



Analisis Perbandingan Metode Klasifikasi Pada Pemetaan Tutupan Lahan di Provinsi DI Yogyakarta Tahun 2023

Fauzana Afininnas¹, Yulia Nawang Wulandari², Achmad Fioren Jati Golo³, Robert Kurniawan⁴

^{1,2,3}Program Studi Statistika, Politeknik Statistika STIS Jakarta, Indonesia

⁴Program Studi Komputasi Statistik, Politeknik Statistika STIS Jakarta, Indonesia

¹212112054@stis.ac.id

²212112425@stis.ac.id

³212111837@stis.ac.id

⁴robertk@stis.ac.id

Corresponding author email: 212112054@stis.ac.id

Abstract: This research compares three land cover classification methods in DI Yogyakarta Province using Sentinel-2A satellite imagery in 2023. The methods used include Classification and Regression Trees (CART), Random Forest (RF), and Support Vector Machine (SVM). This research aims to identify the most effective classification method in estimating land cover area by comparing the accuracy, efficiency, and adaptability of each method. The results show that the CART method has an overall accuracy of 81.26 percent and a kappa coefficient of 73.35 percent, Random Forest has an overall accuracy of 83.02 percent and a kappa coefficient of 76.28 percent, and SVM has an overall accuracy of 80.50 percent and a kappa coefficient of 71.54 percent. Based on the overall accuracy and kappa coefficient values, the Random Forest method is the best classification method compared to CART and SVM in land cover mapping in the DI Yogyakarta Province in 2023. This method was successful in identifying vegetation as the dominant land cover in the region. These findings contribute to sustainable spatial planning and natural resource management in DI Yogyakarta Province, supporting the achievement of sustainable development goals (SDGs) related to life on land and sustainable cities.

Keywords: Land Cover, Sentinel-2A, CART, Random Forest, SVM

Abstrak: Penelitian ini membandingkan tiga metode klasifikasi tutupan lahan di Provinsi DI Yogyakarta menggunakan citra satelit Sentinel-2A pada tahun 2023. Metode yang digunakan meliputi *Classification and Regression Trees* (CART), *Random Forest* (RF), dan *Support Vector Machine* (SVM). Penelitian ini bertujuan untuk mengidentifikasi metode klasifikasi yang paling efektif dalam mengestimasi luas tutupan lahan dengan membandingkan akurasi, efisiensi, dan adaptabilitas dari masing-masing metode. Hasil menunjukkan bahwa metode CART memiliki *overall accuracy* sebesar 81,26 persen dan *kappa coefficient* sebesar 73,35 persen, *Random Forest* memiliki *overall accuracy* sebesar 83,02 persen dan *kappa coefficient* sebesar 76,28 persen, serta SVM memiliki *overall accuracy* sebesar 80,50 persen dan *kappa coefficient* sebesar 71,54 persen. Berdasarkan nilai *overall accuracy* dan *kappa coefficient*, metode *Random Forest* merupakan metode klasifikasi terbaik dibandingkan CART dan SVM dalam pemetaan tutupan lahan di Provinsi DI Yogyakarta tahun 2023. Metode ini berhasil mengidentifikasi vegetasi sebagai tutupan lahan dominan di wilayah tersebut. Temuan ini berkontribusi pada perencanaan tata ruang yang berkelanjutan dan pengelolaan sumber daya alam di Provinsi DI Yogyakarta, mendukung pencapaian tujuan pembangunan berkelanjutan (SDGs) terkait kehidupan di darat dan kota yang berkelanjutan.

Kata kunci: Tutupan Lahan, Sentinel-2A, CART, *Random Forest*, SVM

I. PENDAHULUAN

Tutupan lahan merupakan gambaran penting dari permukaan bumi dan informasi tutupan lahan yang eksplisit secara spasial serta ringkasan statistik merupakan persyaratan untuk serangkaian keputusan pengelolaan sumber daya alam pada skala lokal, nasional, dan internasional [1]. Tutupan lahan dapat menggambarkan kondisi alam dan sosial dari suatu wilayah sehingga menyediakan informasi penting untuk memahami berbagai fenomena di permukaan bumi. Sebagai sumber daya alam dan elemen yang penting dalam kehidupan manusia, tutupan lahan berubah sesuai dengan ruang dan waktu [2]. Perubahan tutupan lahan sendiri merupakan peralihan dari berbagai jenis penggunaan lahan dan hasil dari interaksi yang kompleks antara lingkungan fisik dan manusia [3].



Pertumbuhan penduduk yang pesat membawa dampak langsung terhadap perubahan tutupan lahan [4]. Salah satu dampak yang timbul pada perubahan tutupan lahan yang diakibatkan oleh pertumbuhan penduduk yang terus meningkat, seperti maraknya penebangan hutan untuk alih fungsi lahan. Tentunya hal tersebut sangat berisiko bagi kehidupan masyarakat karena kurangnya vegetasi menyebabkan menurunnya kualitas udara bersih dan air bersih, serta rusaknya habitat bagi berbagai jenis fauna dan flora. Dampak lainnya dari alih fungsi lahan, di antaranya mudah terjadi banjir bandang, erosi, dan longsor [5]. Berdasarkan data statistik BPS, pertumbuhan penduduk Provinsi DI Yogyakarta pada tahun 2023 sebesar 1,32 persen [6]. Kondisi ini menjadikan Provinsi DI Yogyakarta sebagai provinsi dengan pertumbuhan penduduk terbesar kedua di Pulau Jawa setelah Provinsi Banten. Menurut data Badan Pertanahan Nasional, Provinsi DI Yogyakarta mengalami perubahan penggunaan lahan seluas 282,19 hektar pada tahun 2022, meningkat sebesar 28,73 persen dibandingkan tahun sebelumnya [7]. Sementara itu, berdasarkan data dari Dinas Lingkungan Hidup dan Kehutanan DI Yogyakarta rata-rata penurunan lahan pertanian menjadi lahan terbangun dari tahun 2002 hingga 2018 adalah 232,11 hektar atau 0,42 persen per tahun [8]. Perubahan penggunaan lahan ini mencerminkan dampak dari pertumbuhan penduduk dan kebutuhan pembangunan yang terus meningkat.

