

## Prediksi Perubahan Tutupan Lahan di Kabupaten Bogor Tahun 2026 Menggunakan *Random Forest* dengan Citra Satelit Sentinel-2 Terklasifikasi

### *Land Cover Change Prediction in Bogor Regency in 2026 Using Random Forest with Classified Sentinel-2 Satellite Imagery*

Muhammad Syaifur Rohman,<sup>1\*</sup> Afrinaldi,<sup>1</sup> Ahmad Syauqani,<sup>1</sup> Maya Safira<sup>1</sup>

<sup>1</sup> Institut Teknologi Bandung, Jl. Ganesa No.10, Kota Bandung, Indonesia

\*Corresponding Author: 25423066@mahasiswa.itb.ac.id

Submitted: December 9, 2024 | Accepted: March 24, 2025 | Published: May 2, 2025

**Abstract:** Bogor Regency has experienced significant land cover changes due to urbanization, population growth, and infrastructure expansion. This study predicts land cover changes in 2026 using a random forest model based on classified Sentinel-2 satellite imagery. The model was trained with data from 2017, 2020, and 2023 and evaluated using 2-fold time-series cross-validation, with an accuracy of 87.96%, Kappa 0.8131, and F1-Score 0.8752. The prediction results show an increase in built-up area from 748.02 km<sup>2</sup> (2017) to 953.89 km<sup>2</sup> (2023) and is estimated to reach 976.84 km<sup>2</sup> in 2026—especially in Pamijahan and Jonggol. On the other hand, agricultural areas decreased from 652.53 km<sup>2</sup> to 541.11 km<sup>2</sup> and are predicted to decrease again to 530.33 km<sup>2</sup>, threatening local food security. Tree cover areas also decreased from 1,509.12 km<sup>2</sup> (2017) to 1,385.34 km<sup>2</sup> (2023) but are expected to increase to 1,413.42 km<sup>2</sup> in 2026 due to the reforestation program. These findings emphasize the importance of sustainable land planning to balance development with environmental conservation for the sustainability of the ecosystem and the welfare of the Bogor community.

**Keywords:** Land Cover, Random Forest, Urbanization, Sentinel-2, Land Planning

**Abstrak:** Kabupaten Bogor mengalami perubahan tutupan lahan yang signifikan akibat urbanisasi, pertumbuhan penduduk, dan ekspansi infrastruktur. Penelitian ini memprediksi perubahan tutupan lahan tahun 2026 menggunakan model *Random Forest* berbasis citra satelit Sentinel-2 yang telah diklasifikasi. Model dilatih dengan data tahun 2017, 2020, dan 2023, serta dievaluasi menggunakan *2-fold time-series cross-validation*, dengan akurasi 87,96%, Kappa 0,8131, dan F1-Score 0,8752. Hasil prediksi menunjukkan peningkatan area terbangun dari 748,02 km<sup>2</sup> (2017) menjadi 953,89 km<sup>2</sup> (2023), dan diperkirakan mencapai 976,84 km<sup>2</sup> pada 2026—terutama di Pamijahan dan Jonggol. Sebaliknya, area pertanian menurun dari 652,53 km<sup>2</sup> menjadi 541,11 km<sup>2</sup>, dan diprediksi turun lagi menjadi 530,33 km<sup>2</sup>, mengancam ketahanan pangan lokal. Area tutupan pohon juga menurun dari 1.509,12 km<sup>2</sup> (2017) ke 1.385,34 km<sup>2</sup> (2023), namun diperkirakan meningkat menjadi 1.413,42 km<sup>2</sup> pada 2026 karena program reboisasi. Temuan ini menegaskan pentingnya perencanaan lahan berkelanjutan untuk menyeimbangkan pembangunan dengan pelestarian lingkungan, demi keberlanjutan ekosistem dan kesejahteraan masyarakat Bogor.

**Kata Kunci:** Tutupan Lahan, *Random Forest*, Urbanisasi, Sentinel-2, Perencanaan Lahan



## Pendahuluan

Perubahan tutupan lahan yang pesat di Kabupaten Bogor ini menimbulkan serangkaian dampak negatif, baik dari segi lingkungan maupun sosial-ekonomi. Dari sisi lingkungan, konversi lahan pertanian dan hutan menjadi permukiman dan industri menyebabkan hilangnya lahan produktif (Jaya et al., 2021; Virtriana et al., 2024), meningkatkan risiko degradasi lingkungan seperti erosi tanah, banjir, dan kekeringan (Asyari, et al., 2024; et al., 2018), serta menurunkan kualitas air dan udara (Iqtashada & Febrita, 2023; Virtriana et al., 2024). Kehilangan tutupan vegetasi alami juga mengancam keanekaragaman hayati Kabupaten Bogor yang kaya (Jaya et al., 2021), serta mengurangi kemampuan wilayah dalam menyerap karbon dan mengatur iklim mikro (Yuan et al., 2021). Selain dampak lingkungan, perubahan tutupan lahan juga memberikan tekanan pada sektor pertanian, mengancam ketahanan pangan daerah dan pendapatan petani (Jaya et al., 2021; Monsaputra, 2023; Nabila, 2023). Berkurangnya lahan pertanian dapat menurunkan produksi pertanian lokal, meningkatkan ketergantungan pada pasokan dari luar daerah, dan berpotensi meningkatkan kerentanan ekonomi petani kecil. Lebih lanjut, perubahan ini dapat memicu konflik pemanfaatan lahan, ketimpangan pembangunan (Asyari, et al., 2024), dan mengurangi kualitas hidup masyarakat akibat hilangnya ruang terbuka hijau dan lingkungan yang sehat. Dampak-dampak negatif ini, jika tidak dikelola dengan baik, dapat mengancam keberlanjutan pembangunan dan kesejahteraan masyarakat Kabupaten Bogor di masa depan.

Untuk memberikan pemahaman yang jelas mengenai urgensi analisis dan prediksi, penting untuk terlebih dahulu mendefinisikan hubungan antara beberapa istilah kunci yang digunakan dalam penelitian ini, yaitu tata guna lahan, tutupan lahan, perubahan tutupan lahan, serta konsep *Land Use and Land Cover* (LULC). Tutupan lahan (*land cover*) merujuk pada penampakan fisik permukaan bumi, seperti vegetasi, air, lahan terbangun, tanah kosong, dan lain-lain (Mariati et al., 2022). Inilah yang menjadi fokus utama dalam penelitian ini. Sementara itu, tata guna lahan (*land use*) mengacu pada bagaimana manusia memanfaatkan lahan untuk berbagai aktivitas sosial dan ekonomi, seperti pertanian, pemukiman, industri, dan rekreasi (Arifin, 2018). Tata guna lahan mencerminkan fungsi dan tujuan lahan tersebut dalam konteks aktivitas manusia.

Konsep LULC menekankan keterkaitan antara tutupan dan tata guna lahan. Meskipun dalam konteks penginderaan jauh istilah LULC sering disamakan dengan tutupan lahan, penting untuk memahami bahwa klasifikasi LULC sebenarnya mencoba menyimpulkan tata guna lahan berdasarkan pola tutupan lahan yang teramati (Aryastana et al., 2023). Perubahan tutupan lahan mengacu pada transformasi kondisi fisik permukaan bumi dari waktu ke waktu. Perubahan ini sering kali dipicu oleh perubahan tata guna lahan akibat aktivitas manusia, dan menjadi elemen krusial dalam memahami dinamika pemanfaatan ruang serta mendukung perencanaan tata ruang yang efektif (Sachro et al., 2017). Dalam konteks Indonesia, perubahan tutupan lahan erat kaitannya dengan konsep Alih Fungsi Lahan, yaitu perubahan dari lahan pertanian menjadi penggunaan lain seperti permukiman atau industri. Istilah ini

sangat relevan dalam kebijakan tata ruang, terutama terkait perlindungan lahan pertanian berkelanjutan seperti diamanatkan dalam UU No. 41 Tahun 2009.

Menyadari dampak negatif perubahan tutupan lahan di Kabupaten Bogor, analisis mendalam dan prediksi perubahan lahan menjadi mendesak. Informasi mengenai potensi perubahan lahan di masa depan sangat penting bagi pemerintah dan pemangku kepentingan dalam merumuskan kebijakan dan strategi pengelolaan lahan yang berkelanjutan. Tanpa prediksi akurat, perencanaan tata ruang dan pengelolaan lingkungan akan cenderung reaktif. Metode tradisional seperti regresi linier seringkali tidak mampu menangkap hubungan kompleks dan non-linear antar faktor pendorong perubahan lahan, menghasilkan prediksi yang kurang akurat (Saha et al., 2020). Sebagai alternatif, metode *machine learning* seperti *Random Forest* menunjukkan potensi besar dalam menangani data yang kompleks dan memberikan prediksi dengan akurasi lebih tinggi (Liu et al., 2021; Pham et al., 2024). Namun, implementasi metode ini di Kabupaten Bogor masih minim, begitu pula dengan pemanfaatan citra satelit resolusi tinggi seperti Sentinel-2.

Penelitian ini bertujuan untuk mengisi kesenjangan tersebut dengan menawarkan pendekatan prediktif berbasis data terkini guna mendukung perencanaan penggunaan lahan yang lebih adaptif dan responsif terhadap dinamika perubahan tutupan lahan. Dalam konteks percepatan perubahan lahan, metode penginderaan jauh (PJ) memberikan keunggulan dalam hal efisiensi pemantauan serta cakupan wilayah yang luas, yang sulit dicapai oleh metode konvensional (Ma et al., 2019; Saini & Rawat, 2023). Analisis spasial berbasis PJ juga memungkinkan identifikasi pola perubahan secara detail dan menghasilkan visualisasi informatif yang sangat berguna dalam proses perencanaan tata ruang.

Fenomena perubahan lahan yang ekstrem, seperti deforestasi di kawasan Amazon yang tercatat mencapai 308.311 km<sup>2</sup> dan degradasi hutan sebesar 337.427 km<sup>2</sup> dalam kurun waktu 1992–2014 (Qin et al., 2021), memiliki dampak besar terhadap keanekaragaman hayati, siklus karbon, dan mata pencaharian masyarakat lokal. Deforestasi mengubah karakteristik permukaan lahan, mempengaruhi pertukaran energi dan air, serta berkontribusi pada perubahan pola iklim regional dan global (Yuan et al., 2021). Studi juga menunjukkan deforestasi berperan dalam emisi gas rumah kaca, terutama di Amazon yang kaya hutan tropis (Larrea-Gallegos & Vázquez-Rowe, 2022), yang mengancam upaya mitigasi perubahan iklim seperti yang diupayakan melalui Kesepakatan Paris. Deforestasi yang terus berlangsung tanpa intervensi kuat dapat menurunkan kapasitas bumi dalam menyerap karbon, memperburuk krisis iklim, dan mempercepat hilangnya habitat penting bagi spesies endemik (Bradley et al., 2017). Pemahaman mendalam tentang pola perubahan lahan sangat penting bagi pengambil kebijakan dalam mengembangkan strategi konservasi yang efektif.

Sebagai respons terhadap kebutuhan analisis prediksi yang mendesak di Kabupaten Bogor, penelitian ini mengusulkan pendekatan prediksi perubahan tutupan lahan yang inovatif dengan memanfaatkan metode *machine learning Random Forest* dan data citra satelit Sentinel-2. Pemilihan metode *Random Forest* didasarkan pada keunggulannya dalam menangani data yang kompleks dan non-linear (Breiman, 2001; Rodriguez-Galiano et al.,

2012), serta kemampuannya untuk memberikan akurasi prediksi yang tinggi dalam klasifikasi tutupan lahan (Saha et al., 2020). *Random Forest* juga dikenal *robust* terhadap *overfitting* dan efisien secara komputasi, sehingga cocok untuk analisis data citra satelit yang besar. Selain itu, penggunaan citra satelit Sentinel-2 memberikan keunggulan dalam hal resolusi spasial dan temporal yang tinggi, serta ketersediaan data yang *open source* dan global, memungkinkan pemantauan perubahan tutupan lahan secara detail dan periodik (Karra et al., 2021). Kombinasi metode *Random Forest* dan citra Sentinel-2 belum banyak dieksplorasi dalam konteks prediksi perubahan tutupan lahan di Kabupaten Bogor. Oleh karena itu, penelitian ini diharapkan dapat memberikan kontribusi metodologis dalam penerapan *machine learning* dan data penginderaan jauh untuk prediksi perubahan tutupan lahan, serta kontribusi substansial dalam menyediakan informasi prediksi yang berguna bagi perencanaan tata ruang dan pengelolaan lingkungan di Kabupaten Bogor.

