

# Peningkatan Akurasi Klasifikasi Tutupan Lahan Menggunakan Random Forest pada Data Sentinel-2 di Jambi

Akhiyar Waladi

Jurusan Teknik Elektro dan Informatika, Fakultas Sains dan Teknologi, Universitas Jambi  
akhiyar.waladi@unja.ac.id\*

## Abstract

Accurate land cover classification plays a crucial role in environmental monitoring, urban planning, and sustainable resource management. With rising concerns over land use changes and ecological degradation, developing effective classification methods has become increasingly important, particularly in regions experiencing rapid landscape transformations. This research evaluates the performance of seven machine learning algorithms (Random Forest, Extra Trees, Logistic Regression, Decision Tree, Naive Bayes, SGD Classifier, and LightGBM) for land cover classification using Sentinel-2 satellite data in the Jambi region. The study incorporates 23 features, including 10 spectral bands and 13 spectral indices, with data collected during Q4 2024. Results show that Random Forest achieved the best overall performance with 85.91% accuracy and 85.48% weighted F1-score, followed by Extra Trees with 84.45% accuracy. Tree-based algorithms demonstrated superior capability in distinguishing urban areas, vegetation, and water bodies, though all algorithms faced challenges with minority classes. These findings represent significant improvement over previous approaches that achieved only 37.7%-66.9% accuracy using single vegetation indices. The improved classification accuracy enables more effective monitoring of deforestation, urban expansion, and ecosystem changes in tropical regions, providing critical support for evidence-based land management policies and conservation strategies in complex landscapes like Jambi.

Keywords: remote sensing, land cover classification, machine learning, sentinel-2, Jambi

## Abstrak

Klasifikasi tutupan lahan yang akurat memainkan peran penting dalam pemantauan lingkungan, perencanaan perkotaan, dan pengelolaan sumber daya berkelanjutan. Dengan meningkatnya kekhawatiran terhadap perubahan penggunaan lahan dan degradasi ekologis, pengembangan metode klasifikasi yang efektif menjadi semakin penting, terutama di wilayah yang mengalami transformasi lanskap secara cepat. Penelitian ini mengevaluasi kinerja tujuh algoritma *machine learning* (Random Forest, Extra Trees, Logistic Regression, Decision Tree, Naive Bayes, SGD Classifier, dan LightGBM) untuk klasifikasi tutupan lahan menggunakan data satelit Sentinel-2 di wilayah Jambi. Studi ini menggunakan 23 fitur, termasuk 10 band spektral dan 13 indeks spektral, dengan data yang dikumpulkan selama Q4 2024. Hasil menunjukkan bahwa Random Forest mencapai kinerja terbaik secara keseluruhan dengan akurasi 85.91% dan *weighted F1-score* 85.48%, diikuti oleh Extra Trees dengan akurasi 84.45%. Algoritma berbasis pohon keputusan menunjukkan kemampuan yang lebih unggul dalam membedakan area perkotaan, vegetasi, dan badan air, meskipun semua algoritma menghadapi tantangan dengan kelas minoritas. Temuan ini merepresentasikan peningkatan signifikan dibandingkan pendekatan sebelumnya yang hanya mencapai akurasi 37.7%-66.9% menggunakan indeks vegetasi tunggal. Peningkatan akurasi klasifikasi memungkinkan pemantauan yang lebih efektif terhadap deforestasi, ekspansi perkotaan, dan perubahan ekosistem di wilayah tropis, memberikan dukungan penting bagi kebijakan pengelolaan lahan berbasis bukti dan strategi konservasi di lanskap kompleks seperti Jambi.

Kata kunci: penginderaan jauh, klasifikasi tutupan lahan, *machine learning*, sentinel-2, Jambi

©This work is licensed under a Creative Commons Attribution - ShareAlike 4.0 International License

## 1. Pendahuluan

Permukaan bumi yang kita tinggali memiliki berbagai tampilan biofisik yang disebut tutupan lahan mulai dari area pemukiman dan industri (lahan terbangun), kawasan hutan dan pertanian (vegetasi), hingga rawa-rawa dan badan air seperti sungai dan danau. Keberagaman tutupan lahan ini memberikan gambaran visual tentang kondisi suatu wilayah dan menyimpan informasi penting yang dapat digunakan untuk memahami berbagai fenomena alam dan interaksi manusia dengan lingkungannya [1].

Pada empat dekade terakhir, paradigma analisis tutupan lahan telah bergeser dari pendekatan manual menuju integrasi teknologi penginderaan jauh dan kecerdasan buatan. Keterbatasan survei lapangan dalam cakupan geografis, waktu, dan tenaga telah mendorong adopsi sistem berbasis satelit yang dilengkapi algoritma *machine learning*. Program Landsat (NASA) dan

Sentinel (ESA) menyediakan data multi-spektral dengan resolusi yang sangat memadai untuk deteksi perubahan tutupan lahan. Meski demikian, efektivitas klasifikasi tidak semata bergantung pada ketersediaan data satelit, melainkan juga pada pendekatan analitis yang mampu memaksimalkan informasi dari berbagai saluran spektral [2]. Tantangan utama dalam klasifikasi tutupan lahan di wilayah tropis adalah kompleksitas landscape yang tinggi, dengan gradasi tutupan vegetasi dan pola perubahan lahan yang dinamis.

Zhao et al., mengembangkan dataset OpenSARUrban menggunakan Sentinel-1 SAR mencakup 33.358 citra dari 21 kota di China, dengan 10 kategori tutupan lahan perkotaan. Evaluasi model VGG19 mencapai akurasi terbaik 89,49% [3]. Sementara itu, Hariyono et al., [4] menggunakan data LiDAR dengan algoritma SVM, dimana kombinasi fitur DSM, intensitas dan nDSM meningkatkan akurasi dari 55% menjadi 77,9%.