Beberapa penelitian terdahulu telah dilakukan untuk mencari metode terbaik dan menganalisis mengenai tutupan lahan. Seperti penelitian yang dilakukan oleh Shao dan Lunetta (2012) yang membandingkan tiga algoritma klasifikasi menggunakan data rangkaian waktu MODIS dan menemukan bahwa Metode *Support Vector Machine* (SVM) memiliki akurasi yang lebih tinggi dibandingkan dengan *Neural Network* (NN) dan *Classification and Regression Trees* (CART) [9]. SVM tampil secara konsisten baik dengan berbagai ukuran sampel *training* dan karakteristik data. SVM terbukti lebih unggul untuk karakterisasi tutupan lahan pada tingkat regional. Studi menyimpulkan bahwa SVM adalah algoritma terbaik untuk jenis klasifikasi ini. SVM menunjukkan hasil yang lebih baik dalam mengklasifikasikan lahan perkotaan dan pertanian, dengan penggunaan piksel homogen sebagai data referensi yang secara signifikan meningkatkan akurasi keseluruhan. SVM juga menunjukkan potensi dalam mengklasifikasikan piksel heterogen dan karakteristik data referensi sangat penting untuk statistik akurasi dalam klasifikasi citra penginderaan jauh. Penelitian lain dilakukan oleh Karina dan Kurniawan (2019) di Kabupaten Lahat menggunakan citra satelit Landsat 8 untuk mengidentifikasi penggunaan lahan [10]. Hasil penelitian menunjukkan bahwa kawasan vegetasi merupakan lahan terluas di Kabupaten Lahat, sementara lahan rumput/semak belukar merupakan yang paling sedikit. Peta penggunaan lahan yang dibuat memiliki *overall accuracy* sebesar 89,38 persen dan *kappa coefficient* sebesar 85,21 persen. Meskipun demikian, observasi lapangan masih diperlukan untuk memperkuat hasil akurasi penggunaan lahan. Dengan demikian, penelitian ini berhasil dalam mengidentifikasi penggunaan lahan di Kabupaten Lahat dengan menggunakan citra satelit Landsat 8 melalui *Google Earth Engine*.

Meskipun berbagai metode klasifikasi telah digunakan untuk mengklasifikasikan tutupan lahan, masih terdapat kekurangan dalam memahami sejauh mana setiap metode dapat memberikan akurasi yang tinggi dalam konteks penggunaan tutupan lahan yang dinamis dan kompleks, seperti yang terjadi di Provinsi DI Yogyakarta. Analisis yang membandingkan berbagai metode, seperti SVM, CART, dan *Random Forest* dalam hal akurasi, efisiensi, dan kemampuan adaptasi terhadap perubahan spasial masih kurang mendapat perhatian. Studi sebelumnya sering kali terbatas pada satu metode atau tidak secara komprehensif mengevaluasi performa relatif dari berbagai teknik klasifikasi dalam konteks perubahan lahan yang pesat. Oleh karena itu, peneliti mengisi celah tersebut dengan mengevaluasi agar



metode klasifikasi ini dapat digunakan untuk mendukung analisis keberlanjutan dan perencanaan lingkungan yang lebih baik.

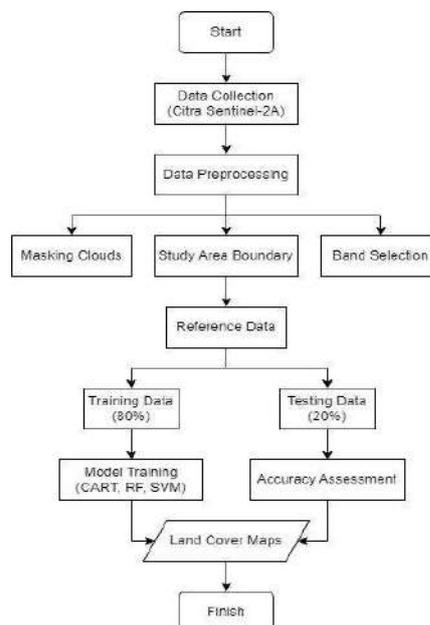
Penelitian ini bertujuan untuk mengidentifikasi metode klasifikasi tutupan lahan yang efektif dengan membandingkan akurasi yang dihasilkan oleh masing-masing metode. Metode klasifikasi yang dibandingkan dalam penelitian ini, yaitu *Classification and Regression Trees* (CART), *Random Forest* (RF), dan *Support Vector Machine* (SVM). Selain itu, penelitian ini juga menganalisis estimasi luas tutupan lahan berdasarkan metode klasifikasi terbaik. Penelitian ini akan mengevaluasi keakuratan, efisiensi, dan adaptasi dari ketiga metode ini dalam mengestimasi luas penggunaan tutupan lahan. Penelitian ini menggunakan citra satelit Sentinel-2A pada *Google Earth Engine*. Dengan demikian, penelitian ini diharapkan dapat memberikan wawasan yang mendalam mengenai metode klasifikasi yang paling tepat untuk aplikasi praktis di wilayah dengan dinamika penggunaan lahan yang tinggi.

