



Pemetaan Klasifikasi dan Analisis Perubahan Vegetasi Mangrove di Pantai Indah Kapuk Tahun 2013 dan 2023

Nabila Randrika Putri¹, Rully Firmansyah Suryo Andriyanto², Laila

Fakarisma Agustin³, Robert Kurniawan⁴

^{1, 2, 3, 4}Program Studi D-IV Statistika, Politeknik Statistika STIS

¹212112235@stis.ac.id

²212112341@stis.ac.id

³212112146@stis.ac.id

⁴robertk@stis.ac.id

Corresponding author email: 212112235@stis.ac.id

Abstract: Mangroves are a collection of small trees that grow abundantly in the tidal zones of river deltas, lagoons, estuaries and coastal systems. According to the Ministry of Environment and Forestry, there has been deforestation of 12,647 hectares per year. This environmental issue threatens all mangrove vegetation throughout Indonesia, including the area of Pantai Indah Kapuk (PIK) in North Jakarta City and Tangerang Regency. As a result of massive development and human activities, mangrove land in the PIK area is indicated to have decreased over the last decade. The aim of this research is to observe changes in the area of mangrove forests in the Pantai Indah Kapuk area in 2013 and 2023. The method used in this research is Classified and Regression Tree (CART) using Landsat 8 imagery. The accuracy used to assess accuracy is overall accuracy. From the classification results, it was found that the area of mangrove land in 2013 was 16,612 km², then reduced to 14,532 km². This situation occurs because of the changes of mangrove land use.

Keywords: mangrove, CART, Landsat Image

Abstrak: Mangrove merupakan sekumpulan dari pohon kecil yang tumbuh subur di zona pasang surut delta sungai, laguna, muara, dan sistem pesisir. Menurut Kementerian Lingkungan Hidup dan Kehutanan, telah terjadi deforestasi dengan luas 12.647 hektar per tahun. Isu lingkungan ini mengancam seluruh vegetasi mangrove di seluruh Indonesia, tak terkecuali di kawasan Pantai Indah Kapuk (PIK) yang berada di Kota Jakarta Utara dan Kabupaten Tangerang. Akibat pembangunan dan aktivitas manusia secara masif, lahan mangrove di kawasan PIK terindikasi mengalami penurunan selama satu dekade terakhir. Tujuan dari penelitian ini adalah untuk mengamati perubahan luas hutan mangrove yang ada di kawasan Pantai Indah Kapuk pada tahun 2013 dan 2023. Metode yang digunakan dalam penelitian ini adalah Classified and Regression Tree (CART) dengan menggunakan citra Landsat 8. Akurasi yang digunakan untuk penilaian akurasi adalah akurasi keseluruhan. Dari hasil klasifikasi, didapatkan hasil bahwa luas lahan mangrove tahun 2013 sebesar 16,612 km² kemudian berkurang menjadi 14,532 km². Hal ini disebabkan karena adanya perubahan alih fungsi lahan mangrove.

Kata kunci: mangrove, CART, Citra Landsat

I. PENDAHULUAN

Mangrove merupakan sekumpulan dari pohon kecil yang tumbuh subur di zona pasang surut delta sungai, laguna, muara, dan sistem pesisir di daerah tropis, subtropis, dan beberapa pantai beriklim sedang [1]. Sebagai habitat, mangrove terdapat di seluruh dunia di zona tropis dan subtropis di dunia, terutama tersebar di antara garis lintang 25° LU dan 25° S, tetapi batas geografis sangat bervariasi tergantung pada wilayah dunia dan iklim lokal [2]. Pada tahun 2022, Indonesia bersama Brazil, Nigeria, Australia, dan Mexico, menyumbang sebanyak 50% total mangrove dunia [3]. Menurut Kementerian Lingkungan Hidup dan Kehutanan, Indonesia menyumbang sebesar 20-25% dari ekosistem mangrove dunia atau sebesar 3,36 juta hektar pada tahun 2022 [3].

Mangrove memiliki produktivitas yang tinggi dan memiliki banyak kebaikan dan pelayanan. Salah satunya sebagai tempat yang menyediakan bahan organik dalam siklus kehidupan biota perairan, seperti udang, ikan, dan moluska [4]. Untuk menjaga ekosistem kehidupan makhluk hidup, mangrove dapat menyerap karbondioksida yang ada di udara dan mengolah sampah organik yang ada di lautan dengan cara menetralkan zat beracun yang disebabkan oleh limbah kimia [4]. Keberadaannya juga mampu



memberikan perlindungan fisik terhadap kawasan pesisir pantai dari terpaan ombak, abrasi, tsunami, angin kencang, lumpur sedimentasi, dan lainnya [4].

Walaupun Indonesia memiliki jumlah *mangrove* yang besar, perubahan ekosistem dan perusakan lingkungan terus terjadi di Indonesia. Menurut data *Global Mangrove Alliance*, sebanyak 67% *mangrove* telah terdegradasi hingga saat ini dan sebanyak 1% *mangrove* hilang setiap tahunnya [5]. Menurut Kementerian Lingkungan Hidup dan Kehutanan, telah terjadi penurunan *mangrove* seluas 430 ribu hektare dari tahun 1985 hingga 2019, atau setara dengan deforestasi dengan luas 12.647 hektar per tahun. Selain itu, menurut penelitian yang telah dilakukan, 33,6% dari 3,31 juta hektar *mangrove* telah terdegradasi [6]. Menurut penelitian yang telah dilakukan, sebanyak 22% dari 4,1 juta hektare *mangrove* Indonesia telah terdegradasi sejak tahun 1800-an hingga tahun 2012 [7]. Pulau yang mengalami kehilangan hutan *mangrove* adalah Pulau Jawa, yaitu sebesar 75% [7]. Hal ini terjadi karena kawasan *mangrove* telah dikonversi menjadi berbagai jenis penggunaan lahan. Banyak pemerintah di berbagai belahan dunia menganggap kawasan *mangrove* merupakan lahan kosong yang lebih baik digunakan untuk kepentingan lain sehingga dieksploitasi secara menyeluruh [8]. Akibatnya, kawasan *mangrove* bertransformasi menjadi area persawahan, perkebunan, bahkan pemukiman.