Penelitian ini juga memiliki relevansi yang kuat terhadap berbagai kebijakan nasional Indonesia yang menekankan pentingnya pengelolaan lahan secara berkelanjutan dan berwawasan lingkungan. Salah satu contohnya adalah komitmen Indonesia dalam Kesepakatan Paris (UNFCCC, 2015), yang telah diratifikasi melalui Undang-Undang No. 16 Tahun 2016. Komitmen ini mengharuskan Indonesia untuk melakukan upaya mitigasi dan adaptasi terhadap perubahan iklim, di mana pengelolaan tutupan lahan serta pengurangan laju deforestasi menjadi komponen penting. Di tingkat nasional, kerangka hukum seperti Undang-Undang No. 32 Tahun 2009 tentang Perlindungan dan Pengelolaan Lingkungan Hidup (PPLH), serta Undang-Undang No. 26 Tahun 2007 tentang Penataan Ruang, mengamanatkan perlunya perencanaan tata ruang yang berkelanjutan dan berorientasi pada perlindungan lingkungan. Dalam konteks ini, informasi prediktif mengenai perubahan tutupan lahan sebagaimana disediakan oleh penelitian ini menjadi sangat penting untuk mendukung perencanaan dan pengambilan keputusan yang berbasis data.

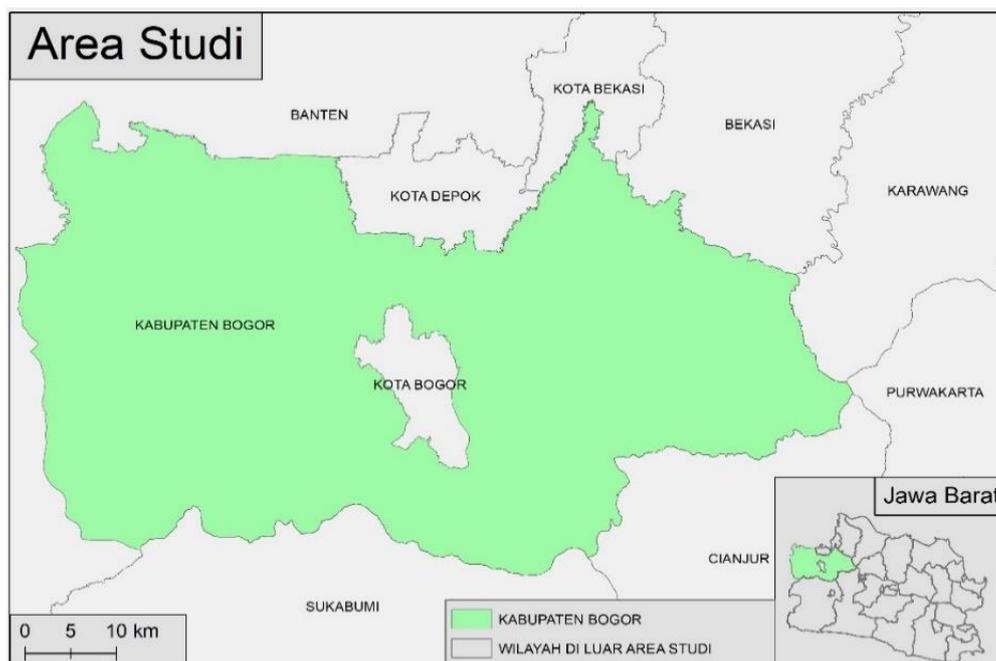
Dukungan metodologis terhadap pendekatan yang digunakan dalam penelitian ini juga dapat ditemukan pada berbagai studi internasional. Misalnya, penelitian di wilayah selatan Madagaskar yang menggunakan algoritma *Random Forest* untuk memodelkan ekspansi urban berhasil mencapai tingkat akurasi hingga 87%, serta mampu mengidentifikasi variabel-variabel kunci yang memengaruhi perubahan lahan di wilayah tersebut (Grinand et al., 2020). Studi lain di Brazil menunjukkan bahwa metode *Random Forest* memiliki performa yang lebih baik dibandingkan regresi linier tradisional dalam menganalisis deforestasi dan fragmentasi hutan, dengan keunggulan dalam menjelaskan variasi spasial dan pola fragmentasi lahan secara lebih akurat (Zanella et al., 2017). Studi terbaru oleh Saha et al. (2020) menunjukkan bahwa *Random Forest* dapat mencapai akurasi prediksi hingga 88,6% (evaluasi menggunakan *Area Under Curve/AUC*) dalam memprediksi perubahan lahan urban di wilayah yang berkembang cepat.

Dengan mengacu pada konteks tersebut, penelitian ini bertujuan untuk memprediksi perubahan tutupan lahan di Kabupaten Bogor pada tahun 2026 menggunakan model *Random Forest* yang diterapkan pada citra satelit Sentinel-2. Selain itu, penelitian ini juga bertujuan

untuk menganalisis dinamika perubahan tutupan lahan dan menyusun strategi pengelolaan lahan yang berkelanjutan. Diharapkan pendekatan ini dapat memberikan pemahaman yang lebih komprehensif mengenai pola-pola perubahan lahan serta dampaknya terhadap lingkungan dan tata ruang. Tahun 2026 dipilih sebagai target prediksi karena berada dalam satu rentang temporal yang konsisten dengan data historis tutupan lahan tahun 2017, 2020, dan 2023, yang masing-masing memiliki interval tiga tahun. Prediksi ini juga sejalan dengan periode Rencana Tata Ruang Wilayah (RTRW) Kabupaten Bogor yang berlaku hingga tahun 2044, sehingga hasil penelitian ini memiliki relevansi praktis dalam proses revisi atau evaluasi RTRW yang mungkin dilakukan sebelum atau setelah tahun 2026. Dengan demikian, informasi prediksi yang dihasilkan diharapkan dapat menjadi dasar pertimbangan yang kuat bagi Pemerintah Kabupaten Bogor dalam menertibkan, mengendalikan, dan mengoptimalkan penggunaan lahan sesuai dengan tujuan pembangunan berkelanjutan.

### Metode Penelitian

Penelitian ini menggunakan pendekatan kuantitatif berbasis *machine learning* untuk memprediksi perubahan tutupan lahan di Kabupaten Bogor, Jawa Barat. Pemilihan wilayah ini didasarkan pada dinamika perubahan lahannya yang tinggi, terutama akibat urbanisasi pesat sebagai daerah penyangga Metropolitan Jakarta. Dengan luas sekitar 2.991,78 km<sup>2</sup> dan terdiri atas 40 kecamatan serta 435 desa/kelurahan, Kabupaten Bogor menghadapi tekanan konversi lahan yang signifikan dari pertanian ke permukiman dan kawasan industri ( et al., 2018). Secara geografis, Kabupaten Bogor terletak pada 106° 01'– 107° 103' Bujur Timur dan antara 6° 18' Lintang Utara - 6° 47' Lintang Selatan, dengan topografi beragam mulai dari dataran rendah hingga dataran tinggi dan pegunungan (Jaya et al., 2021). Lokasi Kabupaten Bogor dapat dilihat pada Gambar 1.



Gambar 1. Lokasi Penelitian Kabupaten Bogor  
Sumber: Badan Informasi Geospasial, 2024

## Data dan Alat

Jenis data utama yang digunakan dalam penelitian ini adalah data tutupan lahan raster multi-temporal yang telah diklasifikasikan sebelumnya, dengan resolusi spasial 10 meter yang diperoleh dari *Esri* dan *Impact Observatory*. Citra ini berbasis citra satelit Sentinel-2 yang diproses oleh *Impact Observatory* menggunakan model *deep learning* yang dilatih dengan miliaran piksel berlabel manusia, yang dikurasi oleh *National Geographic Society*. Data citra satelit Sentinel-2 adalah sumber utama untuk data tutupan lahan ini, namun penelitian ini menggunakan data yang sudah berupa klasifikasi tutupan lahan dengan jumlah *band* hanya 1, bukan citra mentah Sentinel-2. Data citra tutupan lahan yang dihasilkan memiliki akurasi rata-rata lebih dari 75% (Karra et al., 2021). Data dalam format *GeoTIFF* ini mencakup periode 2017 hingga 2023 yang didownload dan diperoleh dari *Esri* serta *Impact Observatory* melalui *planetary computer* untuk keperluan analisis. Unit analisis dalam penelitian ini adalah piksel citra tutupan lahan, di mana setiap piksel memiliki nilai yang merepresentasikan kode kelas tutupan lahan (Tabel 1). Kelas tutupan lahan yang terdapat dalam dataset ini meliputi Air, Pohon, Vegetasi Terendam, Tanaman, Area Terbangun, Tanah Kosong, Salju/Es, Awan, dan Lahan Penggembalaan. Tabel 1 berikut menyajikan klasifikasi berbagai jenis tutupan lahan yang digunakan dalam penelitian ini.

Tabel 1. Klasifikasi Jenis Tutupan Lahan

Nilai	Nama	Keterangan
1	Air	Daerah berair sepanjang tahun, tanpa vegetasi atau bangunan; contoh: sungai, kolam, danau, laut.
2	Pohon	Vegetasi tinggi (~15 kaki), lebat, biasanya dengan tajuk rapat; contoh: hutan, sabana, rawa bakau.
4	Vegetasi yang tergenang	Vegetasi dengan air musiman atau sepanjang tahun; contoh: sawah, hutan bakau, pertanian diairi intensif.
5	Tanaman	Serealia, rumput, tanaman pangan yang tidak setinggi pohon; contoh: jagung, gandum, kedelai.
7	Luas Bangunan	Struktur buatan manusia; jalan, gedung, perumahan; contoh: rumah, kota, jalan beraspal.
8	Tanah kosong	Daerah tanpa vegetasi; contoh: gurun, bukit pasir, tambang, tanah berbatu.
9	Salju/Es	Daerah salju atau es permanen; contoh: gletser, lapisan salju.
10	Awan	Tutupan lahan tidak terlihat karena tertutup awan.
11	Lahan penggembalaan	Area rumput homogen tanpa vegetasi tinggi; contoh: padang rumput, sabana, lapangan golf.

Sumber: *Esri* dan *Impact Observatory* (Karra et al., 2021)

Analisis dalam penelitian ini dilakukan menggunakan *google colab* sebagai lingkungan pengembangan utama. *Python* dipilih sebagai bahasa pemrograman dengan berbagai *library* pendukung, seperti *Rasterio* untuk manipulasi data raster, *NumPy* dan *Pandas* untuk operasi numerik dan manipulasi data tabular, *Scikit-learn* untuk menerapkan algoritma *machine learning*, khususnya *Random Forest*, serta *Matplotlib* digunakan untuk visualisasi hasil analisis.

## Tahapan Analisis

Metodologi analisis data dalam penelitian ini mengikuti tahapan-tahapan berikut, yang dirancang secara sistematis untuk menghasilkan prediksi perubahan tutupan lahan yang akurat dan informatif.

### 1. Persiapan Data

Tahap persiapan data merupakan tahap krusial dalam pemodelan *machine learning*, yang bertujuan untuk menyiapkan data citra satelit tutupan lahan agar sesuai untuk proses pelatihan model dan validasi. Tahapan ini meliputi langkah-langkah berikut: Pengumpulan Data Citra: Langkah awal adalah mengumpulkan data citra tutupan lahan Sentinel-2 multi-temporal yang relevan untuk area studi dan periode waktu penelitian. Dalam penelitian ini, data citra tutupan lahan untuk tahun 2017, 2020, dan 2023 dikumpulkan dalam format *GeoTIFF* dari sumber Esri dan *Impact Observatory*. Pemilihan periode waktu ini didasarkan pada ketersediaan data yang *up-to-date* dan representasi dinamika perubahan lahan dalam beberapa tahun terakhir.