Indarto et al., [5] menggunakan NDVI dari Sentinel-2A untuk pemetaan lahan sub-optimal di Situbondo dengan akurasi 66.9% dan nilai kappa 61.6%, sementara penelitian Nadzirah, Rizqon, dan Indarto [6] melakukan klasifikasi tutupan lahan di Jember dengan metode serupa yang mengidentifikasi lima kelas dengan akurasi 37.7% dan 39.9%. Penelitian-penelitian ini menunjukkan bahwa keberhasilan klasifikasi tutupan lahan bergantung pada pemilihan data, metode yang tepat, dan optimalisasi kombinasi fitur, di mana teknologi *machine learning* dan *deep learning* sebagai pendekatan modern memiliki potensi meningkatkan akurasi meski masih membutuhkan eksplorasi dan pengembangan lebih lanjut [7].

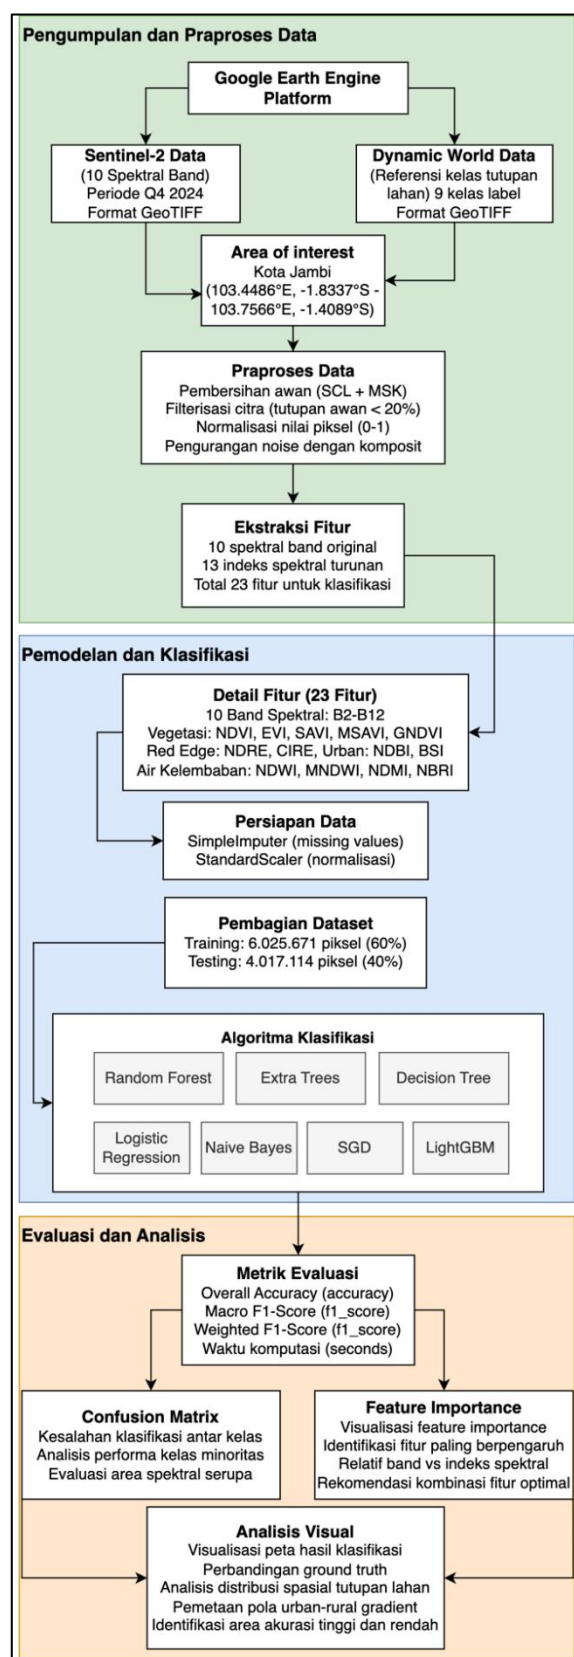
Jamali [8] telah melakukan evaluasi kinerja delapan algoritma *machine learning* dalam klasifikasi tutupan lahan menggunakan data Landsat8 OLI di wilayah utara Iran, sementara Baidy dan Rees [9] mengevaluasi lima algoritma serupa untuk kawasan perkotaan menggunakan data Sentinel-2. Kedua penelitian mengidentifikasi *Random Forest* sebagai algoritma dengan akurasi tertinggi. Namun, studi-studi ini belum menyelidiki algoritma berbasis pohon lainnya seperti *Decision Trees* dan *Extra Trees*. Perlu diteliti apakah algoritma berbasis pohon keputusan memberikan kinerja unggul untuk klasifikasi tutupan lahan di wilayah dengan karakteristik berbeda.

Kota Jambi merupakan lokasi strategis untuk penelitian klasifikasi tutupan lahan dengan beragam lanskap, meliputi hutan hujan tropis alami, perkebunan luas, lahan gambut kritis, dan kawasan perkotaan berkembang. Wilayah ini mengalami perubahan tutupan lahan intensif, khususnya konversi hutan menjadi perkebunan dan pemukiman. Perkembangan kota dan infrastruktur menciptakan pola tutupan lahan beragam, dengan pembangunan terintegrasi bersama area hijau dan pertanian. Kondisi ini membuka peluang pengujian teknik kategorisasi tutupan lahan yang lebih akurat dalam mendeteksi transformasi fungsi lahan di daerah perkotaan [10].

Penelitian ini bertujuan untuk mengevaluasi kinerja tujuh algoritma *machine learning* (*Random Forest*, *Extra Trees*, *Logistic Regression*, *Decision Tree*, *Naive Bayes*, *SGD Classifier*, dan *LightGBM*) dalam klasifikasi tutupan lahan di Jambi. Fokus penelitian meliputi: (1) perbandingan akurasi dan F1-score algoritma dalam identifikasi sembilan kelas tutupan lahan; (2) analisis pola kesalahan klasifikasi melalui confusion matrix; dan (3) identifikasi kontribusi relatif band dan indeks spektral melalui analisis feature importance. Kontribusi utama penelitian ini adalah analisis komprehensif algoritma menggunakan 23 fitur dari data Sentinel-2, yang meningkatkan pendekatan sebelumnya yang hanya menggunakan indeks vegetasi tunggal dengan akurasi 37.7%-66.9%. Hasil penelitian dapat memperbaiki sistem pemantauan tutupan lahan, untuk pengelolaan sumber daya dan perencanaan tata ruang di wilayah kompleks seperti Jambi.

