

Identifikasi Perkebunan Kelapa Sawit Menggunakan Citra Sentinel-2 Dengan Algoritma *Random Forest* (Studi Kasus: Kecamatan Koto Kampar Hulu, Riau)

Afdhal^{1*}, Feri Agriani², Boris Kaido³, Sri Oktika Syahputri⁴ dan Rizqy Qurnia Zary⁵
Email: afdhalalkampari@gmail.com^{1*}, feriagriani@gmail.com², boriskaido@poltek-kampar.ac.id³, srioktika64@gmail.com⁴, zaryrizky@gmail.com⁵

^{1,2,3,4} Program Studi Pengelolaan Perkebunan, Politeknik Kampar, Bangkinang, Indonesia

Article Article Info

Received: June 3rd, 2026

Revised: Juni 30th, 2026

Accepted: Juni 30th, 2026

Correspondence:

Phone: +62 822-8805-4115

ABSTRACT: The rapid expansion of oil palm plantations is widely recognized as a major driver of deforestation, creating an urgent need for accurate and reproducible spatial inventories to support sustainable land management. However, multi-class land-cover inventories that explicitly separate oil palm from natural forest at the sub-district scale in Kampar Regency, Riau, remain limited, and few studies have quantified which freely available Sentinel-2 predictors most strongly sustain classification accuracy. This study aims to identify and map the spatial distribution of oil palm plantations in Koto Kampar Hulu District, Kampar Regency, Riau Province, using a 2024 Sentinel-2 annual composite processed on Google Earth Engine and classified with the Random Forest algorithm. The model integrated the original Sentinel-2 multispectral bands with three biophysical indices (NDVI, NDWI, and NDBI) to delineate five land-cover classes: forest, oil palm, settlement, road, and river. The classification achieved an overall accuracy of 94.58% and a Kappa coefficient of 0.90. Random Forest was highly effective for vegetation classes, with F1-scores of 96.0% for forest and 93.8% for oil palm, whereas narrow linear roads were poorly detected (F1 = 24.4%; class error 84.92%) owing to the mixed-pixel effect at the 10 m resolution. Variable importance analysis identified the Blue band (B2) and the SWIR band (B11) as the most influential predictors. Oil palm was the dominant cover (22,788.56 ha), slightly exceeding the remaining forest (21,427.95 ha). The integration of Random Forest and Sentinel-2 on Google Earth Engine is recommended for regional-scale oil palm inventories, while radar (Sentinel-1) or multi-temporal data are needed to improve the detection of small linear features.

Keywords: Land cover, palm oil, random forest, sentinel-2.

Citation : Afdhal, et. al., (2026). Identifikasi Perkebunan Kelapa Sawit Menggunakan Citra Sentinel-2 Dengan Algoritma *Random Forest*. Rawa Sains: Jurnal Sains STIPER Amuntai, 16(1), 32-40. <https://doi.org/10.36589/rs.v16i1.326>

PENDAHULUAN

Perkebunan kelapa sawit berperan penting dalam perekonomian Indonesia. Kelapa sawit menjadi komoditas utama yang menyumbang devisa ekspor sebesar 35 juta US\$ dan menyediakan 17 juta lapangan pekerjaan pada tahun 2021 (Saefudin & Sri Wahyuningsih, 2024). Industri kelapa sawit juga merupakan kontributor penting terhadap Produk Domestik Bruto (PDB) nasional Indonesia, mencapai 1,5% pada tahun 2020 (Sarzynski, et. al., 2020). Hal ini menunjukkan bahwa perkebunan kelapa sawit memberikan dampak luas pada pembangunan ekonomi, pengentasan kemiskinan, dan penyediaan lapangan kerja.

Perkembangan luas lahan kelapa sawit di Indonesia menunjukkan tren peningkatan yang signifikan.

Pada tahun 2023, luas areal kelapa sawit di Indonesia diperkirakan mencapai 16,83 juta hektar, yang didominasi oleh perkebunan besar swasta (51,08%), diikuti perkebunan rakyat (37,37%), PTPN (3,24%), dan areal yang masih perlu dikonfirmasi luasnya (8,31%) (Saefudin & Sri Wahyuningsih, 2024). Ekspansi

perkebunan kelapa sawit ini sering disebut sebagai salah satu pendorong utama deforestasi di Indonesia (Susanti & Maryudi, 2016). Oleh karena itu, diperlukan inventarisasi lahan kelapa sawit yang baik agar ekspansi perkebunan menjadi terarah dan tidak merusak lingkungan.

Inventarisasi lahan kelapa sawit penting dilakukan untuk memberikan data yang akurat mengenai total luas areal dan distribusi kepemilikan antara perkebunan besar swasta, perkebunan rakyat, dan perkebunan negara (Saefudin & Sri Wahyuningsih, 2024). Informasi ini krusial untuk pemantauan perubahan tutupan lahan dan pencegahan deforestasi yang sering dikaitkan dengan ekspansi kelapa sawit, serta untuk merumuskan kebijakan pengelolaan lahan yang berkelanjutan (Susanti & Maryudi, 2016). Selain itu, data yang terperinci dapat membantu mengidentifikasi potensi konflik lahan dan mendukung perencanaan pembangunan wilayah (Purboyo, et. al., 2024). Salah satu metode yang dapat digunakan untuk inventarisasi ini adalah penginderaan jauh.