Hasil dari penelitian ini diharapkan dapat memberikan kontribusi signifikan terhadap pencapaian tujuan pembangunan berkelanjutan atau SDGs. Dengan memahami penggunaan tutupan lahan, penelitian ini dapat mendukung SDG 11 (Kota dan Permukiman yang Berkelanjutan) dengan menyediakan data yang akurat untuk perencanaan tata ruang yang berkelanjutan. Selain itu, penelitian ini juga dapat mendukung SDG 15 (Ekosistem Daratan) dengan membantu dalam pelestarian ekosistem darat dan pengelolaan sumber daya alam secara berkelanjutan. Selain itu, untuk berkontribusi terhadap kebijakan pengelolaan sumber daya alam dan perencanaan tata ruang di Provinsi DI Yogyakarta. Dengan memahami metode klasifikasi yang memberikan hasil paling akurat dan efisien, pembuat kebijakan dapat mengambil langkah yang tepat dalam mengelola penggunaan tutupan lahan. Hal ini penting untuk memastikan bahwa pertumbuhan penduduk dan pembangunan wilayah dapat berjalan seimbang dengan pelestarian lingkungan sehingga keberlanjutan lingkungan dan kesejahteraan masyarakat dapat terjaga.

II. METODE PENELITIAN

II.1. Alur Penelitian

Alur penelitian yang digunakan pada penelitian ini digambarkan pada diagram Gambar 1.



Gambar 1. Diagram Alur Penelitian



II.2. Lokasi Penelitian

Penelitian ini dilakukan di Provinsi Yogyakarta. Daerah ini terletak antara $110^{\circ}00'$ - $110^{\circ}50'$ Bujur Timur dan $07^{\circ}33'$ - $08^{\circ}12'$ Lintang Selatan dengan luas sekitar $3.185,8 \text{ km}^2$. Provinsi Yogyakarta terdiri dari 1 kota dan 4 kabupaten, yaitu Kabupaten Bantul, Kabupaten Kulonprogo, Kabupaten Gunungkidul, Kabupaten Sleman, dan Kota Yogyakarta.

II.3. Alat dan Bahan Penelitian

Penelitian ini menggunakan perangkat dengan spesifikasi yang memadai untuk mengakses *Google Earth Engine* sehingga pengumpulan, pemrosesan, analisis, dan evaluasi data berjalan dengan lancar. Bahan yang digunakan berupa data citra satelit Sentinel-2 MultiSpectral Instrument Level-2A atau biasa disebut dengan citra satelit Sentinel-2A. Data ini memiliki resolusi spasial menengah dan menyediakan informasi spektral yang dibutuhkan untuk pemetaan tutupan lahan.

II.4. Tahapan Pengolahan

Tahapan pengolahan data menggunakan *Google Earth Engine* (GEE) melibatkan beberapa langkah yang sistematis untuk memastikan data siap digunakan untuk dianalisis dan dimodelkan. Langkah pertama adalah mengimpor citra satelit Sentinel-2A SR Harmonized yang sudah dikoreksi atmosfer dan difilter berdasarkan tanggal, wilayah, dan persentase awan. Citra dibatasi pada DI Yogyakarta 1 Januari 2023 sampai 31 Desember 2023. Selanjutnya, memilih *band* yang relevan, seperti B2, B3, dan B4. Langkah ketiga melakukan *tagging* atau pengambilan titik sampel yang akan digunakan dalam pemrosesan data. Batas minimal sampel untuk setiap kelas tutupan lahan sebesar 30 titik sampel [11]. Langkah keempat membagi titik sampel menjadi data *training* sebesar 80 persen dan data *testing* sebesar 20 persen. Langkah kelima, yakni melatih model dengan data *training* yang telah disiapkan. Langkah keenam melakukan klasifikasi dengan model yang ada. Terakhir, memvalidasi dan mengevaluasi hasil klasifikasi menggunakan data *testing* untuk mengukur keakuratan model.

II.5. Klasifikasi Tutupan Lahan

Penelitian ini menggunakan tiga metode klasifikasi, yaitu *Classification and Regression Trees* (CART), *Random Forest* (RF), dan *Support Vector Machine* (SVM). CART merupakan metode eksplorasi non-parametrik yang intensif secara komputasi dan tidak membutuhkan asumsi distribusi apapun. Analisis CART sering disebut partisi rekursif [12], [13] karena menekan data untuk dipecah oleh algoritma menjadi *subset* yang semakin kecil dan homogen sesuai dengan kriteria yang ditentukan peneliti [14]. Semua variabel prediktor diperiksa setiap level untuk pemisahan yang akan menghasilkan *node* yang jelas sesuai dengan algoritma yang dipelajari oleh mesin [15]. Algoritma CART yang dipelajari akan diulangi dan disesuaikan dengan data di setiap *subset* yang dipartisi dengan menguji semua variabel untuk mencari variabel yang menghasilkan pemisahan terjelas [16]. RF adalah skema yang diusulkan oleh Leo Breiman pada tahun 2000-an untuk membangun sebuah prediktor *ensemble* dengan sekumpulan *decision tree* yang tumbuh di subruang data yang dipilih secara acak [17]. RF dirancang khusus untuk beroperasi dengan cepat dan efisien pada kumpulan data besar karena penyederhanaannya dan menawarkan prediksi tertinggi akurasi dibandingkan dengan metode klasifikasi lainnya [18]. Metode ini menggabungkan banyak pohon yang tidak berkorelasi, yang akan tahan terhadap *overfitting*, yaitu situasi ketika model terlalu *fit* (cocok) dengan data *training* sehingga kehilangan kemampuan untuk menggeneralisasi pada data baru yang tersedia. RF juga dapat menangani *missing data* sehingga mampu memberikan estimasi yang akurat. Akan tetapi, metode ini membutuhkan daya komputasi dan memori yang lebih untuk diterapkan. Sedangkan SVM adalah algoritma *machine learning supervised* yang digunakan untuk klasifikasi dan regresi. SVM bertujuan untuk menemukan