## 2. Metode Penelitian

Penelitian ini mengadopsi pendekatan sistematis untuk klasifikasi tutupan lahan menggunakan integrasi teknologi penginderaan jauh dan machine learning.



Gambar 1. Tahapan Penelitian Klasifikasi Tutupan Lahan

Metodologi disusun dengan memanfaatkan kombinasi data citra satelit Sentinel-2 dan kelas referensi dari data *Dynamic World* seperti pada Gambar 1. Proses ini memungkinkan identifikasi sembilan kelas tutupan lahan berbeda melalui serangkaian tahapan yang meliputi pra-pemrosesan citra, ekstraksi fitur spektral, implementasi algoritma klasifikasi, dan validasi hasil.

### 2.1. Pemrosesan Awal Data

Langkah awal pemrosesan data melibatkan proses pembersihan secara menyeluruh terhadap tutupan awan menggunakan kombinasi *Scene Classification Layer* (SCL) dan band MSK untuk klasifikasi awan. Dalam tahap ini, sistem melakukan eliminasi terhadap piksel-piksel yang mengandung awan, bayangan awan, atau salju yang teridentifikasi melalui kode SCL 3, 8, dan 9, serta menghapus piksel yang mengalami kerusakan atau saturasi yang ditandai dengan kode SCL 1 dan 2. Pemrosesan dilanjutkan dengan seleksi ketat dimana piksel dengan probabilitas awan di atas 40% dikeluarkan dari dataset, dan hanya memproses citra yang memiliki total tutupan awan di bawah 20%.

Setelah pembersihan awan, data memasuki tahap standarisasi dengan melakukan pembagian setiap nilai piksel dengan konstanta 10000 sehingga menghasilkan nilai dalam rentang 0 hingga 1. Langkah berikutnya adalah reduksi *noise* melalui pembuatan citra komposit dengan pendekatan median pada koleksi citra yang telah dibersihkan. Sebagai bagian dari kontrol kualitas, dilakukan perhitungan nilai indeks vegetasi NDVI (*Normalized Difference Vegetation Index*) yang akan berfungsi sebagai parameter untuk menilai kualitas vegetasi dalam citra.

Dataset yang digunakan dalam penelitian ini terdiri dari 23 fitur yang diekstraksi dari data Sentinel-2. Fitur tersebut mencakup 10 band spektral (B2-B12) berupa Blue, Green, Red, Red Edge 1-4, NIR, dan SWIR 1-2 [11]. Selain itu, digunakan juga 13 indeks spektral yang diturunkan dari kombinasi band-band tersebut. Rincian karakteristik band spektral dan formula indeks spektral yang digunakan dapat dilihat pada Tabel 1 dan Tabel 2.

Tabel 1. Fitur Band Spektral

Nama Fitur	Deskripsi & Kegunaan
B2 (Blue)	Penetrasi air & aerosol
B3 (Green)	Reflektansi vegetasi hijau
B4 (Red)	Absorpsi klorofil
B5 (Red Edge 1)	Transisi red-NIR untuk vegetasi
B6 (Red Edge 2)	Indikator status vegetasi
B7 (Red Edge 3)	Transisi red-NIR untuk vegetasi
B8 (NIR)	Reflektansi vegetasi kuat
B8A (Red Edge 4)	Indikator biomassa
B11 (SWIR 1)	Kelembaban tanah/vegetasi
B12 (SWIR 2)	Kelembaban tanah/vegetasi

Indeks spektral mencakup indeks vegetasi dasar (NDVI, EVI, SAVI), indeks air (NDWI, MNDWI), indeks urban dan lahan terbuka (NDBI, BSI), indeks red edge (NDRE, CIRE), indeks vegetasi lanjutan (MSAVI, GNDVI), serta indeks kelembaban (NDMI, NBRI) [12]. Seluruh fitur hasil kalkulasi ini dapat dilihat pada Tabel 2, digunakan untuk mengoptimalkan hasil dari klasifikasi tutupan lahan. Band spektral dan indeks spektral yang digunakan secara bersamaan membuat model dapat mengenali karakteristik unik dari setiap kelas tutupan lahan dengan lebih baik.

Tabel 2. Fitur Indeks Spektral

Kategori	Nama	Rumus
Indeks Vegetasi Dasar	NDVI	$\frac{(NIR - Red)}{(NIR + Red)}$
	EVI	$\frac{2.5 \times (NIR - Red)}{(NIR + 6 \times Red - 7.5 \times Blue + 1)}$
	SAVI	$\frac{1.5 \times (NIR - Red)}{(NIR + Red + 0.5)}$
Indeks Air	NDWI	$\frac{(Green - NIR)}{(Green + NIR)}$
	MNDWI	$\frac{(Green - SWIR1)}{(Green + SWIR1)}$
Indeks Urban & Tanah	NDBI	$\frac{(SWIR1 - NIR)}{(SWIR1 + NIR)}$
	BSI	$\frac{((SWIR1 + Red) - (NIR + Blue))}{((SWIR1 + Red) + (NIR + Blue))}$
Indeks Red Edge	NDRE	$\frac{(NIR - RedEdge1)}{(NIR + RedEdge1)}$
	CIRE	$\frac{NIR}{RedEdge1} - 1$
Indeks Vegetasi Lanjutan	MSAVI	$\frac{2NIR + 1 - \sqrt{2NIR + 1 - 8NIR - Red}}{2}$
	GNDVI	$\frac{(NIR - Green)}{(NIR + Green)}$
Indeks Kelembaban	NDMI	$\frac{(NIR - SWIR1)}{(NIR + SWIR1)}$
	NBRI	$\frac{(NIR - SWIR2)}{(NIR + SWIR2)}$

### 2.2. Klasifikasi Tutupan Lahan

Tahapan klasifikasi dimulai dengan persiapan data menggunakan dua komponen penting: *SimpleImputer* untuk menangani nilai-nilai yang hilang (*missing values*) dalam dataset dan *StandardScaler* untuk melakukan normalisasi data. *SimpleImputer* secara otomatis mengisi nilai yang hilang dengan statistik dari data yang telah tersedia, sedangkan *StandardScaler* melakukan transformasi data sehingga memiliki rata-rata 0 dan deviasi standar 1, yang dapat membantu algoritma machine learning bekerja secara optimal.