Penginderaan jauh berperan penting dalam inventarisasi lahan kelapa sawit karena kemampuannya

menyediakan metode yang efisien untuk pemetaan dan pemantauan distribusi spasial perkebunan di area yang luas (Purboyo, *et. al.*, 2024), serta lebih murah dan cepat dibandingkan metode terestrial (Koto, *et. al.*, 2023). Berbagai jenis citra satelit, baik data optik (Landsat-8, Sentinel-2) maupun data sensor aktif (LiDAR, SAR), dapat menjadi sumber data utama untuk mendelineasi area perkebunan kelapa sawit (Wijanarko & Djurdjani, 2022). Data tersebut kini dapat diakses dan diolah secara langsung melalui platform Google Earth Engine (GEE) dengan proses yang relatif sederhana (Koto, *et. al.*, 2023).

Penggunaan penginderaan jauh dan *machine learning* telah banyak diterapkan untuk identifikasi tutupan lahan. Purboyo, *et. al.*, (2024) mengklasifikasikan tutupan lahan di Kawasan Perkotaan Cekungan Bandung menggunakan algoritma *Support Vector Machine* (SVM) pada citra Landsat OLI dan memperoleh akurasi keseluruhan 90% dengan indeks Kappa 0,886. Pada konteks integrasi sensor, Wijanarko & Djurdjani (2022) menggabungkan citra Pleiades dengan data LiDAR (nDSM) menggunakan *Object-Based Image Analysis* (OBIA) di Kota Makassar, dan akurasi meningkat dari 44,44% (hanya Pleiades) menjadi 63,89% setelah LiDAR diintegrasikan, menegaskan bahwa penambahan dimensi data dapat menaikkan akurasi pada lanskap yang kompleks.

Khusus untuk pemetaan kelapa sawit, Nomura & Mitchard (2018) menggunakan citra Sentinel-2 dan algoritma *Random Forest* pada GEE untuk memetakan perkebunan kecil di lanskap hutan tropis yang kompleks dan mencapai akurasi keseluruhan di atas 95%, walaupun beberapa kelas tanaman tampak serupa secara visual pada resolusi 20 m. Di Indonesia, Nurmasari & Wijayanto (2021) mendeteksi perkebunan kelapa sawit di Kabupaten Rokan Hulu, Provinsi Riau, dengan membandingkan beberapa pengklasifikasi (CART, *Random Forest*, SVM, dan Naive Bayes) pada citra Sentinel-2 dan Landsat-8, serta memperoleh akurasi keseluruhan terbaik hingga 92%. Studi tersebut menunjukkan bahwa kombinasi band multispektral dengan indeks turunan memberikan akurasi tertinggi.

Meskipun demikian, masih terdapat kesenjangan penelitian (*research gap*) yang perlu dijawab. Pertama, inventarisasi tutupan lahan multikelas yang secara eksplisit memisahkan perkebunan kelapa sawit dari hutan alami pada skala kecamatan di Kabupaten Kampar belum banyak dilakukan, padahal kedua kelas vegetasi ini memiliki kemiripan spektral yang tinggi. Kedua, banyak studi belum melaporkan kontribusi tiap variabel prediktor (*variable importance*) sehingga tidak diketahui saluran spektral atau indeks mana yang paling menentukan akurasi pada kasus pemisahan sawit-hutan. Ketiga, sebagian studi terdahulu belum menyajikan penilaian akurasi yang lengkap (akurasi keseluruhan, Kappa, serta akurasi per kelas). Citra Sentinel-2 dipilih dalam penelitian ini karena resolusi spasialnya yang lebih tinggi (10 m) dibandingkan Landsat (30 m), tersedia gratis dengan periode ulang lima hari, dan terintegrasi langsung dengan GEE, sehingga lebih sesuai untuk mendelineasi batas perkebunan dan hutan yang relatif rapat.

Kebaruan (*novelty*) penelitian ini terletak pada integrasi saluran spektral asli Sentinel-2 dengan tiga indeks biofisik (NDVI, NDWI, dan NDBI) yang diproses

pada GEE, disertai analisis *variable importance* untuk mengidentifikasi prediktor kunci, serta penilaian akurasi yang lengkap pada wilayah studi yang belum pernah dipetakan secara khusus, yaitu Kecamatan Koto Kampar Hulu, Kabupaten Kampar. Berdasarkan uraian tersebut, penelitian ini bertujuan untuk mengidentifikasi dan memetakan distribusi spasial perkebunan kelapa sawit di Kecamatan Koto Kampar Hulu, Kabupaten Kampar, Provinsi Riau, menggunakan citra Sentinel-2 dan algoritma *Random Forest* pada platform Google Earth Engine, sekaligus mengevaluasi kontribusi setiap saluran spektral dan indeks biofisik terhadap akurasi klasifikasi.

METODE PENELITIAN

Tempat dan Waktu


Penelitian dilakukan di wilayah administratif Kecamatan Koto Kampar Hulu, Kabupaten Kampar, Provinsi Riau dengan koordinat 0° 18' 11.75" LU dan 100° 35' 38.99" BT. Data utama yang dianalisis adalah data sekunder berupa citra Sentinel-2 perekaman tahun 2024 (Januari sampai Desember) yang dikompositkan menjadi citra komposit tahunan.

