

MONITORING PERUBAHAN TUTUPAN LAHAN KABUPATEN KLATEN TAHUN 2019 DAN 2023 SELAMA PEMBANGUNAN JALAN TOL YOGYAKARTA – SOLO MENGGUNAKAN *GOOGLE EARTH ENGINE* (GEE)

Dessy Apriyanti*, Ilfa Layali, Muammar Gomereuzzaman, Nova Wahyu Pratiwi, Rial Dwi
Martasari

UPN “Veteran” Yogyakarta, Indonesia

Corresponding author(s) e-mail: dessy.apriyanti22@gmail.com*

(Received 10 Januari 2025, Accepted 09 Juni 2025, Published 09 Juni 2025)

ABSTRAK

Perubahan tutupan lahan akibat pembangunan infrastruktur seperti Jalan Tol Yogyakarta-Solo memerlukan pemantauan sistematis. Penelitian ini menganalisis dinamika tutupan lahan di Kabupaten Klaten periode 2019–2023 menggunakan citra satelit Sentinel-2A dan algoritma *Random Forest* (RF) berbasis *Google Earth Engine* (GEE). Metode ini dipilih karena efisiensinya dalam pemrosesan data besar dan akurasi klasifikasi yang tinggi. Lima kelas tutupan lahan dikaji: sawah, vegetasi, badan air, lahan terbuka, dan bangunan. Hasil menunjukkan penurunan signifikan pada lahan sawah (6.835 ha) dan peningkatan area bangunan (4.972 ha), diduga terkait pembangunan tol. Uji akurasi menggunakan matriks konfusi menghasilkan *Overall Accuracy* 88% dan *Kappa Accuracy* 84% (2023), mengindikasikan keandalan metode RF dalam klasifikasi. Analisis tambahan dengan NDVI dan NDBI memperkuat identifikasi perubahan vegetasi dan permukiman. Penelitian ini membuktikan efektivitas GEE dan RF untuk pemantauan tutupan lahan secara *real-time*, dengan implikasi kebijakan bagi perencanaan tata ruang berkelanjutan.

Kata kunci : *Pembangunan, Penginderaan Jauh, Random Forest, Google Earth Engine*

ABSTRACT

Systematic monitoring of land cover changes due to infrastructure development such as the Yogyakarta-Solo Toll Road is essential. This study analyzes land cover dynamics in Klaten Regency from 2019 to 2023 using Sentinel-2A satellite imagery and the Random Forest (RF) algorithm based on Google Earth Engine (GEE). This method was chosen for its efficiency in processing big data and high classification accuracy. Five land cover classes were examined: rice fields, vegetation, water bodies, open land, and built-up areas. The results show a significant decrease in rice fields (6.835 ha) and an increase in built-up areas (4.972 ha), likely related to toll road construction. Accuracy assessment using a confusion matrix yielded an Overall Accuracy of 88% and Kappa Accuracy of 84% (2023), indicating the reliability of the RF method in classification. Additional analysis using NDVI and NDBI strengthened the identification of vegetation and settlement changes. This study demonstrates the effectiveness of GEE and RF for real-time land cover monitoring, with policy implications for sustainable spatial planning.

Keywords : *Development , Remote Sensing, Google Earth Engine, Random Forest*

1. PENDAHULUAN

Penginderaan jauh merupakan ilmu pengetahuan dan teknologi untuk memperoleh informasi mengenai suatu objek, area, atau fenomena melalui analisis data yang diperoleh dengan menggunakan alat tanpa kontak langsung (Nurazizah, 2022). Teknologi penginderaan jauh berbasis satelit kini sangat populer dan digunakan untuk berbagai keperluan, seperti mengidentifikasi perubahan tutupan lahan. Salah satu metode penginderaan jauh yang dapat digunakan untuk memperoleh informasi

tutupan lahan adalah dengan menggunakan metode klasifikasi (Alvina, 2023). Tutupan lahan dapat mendeskripsikan kondisi sosial dan alam suatu wilayah, sehingga dapat memberikan informasi penting untuk memahami berbagai jenis fenomena yang ada di permukaan bumi (Andiko, 2019). Tutupan lahan juga memainkan peran penting dalam berbagai bidang, seperti penelitian perubahan iklim, yang digunakan untuk memahami hubungan kompleks antara aktivitas manusia dan perubahan global di seluruh dunia (Azham, 2015). Klasifikasi tutupan lahan dengan teknik penginderaan jauh

dapat digunakan di berbagai bidang seperti pengelolaan sumber daya alam, perencanaan kota, pertanian, dan pengelolaan lingkungan hidup (FIKRI, 2022).