satu atau lebih *hyperplane* (sebuah batas keputusan yang memisahkan set data dari kelas yang berbeda) optimal yang memisahkan titik data dari kelas berbeda dalam ruang tertentu [19]. Metode SVM memerlukan persetujuan fungsi kernel khusus untuk membuat *hyperplane* secara tepat dan mengurangi kesalahan klasifikasi [20]. Klasifikasi tutupan lahan pada penelitian ini terdiri dari empat kelas, yaitu badan air, vegetasi, lahan kosong, dan lahan terbangun. Klasifikasi tersebut berdasarkan penelitian Al-Kafy dengan penyesuaian wilayah penelitian [21]. Deskripsi setiap kelas tutupan lahan tersaji pada Tabel 1.

Tabel 1. Deskripsi tutupan lahan

Kode	Tutupan Lahan	Deskripsi
0	Badan Air	Danau, sungai, kolam dan waduk, lahan basah, rawa
1	Vegetasi	Hutan, lahan pertanian, taman, padang rumput, dll
2	Lahan Kosong	Lahan yang permukaannya didominasi oleh tanah, pasir, atau batu
3	Lahan Terbangun	Struktur bangunan buatan, wilayah komersial dan industri, perumahan, jaringan transportasi

II.6. Uji Akurasi Tutupan Lahan

Evaluasi hasil klasifikasi tutupan lahan menggunakan GEE dilakukan dengan melakukan uji akurasi. Tahap ini menggunakan *confusion matrix* untuk mengevaluasi tingkat kepercayaan hasil klasifikasi citra. Penghitungan *confusion matrix* dilakukan dengan membandingkan hubungan antara sampel (citra asli) dan hasil klasifikasi otomatis. *Confusion matrix* berbentuk $k \times k$, di mana k merupakan banyaknya kategori yang digunakan pada klasifikasi. Klasifikasi citra dianggap benar jika total piksel yang terklasifikasi dengan benar pada *confusion matrix* lebih besar atau sama dengan 80 persen dari total piksel [22]. Tabel 2 memberikan gambaran umum *confusion matrix* yang dibentuk sebagai alat evaluasi hasil klasifikasi.

Tabel 2. *Confusion matrix*

	Sampel				Total	User's Accuracy	
	0	1	2	3			
Class Image	0	P ₁₁	P ₁₂	P ₁₃	P ₁₄	P ₁₊	P ₁₁ /P ₁₊
	1	P ₂₁	P ₂₂	P ₂₃	P ₂₄	P ₂₊	P ₂₂ /P ₂₊
	2	P ₃₁	P ₃₂	P ₃₃	P ₃₄	P ₃₊	P ₃₃ /P ₃₊
	3	P ₄₁	P ₄₂	P ₄₃	P ₄₄	P ₄₊	P ₄₄ /P ₄₊
Total	P ₊₁	P ₊₂	P ₊₃	P ₊₄	n		
Producer's Accuracy	P ₁₁ /P ₊₁	P ₂₂ /P ₊₂	P ₃₃ /P ₊₃	P ₄₄ /P ₊₄			

$$\text{Overall Accuracy} = \frac{\sum_{i=1}^r P_{ii}}{n} \times 100 \% \quad (1)$$

$$\text{Kappa Coefficient} = \frac{n \sum_{i=1}^r P_{ii} - \sum_{i=1}^r P_{1+} P_{+1}}{n^2 - \sum_{i=1}^r P_{1+} P_{+1}} \times 100 \% \quad (2)$$



$$\text{Producer's Accuracy} = \frac{P_{ii}}{P_{+i}} \times 100 \% \quad (3)$$

$$\text{User's Accuracy} = \frac{P_{ii}}{P_{i+}} \times 100 \% \quad (4)$$

di mana

n : banyaknya sampel piksel

P_{i+} : jumlah piksel baris ke- i

P_{+i} : jumlah piksel kolom ke- i

P_{ii} : jumlah piksel baris ke- i dan kolom ke- i

III. HASIL DAN PEMBAHASAN

Interpretasi citra satelit Sentinel-2A terhadap klasifikasi tutupan lahan dilakukan menggunakan kombinasi *band* 432. Kombinasi *band* 432 digunakan untuk menampilkan wilayah penelitian secara nyata dan mengidentifikasi penggunaan lahan di wilayah tersebut. Gambar 2 adalah tampilan wilayah penelitian yang akan diklasifikasikan berdasarkan citra satelit Sentinel-2A tahun 2023.



Gambar 2. Peta Wilayah Penelitian Hasil Citra Satelit Sentinel-2A

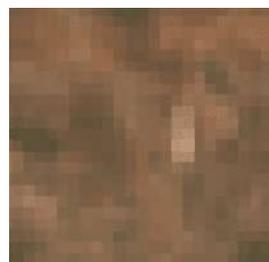
Kelas tutupan lahan di wilayah penelitian terbagi menjadi empat kelas, yaitu badan air, vegetasi, lahan kosong, dan lahan terbangun. Gambar 3 menunjukkan contoh objek pada citra satelit Sentinel-2A dengan kombinasi *band* 432.



Gambar 3a.



Gambar 3b.



Gambar 3c.



Gambar 3d.