Adanya urbanisasi membuat perkotaan semakin padat sehingga dibutuhkan kawasan pemukiman baru. Menurut data Badan Informasi Geospasial, hampir semua kota yang ada di pesisir pantai mengandung hutan *mangrove* dengan total terdapat 15.000 hektare *mangrove* [7]. Jakarta Utara merupakan salah satu kota yang memiliki pesisir pantai. Wilayah kota ini diperluas melalui reklamasi pantai dengan luas lahan baru sebesar 5100 lahan baru atau membentang dari Barat ke Timur Teluk Jakarta seluas 490 kilometer persegi. Pulau reklamasi ini berada di kawasan Pantai Indah Kapuk (PIK) 1 [7]. Proyek ini tentu berdampak pada kawasan *mangrove* yang berada di sekitar pembangunan wilayah PIK. Pembangunan pulau reklamasi ini sempat terhenti karena masalah Analisis Dampak Lingkungan (AMDAL). Proyek ini dilanjutkan kembali pada tahun 2014 berdasarkan SK Gubernur DKI Jakarta No 2238 Tahun 2014 [9]. Pada kawasan tersebut, banjir parah dan penurunan tanah di bagian pesisir kota pernah terjadi [10]. Peristiwa ini menunjukkan bahwa terdapat masalah serius di kawasan pesisir Kota Jakarta Utara. Hal ini menunjukkan betapa pentingnya hutan *mangrove* untuk menjaga kehidupan manusia.

Penelitian mengenai degradasi *mangrove* di kawasan PIK telah dilakukan oleh peneliti sebelumnya. Salah satunya, penelitian yang berfokus pada perubahan *mangrove* di kawasan PIK pada tahun 2010-2015 dengan metode *Maximum Likelihood* [11]. Hasil menunjukkan bahwa terdapat pengurangan lahan *mangrove* di salah satu kawasan PIK sebesar 44% [11]. Namun, pemetaan perubahan area *mangrove* di kawasan PIK dari tahun 2013 hingga tahun 2023 belum pernah dilakukan. Pengamatan pemetaan *mangrove* sebelum pembangunan PIK dilanjutkan kembali. Pengamatan ini dapat dilakukan dengan metode *Classified and Regression Tree* (CART). Metode ini sudah pernah digunakan untuk pemetaan *mangrove* di kawasan Kabupaten Asmat Provinsi Papua, tetapi penggunaannya bertujuan untuk membandingkan beberapa metode mana yang lebih baik dalam mengklasifikasikan kawasan *mangrove* [12]. Oleh karena itu, tujuan dari penelitian ini adalah untuk mengamati pemetaan dan perubahan luas hutan *mangrove* yang ada di kawasan Pantai Indah Kapuk 1 yang berada di Kota Jakarta Utara dan Pantai Indah Kapuk 2 yang berada di Kabupaten Tangerang pada tahun 2013 dan 2023 dengan menggunakan CART.



II. LANDASAN TEORI DAN METODE

II.1. Landasan Teori

Penelitian ini didasarkan pada teori resiliensi. Teori resiliensi merupakan suatu teori yang menggambarkan kemampuan individu untuk berubah secara konstruktif saat menghadapi tekanan atau situasi yang tidak diinginkan [13]. Sebuah penelitian yang menyelidiki tentang perubahan vegetasi *mangrove* di seluruh dunia tahun 2022 menunjukkan hasil bahwa tata guna lahan dan transformasi tutupan lahan terkait dengan bencana alam merupakan faktor utama yang mengancam *mangrove* di masa depan [14]. Penelitian terkait lahan *mangrove* lainnya pada tahun 2020 di Teluk Jakarta yang menunjukkan bahwa kawasan bakau yang kaya karbon masih rentan terhadap pembangunan reklamasi lahan [10]. Pemanfaatan penambangan pasir untuk reklamasi lahan mengancam kawasan kaya karbon dan selanjutnya mempengaruhi percepatan perubahan iklim melalui hilangnya karbon [10]. Selanjutnya, penelitian mengungkapkan bahwa dari tahun 2000 hingga 2016, sekitar 62% kehilangan *mangrove* global disebabkan oleh perubahan penggunaan lahan, terutama untuk akuakultur dan pertanian, dengan hingga 80% dari kehilangan ini terjadi di enam negara Asia Tenggara, sementara ancaman alami terhadap *mangrove* meningkat seiring dengan penurunan kehilangan akibat aktivitas manusia [15]. Fenomena ini juga diperjelas oleh penelitian pada tahun 2023 yang menyebutkan bahwa aktivitas manusia terus mengancam keberlangsungan *mangrove* seperti praktik penangkapan ikan yang tidak berkelanjutan, pembangunan pesisir, dan polusi, terutama di Asia-Pasifik [16]. Sementara pada penelitian di Teluk Dalam Shenzhen (SZIB) di tahun 2020 menyatakan bahwa pelaksanaan proyek reklamasi tanah menghasilkan pengendapan signifikan di SZIB, yang menyeimbangkan efek negatif dari kenaikan permukaan laut, berkontribusi pada 209,9 ha ekspansi *mangrove* dengan menyediakan ruang akomodasi yang sesuai dan menyumbang 78,4% dari total peningkatan *mangrove* [17].