Metode tradisional, seperti klasifikasi berbasis piksel yang biasa digunakan dalam klasifikasi tutupan lahan, memerlukan pengunduhan data citra satelit dan melalui proses pengolahan data tersebut menggunakan software pengolah citra satelit yang cukup memakan waktu. Selain itu, diperlukan komputer berperforma tinggi untuk kelancaran pemrosesan gambar (FIKRI, 2022). GEE adalah platform pemrosesan citra satelit berbasis komputasi awan (Hehanussa dkk., 2023). Platform analisis bumi ini menyediakan data citra satelit yang dapat diakses secara online secara bebas dan memungkinkan pengguna melakukan berbagai jenis analisis permukaan bumi secara real time (Wlary & Manakane, 2023), GEE juga memiliki beberapa teknik pembelajaran mesin untuk analisis gambar. Salah satu teknik pembelajaran mesin yang paling populer adalah *random forest* (Unik & Nadriati, 2022).

Random Forest (Rozi dkk., 2024) merupakan metode klasifikasi berbasis pembelajaran ensemble yang memberikan akurasi tinggi dan konsisten. Untuk analisis tutupan lahan multitemporal, Random Forest lebih konsisten dengan akurasi 85-92% dibanding CART dan SVM, karena mampu mengurangi *overfitting* pada data resolusi berbeda. Berdasarkan penelitian yang sudah ada, dilakukan penelitian tentang perubahan tutupan lahan menggunakan Algoritma *Random Forest* pada platform *Google Earth Engine* di Kabupaten Klaten. Berdasarkan Keputusan Gubernur No.590/34/Tahun 2024 Tentang Perpanjangan Atas Penetapan Lokasi Pengadaan Tanah Bagi Pembangunan Jalan Tol Solo – Yogyakarta Di Kabupaten Klaten. Pembangunan Jalan Tol Yogyakarta – Solo dapat memicu dinamika perubahan lahan yang ada. Perubahan tutupan lahan


menjadi salah satu perhatian utama dalam pemantauan lingkungan. Penelitian ini memanfaatkan algoritma Random Forest pada platform GEE untuk menganalisis perubahan tutupan lahan di Kabupaten Klaten, khususnya sebagai dampak dari pembangunan Jalan Tol Yogyakarta–Solo. Berdasarkan Keputusan Gubernur No. 590/34/Tahun 2024 tentang perpanjangan penetapan lokasi pengadaan tanah pembangunan jalan tol, pembangunan ini berpotensi memicu perubahan signifikan pada tutupan lahan. Analisis perubahan tutupan lahan dilakukan menggunakan data Citra Satelit Sentinel 2A. Citra Sentinel 2A dipilih karena mempunyai saluran tampak (merah, hijau, dan biru) dan saluran inframerah (inframerah dekat dan inframerah jauh). Pemilihan saluran – saluran tersebut sangat mendukung dalam mendeteksi tutupan lahan karena mempunyai nilai pantulan spektral yang tinggi (Danoedoro & Murti, 2021). Dalam penelitian ini akan dihasilkan analisis berupa perubahan tutupan lahan Kabupaten Klaten.

2. METODE PENELITIAN

2.1 Bahan dan Lokasi

Penelitian ini membutuhkan bantuan. Lokasi penelitian adalah studi kasus dan pengumpulan bahan untuk diolah dari berbagai sumber.

Data yang digunakan dalam penelitian ini berasal dari data *Analysis Ready Data* (ARD) dari platform GEE; gambar satelit Sentinel 2A dengan koreksi *TOA Reflectance* yang mencakup Kabupaten Klaten, Jawa Tengah dari tahun 2019 hingga 2023 dengan perekaman data multispektral tahun 2019 dan 2023. Serta data dari peta rupa bumi yang diakses pada laman *inageoportal* yang memberikan informasi batas administrasi. Penelitian dilakukan di Kabupaten Klaten. Jalan Tol Jogja-Solo berdampak pada sepuluh kecamatan di Kabupaten Klaten. Peta lokasi ditunjukkan pada Gambar 1.