Bahan dan Alat

Bahan yang digunakan meliputi citra Sentinel-2 Level-2A (*Surface Reflectance*) dari katalog Google Earth Engine dan peta batas administratif Kabupaten Kampar. Pengolahan data dilakukan menggunakan seperangkat *personal computer* dengan perangkat lunak Google Earth Engine (*code editor*), RStudio (paket *randomForest*), serta ArcGIS untuk tata letak (*layout*) peta. Microsoft Word dan Microsoft Excel digunakan untuk penyusunan dokumen dan tabulasi data.

Pelaksanaan Penelitian

Alur penelitian secara umum terdiri atas pra-pemrosesan citra, ekstraksi fitur, pengumpulan sampel latih, klasifikasi menggunakan algoritma *Random Forest*, dan evaluasi akurasi. Diagram alur penelitian disajikan pada Gambar 1.



Gambar 1. Diagram alur penelitian (*research workflow*)

Pra-pemrosesan Citra Sentinel-2

Koleksi citra Sentinel-2 Level-2A periode Januari-Desember 2024 dipanggil pada GEE. Piksel berawan dan bayangan awan disaring menggunakan informasi kualitas (*band QA60* atau klasifikasi adegan/SCL), kemudian seluruh koleksi yang telah disaring direduksi menjadi satu citra komposit median tahunan untuk meminimalkan tutupan awan. Citra komposit selanjutnya dipotong (*clipping*) mengikuti batas administrasi Kecamatan Koto Kampar Hulu. Dari citra komposit, diekstraksi saluran spektral asli serta tiga indeks biofisik sebagai variabel prediktor tambahan, yang dihitung sebagai berikut: NDVI = $(B8 - B4)/(B8 + B4)$; NDWI = $(B3 - B8)/(B3 + B8)$; dan NDBI = $(B11 - B8)/(B11 + B8)$.

Persiapan Data untuk Klasifikasi Random Forest

Sampel latih dikumpulkan melalui pembuatan poligon *Region of Interest* (ROI) yang representatif untuk lima kelas tutupan lahan (hutan, perkebunan kelapa sawit, pemukiman, jalan, dan sungai) berdasarkan interpretasi visual citra resolusi tinggi pada Google Earth dengan dukungan pengetahuan lokal. Statistik piksel dari dalam poligon ROI digunakan sebagai basis data latih bagi algoritma. Jumlah piksel sampel untuk setiap kelas disajikan pada Tabel 1.

Tabel 1. Distribusi jumlah piksel sampel per kelas tutupan lahan

No	Kelas	Jumlah Piksel Sampel	Proporsi (%)
1	Hutan	16.991	57,61
2	Sungai	9.417	31,93
3	Sungai	1.777	6,03
4	Pemukiman	1.057	3,58
5	Jalan	252	0,85
Total		29.494	100,00

Klasifikasi Menggunakan Algoritma Random Forest

Klasifikasi terbimbing dilakukan menggunakan algoritma *Random Forest*, yaitu metode *ensemble* yang membangun banyak pohon keputusan (*decision trees*) secara acak dan menggabungkan hasilnya melalui pemungutan suara mayoritas. Model dilatih menggunakan variabel prediktor berupa saluran spektral asli dan indeks biofisik. Parameter model yang digunakan disajikan pada Tabel 2.

Tabel 2. Parameter algoritma Random Forest

Parameter	Nilai	Keterangan
n tree	500	Jumlah pohon keputusan dalam ensemble
m try	3 ($\sqrt{p}$)	Jumlah variabel diuji pada setiap pemisahan
nodesize prediktor	1 9	Ukuran minimum simpul terminal $B2 + B3 + B4 + B8 + B11 + B12 + NDVI + NDWI + NDBI$

Evaluasi Akurasi

Kinerja model dievaluasi menggunakan matriks confusion yang membandingkan kelas hasil klasifikasi dengan kelas referensi. Dari matriks tersebut dihitung sejumlah metrik akurasi, yaitu akurasi keseluruhan (*Overall Accuracy, OA*), koefisien Kappa, akurasi pembuat (*Producer's Accuracy/PA*, setara *recall*), akurasi pengguna (*User's Accuracy/UA*, setara *precision*), serta nilai F1 sebagai rata-rata harmonik PA dan UA. Kesalahan omisi (*omission error*) dihitung sebagai $1 - PA$ dan kesalahan komisi (*commission error*) sebagai $1 - UA$. Akurasi keseluruhan dihitung sebagai rasio jumlah piksel terklasifikasi benar (diagonal matriks) terhadap total piksel, sedangkan koefisien Kappa mengukur tingkat kesepakatan setelah memperhitungkan peluang kesepakatan acak.


Analisis Data

Algoritma Random Forest diterapkan pada komposit median tahunan Sentinel-2 untuk memprediksi kelas tutupan lahan setiap piksel di wilayah penelitian, dengan fokus membedakan lahan perkebunan kelapa sawit dari kelas non-sawit. Keluaran utama berupa peta sebaran lima kelas tutupan lahan, tabel luasan tiap kelas, matriks confusion beserta metrik akurasinya, dan plot variable importance untuk mengidentifikasi prediktor yang paling berpengaruh.

