi: 10.1016/J.RSE.2017.06.031.
- [19] BPS, *Kota Malang dalam Angka 2021*. Kota Malang: BPS Kota Malang, 2021.
- [20] S. Jiang, Z. Zhang, H. Ren, G. Wei, M. Xu, and B. Liu, "Spatiotemporal characteristics of urban land expansion and population growth in africa from 2001 to 2019: Evidence from population density data," *ISPRS Int J Geoinf*, vol. 10, no. 9, Sep. 2021, doi: 10.3390/IJGI10090584.
- [21] J. Xu, Y. Zhao, K. Zhong, F. Zhang, X. Liu, and C. Sun, "Measuring spatio-temporal dynamics of impervious surface in Guangzhou, China, from 1988 to 2015, using time-series Landsat imagery," *Science of the Total Environment*, vol. 627, pp. 264–281, Jun. 2018, doi: 10.1016/j.scitotenv.2018.01.155.
- [22] USGS, *Landsat 8 (L8) Data Users Handbook*. U.S. Geological Survey, 2019. [Online]. Available: https://d9-wret.s3.us-west-2.amazonaws.com/assets/palladium/production/s3fs-public/atoms/files/LSDS-1574_L8_Data_Users_Handbook-v5.0.pdf
- [23] T. Tadono *et al.*, "Generation of the 30 M-Mesh Global Digital Surface Model by ALOS PRISM," *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, vol. XLI-B4, pp. 157–162, Jun. 2016, doi: 10.5194/isprs-archives-XLI-B4-157-2016.
- [24] JAXA, *ALOS Global Digital Surface Model (DSM) ALOS World 3D-30m (AW3D30)*. Earth Observation Research Center Japan Aerospace Exploration Agency, 2020.
- [25] A. Khan *et al.*, "Step-wise Land-class Elimination Approach for Extracting Mixed-type Built-up Areas of Kolkata megacity," *Geocarto Int*, vol. 34, pp. 1–47, Nov. 2017, doi: 10.1080/10106049.2017.1408704.
- [26] S. Ghosh, N. das Chatterjee, and S. Dinda, "Relation between urban biophysical composition and dynamics of land surface temperature in the Kolkata metropolitan area: a GIS and statistical based analysis for sustainable planning," *Model Earth Syst Environ*, vol. 5, Mar. 2019, doi: 10.1007/s40808-018-0535-9.
- [27] D. W. Rouse, J.W. Haas, R.H., Scheel, J.A., and Deering, "Monitoring Vegetation Systems in the Great Plains with ERTS," in *Proceedings, 3rd Earth Resource Technology Satellite (ERTS) Symposium*, 1974, pp. 48–62.
- [28] A. Huete, K. Didan, T. Miura, E. P. Rodriguez, X. Gao, and L. G. Ferreira, "Overview of the radiometric and biophysical performance of the MODIS vegetation indices," *Remote Sens Environ*, vol. 83, no. 1–2, pp. 195–213, Nov. 2002, doi: 10.1016/S0034-4257(02)00096-2.

- [29] L. Lu, H. Guo, C. Wang, M. Pesaresi, and D. Ehrlich, "Monitoring bidecadal development of urban agglomeration with remote sensing images in the Jing-Jin-Tang area, China," *J Appl Remote Sens*, vol. 8, no. 1, pp. 1–13, Feb. 2014, doi: 10.1117/1.JRS.8.084592.
- [30] X. Xiao *et al.*, "Satellite-based modeling of gross primary production in an evergreen needleleaf forest," *Remote Sens Environ*, vol. 89, no. 4, pp. 519–534, 2004, doi: <https://doi.org/10.1016/j.rse.2003.11.008>.
- [31] H. Xu, "Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery," *Int J Remote Sens*, vol. 27, no. 14, pp. 3025–3033, Jul. 2006, doi: 10.1080/01431160600589179.
- [32] S. Park, J. Im, S. Park, C. Yoo, H. Han, and J. Rhee, "Classification and Mapping of Paddy Rice by Combining Landsat and SAR Time Series Data," *Remote Sensing*, vol. 10, no. 3, 2018. doi: 10.3390/rs10030447.
- [33] T. N. Phan, V. Kuch, and L. W. Lehnert, "Land Cover Classification using Google Earth Engine and Random Forest Classifier—The Role of Image Composition," *Remote Sensing*, vol. 12, no. 15, 2020. doi: 10.3390/rs12152411.
- [34] V. Nasiri, A. Deljouei, F. Moradi, S. M. Sadeghi, and S. A. Borz, "Land Use and Land Cover Mapping Using Sentinel-2, Landsat-8 Satellite Images, and Google Earth Engine: A Comparison of Two Composition Methods," *Remote Sensing*, vol. 14, no. 9, 2022. doi: 10.3390/rs14091977.
- [35] L. Sujud, H. Jaafar, M. A. Haj Hassan, and R. Zurayk, "Cannabis detection from optical and RADAR data fusion: A comparative analysis of the SMILE machine learning algorithms in Google Earth Engine," *Remote Sens Appl*, vol. 24, p. 100639, 2021, doi: <https://doi.org/10.1016/j.rsase.2021.100639>.
- [36] C. J. Breiman, L., Friedman, J.H., Olshen, R.A., & Stone, *Classification And Regression Trees*, 1st ed. Routledge, 1984. doi: <https://doi.org/10.1201/9781315139470>.
- [37] C. Cortes and V. Vapnik, "Support-vector networks," *Mach Learn*, vol. 20, no. 3, pp. 273–297, 1995, doi: 10.1007/BF00994018.
- [38] L. Breiman, "Random Forests," *Mach Learn*, vol. 45, no. 1, pp. 5–32, 2001, doi: 10.1023/A:1010933404324.
- [39] A. G. Wacker and D. A. Landgrebe, *Minimum Distance Classification in Remote Sensing*. Purdue University, Laboratory for Applications of Remote Sensing (LARS), 1972. [Online]. Available: <https://books.google.co.id/books?id=VUOnAQAACAAJ>
- [40] J. H. Friedman, "Greedy Function Approximation: A Gradient Boosting Machine," *The Annals of Statistics*, vol. 29, no. 5, pp. 1189–1232, 2001, [Online]. Available: <http://www.jstor.org/stable/2699986>
- [41] L. Breiman, *Classification and Regression Trees*. Wadsworth/Thomson Learning, 1984. [Online]. Available: <https://books.google.co.id/books?id=8E9QAQACAAJ>
- [42] K. Congalton, R.G., & Green, *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*, 2nd ed. CRC Press, 2008. doi: <https://doi.org/10.1201/9781420055139>.