Gambar 3. Contoh objek (3a) badan air (3b) vegetasi (3c) lahan kosong (3d) lahan terbangun

Langkah awal sebelum melakukan klasifikasi, yaitu membuat titik sampel pada setiap kelas tutupan lahan. Titik sampel disesuaikan dengan wilayah yang mewakili setiap kelas, misalnya kelas tutupan lahan adalah badan air maka sampel berada di wilayah yang jelas merepresentasikan sebagai badan air. Total titik sampel yang digunakan pada penelitian ini sebanyak 2693 piksel yang terbagi



menjadi 2170 piksel untuk data *training* dan 523 piksel untuk data *testing*. Gambar 4 merupakan contoh titik sampel pada setiap kelas tutupan lahan.



Gambar 4. Contoh titik sampel setiap kelas tutupan lahan (4a) badan air (4b) vegetasi (4c) lahan kosong (4d) lahan terbangun

Klasifikasi tutupan lahan dilakukan dengan menggunakan metode CART, RF, dan SVM. Performa masing-masing metode klasifikasi ditunjukkan dengan nilai akurasi yang diperoleh menggunakan *confusion matrix*. Perhitungan nilai akurasi yang dilakukan adalah *user’s accuracy*, *producer’s accuracy*, *overall accuracy*, dan *kappa coefficient*. Nilai *kappa coefficient* yang mendekati 1 menunjukkan tingkat akurasi yang tinggi. Hasil tabel *confusion matrix* dari klasifikasi tutupan lahan di Provinsi DI Yogyakarta dengan metode CART, RF, dan SVM dapat dilihat pada Tabel 3, 4, dan 5.

Tabel 3. *Confusion matrix* klasifikasi tutupan lahan dengan metode CART

Class Image (piksel)		Sampel (piksel)				Total	User’s Accuracy (%)
		Badan Air	Vegetasi	Lahan Kosong	Lahan Terbangun		
Class Image (piksel)	Badan Air	95	10	2	9	116	81,90
	Vegetasi	5	191	2	7	205	93,17
	Lahan Kosong	3	5	27	19	54	50
	Lahan Terbangun	7	8	21	112	148	75,68
Total		110	214	52	147	523	
Producer’s Accuracy (%)		85,36	89,25	51,92	76,19		
						Overall Accuracy	81,26
						Kappa Coefficient	73,35

Tabel 3 memberikan informasi bahwa nilai diagonal dengan warna abu-abu tebal merupakan nilai dari piksel yang berhasil terklasifikasi benar, sedangkan nilai-nilai dengan warna abu-abu muda merupakan nilai piksel yang salah/error. Kesalahan klasifikasi dapat disebabkan oleh kemiripan warna dan rona antara kelas tersebut dengan kelas lainnya atau disebabkan oleh penempatan *point* kelas tutupan lahan yang tidak tepat.

Dilihat dari *producer’s accuracy*, kelas vegetasi memiliki nilai tertinggi sebesar 89,25 persen. Artinya, terdapat 89,25 persen hasil yang terklasifikasi benar dan 10,75 persen kesalahan berupa pengurangan piksel yang terklasifikasi salah. Jika dilihat berdasarkan *user’s accuracy*, nilai tertinggi juga ditemukan pada kelas vegetasi. Terdapat 93,17 persen hasil yang terklasifikasi benar dan 6,83 persen merupakan penambahan jumlah piksel yang terklasifikasi salah. Nilai pada *producer’s* dan *user’s accuracy* untuk setiap kelas berbeda-beda. Pada kelas vegetasi memiliki nilai *producer’s accuracy* sebesar 89,25 persen, sedangkan nilai *user’s accuracy*-nya sebesar 93,17 persen. Hal ini berarti bahwa 89,25 persen kelas vegetasi di DI Yogyakarta berhasil masuk dalam peta klasifikasi, tetapi hanya 93,17 persen hasil klasifikasi yang benar-benar merupakan “vegetasi” di Provinsi DI Yogyakarta.



Tabel 4. *Confusion matrix* klasifikasi tutupan lahan dengan metode RF

Class	Badan Air	Sampel (piksel)				Total	User's Accuracy (%)
		Badan Air	Vegetasi	Lahan Kosong	Lahan Terbangun		
Badan Air		76	7	4	5	92	82,61
Vegetasi		4	179	3	7	193	92,75
Lahan Kosong		2	3	56	18	79	80,89
Lahan Terbangun		7	12	18	129	166	77,71
Total		89	201	81	159	530	
Producer's Accuracy (%)		85,39	89,05	69,14	81,13		
Overall Accuracy							83,02
Kappa Coefficient							76,28

Dilihat dari *producer's accuracy* pada Tabel 4, kelas vegetasi memiliki nilai tertinggi sebesar 89,05 persen. Artinya, terdapat 89,05 persen hasil yang terklasifikasi benar dan 10,95 persen kesalahan berupa pengurangan piksel yang terklasifikasi salah. Jika dilihat berdasarkan *user's accuracy*, nilai tertinggi juga ditemukan pada kelas vegetasi. Terdapat 92,75 persen hasil yang terklasifikasi benar dan 7,25 persen merupakan penambahan jumlah piksel yang terklasifikasi salah. Nilai pada *producer's* dan *user's accuracy* untuk setiap kelas berbeda-beda. Pada kelas vegetasi memiliki nilai *producer's accuracy* sebesar 89,05 persen, sedangkan nilai *user's accuracy*-nya sebesar 92,75 persen. Hal ini berarti bahwa 89,05 persen kelas vegetasi di DI Yogyakarta berhasil masuk dalam peta klasifikasi, tetapi hanya 92,75 persen hasil klasifikasi yang benar-benar merupakan “vegetasi” di Provinsi DI Yogyakarta.