- Pembacaan Data Raster: Setiap file citra tutupan lahan dalam format *GeoTIFF* dibaca dan diimpor ke dalam lingkungan *Python* sebagai *array NumPy* menggunakan *library Rasterio*. *Library Rasterio* dipilih karena kemampuannya yang efisien dalam menangani data raster geospasial dalam format *GeoTIFF*. Penelitian ini hanya memanfaatkan *band* pertama dari data citra tutupan lahan, karena *band* pertama ini berisi informasi mengenai kelas tutupan lahan yang telah diklasifikasikan oleh penyedia data (Esri dan *Impact Observatory*), dan nilai pikselnya merepresentasikan kode kelas tutupan lahan sesuai Tabel 1.
- Pembentukan Variabel Prediktor (X) dan Target (Y): Untuk membangun model prediksi perubahan tutupan lahan, data perlu disusun menjadi variabel prediktor (fitur) dan variabel target. Dalam penelitian ini, nilai piksel dari citra tutupan lahan tahun 2017 dan 2020 digabungkan dan digunakan sebagai variabel prediktor (X), yang merepresentasikan kondisi tutupan lahan pada masa lampau. Sementara itu, nilai piksel dari citra tutupan lahan tahun 2023 digunakan sebagai variabel target (Y), yang merepresentasikan kondisi tutupan lahan yang ingin diprediksi oleh model berdasarkan data masa lampau. Data prediktor (X) dan target (Y) disusun dalam format array 2 dimensi yang sesuai sebagai input untuk algoritma *machine learning*.
- Normalisasi Data: Data variabel prediktor (X) kemudian dilakukan normalisasi menggunakan metode *StandardScaler* dari library Scikit-learn. Normalisasi data sangat penting dalam pemodelan *machine learning*, terutama untuk data spasial multi-temporal seperti citra satelit. Tujuan normalisasi adalah untuk menyeragamkan skala nilai dari semua variabel prediktor, sehingga mencegah variabel dengan skala nilai yang lebih besar mendominasi proses pembelajaran model. *StandardScaler* melakukan normalisasi dengan mengurangi nilai rata-rata (*mean*) dari setiap variabel dan membaginya dengan standar deviasi, sehingga data memiliki rata-rata nol dan varians satu. Proses normalisasi dilakukan secara terpisah untuk data latih dan data

validasi/uji, dengan parameter *scaling* (nilai *mean* dan standar deviasi) hanya dihitung dari data *training* dan diterapkan pada data validasi/uji. Pendekatan ini mencegah data *leakage* dari data validasi/uji ke data *training*, yang dapat menghasilkan evaluasi model yang bias dan terlalu optimis.

- Pembagian Dataset: Membagi dataset yang telah dinormalisasi menjadi tiga bagian: data latih (60%), data validasi (20%), dan data uji (20%) menggunakan fungsi *train\_test\_split* dari *Scikit-learn*. Pembagian dataset ini dilakukan secara acak (*random split*), namun dengan mempertimbangkan dan mempertahankan proporsi kelas tutupan lahan yang seimbang (*stratify=Y*) antara data latih, validasi, dan uji. Hal ini penting untuk memastikan bahwa model dilatih dan dievaluasi pada dataset yang memiliki representasi kelas yang proporsional, terutama jika terdapat ketidakseimbangan kelas dalam data tutupan lahan, dan untuk meminimalkan bias model terhadap kelas mayoritas (Mellor et al., 2015). Dataset yang dihasilkan dari pembagian ini memiliki ukuran total 49.566.841 sampel (piksel) dari 3 raster (2017, 2020 dan 2023), yang terbagi menjadi data latih sebesar 29.740.104 sampel, data validasi sebesar 9.913.368 sampel, dan data uji sebesar 9.913.369 sampel.

## 2. Pemodelan

Pemodelan prediksi perubahan tutupan lahan tahap pemodelan merupakan inti dari penelitian ini, di mana algoritma *machine learning Random Forest* digunakan untuk membangun model prediksi perubahan tutupan lahan. Langkah-langkah pemodelan adalah sebagai berikut:

- Inisialisasi Model *Random Forest*: Model *Random Forest* diinisialisasi menggunakan *class RandomForestClassifier* dari library *Scikit-learn*. *Random Forest* dipilih sebagai algoritma *machine learning* karena keunggulannya dalam menangani data yang kompleks dan non-linear, *robustness* terhadap *overfitting*, efisiensi komputasi, dan kemampuan interpretasi model yang baik (Rodriguez-Galiano et al., 2012; Saha et al., 2020). Model diinisialisasi dengan parameter *n\_estimators=100*, yang berarti model akan membangun 100 pohon keputusan (*decision trees*) sebagai ensemble model. Parameter *random\_state=42* juga ditetapkan untuk memastikan reproduktibilitas hasil penelitian, sehingga hasil pemodelan dapat diulang dengan hasil yang sama jika kode dijalankan kembali.
- Pelatihan Model: Model *Random Forest* yang telah diinisialisasi kemudian dilatih (*training*) menggunakan data latih (*X\_train*, *y\_train*) yang telah dipersiapkan pada tahap sebelumnya. Proses pelatihan ini melibatkan algoritma *Random Forest* untuk mempelajari pola hubungan antara variabel prediktor (tutupan lahan tahun 2017 dan 2020) dan variabel target (tutupan lahan tahun 2023) berdasarkan data latih. Selama proses pelatihan, algoritma *Random Forest* akan membangun *ensemble* pohon keputusan secara iteratif dengan teknik *bootstrap aggregating (bagging)* dan *feature randomness*, serta mengoptimalkan parameter model untuk meminimalkan kesalahan prediksi pada data latih.

- Prediksi Tutupan Lahan Tahun 2026: Setelah model *Random Forest* selesai dilatih menggunakan data historis (data latih), model tersebut kemudian digunakan untuk memprediksi kondisi tutupan lahan di Kabupaten Bogor pada tahun 2026. Untuk melakukan prediksi tahun 2026, data input prediksi dibentuk dengan menggabungkan data piksel citra tutupan lahan tahun 2020 dan 2023 yang telah dinormalisasi menggunakan *StandardScaler* yang sama yang digunakan untuk data training. Data input prediksi ini kemudian dimasukkan ke dalam model *Random Forest* yang telah dilatih, dan model akan menghasilkan peta prediksi tutupan lahan tahun 2026. Proses prediksi dilakukan menggunakan fungsi *predict* yang tersedia pada objek model *Random Forest* di library *Scikit-learn*.

### 3. Evaluasi Model dan Validasi

Tahap evaluasi model dan validasi bertujuan untuk kinerja model *Random Forest* dalam memprediksi perubahan tutupan lahan, serta memastikan keandalan dan keterpercayaan hasil prediksi. Tahap ini meliputi dua jenis validasi:

- Evaluasi Kinerja Model (*2-fold time-series Cross-Validation*): Evaluasi ini untuk memberikan estimasi yang lebih *robust* terhadap data temporal serta menghindari *overfitting* dan data *leakage*. Pada *Fold 1* (Validasi 2020), model *Random Forest* dilatih menggunakan data tutupan lahan tahun 2017 dan dievaluasi dengan data tahun 2020. Validasi ini bertujuan untuk menguji kemampuan model dalam memprediksi perubahan tutupan lahan dari tahun 2017 ke 2020. Pada *Fold 2* (Validasi 2023), model dilatih menggunakan data tahun 2017 dan 2020, lalu dievaluasi dengan data tahun 2023. Validasi ini menguji kemampuan model dalam memprediksi perubahan tutupan lahan pada periode yang lebih akhir (2020 ke 2023) dengan data *training* yang lebih lengkap. Kinerja model diukur menggunakan beberapa metrik evaluasi. *Overall Accuracy* digunakan untuk menghitung persentase prediksi yang benar dari total piksel. *Cohen's Kappa* menilai tingkat kesesuaian prediksi dengan data aktual dengan mempertimbangkan peluang acak. *F1-Score* digunakan untuk mengukur keseimbangan antara *Precision* dan *Recall*, terutama pada data yang tidak seimbang. *Area Under the Curve* (AUC) menunjukkan kemampuan model dalam membedakan antar kelas tutupan lahan. Terakhir, *Confusion Matrix* menyajikan jumlah piksel prediksi terhadap data aktual untuk setiap kelas, memberikan gambaran detail mengenai kinerja model serta jenis kesalahan prediksi yang terjadi.
- Validasi Visual dengan *Google Earth Pro*: penelitian ini juga melakukan validasi visual dengan memanfaatkan platform *Google Earth Pro*. Validasi visual ini dilakukan dengan cara membandingkan secara visual peta prediksi tutupan lahan tahun 2023 (hasil validasi *Fold 2*) dengan citra satelit resolusi tinggi yang tersedia di *Google Earth Pro* untuk tahun 2023. Prediksi tahun 2026 tidak dibandingkan karena belum tersedia. Validasi visual ini difokuskan pada peta prediksi tutupan lahan tahun 2023 yang dihasilkan dari validasi *Fold 2*, untuk menilai kewajaran spasial hasil prediksi model pada periode validasi.

## Hasil dan Pembahasan

### Evaluasi Kinerja Model

Evaluasi kinerja model *Random Forest* dilakukan melalui *2-fold Cross-Validation* berbasis *time-series* untuk memastikan robustitas model dalam memprediksi tutupan lahan di Kabupaten Bogor. Pada *Fold 1*, data tahun 2017 dan 2023 digunakan untuk melatih model, dengan data validasi tahun 2020 digunakan untuk pengujian. Pada *Fold 2*, data tahun 2017 dan 2020 digunakan untuk pelatihan, dengan data validasi tahun 2023 dievaluasi. Metrik evaluasi keseluruhan untuk kedua *fold* dirangkum dalam Tabel 2, yang menunjukkan performa model secara umum sebelum analisis lebih rinci per kelas. Tabel ini menampilkan nilai rata-rata metrik evaluasi (Akurasi, Kappa, *F1-Score* dan *AUC*) yang dihitung dari *Fold 1* dan *Fold 2*, yang memberikan indikasi umum tingkat akurasi dan keandalan model dalam memprediksi perubahan tutupan lahan di Kabupaten Bogor.

Tabel 2. Hasil Evaluasi Model dengan *2-Fold* Validasi

Metode Evaluasi	<i>Fold 1</i>	<i>Fold 2</i>	Rata-rata
Akurasi	0.8796	0.8796	0.8796
<i>Kappa</i>	0.8131	0.8131	0.8131
<i>F1-Score</i>	0.8752	0.8752	0.8752
<i>AUC</i>	0.9449	0.9451	0.9450

Sumber: Hasil Analisis, 2024

Berdasarkan Tabel 2, akurasi model mencapai 0,8796 (87,96%) untuk *Fold 1*, *Fold 2*, dan rata-ratanya, yang berarti model mampu mengklasifikasikan 87,96% piksel dengan benar pada kedua periode validasi (2020 dan 2023). Nilai akurasi ini menunjukkan bahwa model memiliki tingkat kebenaran yang tinggi dalam memprediksi tutupan lahan, meskipun ada dinamika perubahan lahan yang signifikan antara tahun-tahun tersebut. Nilai Kappa sebesar 0,8131 untuk kedua *fold* dan rata-ratanya menunjukkan tingkat kesesuaian yang sangat baik antara prediksi model dan data aktual, jauh di atas nilai 0,61 yang dianggap sebagai ambang batas untuk kesesuaian baik (Landis & Koch, 1977). Ini mengindikasikan bahwa model tidak hanya akurat secara keseluruhan, tetapi juga konsisten dalam menangani distribusi kelas yang timpang. *F1-Score* sebesar 0,8752 (87,52%) untuk *Fold 1*, *Fold 2*, dan rata-ratanya mencerminkan keseimbangan yang baik antara *Precision* dan *Recall*, menunjukkan bahwa model efektif dalam mengidentifikasi kelas yang benar (tanpa banyak kesalahan positif) sekaligus menangkap sebagian besar piksel yang relevan untuk setiap kelas. Nilai *AUC* (*Area Under the Curve*) sebesar 0,9449 untuk *Fold 1*, 0,9451 untuk *Fold 2*, dan 0,9450 untuk rata-ratanya menunjukkan kemampuan diskriminasi kelas yang sangat baik, mendekati nilai sempurna 1,0. *AUC* di atas 0,9 mengindikasikan bahwa model sangat mampu membedakan antara kelas-kelas yang berbeda, bahkan dalam dataset multi-temporal dengan variasi temporal yang signifikan. Secara keseluruhan, metrik ini menegaskan bahwa model *Random Forest* memiliki performa yang konsisten dan andal untuk prediksi tutupan lahan di Kabupaten Bogor.