Gambar 1. Lokasi Penelitian

2.2 Klasifikasi Supervised

Langkah pertama dalam penelitian adalah melakukan filter rentang waktu yang diinginkan dan memasukkan gambar Sentinel-2A yang bebas awan. Selanjutnya, *Region Of Interest* (ROI) dibuat menggunakan shapefile Kabupaten Klaten. Kemudian, metode klasifikasi terlihat digunakan untuk mengklasifikasikan penggunaan lahan. Metode ini menggunakan sampel piksel dan nilai digital yang memiliki nilai yang sudah sesuai dengan kelas yang telah ditentukan. Ini digunakan untuk mengklasifikasikan piksel yang identitasnya belum diketahui (Cholidah & Irawan, 2024)

2.3 Random Forest

Metode random forest, yang menggunakan agregasi bootstrap (pemecatan) dan metode random feature selection, merupakan pengembangan lebih lanjut dari metode CART (MAULUDIYAH, 2020). Hutan acak terbentuk karena banyak pohon tumbuh di hutan acak. Oleh karena itu, koleksi kayu ini dianalisis dalam kumpulan data yang terdiri dari n observasi dan p variabel penjelas. Hutan acak dilakukan oleh (Haryani dkk., 2023)

Gambar 2 Kerangka Random Forest
(Haryani dkk., 2023)

Metode Algoritma Hutan Random digunakan untuk mengklasifikasikan tutupan lahan di Kabupaten Kendal. Kelas klasifikasi terdiri dari badan air, vegetasi, sawah, lahan terbuka, dan bangunan. Penggunaan lahan dalam penelitian ini diklasifikasikan berdasarkan klasifikasi penggunaan lahan, yang terdiri dari lima kelas: sawah, badan air, bangunan, vegetasi lain, dan lahan terbuka (Wijaya, 2015).

2.4 Uji Akurasi

Setelah klasifikasi dilakukan menggunakan metode klasifikasi yang diawasi, uji akurasi dilakukan menggunakan matriks kekacauan.

Dalam penelitian ini, *Google Earth Engine* juga digunakan untuk melakukan uji akurasi ini Tingkat ketelitian, atau akurasi, penelitian ini adalah lebih dari 75%. Persamaan uji akurasi yang digunakan adalah sebagai berikut (Magdalena dkk., 2021). (Wulansari, 2017) menyatakan bahwa, karena akurasi yang berlebihan umumnya masih dianggap terlalu tinggi, akurasi kappa saat ini adalah yang disarankan. Akurasi kappa juga dikenal sebagai indeks kappa, dan nilainya menunjukkan perbandingan antara hasil klasifikasi yang diuji dengan hasil klasifikasi acak; dengan kata lain nilai kappa yang dapat diperoleh, menunjukkan konsistensi akurasi hasil klasifikasi, dengan memanfaatkan persamaan berikut:

$$User Accuracy (\%) = \frac{x_{ii}}{x_{1+i}} \times 100\% \quad (1.1)$$

$$Producer Accuracy (\%) = \frac{x_{ii}}{x_{i+1}} \times 100\% \quad (1.2)$$

$$F1 score = 2 \times \frac{CA \times PA}{CA + PA} \quad (1.3)$$

Keterangan :

x_{ii} : nilai diagonal dari matriks kontingensi baris ke-I dan kolom ke-I

x_{+i} : Jumlah sample yang terklasifikasikan sebagai kelas tersebut (baris)


x_{i+} : Jumlah sample yang terklasifikasikan sebagai kelas tersebut (kolom)

CA : *Consumer Accuracy*

PA : *Producer Accuracy*

Uji kesesuaian klasifikasi gambar dikatakan baik jika memenuhi syarat tertentu yang tergantung pada tujuan klasifikasinya. Uji ini dikatakan baik jika hasil perhitungan keakuratan umum, keakuratan pengguna, dan keakuratan pembuat mendekati 100% dan perhitungan kesalahan omisi dan komisi mendekati nol persen (Fibrianda & Bhawiyuga, 2018).

Proses penelitian ini dimulai dengan meninjau literatur yang relevan, kemudian menyusun bahan yang akan digunakan, yaitu gambar Sentinel 2A 2019 dan 2023. Citra tersebut dilakukan proses *cropping* sesuai batas administrasi Kabupaten Klaten. Selanjutnya, algoritma *Random Forest* digunakan untuk mengolah klasifikasi *supervised* di GEE. Metode ini melibatkan pembuatan sampel pelatihan 70% dan pengujian 30%, Gambar 3 menunjukkan diagram alir alur penelitian.



Gambar 3 Diagram Alir

3. HASIL DAN PEMBAHASAN

3.1 Hasil Kombinasi Data Citra Satelit

Kombinasi citra atau komposit citra pada tahap ini berhasil membantu keterbatasan mata dalam membedakan warna pada citra. Komposit citra akan menghasilkan data citra baru yaitu citra multispectral yang merupakan hasil gabungan dari 3 kanal yang mempermudah peneliti dalam mengidentifikasi suatu objek pada citra. Proses komposit band yang akan dilakukan melakukan true

color dengan kombinasi variasi komposit band 4, band 3, dan band 2.