1. Mangrove

Mangrove adalah hutan pesisir yang terbentang antara daratan dan laut di daerah tropis dan subtropis di seluruh dunia [18]. Hutan mangrove merupakan kumpulan pohon dan semak yang dapat tumbuh dalam kondisi ekologi yang dinamis dengan konsentrasi oksigen tanah yang bervariasi dan aliran air asin [19, 20, 21]. Karena memiliki keanekaragaman hayati, hutan mangrove dikenal sebagai "hutan hujan di laut" [22]. Hutan mangrove adalah tempat tinggal bagi flora dan fauna lokal, yang menyediakan barang-barang penting seperti makanan dalam bentuk akuakultur dan pertanian, kayu bakar, bahan bangunan, serta herbal dan obat-obatan tradisional. Selain itu, hutan mangrove melindungi lingkungan pesisir dengan meminimalkan dampak parah dari bencana alam, termasuk banjir, badai, dan tsunami, menahan perubahan salinitas, menyerap karbon atmosfer, mengurangi erosi, dan mendukung keanekaragaman hayati [23].

2. Band 1

Band ini mengukur band pesisir/aerosol, yang digunakan untuk mendeteksi air dangkal dan melacak partikel halus seperti debu dan asap. Band ini memiliki rentang panjang gelombang 0,433-0,453 μm dan resolusi 30 meter [24].

3. Band 2

Band ini mengukur band biru, yang digunakan untuk menangkap cahaya biru yang terlihat. Band ini memiliki rentang panjang gelombang 0,450-0,515 μm dan resolusi 30 meter [24].

4. Band 3

Band ini mengukur band hijau, yang digunakan untuk menangkap cahaya hijau yang terlihat. Band ini memiliki rentang panjang gelombang 0,525-0,600 μm dan resolusi 30 meter [24].



5. Band 4

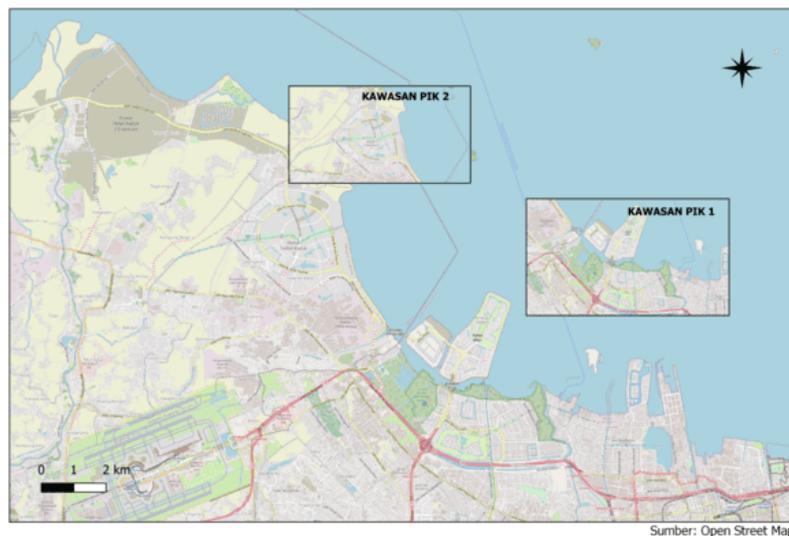
Band ini mengukur band merah, yang digunakan untuk menangkap cahaya merah yang terlihat. Band ini memiliki rentang panjang gelombang 0,630-0,680 μm dan resolusi 30 meter [24].

II.2. Metode

2.2.1. Waktu dan Tempat

Penelitian ini menggunakan data citra Landsat 8 untuk selanjutnya dilakukan klasifikasi dan analisis. Kawasan yang menjadi fokus penelitian adalah kawasan Pantai Indah Kapuk (PIK) yang digambarkan oleh koordinat ROI (*Region of Interest*). Data citra yang diambil berasal dari *Google Earth Engine* (GEE) dari koleksi gambar Landsat 8 ('LANDSAT/LC08/C02/T1_L2') pada tahun 2013 dan 2023.

Kawasan Pantai Indah Kapuk (PIK) terletak pada dua kabupaten/kota yang berbeda. PIK 1 terletak di sekitar kawasan pesisir yang ada di Kota Jakarta Utara, sedangkan kawasan PIK 2 terletak di Kabupaten Tangerang. Kawasan PIK 1 tidak hanya yang ada di daratan Jakarta Utara, tetapi juga termasuk dua pulau reklamasi, yaitu Pulau Pantai Kita dan Pulau Pantai Maju. Untuk detail kawasan PIK, dapat dilihat di Gambar. 1.



Gambar 1. Peta Kawasan Pantai Indah Kapuk



Gambar 2. Alur penelitian

Gambar 2 tersebut menyajikan alur yang dilakukan dalam penelitian ini. Tahapan-tahapan tersebut dirincikan, sebagai berikut:

a. Prapengolahan Citra

Proses pra pengolahan dimulai dari studi literatur-literatur yang berkaitan dengan topik dan masalah penelitian. Lalu dilakukan pembuatan peta gambaran umum wilayah amatan penelitian dengan aplikasi QGIS 3.20.1 untuk mendeskripsikan peta kawasan PIK. Peta utama yang digunakan selanjutnya dibuat inset peta untuk menjelaskan wilayah pada peta utama dengan wilayah lain yang mengelilinginya. Inset peta dalam penelitian ini berfungsi juga untuk memperjelas suatu daerah, utamanya yang terlihat kecil dalam peta utama.