Dataset kemudian dibagi menjadi dua bagian: 6.025.671 piksel (60%) untuk data *training* dan 4.017.114 piksel (40%) untuk data *testing*. Pembagian

ini memastikan model dapat dilatih dengan jumlah data yang memadai serta diuji pada data independen untuk mengevaluasi generalisasi model.

Parameter utama pada *function* yang digunakan algoritma klasifikasi dapat dilihat pada Tabel 3. Parameter yang digunakan pada setiap algoritma dipilih berdasarkan pertimbangan penting dan serangkaian uji coba awal. *Random Forest* dan *Extra Trees* memilih  $n\_estimators=200$  dan  $max\_depth=25$  guna mencapai keseimbangan antara kompleksitas model dan performa klasifikasi [13], dimana jumlah pohon yang cukup banyak memungkinkan model menangkap pola kompleks dalam data tutupan lahan. Nilai  $n\_estimators=200$  dipilih berdasarkan studi empiris yang menunjukkan bahwa performa klasifikasi pada data Sentinel-2 cenderung stabil setelah 150-200 pohon [14]. Opsi  $class\_weight='balanced'$  diterapkan dalam mengatasi ketidakseimbangan jumlah sampel antar kelas tutupan lahan, terutama untuk kelas minoritas seperti *Snow & ice* yang hanya memiliki jumlah sampel terbatas.

Tabel 3. Parameter Utama Algoritma Klasifikasi

Algoritma	Parameter Utama
<i>Random Forest</i> [13][14]	$n\_estimators=200, max\_depth=25, class\_weight='balanced'$
<i>Extra Trees</i> [15]	$n\_estimators=200, max\_depth=25, class\_weight='balanced'$
<i>Logistic Regression</i> [16]	$multi\_class='multinomial', max\_iter=500, class\_weight='balanced'$
<i>Decision Tree</i> [17]	$max\_depth=15, class\_weight='balanced'$
<i>Naive Bayes</i> [18]	$priors=None, var\_smoothing=1e-9$
<i>SGD Classifier</i> [19]	$loss='modified\_huber', max\_iter=1000, penalty='l2'$
<i>LightGBM</i> [20]	$n\_estimators=100, learning\_rate=0.1, max\_depth=15$

Algoritma *Logistic Regression* mengadopsi parameter  $multi\_class='multinomial'$  karena kesesuaiannya dalam klasifikasi dengan lebih dari dua kelas, sementara  $max\_iter=500$  memberikan kesempatan yang cukup bagi model untuk mencapai konvergensi. Penelitian sebelumnya menunjukkan bahwa nilai *default* (100) sering tidak mencukupi untuk konvergensi pada data penginderaan jauh [15]. *Decision Tree* memanfaatkan  $max\_depth=15$  dalam mencegah *overfitting* sambil tetap mempertahankan kemampuan model menangkap pola data yang kompleks. *Naive Bayes* menggunakan pengaturan  $priors=None$  yang memungkinkan model mempelajari probabilitas prior secara langsung dari data pelatihan, sementara nilai  $var\_smoothing=1e-9$  menyediakan stabilitas numerik untuk mengatasi masalah *zero-frequency* yang umum terjadi pada distribusi band spektral dengan rentang nilai luas [17]. *SGD Classifier* dengan  $loss='modified\_huber'$  dipilih karena kesesuaiannya dalam klasifikasi multi-kelas dengan data yang tidak seimbang, dimana fungsi

kerugian ini memberikan ketahanan yang lebih baik terhadap outlier spektral. *LightGBM* menggunakan  $learning\_rate$  yang relatif kecil (0.1), agar dapat meningkatkan stabilitas proses pembelajaran pada dataset heterogen, sementara nilai  $max\_depth=15$  menyeimbangkan antara kemampuan model untuk menangkap kompleksitas spasial dan risiko *overfitting*.

Data input untuk klasifikasi terdiri dari 23 fitur yang mencakup 10 band spektral Sentinel-2 (B2-B12) dan 13 indeks spektral. Total dataset yang digunakan adalah 10,042,785 piksel, dengan pembagian 6,025,671 piksel (60%) untuk data training dan 4,017,114 piksel (40%) untuk data testing. *Stratified sampling* digunakan untuk mempertahankan distribusi kelas seimbang antara *training* dan *testing*.

### 2.3 Evaluasi Performa

Evaluasi performa klasifikasi dilakukan menggunakan beberapa metrik utama yaitu *overall accuracy* untuk mengukur rasio prediksi benar terhadap total sampel, *macro F1-score* yang menghitung rata-rata *F1-Score* untuk semua kelas dengan bobot sama, serta *weighted F1-score* yang memberikan pembobotan berdasarkan jumlah sampel untuk setiap kelas. Pendekatan ini dipilih mengingat karakteristik dataset yang digunakan tidak seimbang antar kelasnya.

Analisis visual dilakukan dengan membandingkan peta hasil klasifikasi dari setiap algoritma dengan *ground truth* dari *Dynamic World*. *Confusion matrix* digunakan untuk mengidentifikasi pola kesalahan klasifikasi spesifik untuk setiap kelas tutupan lahan seperti Gambar 2. Evaluasi juga mencakup analisis waktu komputasi untuk menilai efisiensi masing-masing algoritma, serta analisis *feature importance* untuk *Random Forest* guna memahami kontribusi relatif setiap fitur dalam proses klasifikasi.


## 3. Hasil dan Pembahasan

### 3.1. Pemrosesan Awal Data

Pada penelitian ini, data dikumpulkan menggunakan platform *Google Earth Engine* untuk mengekstrak citra Sentinel-2 dan klasifikasi tutupan lahan *Dynamic World* di area Provinsi Jambi (koordinat pilihan 103.4486°E, -1.8337°S hingga 103.7566°E, -1.4089°S) selama periode Q4 2024 (Oktober-Desember). Hasil pengolahan data pada Gambar 2 menunjukkan berbagai representasi dan analisis tutupan lahan di wilayah Jambi. Visualisasi ini menampilkan citra *natural color*, komposit warna palsu, kombinasi indeks spektral, dan kelas referensi tutupan lahan *Dynamic World*.