3.2 NDVI Citra Satelit

Perhitungan NDVI (*Normalized Difference Vegetation Index*) memanfaatkan band *Red* (band 4) dan band *Near – infrared* (band 5) yang dipantulkan oleh tumbuhan untuk memperoleh nilai variasi vegetasi dan tingkat kerapatan vegetasi berdasarkan piksel pada citra satelit. Nilai NDVI menunjukkan tingkat kehijauan dan menunjukkan status

(Kesehatan/kerapatan) vegetasi pada wilayah penelitian. Hasil perhitungan NDVI pada Citra tahun 2019 dan 2023 didapatkan sebaran titik – titik yang mengindikasikan objek Vegetasi, terlihat secara tingkat kehijauan di beberapa titik yang sangat rapat/pekat yang daerahnya didominasi oleh liputan vegetasi. Sebaran titik ini membantu secara visual untuk melakukan pembuatan sampel objek yang akan dilakukan training untuk model *Random Forest*.


3.3 NDBI Citra

Perhitungan NDBI (*Normalized Difference Building Index*) memanfaatkan band SWIR (band 6) dan band *Near – infrared* (band 5) yang dipantulkan oleh bangunan untuk memperoleh nilai variasi bangunan dan tingkat kerapatan bangunan berdasarkan piksel pada citra satelit. Hasil perhitungan NDBI pada Citra tahun 2019 dan 2023 didapatkan sebaran titik – titik yang mengindikasikan objek bangunan, seperti pemukiman kota maupun pemukiman desa. Sebaran titik ini membantu secara visual untuk melakukan

pembuatan sampel objek yang akan dilakukan training untuk model *Random Forest*.

3.4 Hasil Klasifikasi Data Citra Satelit

Proses klasifikasi data citra pada penelitian ini dapat langsung dilakukan pada platform GEE. Pada tahap ini akan dilakukan metode klasifikasi yaitu klasifikasi terbimbing (*Supervised Classification*). Klasifikasi terbimbing dilakukan dengan mengelompokkan piksel pada citra menjadi beberapa kelas berdasarkan pada statistik sampel piksel (*training*) atau *region of interest* (ROI) yang akan berguna sebagai piksel acuan yang akan digunakan server sebagai dasar melakukan klasifikasi terbimbing. Klasifikasi terbimbing citra satelit pada penelitian ini dibagi dalam 5 tutupan lahan antara lain vegetasi, badan air, lahan terbangun, lahan terbuka dan lahan sawah. Proses awal klasifikasi yang dilakukan ialah menentukan metode klasifikasi yang akan digunakan. Metode klasifikasi terbimbing yang digunakan pada penelitian ini ialah Hasil klasifikasi ditunjukkan pada Gambar 4.



Gambar 4 Hasil Klasifikasi Tutupan Lahan

3.5 Hasil Perhitungan Luas Kelas Tutupan Lahan

Hasil perhitungan luas diperoleh berdasarkan citra hasil klasifikasi terbimbing tahun 2019 dan 2023 yang telah ditampilkan sebelumnya. Berdasarkan nilai luas diperoleh dibuat tabel yang memiliki informasi masing – masing tutupan lahan pada setiap tahun meliputi jenis kelas, warna yang mewakili karakteristik dari setiap kelas tutupan lahan, luas wilayah pada setiap kelas tutupan lahan.

Tabel 1 Luas wilayah pada setiap tutupan lahan

No.	Kelas	2019 (ha)	2023(ha)
1.	Vegetasi	5.807	10.660
2	Badan Air	1.342	0.341
3	Lahan Terbuka	7.061	5.072
4	Sawah	47.780	40.945
5	Bangunan	7.484	12.454

Peningkatan luas vegetasi sebesar 4.853 ha (dari 5.807 ha pada 2019 menjadi 10.660 ha pada 2023). Hal ini mengindikasikan bahwa kenaikan vegetasi tidak hanya bersifat kuantitatif, tetapi juga kualitatif dalam hal kerapatan dan kesehatan tanaman. Beberapa faktor yang mungkin berkontribusi antara lain: (1) program penghijauan (*greening*) pasca-pembangunan tol sebagai bagian dari kompensasi lingkungan, sebagaimana terlihat dari sebaran di area reklamasi; (2) konversi lahan terbuka menjadi area bervegetasi, yang sesuai dengan penurunan luas lahan terbuka sebesar 1.989 ha; dan (3) perubahan pola tanam dari sawah ke tanaman keras (misal: kebun atau tanaman peneduh), yang tetap mempertahankan nilai NDVI tinggi meskipun terjadi reduksi luas persawahan. Temuan ini sejalan dengan penelitian Wulansari (2021) yang melaporkan bahwa pembangunan infrastruktur di Jawa sering diikuti oleh penanaman vegetasi untuk mitigasi erosi. Namun, perlu kajian lebih lanjut untuk memastikan keberlanjutan vegetasi ini, termasuk kesesuaian spesies tanaman dengan ekosistem lokal dan dampaknya terhadap produktivitas lahan pertanian di sekitarnya.