HASIL DAN PEMBAHASAN

Region Of Interest

Penetapan *Region of Interest* (ROI) dilakukan untuk membatasi cakupan analisis spasial pada lokasi penelitian dengan memotong citra mengikuti batas Kecamatan Koto Kampar Hulu, sekaligus meningkatkan efisiensi komputasi. Teknik ROI juga diaplikasikan dalam penentuan area sampel (*training areas*): serangkaian poligon dibuat secara representatif pada berbagai kelas tutupan lahan untuk merekam karakteristik tanda spektral (*spectral signature*) masing-masing objek (Gambar 2). Statistik piksel dari dalam ROI kemudian menjadi basis data latih bagi algoritma klasifikasi (Campbell, *et. al.*, 2023).




Gambar 2. *Region Of Interest*

Analisis Separabilitas Spektral

Evaluasi pola spektral dilakukan untuk mengetahui daya pisah (*separability*) antar kelas tutupan lahan sebelum klasifikasi. Karakteristik pantulan spektral rata-rata setiap ROI pada berbagai panjang gelombang Sentinel-2 disajikan pada Gambar 4 dan Gambar 5. Secara umum, kurva spektral menunjukkan perbedaan signifikan antara objek vegetasi (kelapa sawit dan hutan) dengan objek non-vegetasi (badan air, lahan terbangun, dan jalan), terutama pada rentang *Visible* dan *Near-Infrared* (NIR) (Prasad, 2015). Objek kelapa sawit menunjukkan nilai reflektansi tinggi pada Band 8 (NIR) dan Band 11 (SWIR-1). Perbedaan paling distingtif terlihat pada rentang *Short Wave Infrared* (SWIR), di mana kanopi kelapa sawit memiliki pola pantulan yang berbeda dibandingkan vegetasi hutan alam yang lebih rapat. Perbedaan respons spektral inilah yang menjadi variabel kunci bagi *Random Forest* untuk memisahkan piksel kelapa sawit dari vegetasi lain (Darra, *et. al.*, 2025). Ringkasan nilai reflektansi rata-rata per band dan per kelas disajikan pada Tabel 2.


Tabel 2. Nilai reflektansi rata-rata tiap kelas pada saluran spektral terpilih

Kelas	B2 (Blue)	B4 (Red)	B8 (NIR)	B11 (SWIR-1)	B12 (SWIR-2)
hutan	347.95	536.26	357.76	2996.30	1574.99
jalan	534.44	760.08	744.77	2653.51	2047.41
pemukiman	602.90	764.18	849.26	2234.41	2200.64
sawit	259.80	503.05	350.83	3223.96	1955.36
sungai	520.54	715.19	754.80	1031.09	1077.56



Gambar 3. Karakteristik Spektral Band Citra Sentinel-2

Karakteristik pantulan spektral (*spectral signature*) rata-rata dari masing-masing *Region of Interest* (ROI) pada berbagai panjang gelombang (band) Sentinel-2 disajikan pada Gambar 3. Secara umum, pola kurva spektral menunjukkan perbedaan yang signifikan antara objek vegetasi (kelapa sawit dan hutan) dengan objek non-vegetasi (badan air, lahan terbangun/tanah terbuka serta jalan), terutama pada rentang gelombang *Visible* dan *Near-Infrared* (NIR) (Prasad, 2015).




Gambar 4. Distribusi Panjang Gelombang

Fokus utama analisis ini adalah membedakan kelapa sawit dengan kelas vegetasi lainnya. Berdasarkan grafik spektral, objek kelapa sawit menunjukkan nilai reflektansi yang tinggi pada Band 8 (NIR) dan Band 11 (SWIR-1) seperti pada Gambar 4. Perbedaan pola yang paling distingtif terlihat pada rentang *Short Wave Infrared* (SWIR), di mana kanopi kelapa sawit cenderung memiliki nilai pantulan yang sedikit lebih tinggi dibandingkan vegetasi hutan alam yang lebih rapat, namun memiliki pola serapan yang berbeda dibandingkan semak belukar. Perbedaan respons spektral pada band-band inilah yang menjadi variabel kunci bagi algoritma *Random Forest* untuk memisahkan piksel kelapa sawit dari objek vegetasi lainnya dengan akurat (Darra, *et. al.*, 2025).

Analisis Karakteristik Spektral dan Distribusi Spasial Indeks Biofisik Lahan

Analisis karakteristik spektral pada citra Sentinel-2 dilakukan untuk mengevaluasi pola distribusi nilai indeks NDVI, NDWI, dan NDBI terhadap lima kelas tutupan lahan, yaitu hutan, jalan, pemukiman, sawit, dan sungai. Berdasarkan visualisasi data statistik menggunakan boxplot, terlihat adanya variasi rentang nilai yang signifikan antar kelas, yang mengindikasikan kemampuan setiap indeks dalam memisahkan objek biofisik di permukaan bumi. Evaluasi ini penting untuk memastikan bahwa indeks yang digunakan mampu merepresentasikan kondisi aktual tutupan lahan di wilayah studi sebelum dilakukan proses klasifikasi lebih lanjut.




Gambar 5. Sebaran indeks NDVI, NDWI, dan NDBI

Pada indeks vegetasi (NDVI), hasil boxplot menunjukkan bahwa kelas hutan dan sawit memiliki nilai median tertinggi yang mendekati angka 0,8 hingga 0,9. Tingginya nilai ini merefleksikan kerapatan vegetasi dan kandungan klorofil yang padat pada kedua kelas tersebut. Sebaliknya, kelas jalan dan pemukiman menunjukkan nilai NDVI yang jauh lebih rendah dan bervariasi, sementara kelas sungai memiliki nilai terendah. Pola ini mengonfirmasi bahwa NDVI sangat sensitif terhadap keberadaan biomassa hijau dan efektif memisahkan area vegetasi (sawit dan hutan) dari area non-vegetasi (lahan terbangun dan badan air) (Fakhri, *et. al.*, 2025).