b. Ekstraksi Data

Pengumpulan dan pengolahan citra dilakukan pada laman situs GEE pada bagian *code editor* dengan sintaks JavaScript. Dengan GEE, dapat dilakukan pengumpulan data, pengolahan, analisis, dan visualisasi data dengan menggunakan peta [25]. Proses pengolahan citra mencakup pembentukan area pelatihan (*training area*) dan segmentasi citra [26]. Pembentukan area pelatihan bertujuan untuk mengelompokkan piksel individu menjadi kelompok piksel berdasarkan kesamaan nilai spektral, yang kemudian akan dianalisis [27]. Area pelatihan merupakan langkah untuk mengidentifikasi atau menentukan area contoh atau objek yang akan mewakili setiap kelas berdasarkan data lapangan [28]. Pemilihan area pelatihan dilakukan dengan melakukan survei lapangan untuk mencari koordinat setiap kelas yang ada, seperti *mangrove*, air, lahan terbangun, vegetasi hijau lainnya. Pembentukan area pelatihan dilakukan dengan membentuk poligon pada setiap kelas klasifikasi berdasarkan titik referensi yang digunakan [29]. Pembentukan poligon dimaksudkan untuk mengklasifikasikan



titik referensi masing-masing kelas klasifikasi agar bisa diklasifikasikan berdasarkan kelasnya [30].

Segmentasi citra dilakukan sebagai langkah awal dalam metode klasifikasi berbasis objek, di mana setiap region atau wilayah dibuat [31]. Segmentasi citra menggunakan algoritma segmentasi multiresolusi dengan tiga parameter, yaitu skala, bentuk, dan kekompakan, yang akan mempengaruhi jumlah, ukuran, dan bentuk dari objek segmen citra yang dihasilkan untuk sampel pengujian (*training sample*) yang akan diklasifikasikan [32]. Nilai parameter yang digunakan pada citra Landsat 8 ditentukan secara eksperimen oleh pengguna melalui proses segmentasi berulang untuk menemukan nilai parameter yang sesuai dengan citra yang digunakan [33].

c. Pembagian Data Pelatihan dan Pengujian

Penelitian ini membagi data pelatihan dan pengujian secara acak untuk memastikan validitas model klasifikasi yang akan dikembangkan berikutnya. Proses diawali dengan pemilihan dataset citra Landsat 8 yang telah dipilih untuk ditambahkan kolom acak pada setiap sampel data. Kemudian data diseleksi untuk membagi menjadi dua subset yaitu data pelatihan dan pengujian. Sejumlah 75% dari total data yang memiliki nilai acak kurang dari 0,75 ditetapkan sebagai data pelatihan, sedangkan 25% sisanya yang memiliki nilai acak lebih besar atau sama dengan 0,75 ditetapkan sebagai data pengujian [34]. Pembagian ini dilakukan untuk memastikan bahwa model mendapatkan variasi atau ragam yang cukup untuk pelatihan serta memiliki data yang memadai untuk evaluasi performa melalui pengujian [35]. Metode ini memberikan pendekatan yang seimbang dan tidak bias saat membagi data. Hal ini penting untuk menghindari *overfitting* serta memastikan generalisasi model yang baik [36].

d. Pembangunan Model Klasifikasi

Classified and Regression Tree (CART) merupakan metode yang digunakan dalam pembentukan model klasifikasi. CART adalah model nonparametrik yang terutama berfungsi untuk mengidentifikasi subkelompok anggota yang memiliki karakteristik serupa secara eksklusif dan lengkap, di mana karakteristik tersebut mempengaruhi variabel dependen [37]. Hasil dari model ini disajikan berdasarkan aturan tertentu yang mudah dipahami dan divisualisasikan. Algoritma CART membentuk pohon biner dengan node-node yang terbagi berdasarkan jawaban ya/tidak sebagai nilai prediksi [38]. Salah satu keunggulan model ini adalah kemampuan untuk menggunakan variabel bebas berupa bilangan, biner, atau kategori. Pemilihan variabel prediktor untuk menyusun pohon dilakukan dengan tujuan meminimalkan kesalahan data [39]. Ketika menggunakan CART untuk memprediksi data baru, nilai yang hilang diatasi dengan penggantian [40]. Nilai prediksi pada simpul terminal dihitung sebagai rata-rata dari nilai respons di simpul tersebut. Aturan pengambilan sampel optimal dari algoritma CART didasarkan pada perbandingan langsung target di dua node anak. Aturan tersebut berdasarkan pada hubungan [39]:

$$I(\text{Split}) = [0,25(q(1-q))^u \sum_k |PL(k) - PR(k)|]^2 (1)$$

keterangan,

k : kelas target

PL(k) : distribusi probabilitas target di simpul anak kiri

PR(k) : distribusi probabilitas target di simpul anak kanan



u : penalti yang dapat dihukum pengguna dalam pembuatan perpecahan ukuran yang tidak sama

e. Uji Akurasi

Pada proses penilaian akurasi citra, penelitian ini menggunakan Matriks kesalahan (*Confusion Matrix*) sebagai alat untuk mengamati perbedaan dalam klasifikasi, seperti kelebihan piksel dari suatu kelas dibanding kelas lainnya atau kekurangan piksel dalam setiap kelas. Langkah selanjutnya adalah mengevaluasi akurasi klasifikasi untuk menilai sejauh mana hasil klasifikasi citra sesuai dengan kondisi lapangan. Ketepatan hasil klasifikasi tergambarakan melalui nilai akurasi pembuat (*Producer Accuracy*), akurasi pengguna (*User Accuracy*), serta akurasi keseluruhan (*Overall Accuracy*). Bentuk matriks kesalahan disampaikan pada Tabel 1 sebagai berikut [41]:

Tabel 1. Bentuk Matriks Kesalahan

Kelas Referensi	Data Sampel				Jumlah Piksel	Akurasi Pembuat
	A	B	C	D		
A	X_{11}	X_{12}	X_{13}	X_{14}	X_{1+}	X_{11}/X_{1+}
B	X_{21}	X_{22}	X_{23}	X_{24}	X_{2+}	X_{22}/X_{2+}
C	X_{31}	X_{32}	X_{33}	X_{34}	X_{3+}	X_{33}/X_{3+}
D	X_{41}	X_{42}	X_{43}	X_{44}	X_{4+}	X_{44}/X_{4+}
Total Piksel	X_{+1}	X_{+2}	X_{+3}	X_{+4}	N	
Akurasi Pengguna	X_{11}/X_{+1}	X_{22}/X_{+2}	X_{33}/X_{+3}	X_{44}/X_{+4}	X_{ii}	

Sumber: (Foody, 2002)

Akurasi pembuat (*Producer Accuracy*) adalah probabilitas atau kemungkinan seberapa besar suatu data lapangan telah diklasifikasikan dengan tepat. Rumus untuk menghitung akurasi pembuat dapat dirumuskan dalam persamaan 2 sebagai berikut [41]:

$$\text{Akurasi pembuat} = \frac{X_{ii}}{X_{+i}} \times 100 \quad (2)$$

Akurasi pengguna (*User Accuracy*) adalah probabilitas bahwa suatu piksel dalam peta secara tepat mewakili kelas yang sesuai di lapangan. Rumus untuk menghitung akurasi pengguna dapat diungkapkan dalam persamaan 3 berikut [41]:

$$\text{Akurasi pengguna} = \frac{X_{ii}}{X_{i+}} \times 100 \quad (3)$$

Overall Accuracy (OA) adalah suatu teknik yang digunakan untuk menguji akurasi secara keseluruhan dari kelas-kelas hasil klasifikasi. Rumus untuk menghitung akurasi keseluruhan dapat diungkapkan dalam persamaan 4 berikut [41]:

$$\text{Akurasi keseluruhan} = \frac{\sum_{i=1}^r X_{ii}}{N} \times 100 \quad (4)$$

keterangan,

- N : jumlah semua piksel yang digunakan untuk pengamatan
- X_{ii} : nilai diagonal dari matriks kesalahan baris ke -i dan kolom ke-i
- X_{+i} : jumlah piksel dalam kolom ke-i
- X_{i+} : jumlah piksel dalam baris ke-i
- r : jumlah baris atau lajur pada matriks kesalahan (jumlah kelas)



f. Perhitungan dan Perbandingan Luas Lahan Mangrove

Setelah model klasifikasi didapatkan dan uji akurasi telah dilakukan, proses dilakukan dengan menghitung luas lahan mangrove tahun 2013 dan 2023 menggunakan Google Earth Engine (GEE). Proses awal dilakukan dengan menambahkan band piksel area ke citra yang telah diklasifikasikan untuk membuat gambar area. Kemudian, dilanjutkan dengan penggunaan fungsi `reduceRegion` dengan reduksi `sum` dan pengelompokan berdasarkan kelas untuk menghitung total luas setiap kelas dalam wilayah kajian (roi) dengan resolusi 30 meter dengan hasil berupa daftar luas untuk setiap kelas yang dievaluasi menggunakan fungsi `evaluate`, dan diubah menjadi *objek dictionary*. Luas setiap kelas kemudian dikonversi dari meter persegi ke kilometer persegi dengan membagi nilai luas dengan 1 juta hingga pada akhirnya dapat ditampilkan hasil luas area untuk setiap kelas di *console*.

III. HASIL DAN PEMBAHASAN

Identifikasi karakteristik penggunaan lahan dapat dilakukan dengan menyajikan data citra dan mengkombinasikan beberapa band. Dalam hal ini, peneliti menggunakan band 1, band 2, band 3, dan band 4. Penggunaan kombinasi band tersebut sudah cukup untuk melakukan klasifikasi lahan di kawasan PIK. Setelah melakukan digitasi pada beberapa sampel klasifikasi dan menjalankan metode klasifikasi CART maka dilanjutkan dengan menghitung akurasi menggunakan matriks kesalahan.

Tabel 2. Matriks Kesalahan Tahun 2013

Kelas Aktual	Data Sampel				Total Piksel	Akurasi Pembuat
	Air	Bangunan	Mangrove	Vegetasi		
Air	167	9	38	18	232	0,720
Bangunan	11	140	11	33	195	0,718
Mangrove	36	6	128	18	188	0,681
Vegetasi	12	31	13	92	148	0,622
Total Piksel	226	186	190	161	763	
Akurasi Pengguna	0,739	0,753	0,674	0,571	0,691	

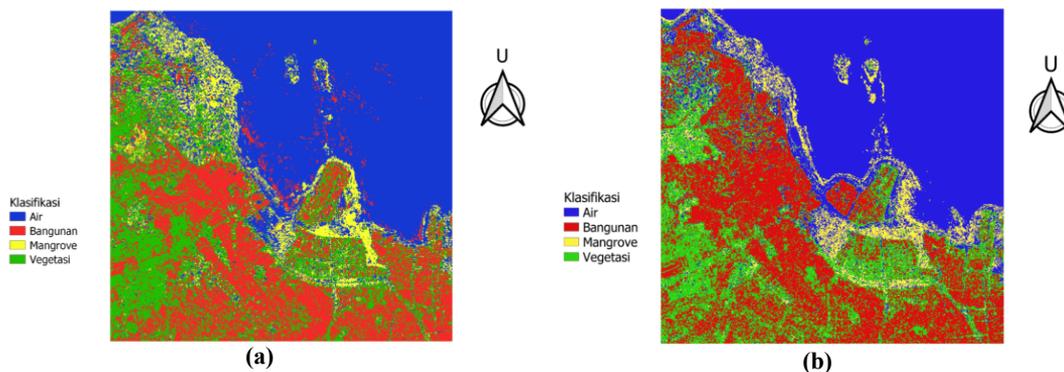
Tabel 3. Matriks Kesalahan Tahun 2023

Kelas Aktual	Data Sampel				Total Piksel	Akurasi Pembuat
	Air	Bangunan	Mangrove	Vegetasi		
Air	154	2	60	10	226	0,681
Bangunan	2	132	1	27	162	0,815
Mangrove	54	0	130	10	194	0,670
Vegetasi	16	38	12	88	154	0,571
Total Piksel	226	172	203	135	736	
Akurasi Pengguna	0,681	0,767	0,640	0,652	0,685	