3.6 Uji Kesesuaian Klasifikasi Pada Citra Satelit

Hasil klasifikasi citra satelit yaitu klasifikasi terbimbing kemudian di uji untuk mengetahui tingkat kesesuaiannya dengan kondisi sebenarnya dan tingkat akurasi hasil klasifikasi yang telah dilakukan sehingga dapat diketahui metode yang lebih memenuhi dalam proses pengolahan selanjutnya. Berikut ini merupakan hasil uji menggunakan matrik konfusi menggunakan data hasil klasifikasi terbimbing citra satelit tahun 2019

dan 2023 yang menunjukkan tingkat akurasi dari interpretasi citra yang telah dilakukan pada GEE.

Tabel 2 Matriks Konfusi Tahun 2019

Klasifikasi	Data Referensi					Sampel
	(BA)	(V)	(S)	(BG)	(L)	
BA	6	0	0	0	0	6
V	0	16	0	0	0	16
S	0	0	21	0	0	21
BG	0	0	2	8	2	12
L	0	0	3	7	16	26
Total sampel	6	16	26	15	18	81

*Keterangan : Badan Air (BA), Vegetasi (V), Sawah (S), Bangunan (BG), Lahan Terbuka (L)

Pada matrik konfusi hasil klasifikasi terbimbing tahun 2019 yang ditunjukkan tabel 2 didapatkan total sampel sejumlah 81. Dari adanya tabel matriks konfusi akan dihitung akurasi yaitu *overall accuracy*, *user accuracy*, *producer accuracy* dan *Fscore* hasil perhitungan akurasi perkelas bisa dilihat pada tabel 3.

Tabel 3 Hasil Perhitungan akurasi perkelas

No.	Akurasi	BA	V	S	BG	L
1.	UA	1	1	0.80	0.53	0.88
2	PA	1	1	1	0.66	0.61
3	Fscore	1	1	0.89	0.59	0.72
OA						83%
KA						77%

Keterangan : *User Accuracy (UA)*, *Producer Accuracy (PA)*, *Overall Accuracy (OA)*, *Kappa Accuracy (KA)*.

Tabel 4 merupakan hasil uji menggunakan matrik konfusi menggunakan data hasil klasifikasi terbimbing citra satelit Sentinel 2A tahun 2023 yang menunjukkan tingkat akurasi dari interpretasi citra yang telah dilakukan pada GEE. Interpretasi teridentifikasi menjadi lima kelas tutupan lahan dengan jumlah sampel sebanyak 101. Pemilihan sebanyak 110 titik sampel dalam penelitian ini didasarkan pada pertimbangan representativitas, kompleksitas kelas tutupan lahan, serta efisiensi dalam pemrosesan data di platform *Google Earth Engine*. Berdasarkan total dari lima kelas klasifikasi secara acak yang disusun dalam matrik konfusi uji

klasifikasi terbimbing seperti yang ditunjukkan pada Tabel 4.

Tabel 4 Matriks Konfusi Tahun 2023

Data Klasifikasi	Data Referensi					Sampel
	BA	V	S	BG	L	
BA	4	0	0	0	0	4
V	0	17	0	0	0	17
S	0	0	25	0	0	27
B	0	0	0	13	3	16
L	0	0	4	3	30	37
Total sampel	4	17	29	16	35	101

*Keterangan : Badan Air (BA), Vegetasi (V), Sawah (S), Bangunan (BG), Lahan Terbuka (L)
Pada matrik konfusi hasil klasifikasi terbimbing tahun 2023 yang ditunjukkan tabel 4 didapatkan total sampel sejumlah 101. Dari adanya tabel matriks konfusi akan dihitung akurasi yaitu *overall accuracy*, *user accuracy*, *producer accuracy* dan *Fscore* hasil perhitungan akurasi perkelas bisa dilihat pada Tabel 5

Tabel 5 Hasil Perhitungan Akurasi Perkelas

No.	Akurasi	BA	V	S	BG	L
1.	<i>UA</i>	1	1	0.86	0.72	0.90
2	<i>PA</i>	1	1	0.93	0.81	0.81
3	<i>Fscore</i>	1	1	0.89	0.76	0.85
	<i>OA</i>					88%
	<i>KA</i>					84%

*Keterangan : *User Accuracy (UA)*, *Producer Accuracy (PA)*, *Overall Accuracy (OA)*, *Kappa Accuracy (KA)*.