Sebaliknya, analisis pada indeks bangunan (NDBI) memperlihatkan pola kebalikan dari NDVI, di mana kelas pemukiman dan jalan mencatatkan nilai spektral yang lebih tinggi dibandingkan kelas lainnya. Meskipun nilai median untuk kelas terbangun ini tidak selalu positif tinggi—yang mungkin disebabkan oleh resolusi spasial atau pencampuran piksel dengan vegetasi di sekitarnya—namun secara relatif nilainya tetap lebih tinggi dibandingkan area hutan dan sawit yang konsisten bernilai negatif. Hal ini menunjukkan bahwa NDBI cukup responsif dalam mendeteksi fitur antropogenik atau lahan terbuka di tengah dominasi vegetasi.

Untuk karakteristik fitur air yang dianalisis menggunakan NDWI, boxplot memperlihatkan bahwa kelas sungai memiliki distribusi nilai yang unik dan terpisah dari kelas daratan. Meskipun terdapat variasi rentang nilai (lebar box) yang cukup besar pada kelas sungai—yang kemungkinan disebabkan oleh tingkat kekeruhan air atau pengaruh pantulan spektral dari dasar sungai yang dangkal—namun secara umum median nilainya lebih tinggi dibandingkan kelas vegetasi dan pemukiman. Fenomena ini menegaskan bahwa NDWI efektif untuk mendelineasi batas badan air, meskipun perlu kehati-hatian pada area tepian sungai yang rawan terhadap efek mixed pixel.




Gambar 6. Pola distribusi nilai indeks NDVI, NDWI, dan NDBI

Secara spasial, distribusi nilai ketiga indeks tersebut divisualisasi dengan jelas pada peta hasil pengolahan citra. Peta NDVI didominasi oleh rona nilai tinggi yang merepresentasikan luasnya tutupan perkebunan sawit dan hutan di wilayah studi. Sementara itu, pada peta NDBI dan NDWI, pola-pola linier dan terkluster mulai terlihat menonjol, yang berasosiasi dengan jaringan jalan, area pemukiman, serta aliran sungai. Konsistensi antara statistik boxplot dan pola spasial pada peta menyimpulkan bahwa integrasi ketiga indeks ini memberikan gambaran yang komprehensif dan akurat mengenai kondisi tutupan lahan di lokasi penelitian.

Identifikasi Tutupan Lahan dengan Random Forest

Identifikasi tutupan lahan dilakukan dengan algoritma *Random Forest* yang dipilih karena keandalannya menangani data berdimensi tinggi serta kemampuannya meminimalkan *overfitting* dibandingkan metode konvensional (Yu, *et. al.*, 2024). Model dibangun dengan mengintegrasikan saluran spektral asli Sentinel-2 dan indeks biofisik (NDVI, NDWI, NDBI) untuk mendelineasi lima kelas tutupan lahan utama (Nurmasari & Wijayanto, 2021).




Gambar 7. Sebaran Klasifikasi Tutupan Lahan dengan Random Forest

Visualisasi hasil klasifikasi tutupan lahan menggunakan algoritma Random Forest, sebagaimana disajikan pada Gambar 6, memperlihatkan pola distribusi spasial yang didominasi oleh aktivitas perkebunan. Kelas Sawit (divisualisasikan dengan warna kuning) teridentifikasi sebagai tutupan lahan yang paling dominan, menutupi sebagian besar wilayah tengah hingga utara area studi. Pola penyebaran kelapa sawit ini terlihat masif dan kontigu, mengindikasikan adanya pengelolaan lahan intensif berupa perkebunan skala besar. Di sisi lain, kelas Hutan (warna hijau) terkonsentrasi di bagian barat daya dan selatan peta, yang kemungkinan merepresentasikan sisa tutupan vegetasi alami atau kawasan konservasi yang belum terkonversi menjadi lahan budidaya.

Fitur antropogenik dan hidrologi juga berhasil terpetakan dengan detail yang cukup baik. Kelas Sungai (warna biru) terlihat membelah wilayah studi dari arah barat laut ke tenggara, berfungsi sebagai fitur alami yang memisahkan beberapa blok penggunaan lahan. Sementara itu, kelas Pemukiman (warna merah) terdeteksi membentuk pola kluster yang umumnya berasosiasi dekat dengan aliran sungai dan persimpangan jalur transportasi utama. Yang menarik adalah pola kelas Jalan (warna abu-abu) yang membentuk jaringan grid atau kotak-kotak di dalam area perkebunan sawit; pola geometris ini merupakan karakteristik khas dari jaringan jalan panen (collection roads) pada perkebunan kelapa sawit, yang membedakannya dari jalan arteri umum.

Secara keseluruhan, model *Random Forest* menunjukkan kinerja visual yang efektif dalam mendelineasi batas antar kelas, terutama dalam memisahkan vegetasi sejenis (hutan dan sawit) yang seringkali memiliki kemiripan spektral. Batas antara area perkebunan dan hutan terlihat tegas, begitu pula dengan deteksi objek kecil seperti jaringan jalan yang memotong area perkebunan. Hasil klasifikasi ini memberikan gambaran komprehensif mengenai dinamika lanskap di wilayah studi, di mana konversi lahan menjadi perkebunan kelapa sawit tampak sangat signifikan mendesak keberadaan tutupan hutan alami.