Pada citra Sentinel-2 terlihat pola meander sungai yang melintasi area studi, dengan kawasan urban ditandai oleh patch keabu-abuan di bagian tengah. Hasil dari klasifikasi *Dynamic World* mengidentifikasi beberapa kelas tutupan lahan dominan: kawasan terbangun (merah) yang terpusat di tengah wilayah, area pohon/hutan (hijau tua) yang mendominasi *landscape*, jalur badan air (biru) yang menggambarkan alur sungai,

serta zona pertanian (kuning) dan berbagai tipe vegetasi seperti semak dan rumput yang terdistribusi di sejumlah lokasi.



Gambar 2. Visualisasi data Sentinel-2 dan klasifikasi tutupan lahan: (a) RGB natural color, (b) Komposit warna palsu NIR-Red-Green, (c) Komposit indeks spektral NDBI-NDVI-NDWI, (d) Kelas referensi tutupan lahan Dynamic World.

### 3.2. Klasifikasi Tutupan Lahan

Hasil perbandingan berbagai model *machine learning* yang diuji, dapat dilihat pada Tabel 4. *Random Forest* memiliki performa terbaik dengan *overall accuracy* 85.91% dan *Macro F1-Score* 44.43% (tertinggi kedua setelah *Extra Trees* 45.95%). Model ini juga mencapai *Weight F1-Score* tertinggi sebesar 85.48%. Hasil ini menunjukkan kemampuan menyeimbangkan presisi dan *recall* pada dataset.

*Extra Trees* memberikan performa yang hampir serupa dengan *Random Forest* yaitu mencapai *overall accuracy* 84.45% dan *Macro F1-Score* tertinggi 45.95%, namun dengan *Weight F1-Score* yang sedikit lebih rendah yaitu 84.85%. Meskipun *classifier SGD Classifier* mencatatkan *overall accuracy* tertinggi sebesar 85.95%, model ini memiliki *Macro F1-Score* yang jauh lebih rendah yaitu 35.35%. Hal ini menunjukkan ketidakseimbangan model dalam mengklasifikasikan kelas-kelas minoritas.

Dalam hal waktu komputasi *training*, *Random Forest* memerlukan 234 detik yang lebih lama dibanding *Decision Tree* (64 detik) dan *Logistic Regression* (77 detik), namun performa yang dihasilkan menunjukkan *trade-off* yang sepadan.

Tabel 4. Hasil Klasifikasi dengan 7 Algoritma

	Overall Accuracy	Macro F1	Weight F1	Time
<i>Random Forest</i>	85.91	44.43	85.48	234
<i>Extra Trees</i>	84.45	45.95	84.85	222
<i>Logistic Regression</i>	72.13	38.95	77.86	77
<i>Decision Tree</i>	74.53	37.40	78.10	64
<i>Naive Bayes</i>	72.97	32.56	77.05	71
<i>SGD Classifier</i>	85.95	35.35	83.83	64
<i>LightGBM</i>	80.73	33.88	80.92	340

Model klasifikasi tradisional *Logistic Regression* dan *Naive Bayes* memperlihatkan performa lebih rendah di semua metrik, dengan *overall accuracy* masing-masing 72.13% dan 72.97%. *LightGBM* menghabiskan waktu komputasi terlama (340 detik), tetapi hanya mencapai *overall accuracy* 80.73% dengan *Macro F1-Score* relatif rendah (33.88%). Secara keseluruhan, model *Random Forest* dapat memberikan keseimbangan terbaik antara akurasi, kemampuan klasifikasi kelas minoritas, dan efisiensi komputasi.

### 3.3. Evaluasi Performa

Berdasarkan analisis confusion matrix hasil klasifikasi *Random Forest*, model menunjukkan variasi performa yang signifikan antar kelas tutupan lahan. Tabel 5 menampilkan kesalahan klasifikasi signifikan yang teridentifikasi dari model *Random Forest*.

Tabel 5. Kesalahan Klasifikasi Signifikan pada Model Terbaik


Kelas Sebenarnya	Kelas Prediksi	Jumlah Pikel	Persentase Kesalahan
<i>Trees</i>	<i>Shrub &amp; scrub</i>	73,326	2.58
<i>Trees</i>	<i>Built area</i>	65,381	2.3
<i>Built area</i>	<i>Trees</i>	75,728	20.16
<i>Water</i>	<i>Trees</i>	39,933	41.49
<i>Shrub &amp; scrub</i>	<i>Trees</i>	38,233	43.90
<i>Shrub &amp; scrub</i>	<i>Crops</i>	31,748	36.46
<i>Grass</i>	<i>Trees</i>	27,157	96.40
<i>Crops</i>	<i>Shrub &amp; scrub</i>	14,616	59.61
<i>Snow &amp; ice</i>	<i>Water</i>	202	93.09

Analisis *confusion matrix* mengungkapkan pola kesalahan klasifikasi yang signifikan pada beberapa kelas referensi tutupan lahan. Kelas-kelas yang paling bermasalah dapat dikelompokkan menjadi dua kategori utama: kelas minoritas dan pasangan kelas dengan karakteristik spektral serupa. Dalam kelompok kelas minoritas, *Snow & ice*, *Grass*, dan *Flooded vegetation* menunjukkan performa klasifikasi yang sangat rendah dengan akurasi di bawah 20%. Dari 15 piksel *Snow & ice* yang teridentifikasi dengan benar, 202 piksel salah diklasifikasi sebagai *Water*, menunjukkan tumpang tindih karakteristik spektral kedua kelas ini. Kelas

Grass hanya mencapai akurasi 1,011 piksel (2.1%) dari total 48,620 piksel, dengan kesalahan terbesar berupa misklasifikasi sebagai *Trees* (27,157 piksel) dan *Shrub & scrub* (14,650 piksel).