Pada tabel perhitungan akurasi diperoleh nilai *overall accuracy* sebesar 88% dengan nilai kappa 84%. Nilai *overall accuracy* dan nilai kappa mengidentifikasi bahwa kelas tutupan lahan sesuai dengan kondisi pada acuan karena masih diatas 80%. Nilai dari *user accuracy*, *producer accuracy* dan *Fscore* juga dihitung pada setiap kelas yang dapat dilihat pada tabel 5 nilai *user accuracy* terbesar 1 pada kelas badan air. Sedangkan nilai terkecil 0.72, untuk nilai *producer accuracy* terbesar 1 pada vegetasi dan terkecil 0.73. Nilai *Fscore* terbesar yaitu 0.967 dan terkecil yaitu 0.73. Hasil uji klasifikasi menggunakan algoritma *Random Forest* pada platform *Google Earth Engine (GEE)* menunjukkan kinerja yang memadai dengan akurasi keseluruhan (*overall accuracy*) sebesar 88%

dan akurasi kappa 84% untuk tahun 2023. Nilai akurasi ini lebih tinggi dibandingkan tahun 2019 yang mencapai 83% (OA) dan 77% (kappa), menunjukkan peningkatan konsistensi klasifikasi seiring dengan ketersediaan data yang lebih lengkap dan penyempurnaan metode. Hasil ini sejalan dengan penelitian Belgiu & Drăguț (2016) yang menyatakan bahwa *Random Forest* pada GEE mampu menghasilkan akurasi stabil di atas 85% untuk klasifikasi tutupan lahan berbasis Sentinel-2. Analisis matriks konfusi menunjukkan variasi akurasi antar kelas, dimana kelas badan air dan vegetasi mencapai akurasi pengguna (*user's accuracy*) sempurna (100%), sementara kelas bangunan menunjukkan akurasi lebih rendah (72%). Hal ini disebabkan oleh kemiripan spektral antara bangunan dengan lahan terbuka pada citra Sentinel-2, sebagaimana diungkapkan dalam studi Zhang. (2021). Nilai *F1-score* yang berkisar antara 0.76-1.00 mengindikasikan bahwa ketidakseimbangan sampel training telah berhasil diminimalkan melalui pendekatan stratified sampling.

3.7 Perubahan Tutupan Lahan tahun 2019 – 2023

Pada penelitian ini, informasi mengenai perubahan tutupan lahan diperoleh dari data citra hasil klasifikasi terbimbing (*Supervised Classification*) yang ditampilkan sebelumnya. Perubahan tutupan lahan kemudian diketahui dari selisih nilai luas tahun 2019 dengan tahun 2023 yang dijelaskan pada bentuk tabel yang bisa dilihat pada Tabel 6.


Tabel 6 Rincian perubahan luas tiap kelas tutupan lahan

Kelas Tutupan Lahan	2019	2023	Perubahan Luas (ha)
	Luas (ha)	Luas (ha)	
Badan Air	5.807	10.660	-4.853
Vegetasi	1.343	0.431	0.982
Sawah	7.061	5.072	1.989
Bangunan	47.780	40.945	6.835
Lahan Terbuka	7.842	12.454	-12.454
Jumlah	69.453	69.472	

Berdasarkan hasil klasifikasi terbimbing *Random Forest* pada 2019 dan 2023 yang dinyatakan pada tabel 5.8. Tutupan lahan didominasi dengan sawah dengan total luas pada tahun 2019 sebesar 47.780 ha dan tahun 2023 sebesar 40.945 ha. Kelas yang

mengalami penurunan terbesar yaitu tutupan lahan sawah perubahan nilai luas dari tahun 2019 sampai dengan tahun 2023 sebesar 6.835 ha. Kelas tutupan lahan yang mengalami peningkatan terbesar yaitu Bangunan dengan perubahan nilai dari tahun 2019

sampai dengan 2023 sebesar 4.972 ha. Secara statistik dilihat pada grafik perubahan tutupan lahan yang sudah di sajikan pada Gambar 5.



Gambar 5 Grafik Perubahan Luas Tutupan Lahan

Hasil penelitian menunjukkan adanya peningkatan luas sawah yang signifikan di Kabupaten Klaten, yakni dari 40.945 hektar pada tahun 2019 menjadi 47.780 hektar pada tahun 2023. Hal ini tampak kontradiktif mengingat adanya pembangunan Jalan Tol Yogyakarta–Solo yang melintasi wilayah tersebut. Namun, terdapat beberapa faktor yang dapat menjelaskan fenomena ini. Pertama, kemungkinan terjadinya konversi lahan terbuka dan vegetasi sekunder menjadi lahan sawah. Data menunjukkan bahwa luas lahan terbuka berkurang sebesar 1.989 hektar dan vegetasi lain berkurang 0.982 hektar, sementara sawah hanya berkurang 6.835 hektar. Ketidaksesuaian angka ini mengindikasikan adanya alih fungsi lahan marginal menjadi sawah sebagai bentuk kompensasi terhadap hilangnya lahan pertanian akibat proyek tol.