Metrik performa per kelas untuk *Fold 1* (validasi 2020) menunjukkan variasi yang signifikan antar kelas. Kelas Pohon (2) memiliki *Precision* 89% dan *Recall* 95%, menghasilkan *F1-Score* 0,92, yang mencerminkan kemampuan model yang sangat baik dalam mengidentifikasi kelas dominan ini (692.934 piksel, ~46,3% dari total data validasi 2020). *Precision* yang tinggi menunjukkan bahwa sebagian besar piksel yang diprediksi sebagai Pohon memang benar-benar Pohon, sementara *Recall* yang lebih tinggi menunjukkan bahwa model berhasil menangkap sebagian besar piksel Pohon yang ada. Kelas Area Terbangun (7) juga menunjukkan performa kuat dengan *Precision* 96% dan *Recall* 86%, menghasilkan *F1-Score* 0,91, konsisten dengan dominasinya dalam dataset (476.531 piksel, ~31,8%). *Precision* yang sangat tinggi pada kelas ini menunjukkan sedikitnya kesalahan klasifikasi ke kelas lain, tetapi *Recall* yang lebih rendah mengindikasikan bahwa beberapa piksel Area Terbangun salah diklasifikasikan, kemungkinan ke Tanaman (5) akibat area transisi. Kelas Tanaman (5) memiliki *Precision* 76% dan *Recall* 86% (*F1-Score* 0,81), menunjukkan bahwa model lebih baik dalam menangkap piksel Tanaman yang ada (*Recall* tinggi), tetapi kurang akurat dalam memastikan bahwa piksel yang diprediksi sebagai Tanaman memang benar (*Precision* lebih rendah). Kelas minor seperti Vegetasi Tergenang (4) menunjukkan performa buruk dengan *Precision* 60% dan *Recall* hanya 30% (*F1-Score* 0,40), karena jumlah sampel yang sangat kecil (5 piksel). *Precision* yang lebih tinggi dibandingkan *Recall* menunjukkan bahwa model cenderung konservatif dalam memprediksi kelas ini, tetapi gagal menangkap sebagian besar piksel yang sebenarnya Vegetasi Tergenang. Kelas Awan (10) memiliki *Precision* dan *Recall* 0%, yang diharapkan karena data validasi telah dibersihkan dari piksel yang tertutup awan, sehingga kelas ini tidak terdeteksi (2.037 piksel salah diklasifikasikan ke kelas lain). Kelas Lahan Penggembalaan (11) menunjukkan *Precision* 67% tetapi *Recall* sangat rendah (26%), menghasilkan *F1-Score* 0,38. Hal ini menunjukkan bahwa meskipun model cukup akurat ketika memprediksi Lahan Penggembalaan (*Precision* 67%), ia gagal menangkap sebagian besar piksel yang sebenarnya Lahan Penggembalaan (45.589 piksel), kemungkinan salah diklasifikasikan ke pohon atau tanaman akibat kemiripan spektral.

Pada *Fold 2* (validasi 2023), model dilatih dengan data prediktor 2017 dan 2020, yang memberikan informasi tambahan tentang perubahan tutupan lahan selama periode tersebut. Performa model tetap konsisten dengan akurasi 87,96%. Kelas Pohon (2) tetap unggul dengan *Precision* 89% dan *Recall* 95% (*F1-Score* 0,92), konsisten dengan dominasinya (692.119 piksel). *Precision* dan *Recall* yang stabil antar *fold* menunjukkan bahwa model sangat konsisten dalam menangani kelas dominan ini, meskipun ada perubahan kecil dalam distribusi piksel (penurunan dari 692.934 ke 692.119 piksel). Kelas Area Terbangun (7) juga mempertahankan performa tinggi dengan *Precision* 96% dan *Recall* 86% (*F1-Score* 0,91), identik dengan *Fold 1*, menunjukkan stabilitas model dalam mengidentifikasi kelas ini meskipun ada peningkatan jumlah piksel (dari 476.531 ke 477.141). Namun, kelas Vegetasi Tergenang (4) memburuk dengan *Precision* 25% dan *Recall* 14% (*F1-Score* 0,18), karena sampelnya semakin kecil (3 piksel dibandingkan 5 piksel pada *Fold 1*). Penurunan *Precision* dan *Recall* ini menunjukkan bahwa model semakin kesulitan mengidentifikasi kelas ini seiring berkurangnya data, dengan

*Recall* yang sangat rendah mengindikasikan bahwa model gagal menangkap sebagian besar piksel Vegetasi Tergenang yang ada. Kelas Awan (10) kembali memiliki *Precision* dan *Recall* 0%, dengan 1.948 piksel salah diklasifikasikan, konsisten dengan *Fold 1*. Kelas Lahan Penggembalaan (11) sedikit lebih baik dibandingkan *Fold 1*, dengan *Precision* 66% dan *Recall* 26% (*F1-Score* 0,37). Meskipun *Precision* sedikit menurun (dari 67% ke 66%), *Recall* tetap stabil, menunjukkan bahwa model masih menghadapi tantangan yang sama dalam menangkap piksel Lahan Penggembalaan, tetapi sedikit lebih konservatif dalam prediksinya pada *Fold 2*. Kelas Tanah Kosong (8) menunjukkan peningkatan kecil pada *Precision* (dari 67% ke 68%) tetapi penurunan pada *Recall* (dari 84% ke 83%), menunjukkan bahwa model menjadi lebih akurat dalam memprediksi kelas ini tetapi gagal menangkap beberapa piksel yang sebenarnya Tanah Kosong, kemungkinan karena perubahan distribusi lahan kosong antara 2020 dan 2023.

Untuk memberikan gambaran lebih jelas tentang performa per kelas, metrik *precision*, *Recall*, dan *F1-Score* dari kedua *fold* dirangkum dalam Tabel 4. Tabel ini memungkinkan perbandingan langsung antara *Fold 1* dan *Fold 2*, serta menunjukkan distribusi piksel (support) untuk setiap kelas, yang membantu memahami ketidakseimbangan data.

Tabel 3. Metrik Performa per Kelas pada 2-Fold Cross-Validation

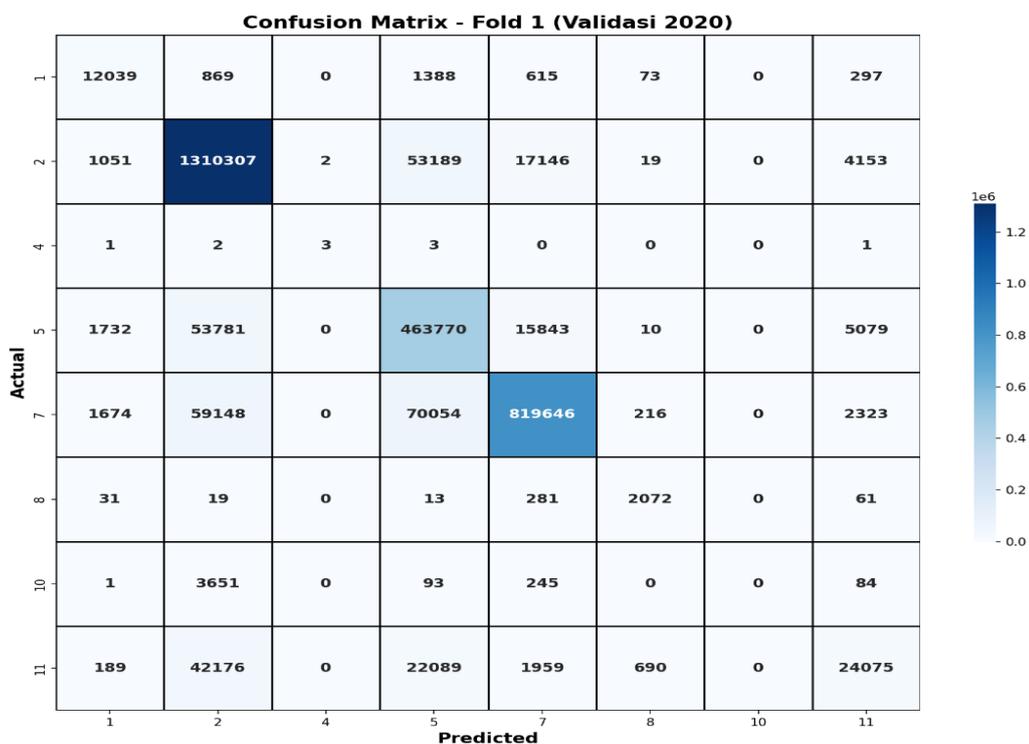
Kelas	Fold 1			Fold 2		
	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
1	0.72	0.79	0.75	0.71	0.79	0.75
2	0.89	0.95	0.92	0.89	0.95	0.92
4	0.6	0.3	0.4	0.25	0.14	0.18
5	0.76	0.86	0.81	0.76	0.86	0.81
7	0.96	0.86	0.91	0.96	0.86	0.91
8	0.67	0.84	0.75	0.68	0.83	0.75
10	0	0	0	0	0	0
11	0.67	0.26	0.38	0.66	0.26	0.37

Sumber: Hasil Analisis, 2024

Berdasarkan Tabel 3, perbedaan *Precision* dan *Recall* antar *fold* memberikan wawasan penting tentang performa model. Untuk kelas Pohon (2) dan Area Terbangun (7), *Precision* dan *Recall* yang stabil antar *fold* menunjukkan bahwa model sangat konsisten dalam menangani kelas dominan, meskipun ada perubahan kecil dalam distribusi piksel. Hal ini menegaskan bahwa *Random Forest* efektif dalam menangani data yang timpang, di mana kelas mayoritas mendominasi (78% piksel). Namun, untuk kelas minor seperti Vegetasi Tergenang (4), penurunan *Precision* (dari 60% ke 25%) dan *Recall* (dari 30% ke 14%) dari *Fold 1* ke *Fold 2* menunjukkan bahwa model semakin kesulitan seiring berkurangnya data pelatihan untuk kelas ini (dari 5 piksel ke 3 piksel). *Precision* yang lebih rendah pada *Fold 2* mengindikasikan bahwa model lebih sering salah memprediksi piksel lain sebagai Vegetasi Tergenang, sementara *Recall* yang lebih rendah menunjukkan bahwa model gagal menangkap piksel Vegetasi Tergenang yang ada. Untuk kelas Lahan Penggembalaan (11), *Precision* yang

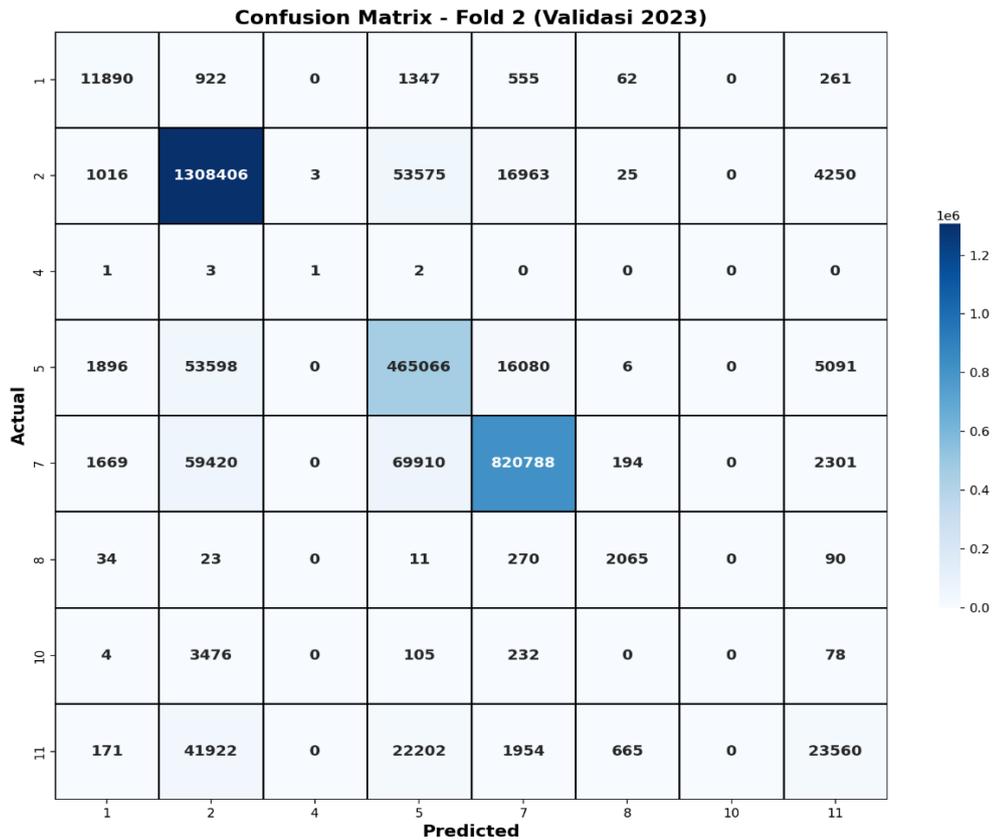
sedikit menurun (dari 67% ke 66%) tetapi *Recall* yang stabil (26%) menunjukkan bahwa model menjadi lebih konservatif dalam memprediksi kelas ini pada *Fold 2*, kemungkinan karena perubahan distribusi lahan penggembalaan antara 2020 dan 2023 (dari 51,79 km<sup>2</sup> ke 90,54 km<sup>2</sup>, Tabel 2). *Recall* yang rendah pada kedua *fold* menegaskan bahwa model kesulitan menangkap piksel Lahan Penggembalaan, sering kali salah mengklasifikasikannya sebagai Pohon atau Tanaman, yang memiliki karakteristik spektral serupa. Kelas Tanah Kosong (8) menunjukkan peningkatan kecil pada *Precision* (dari 67% ke 68%) tetapi penurunan pada *Recall* (dari 84% ke 83%), mengindikasikan bahwa model menjadi lebih akurat dalam memprediksi kelas ini pada *Fold 2*, tetapi gagal menangkap beberapa piksel Tanah Kosong yang sebenarnya, kemungkinan karena konversi lahan kosong ke kelas lain seperti Area Terbangun atau Lahan Penggembalaan.