Gambar 8. Variable Importance

Analisis tingkat kepentingan variabel (variable importance) dilakukan untuk mengidentifikasi kontribusi setiap saluran spektral dan indeks transformasi dalam pembentukan model klasifikasi. Berdasarkan metrik Mean Decrease Accuracy (MDA), saluran B2 (Blue) teridentifikasi sebagai variabel yang paling berpengaruh secara signifikan, diikuti oleh saluran Shortwave Infrared (B11 dan B12). Tingginya nilai MDA pada saluran B2 mengindikasikan bahwa informasi pada panjang gelombang biru memegang peranan krusial dalam menjaga performa model, di mana penghilangan atau pengacakan data pada saluran ini akan menyebabkan penurunan akurasi klasifikasi yang paling drastis dibandingkan variabel lainnya. Dominasi saluran SWIR (B11 dan B12) juga menegaskan bahwa variabilitas spektral yang berkaitan dengan kadar air tanah dan vegetasi sangat membantu model dalam memisahkan kelas-kelas tutupan lahan yang kompleks.

Selanjutnya, berdasarkan metrik Mean Decrease Gini (MDG) yang mengukur efektivitas variabel dalam mereduksi ketidakmurnian (impurity) pada setiap percabangan pohon keputusan, saluran B11 menempati posisi tertinggi sebagai variabel penentu utama, diikuti oleh B2 dan indeks NDVI. Hal ini menunjukkan bahwa B11 memiliki kapasitas pemisahan (splitting power) yang paling optimal untuk membedakan karakteristik antar kelas secara homogen. Kehadiran indeks NDVI dan NDBI pada peringkat menengah ke atas dalam plot Gini menunjukkan bahwa integrasi indeks biofisik mampu memberikan informasi tambahan yang efektif untuk mempertajam batas separabilitas, khususnya dalam membedakan densitas vegetasi dan fitur area terbangun, melengkapi kontribusi dari saluran multispektral asli (Darra, *et. al.*, 2025).

Tabel 3. Sebaran Luasan Tutupan Lahan

No.	Klasifikasi	Luas (Ha)
1	Hutan	21427.95
2	Jalan	65.25
3	Pemukiman	1216.47
4	Perkebunan Sawit	22788.56
5	Sungai	308.56

Kuantifikasi hasil klasifikasi tutupan lahan disajikan pada Tabel 4, yang memperlihatkan komposisi luasan absolut untuk setiap kategori di wilayah studi. Berdasarkan perhitungan tersebut, lanskap wilayah didominasi oleh dua kelas vegetasi utama, yaitu Perkebunan Sawit yang menempati area terluas mencapai 22.788,56 Ha, diikuti secara signifikan oleh tutupan Hutan seluas 21.427,95 Ha. Dominasi kedua kelas ini merefleksikan karakteristik penggunaan lahan yang bertumpu pada aktivitas budidaya perkebunan

tanpa menghilangkan sepenuhnya eksistensi vegetasi alami. Sementara itu, area terbangun (Pemukiman) teridentifikasi seluas 1.216,47 Ha, sedangkan fitur hidrologi (Sungai) dan infrastruktur (Jalan) menempati

proporsi minor, masing-masing seluas 308,56 Ha dan 65,25 Ha, yang wajar mengingat karakteristik geometri linear dari kedua objek tersebut dibandingkan luasan blok lahan.

Tabel 4. Confusion Matrix

Klasifikasi	hutan	jalan	pemukiman	sawit	sungai	class.error
hutan	16326	12	34	608	11	0.0391
jalan	82	38	80	49	3	0.8492
pemukiman	60	7	931	50	9	0.1192
sawit	458	2	6	8950	1	0.0496
sungai	101	0	19	7	1650	0.0715

Berdasarkan confusion matrix yang dihasilkan, model Random Forest menunjukkan kinerja yang sangat memuaskan dalam mengidentifikasi kelas vegetasi dominan. Hal ini terlihat dari rendahnya nilai class error pada kelas Hutan (3,91%) dan Sawit (4,96%). Dari total 16.991 piksel sampel referensi Hutan, sebanyak 16.326 piksel berhasil diklasifikasikan dengan tepat, begitu pula dengan kelas Sawit yang berhasil memprediksi 8.950 piksel dengan benar. Tingginya akurasi pada kedua kelas ini mengindikasikan bahwa kombinasi saluran spektral dan indeks vegetasi (NDVI) yang digunakan sangat efektif dalam membedakan karakteristik kanopi hutan alami dan perkebunan kelapa sawit.

Tabel 5. Metrik akurasi per kelas dan akurasi keseluruhan

Kelas	PA (%)	UA (%)	F1 (%)	Omisi (%)	Komisi (%)
Hutan	96,09	95,88	95,98	3,91	4,12
Sawit	95,04	92,61	93,81	4,96	7,39
Sungai	92,85	98,57	95,62	7,15	1,43
Pemukiman	88,08	87,01	87,54	11,92	12,99
Jalan	15,08	64,41	24,44	84,92	35,59

Akurasi keseluruhan (Overall Accuracy) = 94,58%; Koefisien Kappa = 0,90 (0,9029); rata-rata F1 (macro) = 79,48%. PA = Producer's Accuracy; UA = User's Accuracy.