Kedua, pembangunan infrastruktur seperti jalan tol berpotensi mendorong intensifikasi pertanian di wilayah sekitarnya. Akses transportasi yang lebih cepat meningkatkan efisiensi distribusi hasil pertanian, mendorong petani untuk memperluas atau mengaktifkan kembali lahan sawah. Studi serupa oleh Nugroho et al. (2021) menunjukkan bahwa pembangunan Tol Trans-Jawa turut

meningkatkan produktivitas pertanian karena terbukanya akses pasar. Ketiga, kemungkinan adanya kesalahan klasifikasi dalam proses interpretasi citra Sentinel-2. Karakter spektral sawah yang tergenang air atau baru dipanen bisa menyerupai lahan terbuka atau vegetasi non-produktif, sehingga sawah aktif bisa terdeteksi sebagai kelas lain. Selain itu, peningkatan nilai NDVI akibat penggunaan varietas padi baru yang lebih hijau dan rapat juga berpotensi menyebabkan sawah diklasifikasikan sebagai vegetasi biasa oleh algoritma Random Forest.

Meski demikian, hasil penelitian ini tetap perlu dikritisi. Salah satu potensi kelemahannya adalah kemungkinan overestimasi kelas sawah akibat keterbatasan data pelatihan (training sample). Jika sampel sawah didominasi oleh sawah irigasi dengan nilai spektral yang khas, maka sawah tadah hujan atau sawah dengan kondisi vegetasi berbeda bisa tidak terklasifikasi dengan akurat. Oleh karena itu, diperlukan penambahan sampel yang lebih representatif dan validasi lapangan. Selain itu, perlu disadari bahwa dampak pembangunan tol bersifat spasial dan tidak merata. Kehilangan sawah bisa jadi terkonsentrasi pada 10 kecamatan yang dilintasi tol,

sementara penambahan sawah justru terjadi di kecamatan lain yang tidak terdampak langsung, sehingga jika dianalisis secara agregat kabupaten, tren peningkatan luas sawah tetap tampak.

Untuk penelitian lanjutan, disarankan dilakukan analisis spasial eksplisit dengan membandingkan perubahan tutupan lahan di area terdampak langsung (menggunakan buffer zone di sepanjang tol) dan area yang tidak terdampak. Selain itu, penggunaan data time-series NDVI dapat membantu membedakan sawah aktif dengan lahan terbuka

musiman. Verifikasi lapangan melalui wawancara petani dan pemetaan partisipatif juga sangat disarankan untuk memahami dinamika alih fungsi lahan secara lebih akurat. Dengan pendekatan tersebut, kenaikan luas sawah yang teridentifikasi dapat diinterpretasikan secara lebih hati-hati. Jika data tersebut benar menunjukkan tren positif, maka ini bisa menjadi temuan penting yang mendukung kebijakan ketahanan pangan di Kabupaten Klaten.

4. KESIMPULAN DAN SARAN

Dari pemanfaatan citra satelit dengan pengolahan klasifikasi tutupan lahan menggunakan Google Earth Engine (GEE) diketahui bahwa kondisi tutupan lahan di Kabupaten Klaten sebelum dibangunnya Jalan Tol Yogyakarta – Solo pada Tahun 2019 didominasi oleh tutupan lahan sawah sebesar 47.780 ha. Tutupan lahan pada kelas lain memiliki nilai; Vegetasi 5.807, Badan Air 1.323 ha, lahan terbuka 7.061 ha, dan bangunan 7.482 ha. Pada penelitian ditemukan adanya perubahan luas tutupan lahan di Kabupaten Klaten yaitu mengalami pengurangan dan juga penambahan pada kelas tertentu setelah pembangunan Jalan Tol Yogyakarta – Solo. Dari visualisasi klasifikasi tutupan lahan terlihat daerah persawahan menjadi ruas pembangunan jalan tol jika dilihat secara angka lahan sawah mengalami penurunan sekitar 6.835 ha. Pada penelitian ini hasil klasifikasi model Random Forest juga menunjukkan uji akurasi dengan Kappa Accuracy 77% pada tahun 2019, serta Kappa Accuracy 84% pada tahun 2023.

UCAPAN TERIMA KASIH

Penulis ucapkan terima kasih kepada rekan dosen tim penelitian serta mahasiswa UPN “Veteran” Yogyakarta serta instansi – instansi terkait penyediaan data yang telah mendukung serta membantu dalam kelancaran penelitian ini.