Untuk memahami lebih lanjut kesalahan klasifikasi, *Confusion Matrix* untuk *Fold 1* (validasi 2020) ditunjukkan pada Gambar 2. Kelas Pohon (2) memiliki 655.153 piksel diklasifikasikan benar, tetapi 26.595 piksel salah diklasifikasikan sebagai Tanaman (5), kemungkinan karena kemiripan spektral antara vegetasi tinggi dan tanaman pertanian. Kelas Area Terbangun (7) menunjukkan 409.823 piksel benar, dengan kesalahan utama ke Tanaman (5) sebanyak 35.027 piksel, yang mungkin terjadi di area transisi antara permukiman dan lahan pertanian. Kelas Tanaman (5) memiliki 231.885 piksel benar, tetapi 7.922 piksel salah diklasifikasikan sebagai Area Terbangun (7), mencerminkan konversi lahan pertanian ke permukiman yang terjadi di lapangan. Kelas Lahan Penggembalaan (11) menunjukkan hanya 12.038 piksel benar dari 45.589 piksel aktual, dengan 21.088 piksel salah diklasifikasikan sebagai Pohon (2), menegaskan tantangan model dalam membedakan kelas ini.



Gambar 2. Confusion Matrix Validasi *Fold 1*  
 Sumber: Hasil Analisis, 2024

Pada *Fold 2* (validasi 2023), *Confusion Matrix* yang ditunjukkan pada Gambar 3 menunjukkan pola serupa. Kelas Pohon (2) memiliki 654.203 piksel diklasifikasikan benar, dengan 26.788 piksel salah ke Tanaman (5). Kelas Area Terbangun (7) mencatat 410.394 piksel benar, dengan 34.955 piksel salah ke Tanaman (5). Kelas Tanaman (5) memiliki 232.533 piksel benar, tetapi 8.040 piksel salah ke Area Terbangun (7). Kelas Lahan Penggembalaan (11) sedikit lebih baik dengan 11.780 piksel benar, tetapi 20.961 piksel salah diklasifikasikan sebagai Pohon (2), konsisten dengan tantangan yang terlihat pada *Fold 1*. Perbedaan kecil dalam jumlah piksel yang salah diklasifikasikan antar *fold* (misalnya, 21.088 piksel pada *Fold 1* vs. 20.961 piksel pada *Fold 2* untuk Lahan Penggembalaan ke Pohon) mencerminkan perubahan distribusi lahan penggembalaan antara 2020 dan 2023, yang meningkat dari 51,79 km<sup>2</sup> ke 90,54 km<sup>2</sup> (Tabel 2), tetapi tidak cukup signifikan untuk meningkatkan *Recall* model pada kelas ini.



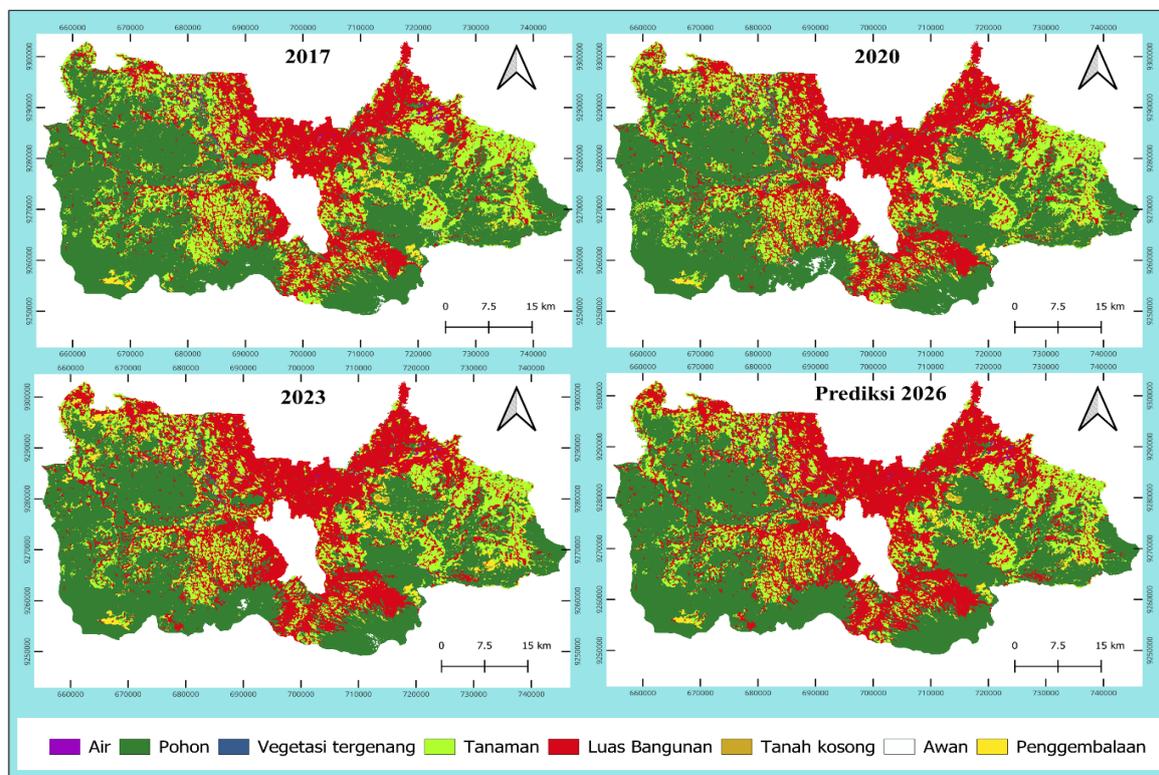
Gambar 3. Confussion Matrix Validasi *Fold 2*  
 Sumber: Hasil Analisis, 2024

Pembahasan ini menunjukkan bahwa model *Random Forest* sangat efektif untuk kelas dominan seperti Pohon dan Area Terbangun, yang bersama-sama mencakup lebih dari 78% piksel dalam dataset. Namun, performa buruk pada kelas minor seperti Vegetasi Tergenang dan Awan disebabkan oleh ketidakseimbangan data dan ketidakrelevanan kelas tertentu dalam konteks geografis Kabupaten Bogor. Perbedaan *Precision* dan *Recall* antar *fold* untuk kelas minor seperti Vegetasi Tergenang dan Lahan Penggembalaan menunjukkan bahwa model sensitif terhadap perubahan distribusi data, yang dapat menjadi fokus perbaikan pada penelitian mendatang, misalnya dengan teknik *oversampling* untuk kelas minor. Secara

keseluruhan, hasil evaluasi *2-fold time-series Cross-Validation*, yang didukung oleh metrik evaluasi kuantitatif dan analisis *Confusion Matrix* per kelas, menegaskan bahwa model *Random Forest* mencapai kinerja yang solid dan memuaskan dalam memprediksi perubahan tutupan lahan di Kabupaten Bogor. Model menunjukkan kemampuan yang baik dalam menggeneralisasi pola perubahan lahan dari data training ke data validasi pada periode waktu yang berbeda, serta mengidentifikasi kelas-kelas tutupan lahan yang dominan dengan akurasi tinggi. Analisis *Confusion Matrix* juga memberikan wawasan menarik mengenai kekuatan dan kelemahan model per kelas, yang dapat menjadi dasar untuk perbaikan model lebih lanjut dan interpretasi hasil prediksi yang lebih hati-hati pada kelas-kelas yang menunjukkan kinerja prediksi yang lebih rendah.

### Proyeksi Tutupan Lahan 2026

Proyeksi tutupan lahan untuk tahun 2026 di Kabupaten Bogor mengungkapkan dinamika perubahan yang signifikan, yang dipengaruhi oleh urbanisasi, degradasi lahan pertanian, dan upaya pemulihan vegetasi. Untuk memberikan gambaran awal tentang distribusi spasial perubahan ini, Gambar 4 menunjukkan peta prediksi tutupan lahan pada tahun 2026. Peta ini menggambarkan konsentrasi area terbangun yang meningkat di kecamatan pinggiran seperti Pamijahan, Jonggol, dan Babakan Madang, yang memiliki aksesibilitas tinggi ke Jakarta, serta pemulihan vegetasi di dataran tinggi seperti Puncak, yang menunjukkan adanya upaya reboisasi atau regenerasi alami.



Gambar 4. Peta Prediksi perubahan lahan Tahun 2026

Salah satu aspek penting dari perubahan tutupan lahan adalah konversi lahan pertanian (Kelas 5) menjadi lahan terbangun (Kelas 7), yang mencerminkan tekanan urbanisasi di Kabupaten Bogor. Gambar 5 menunjukkan perubahan luas lahan pertanian yang dikonversi ke lahan terbangun dari tahun 2023 ke 2026 di 40 kecamatan, dalam satuan hektar. Kecamatan Pamijahan mengalami konversi terbesar, dengan 81,41 hektar (0,81 km<sup>2</sup>) lahan pertanian berubah menjadi lahan terbangun, yang konsisten dengan temuan sebelumnya bahwa Pamijahan adalah salah satu pusat ekspansi urban akibat aksesibilitas tinggi ke Jakarta (Cahya et al., 2018). Sebaliknya, Kecamatan Ciomas menunjukkan konversi terkecil, dengan hanya 3,03 hektar (0,03 km<sup>2</sup>) lahan pertanian yang dikonversi, kemungkinan karena lahan pertanian di wilayah ini sudah banyak dikonversi sebelumnya, sehingga lahan yang tersisa untuk konversi lebih terbatas. Kecamatan Jonggol juga menunjukkan konversi yang signifikan, dengan 65,76 hektar (0,66 km<sup>2</sup>) lahan pertanian berubah menjadi lahan terbangun, sejalan dengan studi oleh Cahya et al. (2018) yang mencatat bahwa Jonggol menjadi pusat ekspansi urban karena aksesibilitasnya melalui jalan tol, mendukung konversi lahan pertanian ke permukiman.



Gambar 5. Prediksi perubahan lahan Pertanian ke Lahan Terbangun per Kecamatan Tahun 2023-2026

Sumber: Hasil Analisis, 2024

Untuk memahami lebih lanjut perubahan luas per kelas dari tahun 2017 hingga 2026, Tabel 4 merangkum data historis dan proyeksi. Area terbangun (Kelas 7) mengalami peningkatan drastis dari 748,02 km<sup>2</sup> pada 2017 menjadi 976,84 km<sup>2</sup> pada 2026, dengan total pertambahan 228,82 km<sup>2</sup> selama sembilan tahun. Khususnya, antara 2023 (953,89 km<sup>2</sup>) dan 2026, terjadi penambahan 22,95 km<sup>2</sup>, atau rata-rata 7,65 km<sup>2</sup> per tahun, sejalan dengan laju urbanisasi pesat akibat pertumbuhan penduduk (5,68 juta jiwa pada 2024, BPS 2024) dan peran Kabupaten Bogor sebagai penyangga metropolitan Jakarta. Sebaliknya, area tanaman (Kelas 5) mengalami penurunan konsisten dari 652,53 km<sup>2</sup> pada 2017 menjadi 530,33 km<sup>2</sup> pada 2026, dengan total pengurangan 122,20 km<sup>2</sup>. Antara 2023 (541,11 km<sup>2</sup>) dan 2026, penurunan sebesar 10,78 km<sup>2</sup> (3,59 km<sup>2</sup> per tahun) menunjukkan tekanan konversi lahan

pertanian menjadi permukiman dan infrastruktur, terutama di kecamatan pinggiran. Penurunan ini berpotensi mengancam ketahanan pangan lokal, mengingat Kabupaten Bogor menyumbang 11,3% populasi Jawa Barat yang bergantung pada sektor pertanian. Area pohon (Kelas 2) menunjukkan pola fluktuatif: turun dari 1.509,12 km<sup>2</sup> (2017) menjadi 1.458,29 km<sup>2</sup> (2020) dan 1.385,34 km<sup>2</sup> (2023) akibat deforestasi awal, lalu diprediksi meningkat menjadi 1.413,42 km<sup>2</sup> pada 2026 (+28,08 km<sup>2</sup> dari 2023). Peningkatan ini mungkin mencerminkan upaya reboisasi atau regenerasi alami di dataran tinggi seperti Puncak, meskipun laju pemulihan lebih lambat dibandingkan kehilangan sebelumnya (-123,78 km<sup>2</sup> dari 2017-2023). Area air (Kelas 1) menurun dari 17,92 km<sup>2</sup> (2017) menjadi 14,28 km<sup>2</sup> (2026), dengan pengurangan 0,91 km<sup>2</sup> antara 2023-2026. Meskipun kecil secara absolut, tren ini signifikan karena dapat memengaruhi ketersediaan sumber daya air di tengah meningkatnya kebutuhan domestik dan industri. Lahan penggembalaan (Kelas 11) mengalami fluktuasi yang lebih kompleks: meningkat dari 51,79 km<sup>2</sup> (2020) menjadi 90,54 km<sup>2</sup> (2023) akibat ekspansi sementara, lalu turun menjadi 55,50 km<sup>2</sup> pada 2026 (-35,04 km<sup>2</sup> dari 2023). Kelas Tanah Kosong (Kelas 8) juga menurun dari 5,38 km<sup>2</sup> (2017) menjadi 2,25 km<sup>2</sup> (2026), mencerminkan pemanfaatan lahan yang sebelumnya *idle*.