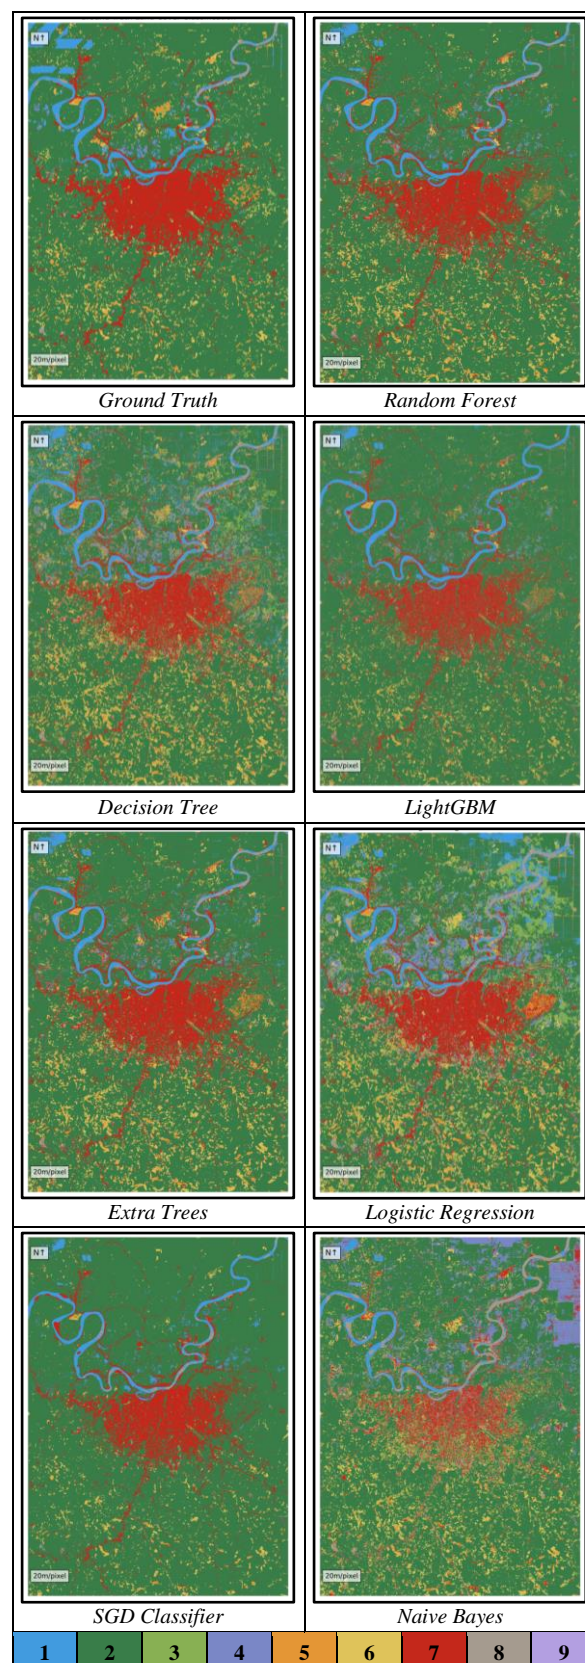
Kesalahan klasifikasi terbesar terjadi antara kelas-kelas yang memiliki karakteristik spektral mirip. Antara *Trees* dan *Shrub & scrub* terdapat kesalahan klasifikasi timbal balik yang tinggi: 73,326 piksel *Trees* (2.5% dari total kelas *Trees*) salah diidentifikasi sebagai *Shrub & scrub*, sedangkan 38,233 piksel *Shrub & scrub* (43.9% dari total kelas) salah diidentifikasi sebagai *Trees*. Hasil prediksi yang salah menunjukkan sulitnya membedakan jenis vegetasi yang berbeda hanya berdasarkan data spektral Sentinel-2. Kesalahan serupa juga terjadi antara *Trees* dan *Built area*, dimana 65,381 piksel *Built area* (17.4%) salah diidentifikasi sebagai *Trees*, dan sebaliknya 75,728 piksel *Trees* (2.7%) salah diidentifikasi sebagai *Built area*. Kesalahan ini sering terjadi pada daerah perbatasan kota dan vegetasi, menunjukkan perlunya pendekatan lebih baik untuk membedakan area perkotaan yang memiliki vegetasi dan area vegetasi yang berada di dekat pemukiman.

*Water* dan *Trees* juga menunjukkan tingkat kesalahan timbal balik yang tinggi, dengan 39,933 piksel *Water* (41.5%) salah diklasifikasi sebagai *Trees*. Kesalahan ini umumnya terjadi di sepanjang badan air yang memiliki vegetasi riparian, di mana reflektansi kombinasi antara vegetasi dan air menciptakan sinyal campuran yang sulit diinterpretasi oleh model. Secara keseluruhan, model Random Forest cukup efektif mengklasifikasikan kelas-kelas dominan, dengan akurasi tinggi untuk *Trees* (2,842,519 piksel atau 94.4%) dan *Built area* (375,721 piksel atau 77.3%), namun masih menghadapi tantangan besar dalam membedakan kelas dengan karakteristik spektral serupa dan kelas minoritas.



Gambar 3. Feature Importance dari hasil klasifikasi Random Forest Analisis feature importance dari model Random Forest pada Gambar 3 menunjukkan band B12 (SWIR 2)

memiliki kontribusi tertinggi (0.069), diikuti oleh B4 (Red) (0.063), dan NBRI (0.057).



Gambar 4. Perbandingan Ground Truth dan hasil prediksi klasifikasi tutupan lahan masing-masing algoritma. (1) *Water*, (2) *Trees*, (3) *Grass*, (4) *Flooded vegetation*, (5) *Crops*, (6) *Shrub and scrub*, (7) *Built area*, (8) *Bare ground*, (9) *Snow and ice*

Dominasi band SWIR 2 mengindikasikan pentingnya informasi kelembaban dan karakteristik material permukaan dalam membedakan tutupan lahan.

Band-band spektral asli (B12, B4, B11, B2, B5, B3) secara konsisten menunjukkan kontribusi yang lebih tinggi dibandingkan indeks-indeks spektral turunan. NBRI dan MNDWI memberikan kontribusi signifikan (0.057 dan 0.054) dalam membedakan area terbakar dan badan air.

Sementara itu, indeks NDVI memiliki kontribusi menengah (0.047) dan band red edge menunjukkan kontribusi relatif rendah, mengindikasikan bahwa kompleksitas landscape di Kota Jambi lebih efektif diidentifikasi menggunakan kombinasi band SWIR dan visible dibandingkan band-band vegetasi spesifik.