Secara keseluruhan, model *Random Forest* mencapai akurasi keseluruhan 94,58% dengan koefisien Kappa 0,90, yang tergolong sangat baik dan menandakan kesepakatan yang kuat antara hasil klasifikasi dan data referensi. Model menunjukkan kinerja sangat memuaskan pada kelas vegetasi dominan, terlihat dari rendahnya *class error* pada Hutan (3,91%; F1 = 95,98%) dan Sawit (4,96%; F1 = 93,81%). Dari 16.991 piksel referensi Hutan, 16.326 piksel terklasifikasi benar; demikian pula 8.950 piksel Sawit terprediksi tepat. Hal ini mengindikasikan bahwa kombinasi saluran spektral dan indeks vegetasi sangat efektif membedakan kanopi hutan alami dari perkebunan kelapa sawit.

Tantangan signifikan ditemukan pada klasifikasi objek linear, khususnya kelas Jalan, yang mencatatkan

tingkat kesalahan tertinggi sebesar 84,92%. Tingginya error ini disebabkan oleh resolusi spasial citra Sentinel-2 (10 meter) yang seringkali lebih besar daripada lebar badan jalan itu sendiri, sehingga menimbulkan fenomena piksel campuran (mixed pixel) (Prasad, 2015). Sebagian besar piksel jalan mengalami misklasifikasi menjadi kelas Hutan (82 piksel) dan Pemukiman (80 piksel). Kesalahan ini dapat dimaklumi mengingat jalan yang sempit seringkali tertutup oleh kanopi pohon di sekitarnya (terbaca sebagai hutan) atau memiliki respons spektral material aspal/beton yang sangat mirip dengan atap bangunan (terbaca sebagai pemukiman).

Selain itu, analisis matriks juga memperlihatkan adanya pola pertukaran (confusion) yang cukup wajar antara kelas-kelas yang memiliki kemiripan karakteristik fisik. Pertukaran terbesar terjadi antara kelas vegetasi, di mana 608 piksel hutan terklasifikasi sebagai sawit, dan sebaliknya 458 piksel sawit terklasifikasi sebagai hutan, yang kemungkinan terjadi pada area transisi atau perkebunan tua yang menyerupai hutan sekunder. Demikian pula pada kelas Pemukiman (class error 11,9%), kesalahan deteksi umumnya tertukar dengan kelas jalan dan tanah terbuka, yang merupakan konsekuensi logis dari kesamaan material penyusun permukaan (impervious surface) pada kedua kelas tersebut. Meskipun demikian, secara umum model ini memiliki reliabilitas yang tinggi untuk pemetaan skala tinjau, terutama untuk estimasi luasan area berbasis vegetasi (Choudhary, *et. al.*, 2022).

Jika dibandingkan dengan studi terdahulu, akurasi keseluruhan penelitian ini (94,58%) sedikit lebih tinggi daripada akurasi terbaik Nurmasari & Wijayanto (2021) untuk deteksi kelapa sawit di Rokan Hulu, Riau (hingga 92%), yang juga menggunakan Sentinel-2 dan *Random Forest*. Hal ini menguatkan temuan bahwa integrasi band multispektral dengan indeks turunan meningkatkan akurasi. Hasil ini juga konsisten dengan Nomura & Mitchard (2018) yang memperoleh akurasi di atas 95% untuk pemetaan tanaman berbasis Sentinel-2 dan *Random Forest* pada lanskap tropis kompleks. Keterbatasan pada objek linear yang ditemukan dalam penelitian ini sejalan dengan argumen Sarzynski, *et. al.* (2020) bahwa kombinasi data radar (SAR) dan optik mampu memperbaiki pemetaan kelapa sawit; integrasi

Sentinel-1 berpotensi mengatasi keterbatasan deteksi jalan dan tepian sungai yang dialami pendekatan optik murni di sini. Meskipun terdapat keterbatasan tersebut, model ini memiliki reliabilitas tinggi untuk pemetaan skala tinjau, khususnya untuk estimasi luasan berbasis vegetasi (Choudhary, *et. al.*, 2022).

KESIMPULAN

Penelitian ini berhasil mengidentifikasi dan memetakan distribusi spasial perkebunan kelapa sawit di Kecamatan Koto Kampar Hulu, Kabupaten Kampar, Provinsi Riau, menggunakan citra Sentinel-2 dan algoritma *Random Forest* pada Google Earth Engine. Integrasi saluran multispektral dengan indeks biofisik (NDVI, NDWI, NDBI) menghasilkan akurasi keseluruhan 94,58% dan koefisien Kappa 0,90, dengan kinerja tinggi pada kelas Perkebunan Sawit (*class error* 4,96%; F1 = 93,81%) dan Hutan (*class error* 3,91%; F1 = 95,98%). Saluran B2 (Blue) dan B11 (SWIR) teridentifikasi sebagai prediktor paling berpengaruh dalam menjaga performa model.