Tabel 4. Perubahan Tutupan Lahan per Kelas dari Tahun 2017 hingga Prediksi 2026 (km<sup>2</sup>)

Kelas	2017	2020	2023	2026 (Prediksi)	Perubahan 2017-2026
1	17.92	17.46	15.19	14.28	-3,64
2	1509.12	1458.29	1385.34	1413.42	-95,70
4	0.74	0.01	0.01	0.01	-0,73
5	652.53	627.79	541.11	530.33	-122,20
7	748.02	823.21	953.89	976.84	+228,82
8	5.38	3.31	2.51	2.25	-3,13
10	4.13	10.73	3.98	0.00	-4,13
11	54.74	51.79	90.54	55.50	+0,76

Sumber: Hasil Analisis, 2024

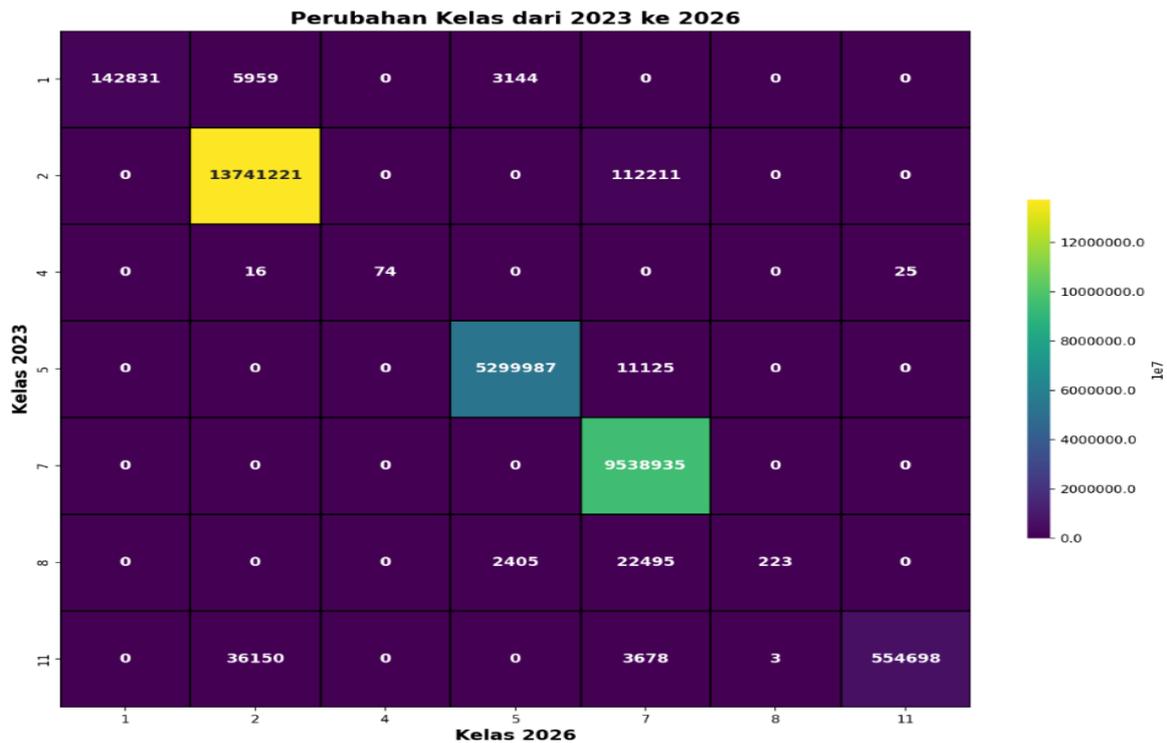
Untuk memahami laju perubahan per kelas secara lebih rinci, Tabel 5 menyajikan tren perubahan tahunan rata-rata berdasarkan data historis (2017-2023) dan proyeksi (2023-2026). Area terbangun menunjukkan pertumbuhan historis sebesar 34,31 km<sup>2</sup>/tahun, melambat menjadi 7,65 km<sup>2</sup>/tahun pada periode proyeksi, menandakan keterbatasan lahan yang tersedia untuk ekspansi lebih lanjut. Area tanaman mengalami penurunan historis 18,57 km<sup>2</sup>/tahun, melambat menjadi 3,59 km<sup>2</sup>/tahun pada 2023-2026, kemungkinan akibat intervensi kebijakan atau keterbatasan lahan pertanian yang tersisa. Area pohon menurun 20,63 km<sup>2</sup>/tahun secara historis, tetapi diprediksi meningkat 9,36 km<sup>2</sup>/tahun pada 2023-2026, mencerminkan upaya pemulihan vegetasi.

Tabel 5. Tren Perubahan Tahunan Rata-Rata per Kelas (km<sup>2</sup>/tahun)

Kelas	2017-2023 (Historis)	2023-2026 (Proyeksi)
1	-0,45	-0,30
2	-20,63	+9,36
5	-18,57	-3,59
7	+34,31	+7,65
11	+6,47	-11,68

Sumber: Hasil Analisis, 2024

Untuk memberikan wawasan lebih mendalam tentang dinamika perubahan antar kelas, Gambar 6 menunjukkan matriks transisi perubahan kelas dari 2023 ke 2026 dalam satuan piksel. Transisi utama meliputi 111.125 piksel (11,11 km<sup>2</sup>) dari Kelas 5 (Tanaman) ke Kelas 7 (Area Terbangun), mencerminkan tekanan urbanisasi yang signifikan, terutama di kecamatan pinggiran. Selain itu, 350.685 piksel (35,07 km<sup>2</sup>) dari Kelas 11 (Lahan Penggembalaan) berpindah ke Kelas 2 (Pohon), menunjukkan regenerasi vegetasi yang kemungkinan didorong oleh upaya reboisasi atau konversi alami di dataran tinggi.



Gambar 6. Metrik Transisi Perubahan Kelas tahun 2023 ke Prediksi 2026

Sumber: Hasil Analisis, 2024

Transisi lain yang lebih kecil namun penting termasuk 5.959 piksel (0,60 km<sup>2</sup>) dari Kelas 1 (Air) ke Kelas 2 (Pohon) dan 3.144 piksel (0,31 km<sup>2</sup>) ke Kelas 5 (Tanaman), yang mungkin mencerminkan perubahan penggunaan lahan di sekitar badan air, seperti pengeringan untuk pertanian atau pertumbuhan vegetasi alami. Sebanyak 112.211 piksel (11,22 km<sup>2</sup>) dari Kelas 2 (Pohon) berpindah ke Kelas 7 (Area Terbangun), mengindikasikan konversi hutan menjadi permukiman, kemungkinan akibat ekspansi urban. Dari Kelas 8 (Tanah Kosong), terdapat 2.405 piksel (0,24 km<sup>2</sup>) yang berpindah ke Kelas 7 (Area Terbangun) dan 223 piksel (0,02 km<sup>2</sup>)

ke Kelas 11 (Lahan Penggembalaan), mencerminkan pemanfaatan lahan kosong untuk pembangunan atau penggembalaan. Kelas 10 (Awan) menunjukkan 36.150 piksel (3,62 km<sup>2</sup>) berpindah ke Kelas 2 (Pohon) dan 3.678 piksel (0,37 km<sup>2</sup>) ke Kelas 7 (Area Terbangun), yang mungkin mencerminkan pembersihan data awan dalam proses proyeksi.

Perubahan tutupan lahan di Kabupaten Bogor didorong oleh beberapa faktor utama. Urbanisasi dan pertumbuhan penduduk menjadi pendorong utama peningkatan area terbangun sebesar 228,82 km<sup>2</sup> dari 2017-2026, sebagaimana ditunjukkan pada Tabel 5, didukung oleh data penduduk 5,68 juta jiwa pada 2024 (BPS 2024) dan peran Kabupaten Bogor sebagai penyangga Jakarta. Kecamatan seperti Pamijahan dan Jonggol, dengan aksesibilitas tinggi melalui jalan tol, menjadi pusat ekspansi urban (Cahya et al., 2018), sebagaimana divisualisasikan pada Gambar 4 dan didukung oleh transisi 11,11 km<sup>2</sup> dari tanaman ke area terbangun serta 11,22 km<sup>2</sup> dari pohon ke area terbangun pada Gambar 6, serta konversi lahan pertanian yang signifikan di Pamijahan dan Jonggol pada Gambar 5. Pembangunan infrastruktur, seperti jalan tol Jakarta-Bogor dan kawasan industri di Cibinong, mendorong konversi lahan tanaman menjadi area terbangun, terlihat dari transisi 11,11 km<sup>2</sup> antara 2023-2026 pada Gambar 5. Aktivitas ekonomi dan pariwisata, khususnya di kawasan Puncak, mendorong konversi lahan kosong dan pertanian menjadi bangunan komersial seperti vila dan hotel, meskipun dalam skala kecil (penurunan Tanah Kosong -3,13 km<sup>2</sup>, Tabel 4; transisi 0,24 km<sup>2</sup> dari tanah kosong ke area terbangun, Gambar 6). Selain itu, kebutuhan lahan pertanian alternatif mendorong fluktuasi lahan penggembalaan (+0,76 km<sup>2</sup> total, tetapi -35,04 km<sup>2</sup> dari 2023-2026), sebagai respons terhadap hilangnya lahan tanaman untuk memenuhi permintaan pangan lokal (Jaya et al., 2021), dengan transisi 0,31 km<sup>2</sup> dari air ke tanaman yang mencerminkan upaya ini.

Namun, beberapa faktor juga menghambat laju perubahan lahan. Kebijakan tata ruang (RTRW) membatasi konversi lahan di zona konservasi dan pertanian produktif, terutama di dataran tinggi, meskipun ada pelanggaran (17,46% penggunaan lahan tidak sesuai RTRW, (Asyari, R. P Sitorus, et al., 2024). Peningkatan area pohon (+28,08 km<sup>2</sup> dari 2023-2026, Tabel 4) mencerminkan penegakan kebijakan reboisasi di Puncak, meskipun efektivitasnya terbatas dibandingkan deforestasi sebelumnya (-123,78 km<sup>2</sup>, 2017-2023). Topografi dan kondisi fisik, seperti dataran tinggi di sekitar Gunung Salak, menghambat ekspansi area terbangun karena aksesibilitas rendah dan risiko bencana longsor, mendukung pemulihan vegetasi (Virtriana et al., 2015). Upaya konservasi dan regenerasi alami juga menjadi penghambat penurunan area pohon lebih lanjut, terlihat dari transisi 35,07 km<sup>2</sup> lahan penggembalaan ke pohon pada Gambar 6. Keterbatasan lahan tersisa, sebagaimana ditunjukkan oleh perlambatan laju ekspansi area terbangun (dari +34,31 km<sup>2</sup>/tahun menjadi +7,65 km<sup>2</sup>/tahun, Tabel 5) dan penurunan lahan tanaman (-18,57 km<sup>2</sup>/tahun ke -3,59 km<sup>2</sup>/tahun), mengindikasikan bahwa lahan yang cocok untuk konversi semakin terbatas, memaksa stabilisasi penggunaan lahan, sebagaimana terlihat dari konversi yang lebih kecil di Ciomas.

Konversi lahan pertanian ke lahan terbangun, sebagaimana ditunjukkan pada Gambar 6, memiliki dampak sosial-ekonomi yang signifikan bagi masyarakat di Kabupaten Bogor,

terutama di kecamatan dengan perubahan besar seperti Pamijahan (81,41 hektar) dan Jonggol (65,76 hektar), serta kecamatan dengan perubahan kecil seperti Ciomas (3,03 hektar). Urbanisasi, yang didorong oleh pertumbuhan penduduk dan aksesibilitas ke Jakarta melalui infrastruktur seperti jalan tol, telah mengubah struktur sosial dan ekonomi masyarakat lokal. Konversi lahan pertanian di Kecamatan Jonggol sejalan dengan rencana pengembangan Jonggol sebagai pusat pemerintahan Kabupaten Bogor Timur berbasis *Smart City* (Dwiantoro et al., 2023). Pengembangan ini berpotensi menstimulasi pertumbuhan ekonomi lokal melalui investasi swasta dan inovasi, seperti penerapan teknologi *Smart City* untuk meningkatkan efisiensi pelayanan publik. Namun, hal ini juga mempercepat konversi lahan pertanian, yang dapat mengurangi lahan produktif dan memengaruhi mata pencaharian petani lokal.