Jika melihat hasil visualisasi peta pada Gambar 4, Algoritma berbasis pohon keputusan seperti *Decision Tree*, *Extra Trees*, *Random Forest*, dan *LightGBM* menunjukkan performa yang mengesankan dengan menghasilkan peta klasifikasi yang sangat mirip *ground truth*, terutama dalam melakukan deteksi area perkotaan di bagian tengah peta. Badan air yang melintasi wilayah studi juga terdeteksi dengan akurat, menunjukkan kemampuan algoritma sangat baik dalam membedakan fitur landscape yang memiliki ciri khas yang terlihat secara kasat mata.

*Logistic Regression* dan *SGD Classifier* menempati posisi menengah dalam hal akurasi. Kedua algoritma ini berhasil menangkap pola umum tutupan lahan dengan cukup baik, namun masih menunjukkan beberapa perbedaan signifikan dibandingkan dengan data referensi dari *ground truth*. *Logistic Regression* mengklasifikasikan terlalu banyak (*over confidence*) area sebagai vegetasi tergenang (warna ungu/biru muda) di sekitar sungai, sedangkan *SGD Classifier* cenderung dapat mengidentifikasi lebih sedikit area perkotaan (warna merah) dari yang seharusnya.

Beberapa area yang seharusnya teridentifikasi sebagai lahan terbangun justru diklasifikasikan sebagai vegetasi oleh algoritma ini. Gaussian Naive Bayes (GaussianNB) menghasilkan hasil yang paling berbeda dibanding algoritma lain. Meskipun masih dapat mendeteksi fitur utama seperti badan air dan area perkotaan, algoritma ini menunjukkan over-detection yang signifikan untuk kelas vegetasi tergenang, ditandai dominasi warna ungu dibanding *ground truth*. Hal ini mengindikasikan bahwa asumsi independensi dalam algoritma Naive Bayes mungkin kurang sesuai untuk kompleksitas pola spasial dalam klasifikasi tutupan lahan. Pola urban-rural gradient terlihat jelas dalam hasil klasifikasi, dengan konsentrasi area terbangun (merah) di pusat yang berangsur berubah menjadi vegetasi (hijau) dan area pertanian (kuning) di wilayah perifer. Badan air yang berkelok melintasi wilayah studi menjadi fitur yang konsisten terdeteksi baik oleh semua algoritma, menunjukkan karakteristik spektral air yang mudah diklasifikasi. Hasil temuan ini mengkonfirmasi bahwa algoritma berbasis pohon

keputusan unggul dalam klasifikasi tutupan lahan karena kemampuannya menangkap pola kompleks dari data spasial, dan menekankan pentingnya pemilihan algoritma yang tepat untuk aplikasi penginderaan jauh.

#### 4. Kesimpulan

Studi klasifikasi tutupan lahan di Jambi menggunakan data Sentinel-2 dan *Dynamic World* telah berhasil membandingkan tujuh algoritma *machine learning* dalam mengklasifikasikan sembilan kelas tutupan lahan. Hasil evaluasi menunjukkan bahwa model *Random Forest* memberikan performa terbaik dengan pencapaian *overall accuracy* 85.91% dan *Weight F1-Score* 85.48%, diikuti oleh *Extra Trees* dengan akurasi 84.45%. Analisis *confusion matrix* mengungkapkan pola kesalahan klasifikasi terutama terjadi antara kelas dengan karakteristik spektral serupa, di mana *Trees* sering terklasifikasi sebagai *Shrub & scrub* (73.326 piksel) dan *Built area* (65.381 piksel). Temuan ini menunjukkan peningkatan nilai substansial dibanding penelitian sebelumnya yang hanya mencapai akurasi 37.7%-66.9%. Analisis *feature importance* pada model *Random Forest* mengungkapkan bahwa band B12 (SWIR 2) memiliki pengaruh terkuat dalam klasifikasi dengan nilai kepentingan 0.069, diikuti oleh band B4 (Red) sebesar 0.063 dan indeks NBRI (Normalized Burn Ratio Index) sebesar 0.057.

Hasil klasifikasi dapat diaplikasikan langsung untuk perencanaan tata ruang dan monitoring lingkungan di daerah Jambi. Kemampuan algoritma berbasis pohon keputusan dalam mendeteksi pola urban-rural gradient dengan performa baik (375.721 piksel area terbangun terklasifikasi dengan benar) menyediakan dasar kuat untuk pemantauan ekspansi perkotaan dan konversi lahan. Pemahaman tentang kesulitan klasifikasi pada kelas tutupan lahan yang jarang muncul memberikan landasan penting untuk strategi konservasi ekosistem yang relatif lebih sensitif terhadap perubahan.

Penelitian selanjutnya kami rekomendasikan beberapa arah strategis: (1) implementasi teknik resampling adaptif untuk mengatasi ketidakseimbangan kelas minoritas; (2) pengintegrasian data DEM dan SAR sebagai fitur komplementer guna meningkatkan diferensiasi kelas vegetasi dengan karakteristik spektral mirip, terutama *Trees* dan *Shrub* yang mengalami konfusi klasifikasi 73.326 piksel; (3) pengembangan model klasifikasi berbasis deret waktu untuk mengkapitalisasi variasi temporal tutupan lahan; dan (4) eksplorasi arsitektur deep learning bagi ekstraksi fitur spasial yang lebih kompleks.

Kontribusi utama penelitian ini adalah bukti empiris keunggulan algoritma berbasis pohon keputusan secara signifikan dalam klasifikasi tutupan lahan di wilayah tropis heterogen, serta pemahaman bahwa band SWIR 2 dan Red jauh lebih informatif dibanding indeks vegetasi tradisional. Temuan ini menyediakan landasan metodologis untuk pengembangan sistem klasifikasi tutupan lahan yang lebih akurat dan efisien di Indonesia dan wilayah tropis lainnya.