Tabel 5. *Confusion matrix* klasifikasi tutupan lahan dengan metode SVM

Class	Badan Air	Sampel (piksel)				Total	User's Accuracy (%)
		Badan Air	Vegetasi	Lahan Kosong	Lahan Terbangun		
Badan Air		77	13	3	23	116	66,38
Vegetasi		2	195	0	8	205	95,12
Lahan Kosong		1	5	11	37	54	20,37
Lahan Terbangun		2	8	0	138	148	93,24
Total		82	221	14	206	523	
Producer's Accuracy (%)		93,90	88,23	78,57	66,99		
Overall Accuracy							80,50
Kappa Coefficient							71,54

Dilihat dari *producer's accuracy* pada Tabel 5, kelas badan air memiliki nilai tertinggi sebesar 93,90 persen. Artinya, terdapat 93,90 persen hasil yang terklasifikasi benar dan 6,1 persen kesalahan berupa pengurangan piksel yang terklasifikasi salah. Jika dilihat berdasarkan *user's accuracy*, nilai tertinggi ditemukan pada kelas vegetasi. Terdapat 95,12 persen hasil yang terklasifikasi benar dan 4,88 persen merupakan penambahan jumlah piksel yang terklasifikasi salah. Nilai pada *producer's* dan *user's accuracy* untuk setiap kelas berbeda-beda. Pada kelas badan air memiliki nilai *producer's accuracy* sebesar 93,90 persen, sedangkan nilai *user's accuracy*-nya sebesar 66,38 persen. Hal ini berarti bahwa 93,90 persen kelas badan air di DI Yogyakarta berhasil masuk dalam peta klasifikasi,

tetapi hanya 66,38 persen hasil klasifikasi yang benar-benar merupakan “badan air” di Provinsi DI Yogyakarta.

Peta hasil klasifikasi tutupan lahan di Provinsi DI Yogyakarta tahun 2023 dari masing-masing metode ditunjukkan pada Gambar 5.



Gambar 5a.



Gambar 5b.



Gambar 5c.

Gambar 5. Peta klasifikasi tutupan lahan masing-masing metode (5a) CART (5b) RF (5c) SVM

Berdasarkan Gambar 5 terlihat bahwa peta klasifikasi tutupan lahan dengan metode CART dan *Random Forest* tidak jauh berbeda. Sebagian besar lahan terbangun terletak di bagian tengah Provinsi DI Yogyakarta, yaitu Kota Yogyakarta. Hal ini disebabkan Kota Yogyakarta merupakan pusat kegiatan di Provinsi DI Yogyakarta, termasuk pusat pemerintahan, perdagangan, pendidikan, dan pariwisata. Semua faktor tersebut berkontribusi pada tingginya intensitas pembangunan di Kota Yogyakarta. Sementara itu, vegetasi masih tersebar di seluruh wilayah dan aliran area badan air berawal dari bagian selatan menuju bagian utara Provinsi DI Yogyakarta. Lahan kosong berupa tanah kosong, ruang terbuka, dan pasir cenderung lebih banyak ditemukan di bagian timur Provinsi DI Yogyakarta. Hal ini berbeda dengan peta klasifikasi tutupan lahan dengan metode SVM yang didominasi oleh kelas tutupan lahan vegetasi dan lahan terbangun.

Dari Gambar 5 juga dapat diperoleh persebaran luas tutupan lahan di Provinsi DI Yogyakarta tahun 2023. Estimasi luas kelas tutupan lahan dari masing-masing metode dapat dilihat pada Tabel 6.

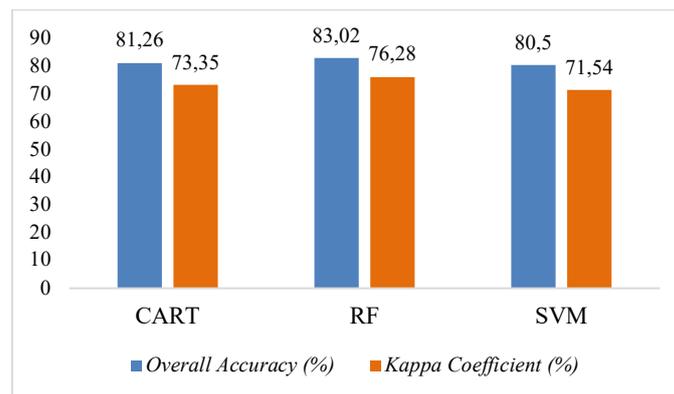


Tabel 6. Estimasi luas tutupan lahan setiap kelas dengan metode CART, RF, dan SVM

Kelas Tutupan Lahan	Luas Tutupan Lahan (km ²)		
	CART	RF	SVM
Badan Air	280,51	154,76	119,93
Vegetasi	1746,52	1953,76	2024,76
Lahan Kosong	418,51	357,16	60,24
Lahan Terbangun	726,85	706,71	967,46

Berdasarkan Tabel 6, dapat diketahui bahwa kawasan vegetasi masih mendominasi tutupan lahan di Provinsi DI Yogyakarta. Hal ini terlihat dari luas kawasan vegetasi yang paling besar dibandingkan dengan kelas tutupan lahan lainnya. Pada metode CART dan RF, urutan luasan tutupan lahan setelah kawasan vegetasi adalah lahan terbangun, lahan kosong, dan badan air. Sementara itu, pada metode SVM, luas lahan kosong lebih kecil daripada luas area badan air.

Untuk menentukan metode klasifikasi terbaik pada pemetaan tutupan lahan menggunakan *Google Earth Engine*, perlu dilakukan perbandingan pada hasil *overall accuracy* dan *kappa coefficient*.