ACUAN REFERENSI

- Alvina, D. (2023). Analisis Perubahan Tutupan Lahan Dengan Menggunakan Citra Satelit Di Areal Register 38 Gunung Balak, Kabupaten Lampung Timur.
- Andiko, J. A. (2019). Pemetaan Tutupan Lahan Di Hutan Pendidikan Konservasi Terpadu Tahura Wan Abdul Rachman Menggunakan Citra Multisensor.

- Azhah, Z. (2015). Estimasi Cadangan Karbon Pada Tutupan Lahan Hutan Sekunder, Semak Dan Belukar Di Kota Samarinda. *Agrifor: Jurnal Ilmu Pertanian Dan Kehutanan*, 14(2), 325–338.
- Cholidah, N. N. Z., & Irawan, L. Y. (2024). Pemanfaatan Penginderaan Jauh Untuk Pemetaan Alih Fungsi Lahan Sawah Di Kabupaten Nganjuk. *Jurnal Geosains Dan Remote Sensing*, 5(1), 43–54.
- Danoedoro, P., & Murti, S. H. (2021). Klasifikasi Penutup/Penggunaan Lahan Data Landsat-8 Oli Menggunakan Metode Random Forest. *Jurnal Penginderaan Jauh Indonesia*, 3(1), 1–7.
- Fibrianda, M. F., & Bhawiyuga, A. (2018). Analisis Perbandingan Akurasi Deteksi Serangan Pada Jaringan Komputer Dengan Metode Naïve Bayes Dan Support Vector Machine (SVM). *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 2(9), 3112–3123.
- Fikri, A. A. (2022). Pemanfaatan Citra Satelit Multi-Sensor Dalam Pemantauan Tutupan Lahan Di Taman Hutan Raya Wan Abdul Rachman.
- Haryani, H., Agustyaningrum, C. I., Surniandari, A., Sahara, S., & Sari, R. K. (2023). Algoritma Klasifikasi Multilayer Perceptron Dalam Analisa Data Kebakaran Hutan. *Jurnal Infortech*, 5(1), 64–70.
- Hehanussa, F. S., Sumunar, D. R. S., & Rakuasa, H. (2023). Pemanfaatan Google Earth Engine Untuk Identifikasi Perubahan Suhu Permukaan Daratan Kabupaten Buru Selatan Berbasis Cloud Computing. *Gudang Jurnal Multidisiplin Ilmu*, 1(1), 37–45.
- Magdalena, R., Saidah, S., Pratiwi, N. K. C., & Putra, A. T. (2021). Klasifikasi Tutupan Lahan Melalui Citra Satelit Spot-6 Dengan Metode Convolutional Neural Network

- (CNN). Jepin (Jurnal Edukasi Dan Penelitian Informatika), 7(3), 335–339.
- Mauludiyah, K. (2020). Klasifikasi Indeks Pembangunan Manusia Kabupaten/Kota Di Indonesia Menggunakan Metode Random Forest.
- Nurazizah, R. H. (2022). Pemanfaatan Citra Penginderaan Jauh Dalam Bidang Kelautan.
- Rozi, K., Muhsi, M., Anwari, A., & Tamam, M. B. (2024). Klasifikasi Penyakit Tanaman Padi Menggunakan Convolutional Neural Network (CNN) Dan Random Forest. Jurnal Mnemonic, 7(2), 241–248.
- Unik, M., & Nadriati, S. (2022). Overview: Random Forest Algorithm For Pm2. 5 Estimation Based On Remote Sensing. Jurnal Coscitech (Computer Science And Information Technology), 3(3), 422–430.
- Wijaya, N. (2015). Deteksi Perubahan Penggunaan Lahan Dengan Citra Landsat Dan Sistem Informasi Geografis: Studi Kasus Di Wilayah Metropolitan Bandung, Indonesia. Geoplanning: Journal Of Geomatics And Planning, 2(2), 82–92.
- Wlary, A., & Manakane, S. E. (2023). Pemanfaatan Geogle Earth Engine Untuk Identifikasi Suhu Permukaan Daratan Pulau Saparua, Provinsi Maluku Menggunakan Data Citra Satelit Landsat 8 Oli/Tirs. Larisa Penelitian Multidisiplin, 1(1), 50–55.
- Wulansari, H. (2017). Uji Akurasi Klasifikasi Penggunaan Lahan Dengan Menggunakan Metode Defuzzifikasi Maximum Likelihood Berbasis Citra Alos Avnir-2. Bhumi: Jurnal Agraria Dan Pertanahan, 3(1), 98–110.