## Daftar Rujukan

- [1] A. A. Nasution, A. M. Muslih, U. H. Ar-Rasyid, and A. Anhar, "Land cover classification using Landsat 8 OLI in West Langsa Sub district, Langsa City," in *IOP Conference Series: Earth and Environmental Science*, IOP Publishing Ltd, Jan. 2022. doi: 10.1088/1755-1315/951/1/012080.
- [2] T. Hermosilla, M. A. Wulder, J. C. White, and N. C. Coops, "Land cover classification in an era of big and open data: Optimizing localized implementation and training data selection to improve mapping outcomes," *Remote Sens Environ*, vol. 268, Jan. 2022, doi: 10.1016/j.rse.2021.112780.
- [3] J. Zhao, Z. Zhang, W. Yao, M. Dacu, H. Xiong, and W. Yu, "OpenSARUrban: A Sentinel-1 SAR Image Dataset for Urban Interpretation," *IEEE J Sel Top Appl Earth Obs Remote Sens*, vol. 13, pp. 187–203, 2020, doi: 10.1109/JSTARS.2019.2954850.
- [4] M. I. Hariyono, Rokhmatuloh, M. P. Tambunan, and R. S. Dewi, "Support Vector Machine for Land Cover Classification using Lidar Data," in *IOP Conference Series: Earth and Environmental Science*, IOP Publishing Ltd, Nov. 2021. doi: 10.1088/1755-1315/873/1/012095.
- [5] Indarto, R. Nadzirah, and H. Reksa Belagama, "Pemetaan Lahan Sub-Optimal Berbasis Nilai NDVI Sentinel 2a: Studi Pendahuluan," *Jurnal Presipitasi*, vol. 17, no. 3, pp. 194–205, 2020, doi: 10.14710/presipitasi.v17i3.194-204.
- [6] R. Nadzirah, M. K. Rizqon, and I. Indarto, "Application of Sentinel-2A Images for Land Cover Classification Using NDVI in Jember Regency," *Geosfera Indonesia*, vol. 9, no. 1, p. 41, Apr. 2024, doi: 10.19184/geosi.v9i1.28846.
- [7] S. Swetanisha, A. R. Panda, and D. K. Behera, "Land use/land cover classification using machine learning models," *International Journal of Electrical and Computer Engineering*, vol. 12, no. 2, pp. 2040–2046, Apr. 2022, doi: 10.11591/ijece.v12i2.pp2040-2046.
- [8] A. Jamali, "Evaluation and comparison of eight machine learning models in land use/land cover mapping using Landsat 8 OLI: a case study of the northern region of Iran," *SN Appl Sci*, vol. 1, no. 11, Nov. 2019, doi: 10.1007/s42452-019-1527-8.
- [9] L. Hebryn-Baidy and G. Rees, "Machine Learning Algorithms Evaluated for Urban Land Use and Land Cover Classification Using Sentinel 2 Data," 2024.
- [10] R. F. Maruddani, L. Somantri, and F. Panjaitan, "ANALISIS SPASIAL PERUBAHAN TUTUPAN LAHAN PASCA KEBAKARAN HUTAN DAN LAHAN DI KABUPATEN MUARO JAMBI," *Jurnal Tanah dan Sumberdaya Lahan*, vol. 11, no. 2, pp. 443–453, Jul. 2024, doi: 10.21776/ub.jtsl.2024.011.2.15.
- [11] Y. Heryadi and E. Miranda, "Land cover classification based on sentinel-2 satellite imagery using convolutional neural network model: A case study in Semarang Area, Indonesia," in *Studies in Computational Intelligence*, vol. 830, Springer Verlag, 2020, pp. 191–206. doi: 10.1007/978-3-030-14132-5\_15.
- [12] X. Yan, J. Li, A. R. Smith, D. Yang, T. Ma, and Y. Su, "Rapid Land Cover Classification Using a 36-Year Time Series of Multi-Source Remote Sensing Data," *Land (Basel)*, vol. 12, no. 12, Dec. 2023, doi: 10.3390/land12122149.
- [13] X. Fu, Y. Chen, J. Yan, Y. Chen, and F. Xu, "BGRF: A broad granular random forest algorithm," *J. Intell. Fuzzy Syst.*, vol. 44, no. 5, pp. 8103–8117, Jan. 2023, doi: 10.3233/JIFS-223960.
- [14] F. E. Penalun, A. Hermawan, and D. Avianto, "Perbandingan Random Forest Regression dan Support Vector Regression Pada Prediksi Laju Penguapan," *Jurnal FASILKOM*, vol. 13, no. 2, pp. 104–111, Aug. 2023, doi: 10.37859/jf.v13i02.4976.
- [15] Y. O. Daddala and K. Shaik, "Cardiovascular Disease Prediction: Employing Extra Tree Classifier-Based Feature Selection and Optimized RNN with Artificial Bee Colony," *Revue d'Intelligence Artificielle*, vol. 38, no. 2, pp. 643–653, Apr. 2024, doi: 10.18280/ria.380228.
- [16] A. Strzelecka, A. KurdyS-Kujawska, and D. Zawadzka, "Application of logistic regression models to assess household financial decisions regarding debt," in *Procedia Computer Science*, Elsevier B.V., 2020, pp. 3418–3427. doi: 10.1016/j.procs.2020.09.055.
- [17] I. D. Mienye and N. Jere, "A Survey of Decision Trees: Concepts, Algorithms, and Applications," *IEEE Access*, vol. 12, pp. 86716–86727, 2024, doi: 10.1109/ACCESS.2024.3416838.
- [18] A. Musthafa, D. Muriyatmoko, S. Kamal Sholihin, P. Studi Teknik Informatika, F. Sains dan Teknologi, and U. Darussalam Gontor, "Deteksi Berita Salah Pada Pemilihan Umum Presiden 2024 Menggunakan Metode Naive Bayes Berbasis Website," *Jurnal FASILKOM*, vol. 14, no. 2, Aug. 2024, doi: https://doi.org/10.37859/jf.v14i2.7110.
- [19] F. T. Admojo and Y. I. Sulistyia, "Analisis performa algoritma Stochastic Gradient Descent (SGD) dalam mengklasifikasi tahu berformalin," *Indonesian Journal of Data and Science (IJODAS)*, vol. 3, no. 1, 2022.
- [20] S. Li, N. Jin, A. Dogani, Y. Yang, M. Zhang, and X. Gu, "Enhancing LightGBM for Industrial Fault Warning: An Innovative Hybrid Algorithm," *Processes*, vol. 12, no. 1, Jan. 2024, doi: 10.3390/pr12010221.