Sementara itu, di Kecamatan Bojonggede, yang juga mengalami konversi lahan pertanian ke terbangun sebesar 4,53 hektar (Gambar 5), Insaf (2004) menemukan bahwa urbanisasi telah menyebabkan perubahan signifikan dalam pola kepemilikan dan penggunaan lahan, serta mata pencaharian masyarakat. Pola kepemilikan lahan bergeser dari tradisional (warisan) ke rasional (transaksi jual-beli), dengan pendatang baru mendominasi kepemilikan lahan, menggeser penduduk asli. Penggunaan lahan beralih dari pertanian ke non-pertanian, terutama untuk permukiman, yang sejalan dengan temuan pada Gambar 6. Secara ekonomi, banyak penduduk asli beralih dari sektor pertanian ke sektor non-pertanian, seperti perdagangan dan jasa, dengan sebagian besar mengalami peningkatan pendapatan. Tapsi et al. (2025) menunjukkan bahwa sektor pertanian di Kabupaten Bogor masih memiliki potensi pengembangan berbasis kewirausahaan, dengan indikator seperti jumlah wirausaha pertanian dan skala usaha. Namun, konversi lahan yang masif di Jonggol dapat menghambat potensi ini jika tidak diimbangi dengan strategi perlindungan lahan pertanian. Sebaliknya, di Kecamatan Ciomas, yang hanya mengalami konversi lahan pertanian sebesar 3,03 hektar (Gambar 5), terdapat potensi untuk mengurangi tekanan konversi lahan melalui pengembangan agrowisata berwawasan lingkungan. Intan et al. (2024) mencatat bahwa 58% lahan di Ciomas telah beralih menjadi kawasan terbangun, tetapi pengembangan agrowisata di Desa Sukaharja dapat menjadi solusi alternatif. Agrowisata tidak hanya dapat mempertahankan lahan pertanian, tetapi juga meningkatkan pendapatan petani dan membuka lapangan pekerjaan baru bagi masyarakat lokal, seperti melalui pengelolaan wisata berbasis pertanian. Strategi ini melibatkan aspek-aspek seperti fasilitas lahan, aksesibilitas, kelembagaan, keterlibatan masyarakat, dan daya tarik, yang dapat mendukung keberlanjutan ekonomi lokal tanpa mengorbankan lahan produktif.

Secara keseluruhan, konversi lahan pertanian ke lahan terbangun di Kabupaten Bogor memiliki dampak ganda. Di satu sisi, urbanisasi mendorong pertumbuhan ekonomi melalui ekspansi permukiman dan infrastruktur, serta peningkatan pendapatan sebagian penduduk yang beralih ke sektor non-pertanian. Di sisi lain, hal ini mengancam mata pencaharian petani, mengurangi lahan produktif, dan melemahkan hubungan sosial antar penduduk asli. Strategi seperti agrowisata, penerapan teknologi pertanian, dan pelestarian kearifan lokal dapat menjadi solusi untuk menyeimbangkan kebutuhan pembangunan dengan pelestarian lahan

pertanian, sekaligus mendukung kesejahteraan sosial-ekonomi masyarakat lokal. Konversi lahan pertanian ke terbangun, terutama di kecamatan seperti Pamijahan dan Jonggol, memperkuat ancaman terhadap ketahanan pangan lokal, yang dapat memperburuk kesejahteraan petani dan meningkatkan ketergantungan pada pasokan pangan dari luar daerah. Faktor pendorong seperti urbanisasi dan infrastruktur mendominasi perubahan lahan, sementara faktor penghambat seperti kebijakan dan topografi mulai memperlambat laju konversi. Temuan ini konsisten dengan studi sebelumnya (Cahya et al., 2018; Jaya et al., 2021) yang mencatat konversi lahan pertanian di kawasan penyangga Jakarta, namun menambah wawasan baru tentang potensi pemulihan vegetasi, keterbatasan lahan sebagai pemicu perubahan tren, dan dampak sosial-ekonomi yang kompleks.

## Kesimpulan

Penelitian ini telah berhasil mencapai tujuannya untuk memprediksi perubahan tutupan lahan di Kabupaten Bogor hingga tahun 2026, menganalisis permasalahan perubahan tutupan lahan yang terjadi, dan menyusun rekomendasi strategi pengelolaan lahan yang berkelanjutan. Model *machine learning Random Forest* yang diterapkan pada data citra satelit Sentinel-2 terklasifikasi terbukti efektif dan andal dalam memprediksi perubahan tutupan lahan di wilayah studi. Hasil prediksi ini memberikan gambaran yang jelas dan terukur mengenai tren perubahan tutupan lahan yang signifikan di Kabupaten Bogor hingga tahun 2026, terutama ekspansi area terbangun yang pesat dan penurunan area tanaman pertanian yang konsisten. *Confusion Matrix* juga memberikan wawasan berharga mengenai kekuatan dan kelemahan model per kelas tutupan lahan, yang dapat menjadi dasar untuk perbaikan model lebih lanjut. Berdasarkan hasil analisis dan pembahasan, dapat ditarik kesimpulan sebagai berikut:

1. Model *Random Forest* Berbasis Sentinel-2 terklasifikasi mampu Memprediksi Perubahan Tutupan Lahan dengan Akurasi Tinggi: Model *Random Forest* yang diterapkan pada data citra satelit Sentinel-2 berhasil memprediksi perubahan tutupan lahan di Kabupaten Bogor hingga tahun 2026 dengan akurasi validasi rata-rata sebesar 87,96% (berdasarkan *2-fold time-series cross-validation*), dengan nilai *Kappa* rata-rata sebesar 0.8131 dan *F1-Score* rata-rata sebesar 0.8752. Hasil evaluasi ini menunjukkan bahwa model *Random Forest* mencapai kinerja yang baik dan memuaskan dalam memprediksi perubahan tutupan lahan di wilayah studi, serta mampu menangkap pola perubahan lahan berdasarkan data historis tutupan lahan dari citra satelit Sentinel-2. Nilai akurasi rata-rata 87,96% dan nilai *Kappa* rata-rata 0.8131 menunjukkan tingkat akurasi dan kesesuaian yang baik antara prediksi model dan data aktual, jauh di atas ambang batas 0.61 yang dianggap sebagai kesesuaian "baik" (Landis & Koch, 1977).
2. Prediksi Perubahan Tutupan Lahan Tahun 2026 Menunjukkan Tren Urbanisasi yang Pesat dan Penurunan Lahan Pertanian: Hasil prediksi menunjukkan adanya peningkatan signifikan pada area terbangun, yang diproyeksikan bertambah

sebesar 22,95 km<sup>2</sup> antara tahun 2023 dan 2026, sehingga luas total area terbangun mencapai 976.84 km<sup>2</sup> pada tahun 2026. Peningkatan area terbangun secara kumulatif dari tahun 2017 hingga 2026 mencapai 228,82 km<sup>2</sup>, mengindikasikan laju urbanisasi yang sangat pesat di Kabupaten Bogor. Sebaliknya, area tanaman pertanian diprediksi terus mengalami penurunan konsisten, berkurang sebesar 10,78 km<sup>2</sup> antara tahun 2023 dan 2026, sehingga luas total area tanaman pertanian menjadi 530.33 km<sup>2</sup> pada tahun 2026. Penurunan area tanaman pertanian secara kumulatif dari tahun 2017 hingga 2026 mencapai 122,2 km<sup>2</sup>, mengkonfirmasi adanya tekanan yang signifikan terhadap sektor pertanian dan potensi ancaman terhadap ketahanan pangan di wilayah ini. Area pohon (Kelas 2) menunjukkan dinamika menarik, dengan penurunan luas area sebesar 123,78 km<sup>2</sup> antara tahun 2017 dan 2023, namun kemudian diprediksi mengalami pemulihan dan meningkat kembali sebesar 28,08 km<sup>2</sup> antara tahun 2023 dan 2026, sehingga luas area pohon pada tahun 2026 diproyeksikan mencapai 1.413,42 km<sup>2</sup>. Meskipun demikian, area pohon secara keseluruhan masih mengalami penurunan neto sebesar 95,7 km<sup>2</sup> dalam periode 2017-2026. Pola perubahan lahan yang diprediksi ini, dengan ekspansi urbanisasi yang dominan dan penurunan lahan pertanian yang mengkhawatirkan, mengarah pada tantangan serius dalam perencanaan tata ruang dan pengelolaan lahan berkelanjutan di Kabupaten Bogor. Peningkatan area terbangun terutama terkonsentrasi di Kecamatan Pamijahan dan Jonggol, yang mengindikasikan potensi tekanan urbanisasi tertinggi di wilayah-wilayah tersebut.

3. Perencanaan dan Pengelolaan Lahan Berkelanjutan Sangat Penting untuk Mengatasi Dampak Perubahan Tutupan Lahan: Temuan penelitian ini semakin menegaskan urgensi perencanaan dan pengelolaan lahan yang berkelanjutan di Kabupaten Bogor. Laju urbanisasi yang pesat dan alih fungsi lahan pertanian yang terus berlanjut, seperti yang diprediksi dalam penelitian ini, berpotensi menimbulkan dampak negatif yang signifikan terhadap lingkungan, sektor pertanian, dan kesejahteraan masyarakat Kabupaten Bogor di masa depan. Oleh karena itu, perencanaan tata ruang yang komprehensif dan implementasi kebijakan pengelolaan lahan yang efektif dan berkelanjutan menjadi kunci utama untuk mengantisipasi dan mengatasi tantangan perubahan tutupan lahan di Kabupaten Bogor, memastikan keseimbangan antara pembangunan dan pelestarian lingkungan, serta menjamin keberlanjutan ekosistem dan kesejahteraan masyarakat di wilayah ini.

Sebagai rekomendasi strategi pengelolaan lahan berkelanjutan berdasarkan temuan penelitian ini, beberapa hal yang perlu dipertimbangkan oleh Pemerintah Kabupaten Bogor adalah:

1. Penguatan Kebijakan Tata Ruang yang Ketat dan Berkelanjutan: Pemerintah Kabupaten Bogor perlu memperkuat regulasi dan implementasi kebijakan tata ruang untuk mengendalikan laju urbanisasi dan mencegah konversi lahan pertanian produktif menjadi area terbangun secara berlebihan. Kebijakan ini harus mencakup penetapan batasan yang jelas untuk pengembangan area terbangun, insentif dan disinsentif untuk mempertahankan lahan pertanian, serta pengawasan dan penegakan hukum yang efektif terhadap pelanggaran tata ruang.
2. Peningkatan Upaya Reboisasi dan Pelestarian Hutan: Mengingat adanya fluktuasi dan potensi penurunan area pohon, Pemerintah Kabupaten Bogor perlu meningkatkan upaya reboisasi dan pelestarian hutan, terutama di area-area yang mengalami penurunan tutupan pohon dan kawasan-kawasan hutan lindung. Program reboisasi dapat dilakukan dengan melibatkan partisipasi aktif masyarakat dan sektor swasta, serta didukung dengan kebijakan insentif untuk mendorong penanaman pohon dan perlindungan hutan yang ada.
3. Pengembangan Pertanian yang Lebih Efisien dan Berkelanjutan: Untuk mengatasi penurunan area tanaman pertanian dan menjaga ketahanan pangan daerah, Pemerintah Kabupaten Bogor perlu mendorong pengembangan teknologi pertanian yang lebih efisien dan berkelanjutan, seperti intensifikasi pertanian, diversifikasi tanaman, pertanian organik, dan pertanian perkotaan. Pelatihan dan pendampingan teknis bagi petani, akses terhadap teknologi dan inovasi pertanian, serta kebijakan dukungan pemasaran produk pertanian lokal juga penting untuk meningkatkan produktivitas dan pendapatan petani.
4. Pengelolaan Sumber Daya Air yang Komprehensif: Mengingat potensi penurunan area air dan tekanan urbanisasi terhadap sumber daya air, Pemerintah Kabupaten Bogor perlu mengembangkan kebijakan pengelolaan sumber daya air yang lebih komprehensif dan terintegrasi. Kebijakan ini harus mencakup konservasi sumber daya air, pengendalian pencemaran air, efisiensi penggunaan air di berbagai sektor, serta penjaminan akses air bersih yang cukup bagi seluruh masyarakat.
5. Peningkatan Monitoring dan Evaluasi Perubahan Tutupan Lahan Berbasis Teknologi Penginderaan Jauh: Untuk memantau dinamika perubahan tutupan lahan secara real-time dan berkelanjutan, Pemerintah Kabupaten Bogor perlu mengembangkan sistem monitoring lahan yang berbasis teknologi penginderaan jauh dan data spasial. Implementasi sistem monitoring ini dapat memanfaatkan data citra satelit resolusi tinggi dan platform analisis data spasial seperti Google Earth Engine, serta mengintegrasikan data monitoring lahan dengan sistem informasi geografis (SIG) tata ruang daerah untuk mendukung pengambilan keputusan yang lebih cepat dan tepat waktu dalam perencanaan dan pengelolaan lahan.