Hasil analisis spasial menunjukkan wilayah studi didominasi perkebunan intensif. Perkebunan Kelapa Sawit merupakan tutupan lahan terluas (22.788,56 Ha) yang persebarannya masif dan kontigu di bagian tengah hingga utara, sedikit melampaui tutupan Hutan tersisa (21.427,95 Ha) yang umumnya berada di barat daya dan selatan. Kontribusi ilmiah penelitian ini adalah penyediaan inventarisasi tutupan lahan multikelas yang memisahkan sawit dari hutan alami pada skala kecamatan di Kabupaten Kampar, lengkap dengan penilaian akurasi dan identifikasi prediktor kunci.

Penelitian ini memiliki keterbatasan, terutama dalam mendeteksi objek linear berukuran kecil seperti jalan (*class error* 84,92%) akibat fenomena *mixed pixel* pada resolusi 10 m. Untuk penelitian selanjutnya disarankan mengintegrasikan data radar Sentinel-1, memanfaatkan analisis deret waktu (*time series*) multi-temporal, serta menambahkan indeks berbasis *red-edge* guna meningkatkan akurasi deteksi objek linear dan pemisahan tingkat kerapatan vegetasi..

UCAPAN TERIMAKASIH

Terimakasih kami sampaikan kepada P3M Politeknik Kampar yang telah mendukung terlaksananya penelitian ini.

DAFTAR PUSTAKA

- Campbell, J. B., Wynne, R. H., & Thomas, V. A. (2023). *Introduction to Remote Sensing* (6th ed.). The Guilford Press.
- Choudhary, K., Shi, W., Dong, Y., & Paringer, R. (2022). Random Forest for rice yield mapping and prediction using Sentinel-2 data with Google Earth Engine. *Advances in Space Research*, 70(8), 2443–2457. <https://doi.org/10.1016/j.asr.2022.06.073>
- Darra, N., Espejo-Garcia, B., Psiroukis, V., Psomiadis, E., & Fountas, S. (2025). Spectral bands vs. vegetation indices: An AutoML approach for processing tomato yield predictions based on Sentinel-2 imagery. *Smart Agricultural Technology*, 10, 100805. <https://doi.org/10.1016/j.atech.2025.100805>
- Fakhri, A., Latifi, H., Samani, K. M., & Fassnacht, F. E. (2025). Introducing a computationally light approach to estimate forest height and fractional canopy cover from Sentinel-2 data. *Journal of Arid Environments*, 228, 105343. <https://doi.org/10.1016/j.jaridenv.2025.105343>
- Koto, A. G., Koto, H. A., & Dangkoa, T. (2023). Spasial Luas Tanam Padi Sawah Irigasi Berdasarkan Citra Satelit Optis. *Jurnal Teknologi Pertanian Gorontalo (JTPG)*, 8(2), 63–69. <https://doi.org/10.30869/jtpg.v8i2.1268>
- Nurmasari, Y., & Wijayanto, A. W. (2021). Oil Palm Plantation Detection In Indonesia Using Sentinel-2 And Landsat-8 Optical Satellite Imagery (Case Study: Rokan Hulu Regency, Riau Province). *International Journal of Remote Sensing and Earth Sciences (IJReSES)*, 18(1), 1. <https://doi.org/10.30536/ijreses.2021.v18.a3537>
- Prasad Thenkabail. (2015). *Remotely Sensed Data Characterization, Classification, and Accuracies* (Ph. D. Thenkabail, Ed.). CRC Press. <https://doi.org/10.1201/b19294>
- Purboyo, A. A., Kurniawan, A., & Muta'ali, L. (2024). Identifikasi Tutupan Lahan Menggunakan Support Vector Machine di Kawasan Perkotaan Cekungan Bandung. *Jurnal Komtika (Komputasi Dan Informatika)*, 8(1), 54–64. <https://doi.org/10.31603/komtika.v8i1.11140>
- Saefudin, & Sri Wahyuningsih. (2024). *Analisis Kinerja Perdagangan Kelapa Sawit*. Kementerian Pertanian.
- Sampurno, R., & Thoriq, A. (2016). Klasifikasi Tutupan Lahan Menggunakan Citra Landsat 8 Operational Land Imager (OLI) Di Kabupaten Sumedang. *Jurnal Teknotan*, 10(2), 61–70. <https://doi.org/10.24198/jt.vol10n2.9>
- Sarzynski, T., Giam, X., Carrasco, L., & Lee, J. S. H. (2020). Combining Radar and Optical Imagery to Map Oil Palm Plantations in Sumatra, Indonesia, Using the Google Earth Engine. *Remote Sensing*, 12(7), 1220. <https://doi.org/10.3390/rs12071220>
- Susanti, A., & Maryudi, A. (2016). Development narratives, notions of forest crisis, and boom of oil palm plantations in Indonesia. *Forest Policy and*

Economics, 73, 130–139.
<https://doi.org/10.1016/j.forpol.2016.09.009>

- Wijanarko, B., & Djurdjani, D. (2022). Klasifikasi Digital Tutupan Lahan Berbasis Objek menggunakan Integrasi Data Lidar dan Citra Satelit di Kawasan Tamalanrea Indah, Kota Makassar. *JGISE: Journal of Geospatial Information Science and Engineering*, 5(1), 51. <https://doi.org/10.22146/jgise.68994>
- Yu, Y., Zhou, Z., Sharma, R. P., Zhang, L., Du, M., & Zhang, H. (2024). Comparing crown ratio models for spruce-fir broadleaved mixed forests using beta regression and random forest algorithm. *Computers and Electronics in Agriculture*, 225, 109302. <https://doi.org/10.1016/j.compag.2024.109302>