Pengklasifikasian menggunakan metode CART menghasilkan matriks kesalahan seperti pada Tabel 2 dan Tabel 3. Angka pada matriks diagonal merupakan hasil klasifikasi data lapangan yang valid. Sementara angka pada sel matriks kesalahan lainnya menunjukkan kesalahan pengklasifikasian [42]. Dari pengklasifikasian tersebut, didapatkan nilai akurasi keseluruhan sebesar 69,1 persen untuk tahun 2013 dan 68,5 persen untuk tahun 2023. Pada data citra tahun 2013, air diklasifikasikan dengan tepat sebesar 72 persen sementara sebagian besar sisanya diklasifikasikan sebagai *mangrove* kemudian pada tahun 2023, air diklasifikasikan dengan tepat sebesar 68,2 persen dan sebagian besar sisanya diklasifikasikan sebagai *mangrove* pula. Ada indikasi kesalahan pengklasifikasian yang diakibatkan oleh beberapa data sampel air dan *mangrove* mirip secara warna yang ditampilkan pada peta sehingga selama digitasi ada kemungkinan kesalahan penafsiran titik yang diidentifikasi dari band. Hal ini

semakin dipertegas pula dengan sebagian besar kesalahan pengklasifikasian pada *mangrove*, yaitu diklasifikasikan sebagai air. Secara nyata, bentuk dari *mangrove* di peta kawasan PIK 2 seolah-olah menyerupai tambak, yaitu bagian tengah berupa air dan sisi-sisinya berupa *mangrove*. Area-area ini mewakili piksel campuran yang kemungkinan besar akan diklasifikasikan sebagai air atau *mangrove*, yang dapat menjelaskan variabilitas klasifikasi yang lebih besar [43]. Dengan ini, dimungkinkan kesalahan pengklasifikasian juga lebih besar.

Tahun 2013, bangunan diklasifikasikan dengan tepat sebesar 71,8 persen sementara sebagian besar kesalahannya diklasifikasikan sebagai vegetasi. Tahun 2023, sebagian besar bangunan juga salah diklasifikasikan sebagai vegetasi sementara klasifikasi yang tepat sebesar 81,5 persen. Sebagian besar kesalahan pengklasifikasian vegetasi juga diklasifikasikan sebagai bangunan. Hanya 62,2 persen (tahun 2013) dan 57,1 persen (tahun 2023) vegetasi diklasifikasikan secara tepat. Kondisi tersebut mengindikasikan bahwa pixel pada digitasi data sampel bangunan dan vegetasi memiliki kemiripan warna sehingga memungkinkan kesalahan klasifikasi.



Gambar 3. Peta klasifikasi lahan PIK: (a) tahun 2013, (b) tahun 2023

Pada peta amatan wilayah di atas, terlihat perubahan luas lahan PIK berdasarkan klasifikasi pada tahun 2013 dan 2023 secara visual. Pengklasifikasian lahan memanfaatkan Band 1, Band 2, Band 3, dan Band 4. Hasil klasifikasi divisualisasikan menggunakan peta dengan warna biru yang menunjukkan lahan perairan, warna merah yang menunjukkan lahan bangunan, warna kuning yang menunjukkan lahan *mangrove*, dan warna hijau yang menunjukkan lahan vegetasi. Dari hasil klasifikasi, didapatkan luas lahan perairan tahun 2013 sebesar 105,051 km² yang berkurang terus menjadi 102,621 km² pada tahun 2023. Luas lahan bangunan tahun 2013 adalah sebesar 52,585 km², lalu bertambah menjadi 57,531 km² pada tahun 2023. Kemudian, luas lahan *mangrove* tahun 2013 adalah sebesar 16,612 km² terus berkurang menjadi 14,532 km². Terakhir, luas lahan vegetasi tahun 2013 adalah sebesar 44,004 km² yang juga berkurang menjadi 43,568 km².

Gambar 3b menunjukkan lahan yang digunakan untuk bangunan semakin luas dibandingkan dengan gambar 3a. Lahan bangunan divisualisasikan seolah-olah semakin memusat ke pesisir laut pada tahun 2023. Hal ini juga ditegaskan bahwa aktivitas manusia menyebabkan luas lahan *mangrove* berkurang karena adanya alih fungsi lahan menjadi permukiman dan gedung-gedung lainnya. Dari tahun 2013 hingga 2023, telah terjadi deforestasi *mangrove* sebesar 12,52%. Perubahan yang paling besar terlihat di kawasan PIK 2 yang sudah didominasi warna merah. Jika dilihat pada gambar 3a dan gambar 3b, area bangunan pada kawasan tersebut semakin meluas pada tahun 2023. Sebagai dampaknya, sebagian area *mangrove* berkurang seiring bertambahnya area bangunan. Kondisi ini sesuai dengan penelitian sebelumnya yang dilakukan pada tahun 2020 yang menyatakan bahwa penurunan *mangrove* disebabkan adanya perubahan penggunaan lahan akibat aktivitas manusia [15]. Manusia