Gambar 6. Nilai *Overall Accuracy* dan *Kappa Coefficient* Metode CART, RF, dan SVM

Berdasarkan Gambar 6, terlihat bahwa nilai *overall accuracy* dan *kappa coefficient* dengan metode RF merupakan nilai tertinggi dibandingkan dengan dua metode lain, yaitu sebesar 83,02 persen dan 76,28 persen. Sementara itu, nilai *overall accuracy* dan *kappa coefficient* terendah dengan metode SVM sebesar 80,5 persen dan 71,54 persen. Nilai *overall accuracy* dari masing-masing metode lebih dari 80 persen yang menunjukkan bahwa kinerja ketiga metode yang diterapkan dalam penelitian ini memadai dan cocok untuk pemetaan tutupan lahan. Namun, hasil dari semua metode menunjukkan bahwa *Random Forest* merupakan metode terbaik untuk pemetaan tutupan lahan di Provinsi DI Yogyakarta tahun 2023.

Berdasarkan hasil penelitian, metode *Random Forest* merupakan metode terbaik untuk melakukan klasifikasi tutupan lahan di Provinsi DI Yogyakarta. Hasil penelitian ini sejalan dengan penelitian Zhao et al (2024) yang menyatakan bahwa metode *Random Forest* terbukti efektif dalam mengklasifikasikan tutupan lahan dengan akurat, menangkap hubungan yang kompleks, dan memberikan prediksi yang andal [23]. Dengan memanfaatkan kekuatan pembelajaran *ensemble* dari banyak *decision tree* yang dibangun pada *subset* data, metode *Random Forest* lebih stabil dan *robust* terhadap variasi dalam data *training* sehingga cenderung terhindar dari *overfitting*. Pada model berbasis pohon keputusan sederhana seperti CART rentan terhadap *overfitting* model dan sensitif terhadap perubahan dalam dataset pelatihan [15]. Di sisi lain, SVM efisien secara komputasi dan bekerja dengan



baik di area berdimensi tinggi dengan *margin* pemisahan yang jelas antar kelas. Namun, metode SVM sulit digunakan, diinterpretasikan, disesuaikan, dan membutuhkan waktu pelatihan yang lama untuk dataset yang berskala besar [24].

IV. KESIMPULAN

Google Earth Engine dapat digunakan untuk melakukan klasifikasi pada pemetaan tutupan lahan di Provinsi DI Yogyakarta menggunakan citra satelit Sentinel-2A. Proses klasifikasi pada penelitian ini menggunakan metode *CART*, *Random Forest*, dan *SVM*. Berdasarkan hasil dan analisis yang telah dilakukan dapat disimpulkan bahwa *Random Forest* merupakan metode klasifikasi terbaik dibandingkan *CART* dan *SVM* dalam pemetaan tutupan lahan di Provinsi DI Yogyakarta tahun 2023. Peta klasifikasi tutupan lahan yang dihasilkan menggunakan metode *Random Forest* memiliki nilai *overall accuracy* tertinggi dan lebih dari 80 persen sehingga klasifikasi tersebut sudah baik dan dapat digunakan. Nilai estimasi luas kelas tutupan lahan menggunakan metode *Random Forest* menunjukkan bahwa kawasan vegetasi masih mendominasi tutupan lahan di Provinsi DI Yogyakarta. Kemudian diikuti oleh lahan terbangun sebagai lahan terluas kedua, lahan kosong, dan badan air. Klasifikasi tutupan lahan ini berperan penting dalam perencanaan tata ruang yang berkelanjutan dan pengelolaan sumber daya alam di Provinsi DI Yogyakarta. Hal ini mendukung pencapaian tujuan pembangunan berkelanjutan (SDGs) yang berkaitan dengan ekosistem daratan dan kota yang berkelanjutan.

Adapun beberapa hal yang dapat dipertimbangkan untuk penelitian selanjutnya, yaitu menggunakan citra yang memiliki resolusi spasial yang lebih tinggi agar dapat menampilkan kenampakan objek permukaan bumi lebih jelas, menambahkan kelas tutupan lahan sesuai dengan wilayah penelitian, serta melakukan analisis *time series* untuk melihat perubahan penggunaan lahan di Provinsi DI Yogyakarta.

UCAPAN TERIMA KASIH

Terima kasih disampaikan kepada semua pihak yang telah membantu dalam penulisan artikel ini.

REFERENSI

1. M. A. Wulder, N. C. Coops, D. P. Roy, J. C. White, and T. Hermosilla, “Land cover 2.0,” *International Journal of Remote Sensing*, vol. 39, no. 12. Taylor and Francis Ltd., pp. 4254–4284, Jun. 18, 2018. doi: 10.1080/01431161.2018.1452075.
2. L. Li *et al.*, “Modeling the impacts of land use/land cover change on meteorology and air quality during 2000–2018 in the Yangtze River Delta region, China,” *Science of The Total Environment*, vol. 829, p. 154669, 2022, doi: <https://doi.org/10.1016/j.scitotenv.2022.154669>.
3. L. A. James and S. A. Lecce, “Impacts of Land-Use and Land-Cover Change on River Systems,” in *Treatise on Geomorphology*, vol. 9, Elsevier Inc., 2013, pp. 768–793. doi: 10.1016/B978-0-12-374739-6.00264-5.
4. J. Maximillian, M. L. Brusseau, E. P. Glenn, and A. D. Matthias, “Pollution and Environmental Perturbations in the Global System,” in *Environmental and Pollution Science (Third Edition)*, M. L. Brusseau, I. L. Pepper, and C. P. Gerba, Eds., Academic Press, 2019, pp. 457–476. doi: <https://doi.org/10.1016/B978-0-12-814719-1.00025-2>.
5. A. Z. Lubis *et al.*, “Meningkatnya Pertumbuhan Penduduk Berdampak Pada Terjadinya Alih Fungsi Lahan Hutan Di Sumatera Utara,” *Jurnal Ilmu Komputer, Ekonomi dan Manajemen (JIKEM)*, vol. 2, no. 1, pp. 2134–2143, 2022.
6. Badan Pusat Statistik, “Jumlah Penduduk Menurut Provinsi di Indonesia (Ribu Jiwa), 2020–2022.” Accessed: Jun. 09, 2024. [Online]. Available: <https://sulut.bps.go.id/indicator/12/958/1/jumlah-penduduk-menurut-provinsi-di-indonesia.html>