## Ucapan Terima Kasih

Kami mengucapkan terima kasih yang sebesar-besarnya kepada Bappenas atas dukungan dan pendanaan yang diberikan, yang memungkinkan penelitian ini terlaksana dengan baik. Dukungan ini sangat penting dalam upaya kami untuk menggali dan menganalisis data yang relevan, serta memberikan kontribusi ilmiah yang bermanfaat bagi perkembangan pengetahuan di bidang ini. Penelitian ini tidak akan dapat berjalan tanpa bantuan dan komitmen Bappenas dalam mendukung riset dan pengembangan yang berfokus pada peningkatan kualitas kehidupan masyarakat serta pembangunan nasional..

## Daftar Pustaka

- Arifin, D. (2018). *Identifikasi Tutupan Lahan Kota Samarinda dengan Memanfaatkan Citra Satelit Landsat-8 dan Algoritma NDVI. Elipsoida: Jurnal Geodesi dan Geomatika*, 1 (02), 79-84. <https://doi.org/10.14710/elipsoida.2018.3470>
- Aryastana, P., Widya, I. G., DAna, G. W., Suyasa, I. P., & Tamara, W. (2023). Estimasi Perubahan Tutupan Lahan Dengan Menggunakan Normalized Difference Vegetation Index (Ndivi) di Kabupaten Klungkung Provinsi Bali. *Jurnal Teknik Gradien*, 15(01), 45-51. [https://doi.org/10.47329/teknik\\_gradien.v15i01.1014](https://doi.org/10.47329/teknik_gradien.v15i01.1014)
- Asyari, N. I., R. P Sitorus, S., & Wicaksono, A. (2024). Land Use Change Pattern of Change and Strategy Directions for Spatial Utilization Control in Bogor Regency. *Journal of World Science*, 3(7), 732–749. <https://doi.org/10.58344/jws.v3i7.665>
- Badan Pusat Statistik. (2024). Statistik Daerah Kabupaten Bogor 2024. BPS Kabupaten Bogor.
- Bradley, A. V, Rosa, I. M. D., Brandão, A., Crema, S., Dobler, C., Moulds, S., Ahmed, S. E., Carneiro, T., Smith, M. J., & Ewers, R. M. (2017). An ensemble of spatially explicit land-cover model projections: prospects and challenges to retrospectively evaluate deforestation policy. *Modeling Earth Systems and Environment*, 3, 1215–1228. <https://doi.org/10.1007/s40808-017-0376-y>
- Breiman, L. (2001). *Random Forests. Machine Learning*, 45, 5–32. <https://doi.org/10.1023/A:1010933404324>
- Cahya, D. L., Martini, E., & Kasikoen, K. M. (2018). Urbanization and Land Use Changes in Peri-Urban Area using Spatial Analysis Methods (Case Study: Ciawi Urban Areas, Bogor Regency). *IOP Conference Series: Earth and Environmental Science*, 123, 012035. <https://doi.org/10.1088/1755-1315/123/1/012035>
- Dwiantoro, D., Kurniyawan, R., Indrayana, D. V., & Septiani, H. (2023). Pengembangan Jonggol Sebagai Pusat Pemerintahan Kabupaten Bogor Timur Berbasis Smart City. *Planners Insight: Urban And Regional Planning Journal*. <https://doi.org/10.36870/insight.v4i1.319>
- Grinand, C., Vieilledent, G., Razafimbelo, T., Rakotoarijaona, J., Nourtier, M., & Bernoux, M. (2020). Landscape-scale spatial modelling of deforestation, land degradation, and regeneration using machine learning tools. *Land Degradation & Development*, 31(13), 1699–1712. <https://doi.org/10.1002/ldr.3526>

- Insaf, Moh. (2004). *Fenomena Urbanisasi Kawasanpinggiran Kota Jakarta (Studi Kasus: Desa Bojonggede Kecamatan BojonggedeKabupaten Bogor)*. <https://www.semanticscholar.org/paper/92feb4d66eee95791c49bb6bd2962ba52fa55ad8>
- Intan, P. T., Notosudjono, D., & Mansyur, U. (2024). Potensi dan Pengembangan Kawasan Agrowisata Berwawasan Lingkungan di Kecamatan Ciomas Kabupaten Bogor Provinsi Jawa Barat. *Jurnal Teknik | Majalah Ilmiah Fakultas Teknik UNPAK*. <https://doi.org/10.33751/teknik.v25i1.10216>
- Iqtashada, & Febrita, J. (2023). Pengaruh Tata Guna Lahan terhadap Kualitas Air Sungai Cisadane di Kota Bogor. *Jurnal Teknik Sipil dan Lingkungan*. <https://doi.org/10.29244/jsil.8.1.9-18>
- Jaya, B., Rustiadi, E., Fauzi, A., & Pravitasari, A. E. (2021). Land conversion and availability of agricultural land in 2035 in Puncak Area Bogor Regency. *IOP Conference Series: Earth and Environmental Science*, 694(1), 012052. <https://doi.org/10.1088/1755-1315/694/1/012052>
- Karra, K., Kontgis, C., Statman-Weil, Z., Mazzariello, J. C., Mathis, M., & Brumby, S. P. (2021). Global land use / land cover with Sentinel 2 and deep learning. *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*, 4704–4707. <https://doi.org/10.1109/IGARSS47720.2021.9553499>
- Landis, J. R., & Koch, G. G. (1977). The Measurement of Observer Agreement for Categorical Data. *Biometrics*, 33(1), 159. <https://doi.org/10.2307/2529310>
- Larrea-Gallegos, G., & Vázquez-Rowe, I. (2022). Exploring machine learning techniques to predict deforestation to enhance the decision-making of road construction projects. *Journal of Industrial Ecology*, 26(1), 225–239. <https://doi.org/10.1111/jiec.13185>
- Liu, H., Homma, R., Liu, Q., & Fang, C. (2021). Multi-scenario prediction of intra-urban land use change using a cellular automata-Random Forest model. *ISPRS International Journal of Geo-Information*, 10(8), 503. <https://doi.org/10.3390/ijgi10080503>
- Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., & Johnson, B. A. (2019). Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 152, 166–177. <https://doi.org/10.1016/j.isprsjprs.2019.04.015>
- Mariati, Y., Widiarti, W. Y., & Halik, G. (2022). Analisis Perubahan Tata Guna Lahan Pada DAS Tanggul Menggunakan Remote Sensing. *Jurnal Rekayasa Sipil Dan Lingkungan*, 6(2), 153. <https://doi.org/10.19184/jrsl.v6i2.16340>
- Mellor, A., Boukir, S., Haywood, A., & Jones, S. (2015). Exploring issues of training data imbalance and mislabelling on *Random Forest* performance for large area land cover classification using the ensemble margin. *ISPRS Journal of Photogrammetry and Remote Sensing*, 105, 155–168. <https://doi.org/10.1016/j.isprsjprs.2015.03.014>
- Monsaputra, M. (2023). Analisis perubahan penggunaan lahan pertanian menjadi perumahan di kota Padang Panjang. *Tunas Agraria*, 6(1), 1–11. <https://doi.org/10.31292/jta.v6i1.200>

- Nabila, D. A. (2023). Pemodelan prediksi dan kesesuaian perubahan penggunaan lahan menggunakan Cellular Automata-Artificial Neural Network (CA-ANN). *Tunas Agraria*, 6(1), 41–55. <https://doi.org/10.31292/jta.v6i1.203>
- Pham, Q. B., Ali, S. A., Parvin, F., Van On, V., Sidek, L. M., Đurin, B., Cetl, V., Šamanović, S., & Minh, N. N. (2024). Multi-spectral remote sensing and GIS-based analysis for decadal land use land cover changes and future prediction using *Random Forest* tree and artificial neural network. *Advances in Space Research*, 74(1), 17–47. <https://doi.org/10.1016/j.asr.2024.03.027>
- Qin, Y., Xiao, X., Wigneron, J.-P., Ciais, P., Brandt, M., Fan, L., Li, X., Crowell, S., Wu, X., & Doughty, R. (2021). Carbon loss from forest degradation exceeds that from deforestation in the Brazilian Amazon. *Nature Climate Change*, 11(5), 442–448. <https://doi.org/10.1038/s41558-021-01026-5>
- Rodriguez-Galiano, V. F., Ghimire, B., Rogan, J., Chica-Olmo, M., & Rigol-Sanchez, J. P. (2012). An assessment of the effectiveness of a *Random Forest* classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67, 93–104. <https://doi.org/10.1016/j.isprsjprs.2011.11.002>
- Sachro, S. S., Edhisono, S., Atmodjo, P. S., & Prasetyo, W. (2017). Korelasi Klasifikasi Penutup Lahan dengan Debit Puncak di Daerah Aliran Sungai. *Media Komunikasi Teknik Sipil*, 23(2), 157–165. <https://doi.org/10.14710/mkts.v23i2.16687>
- Saha, S., Saha, M., Mukherjee, K., Arabameri, A., Ngo, P. T. T., & Paul, G. C. (2020). Predicting the deforestation probability using the binary logistic regression, *Random Forest*, ensemble rotational forest, REPTree: A case study at the Gumani River Basin, India. *Science of The Total Environment*, 730, 139197. <https://doi.org/10.1016/j.scitotenv.2020.139197>
- Saini, R., & Rawat, S. (2023). Land use land cover classification in remote sensing using machine learning techniques. *2023 1st International Conference on Innovations in High-Speed Communication and Signal Processing (IH CSP)*, 99–104. <https://doi.org/10.1109/IH CSP56702.2023.10127126>.
- Tapsi, S. Al, Baga, L. M., & Feryanto, F. (2025). Analisis kluster pengembangan sektor pertanian di Kabupaten Bogor berbasis karakteristik kewirausahaan pertanian. *Region: Jurnal Pembangunan Wilayah dan Perencanaan Partisipatif*. <https://doi.org/10.20961/region.v20i1.87909>
- Undang-Undang Republik Indonesia Nomor 16 Tahun 2016 tentang Pengesahan Paris Agreement to the United Nations Framework Convention on Climate Change. (2016). Lembaran Negara Tahun 2016 Nomor 204, Tambahan Lembaran Negara Nomor 5939.
- UNFCCC. (2015). Paris Agreement. *Conference of the Parties (COP) 21*. [https://unfccc.int/sites/default/files/english\\_paris\\_agreement.pdf](https://unfccc.int/sites/default/files/english_paris_agreement.pdf)
- Virtriana, R., Deanova, M. A., Safitri, S., Anggraini, T. S., Ihsan, K. T. N., Deliar, A., & Riqqi, A. (2024). Identification of land cover change and spatial distribution based on topographic

variations in Java Island. *Ecological Frontiers*, 44(1), 129–142.  
<https://doi.org/10.1016/j.chnaes.2023.08.002>

Virtriana, R., Sumarto, I., Deliar, A., Pasaribu, U. S., & Taufik, Moh. (2015). *Identification of Bogor regency land cover change index based on geospatial data*. 060004.

<https://doi.org/10.1063/1.4915056>

Yuan, K., Zhu, Q., Zheng, S., Zhao, L., Chen, M., Riley, W. J., Cai, X., Ma, H., Li, F., & Wu, H. (2021). Deforestation reshapes land-surface energy-flux partitioning. *Environmental Research Letters*, 16(2), 024014. <https://doi.org/10.1088/1748-9326/abd8f9>

Yuan, K., Zhu, Q., Zheng, S., Zhao, L., Chen, M., Riley, W. J., Cai, X., Ma, H., Li, F., Wu, H., & Chen, L. (2021). Deforestation reshapes land-surface energy-flux partitioning. *Environmental Research Letters*, 16(2), 024014. <https://doi.org/10.1088/1748-9326/abd8f9>

Zanella, L., Folkard, A. M., Blackburn, G. A., & Carvalho, L. M. T. (2017). How well does *Random Forest* analysis model deforestation and forest fragmentation in the Brazilian Atlantic Forest? *Environmental and Ecological Statistics*, 24, 529–549. <https://doi.org/10.1007/s10651-017-0389-8>