merupakan agen perubahan utama terhadap berkurangnya area *mangrove*. Fenomena ini juga sejalan dengan penelitian lainnya yang menyimpulkan bahwa aktivitas manusia seperti pembangunan daerah pesisir mampu mengancam keberlangsungan *mangrove* [16]. Perubahan luas area *mangrove* di PIK juga diakibatkan oleh adanya penambahan pulau reklamasi. Pada umumnya, pulau reklamasi tidak berpengaruh besar terhadap menipisnya luas lahan *mangrove* selama air laut dapat dengan lancar menuju area *mangrove* [11]. Namun, terkait masalah AMDAL yang pernah terjadi di kawasan tersebut menjadikan pembangunan pulau reklamasi sebagai penyebab berkurangnya area *mangrove*.

IV. KESIMPULAN

Dari pengklasifikasian pemetaan sebaran *mangrove* pada Citra Landsat 8 yang diperoleh melalui metode CART, didapatkan nilai akurasi keseluruhan sebesar 71,99 persen. Berdasarkan hasil klasifikasi, didapatkan hasil klasifikasi dengan empat kelas, yaitu air, bangunan, *mangrove*, dan vegetasi biasa. Dari hasil klasifikasi, didapatkan luas lahan perairan tahun 2013 sebesar 105,051 km² yang berkurang terus menjadi 102,621 km² pada tahun 2023. Luas lahan bangunan tahun 2013 adalah sebesar 52,585 km², lalu bertambah menjadi 57,531 km² pada tahun 2023. Kemudian, luas lahan *mangrove* tahun 2013 adalah sebesar 16,612 km² terus berkurang menjadi 14,532 km². Terakhir, luas lahan vegetasi tahun 2013 adalah sebesar 44,004 km² yang juga berkurang menjadi 43,568 km². Dari tahun 2013 hingga 2023, telah terjadi deforestasi *mangrove* sebesar 12,52%.

REFERENSI

1. K. Liu, X. Li, X. Shi, and S. Wang, “Monitoring mangrove forest changes using remote sensing and GIS data With decision-tree learning,” *Wetlands*, vol. 28, no. 2, pp. 336–346, 2008, doi: 10.1672/06-91.1.
2. Y. S. Wang and J. D. Gu, “Ecological responses, adaptation and mechanisms of mangrove wetland ecosystem to global climate change and anthropogenic activities,” *Int. Biodeterior. Biodegrad.*, vol. 162, p. 105248, 2021, doi: 10.1016/j.ibiod.2021.105248.
3. M. Leal and M. D. Spalding, “The State of World’s Mangroves 2022,” 2022.
4. A. P. Cahyaningsih, A. K. Deanova, C. Maylani, Y. Ulumuddin, L. Kusumawati, and A. D. Setyawan, “Review: Causes and impacts of anthropogenic activities on mangrove deforestation and degradation in Indonesia,” *Int. J. Bonorowo Wetl.*, vol. 12, no. 1, pp. 12–22, Jun. 2022, doi: 10.13057/bonorowo/w120102.
5. G. M. Alliance, “Expanding the global area of mangrove habitat 20% over current extent by the year 2030.” <https://www.mangrovealliance.org/gma/> (accessed Jun. 07, 2024).
6. V. B. Arifanti, “Mangrove management and climate change: A review in Indonesia,” *IOP Conf. Ser. Earth Environ. Sci.*, vol. 487, no. 1, pp. 1–10, 2020, doi: 10.1088/1755-1315/487/1/012022.
7. M. Ilman, P. Dargusch, P. Dart, and Onrizal, “A historical analysis of the drivers of loss and degradation of Indonesia’s mangroves,” *Land use policy*, vol. 54, pp. 448–459, 2016, doi: 10.1016/j.landusepol.2016.03.010.
8. M. S. Iftekhar, “Functions and development of reforested mangrove areas: A review,” *Int. J. Biodivers. Sci. Manag.*, vol. 4, no. 1, pp. 1–14, 2008, doi: 10.1080/17451590809618179.
9. G. D. Jakarta, *Keputusan Gubernur Provinsi Daerah Khusus Ibukota Jakarta Nomor 2238 Tahun 2014 tentang Pemberian Izin Pelaksanaan Reklamasi Pulau G Kepada PT Muara Wisesa Samudra*. Indonesia, 2014.
10. N. S. Slamet, P. Dargusch, A. A. Aziz, and D. Wadley, “Mangrove vulnerability and potential carbon stock loss from land reclamation in Jakarta Bay, Indonesia,” *Ocean Coast. Manag.*, vol. 195, p. 105283, 2020, doi: 10.1016/j.ocecoaman.2020.105283.
11. D. Mulyaningsih, I. B. Hendarto, and M. R. Muskananfolo, “Perubahan Luas Hutan Mangrove di Wilayah Pantai Indah Kapuk, Jakarta Utara Tahun 2010-2015,” *J. Maquares*, vol. 6, no. 4, pp. 442–448, 2017, doi: 10.14710/marj.v6i4.21334.
12. M. Kamal, I. Jamaluddin, A. Perala, and N. M. Farda, “Comparison of Google Earth Engine (GEE)-based machine learning classifiers for mangrove mapping,” in *The 40th Asian Conference on Remote Sensing, ACRS 2019: Progress of Remote Sensing Technology for Smart Future*, 2019, pp. 1–8.