7. Badan Pertanahan Nasional, “Luas Perubahan Penggunaan Lahan Provinsi DI Yogyakarta.” Accessed: Jun. 09, 2024. [Online]. Available: https://bappeda.jogjaprov.go.id/dataku/data_dasar/index/321-luas-perubahan-penggunaan-lahan
8. Dinas Lingkungan Hidup dan Kehutanan Daerah Istimewa Yogyakarta, “Dokumen Informasi Kinerja Pengelolaan Lingkungan Hidup Daerah DIY 2020,” 2021.
9. Y. Shao and R. S. Lunetta, “Comparison of support vector machine, neural network, and CART algorithms for the land-cover classification using limited training data points,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 70, pp. 78–87, Jun. 2012, doi: 10.1016/j.isprsjprs.2012.04.001.
10. R. Kintan Karina and R. Kurniawan, “Identifikasi Penggunaan Lahan Menggunakan Citra Satelit Landsat 8 Melalui Google Earth Engine Studi Kasus di Kabupaten Lahat (Identification of Land Use Using Landsat 8 Satellite Image Through Google Earth Engine Case Study in Lahat District),” 2019. [Online]. Available: <https://www.indonesia-geospasial.com/>
11. J. T. Roscoe, *Fundamental Research Statistics for the Behavioral Sciences*, 2nd Edition. Holt Rinehart & Winston, 1975.
12. S. C. Lemon, J. Roy, M. A. Clark, P. D. Friedmann, and W. Rakowski, “Classification and Regression Tree Analysis in Public Health: Methodological Review and Comparison With Logistic Regression,” 2003.
13. C. Strobl, J. Malley, and G. Tutz, “An Introduction to Recursive Partitioning: Rationale, Application, and Characteristics of Classification and Regression Trees, Bagging, and *Random Forests*,” *Psychol Methods*, vol. 14, no. 4, pp. 323–348, Dec. 2009, doi: 10.1037/a0016973.
14. N. J. Crichton, J. P. Hinde, and J. Marchini, “MODELS FOR DIAGNOSING CHEST PAIN: IS CART HELPFUL?,” John Wiley & Sons, 1995.
15. A. M. Prasad, L. R. Iverson, and A. Liaw, “Newer classification and regression tree techniques: Bagging and *Random Forests* for ecological prediction,” *Ecosystems*, vol. 9, no. 2, pp. 181–199, Mar. 2006, doi: 10.1007/s10021-005-0054-1.
16. L. Frisman, M. L. Prendergast, H. J. Lin, E. Rodis, and L. Greenwell, “Applying Classification and Regression Tree Analysis to Identify Prisoners with High HIV Risk Behaviors,” *J Psychoactive Drugs*, vol. 40, no. 4, pp. 447–458, 2008, doi: 10.1080/02791072.2008.10400651.
17. G. Biau, “Analysis of a *Random Forests* Model,” 2012.
18. Z. Ilhan Taskin, K. Yildirak, and C. H. Aladag, “An enhanced *Random Forest* approach using CoClust clustering: MIMIC-III and SMS spam collection application,” *J Big Data*, vol. 10, no. 1, Dec. 2023, doi: 10.1186/s40537-023-00720-9.
19. P. K. Srivastava, D. Han, M. A. Rico-Ramirez, M. Bray, and T. Islam, “Selection of classification techniques for land use/land cover change investigation,” *Advances in Space Research*, vol. 50, no. 9, pp. 1250–1265, Nov. 2012, doi: 10.1016/j.asr.2012.06.032.
20. Awad and Khanna, “Support Vector Machines for Classification SVM from a Geometric Perspective,” 2015.
21. A. Al Kafy *et al.*, “Predicting changes in land use/land cover and seasonal land surface temperature using multi-temporal landsat images in the northwest region of Bangladesh,” *Heliyon*, vol. 7, no. 7, Jul. 2021, doi: 10.1016/j.heliyon.2021.e07623.
22. H. N. Nawangwulan, B. Sudarsono, and B. Sasmito, “Analisis Pengaruh Perubahan Lahan Pertanian Terhadap Hasil Produksi Tanaman Pangan di Kabupaten Pati Tahun 2001-2011\,” *Jurnal Geodesi Undip*, vol. 2, no. 2, pp. 127–140, 2013.
23. Z. Zhao *et al.*, “Comparison of Three Machine Learning Algorithms Using Google Earth Engine for Land Use Land Cover Classification,” *Rangel Ecol Manag*, vol. 92, pp. 129–137, Jan. 2024, doi: 10.1016/j.rama.2023.10.007.
24. C. Huang, L. S. Davis, and J. R. G. Townshend, “An assessment of support vector machines for land cover classification,” *Int J Remote Sens*, vol. 23, no. 4, pp. 725–749, Feb. 2002, doi: 10.1080/01431160110040323.