13. M. Ungar, *Multisystemic Resilience: Adaptation and Transformation in Contexts of Change*. New York: Oxford University Press, 2021. doi: 10.1093/oso/9780190095888.003.0040.
14. T. V. Tran, R. Reef, and X. Zhu, “A Review of Spectral Indices for Mangrove Remote Sensing,” *Remote Sens.*, vol. 14, no. 19, pp. 1–29, 2022, doi: 10.3390/rs14194868.
15. L. Goldberg, D. Lagomasino, N. Thomas, and T. Fatoyinbo, “Global declines in human-driven mangrove loss,” *Glob. Chang. Biol.*, vol. 26, no. 10, pp. 5844–5855, 2020, doi: 10.1111/gcb.15275.
16. Vardi Venkateswarlu, Chenji Venkatrayulu, Adelina Jaya Harsha M, and Govardhan Reddy G, “Review on mangrove restoration: Re-greening the sea coast,” *GSC Biol. Pharm. Sci.*, vol. 22, no. 3, pp. 130–143, 2023, doi: 10.30574/gscbps.2023.22.3.0112.
17. Z. Feng *et al.*, “Dynamics of mangrove forests in Shenzhen Bay in response to natural and anthropogenic factors from 1988 to 2017,” *J. Hydrol.*, vol. 591, p. 125271, 2020, doi: 10.1016/j.jhydrol.2020.125271.
18. K. Judith, *Exploring interstitiality with mangroves: Semiotic materialism and the environmental humanities*. New York: Routledge, 2023. doi: 10.4324/9781003286493.
19. D. A. Friess *et al.*, “The State of the World’s Mangrove Forests: Past, Present, and Future,” *Annu. Rev. Environ. Resour.*, vol. 44, pp. 89–115, 2019, doi: 10.1146/annurev-environ-101718-0033302.
20. B. J. Huntley, *Ecology of Angola: Terrestrial Biomes and Ecoregions*. Cham: Springer Nature Switzerland, 2023. doi: 10.1007/978-3-031-18923-4.
21. A. Chowdhury, R. Prakash, S. Bhattacharyya, and A. Naz, *Role of Ponds as a Local Practice in Mitigating Salinity Intrusion Threats at Coastal Aquifer: A Case Study from Sundarban Biosphere Reserve, India BT - Indigenous and Local Water Knowledge, Values and Practices*. Singapore: Springer Nature Singapore, 2023. doi: 10.1007/978-981-19-9406-7_17.
22. J. W.-F. Law, P. Pusparajah, N.-S. A. Mutalib, S. H. Wong, B.-H. Goh, and L.-H. Lee, “Progress in Microbes and Molecular Biology A Review on Mangrove Actinobacterial Diversity: The Roles of Streptomyces and Novel Species Discovery A Review on Mangrove Actinobacterial Diversity: The Roles of Streptomyces and Novel Species Discovery,” *Prog. Microbes Mol. Biol.*, vol. 2, no. 1, p. a0000024, 2019.
23. H. Akram, S. Hussain, P. Mazumdar, K. O. Chua, T. E. Butt, and J. A. Harikrishna, “Mangrove Health: A Review of Functions, Threats, and Challenges Associated with Mangrove Management Practices,” *Forests*, vol. 14, pp. 1–38, 2023, doi: 10.3390/f14091698.
24. NASA Official, “Landsat 8,” *Landsat Science*, 2013. <https://landsat.gsfc.nasa.gov/satellites/landsat-8/> (accessed Jun. 07, 2024).
25. H. Tamiminia, B. Salehi, M. Mahdianpari, L. Quackenbush, S. Adeli, and B. Brisco, “Google Earth Engine for geo-big data applications: A meta-analysis and systematic review,” *ISPRS J. Photogramm. Remote Sens.*, vol. 164, pp. 152–170, 2020, doi: 10.1016/j.isprsjprs.2020.04.001.
26. A. Upadhyay and R. Kashyap, “Fast Segmentation Methods for Medical Images,” *Int. J. Comput. Appl.*, vol. 156, no. 3, pp. 18–23, 2016, doi: 10.5120/ijca2016912399.
27. F. van der Meer, “The effectiveness of spectral similarity measures for the analysis of hyperspectral imagery,” *Int. J. Appl. Earth Obs. Geoinf.*, vol. 8, pp. 3–17, 2006, doi: 10.1016/j.jag.2005.06.001.
28. T. Kavzoglu, “Increasing the accuracy of neural network classification using refined training data,” *Environ. Model. Softw.*, vol. 24, pp. 850–858, 2009, doi: 10.1016/j.envsoft.2008.11.012.
29. T. G. Whiteside, S. W. Maier, and G. S. Boggs, “Area-based and location-based validation of classified image objects,” *Int. J. Appl. Earth Obs. Geoinf.*, vol. 28, pp. 117–130, 2014, doi: 10.1016/j.jag.2013.11.009.
30. L. Matikainen and K. Karila, “Segment-based land cover mapping of a suburban area-comparison of high-resolution remotely sensed datasets using classification trees and test field points,” *Remote Sens.*, vol. 3, pp. 1777–1804, 2011, doi: 10.3390/rs3081777.
31. M. Musci, R. Q. Feitosa, and G. A. O. P. Costa, “An object-based image analysis approach based on independent segmentations,” in *Joint Urban Remote Sensing Event 2013*, 2013, vol. April 21-2, pp. 275–278. doi: 10.1109/JURSE.2013.6550718.
32. R. Al-Ruzouq, A. Shanableh, M. B. A. Gibril, and S. Al-Mansoori, “Image Segmentation Parameter Selection and Ant Colony Optimization for Date Palm Tree Detection and Mapping from Very-High-Spatial-Resolution Aerial Imagery,” *Remote Sens.*, vol. 10, pp. 1–24, 2018, doi: 10.3390/rs10091413.
33. S. I. Deliry, Z. Y. Avdan, and U. Avdan, “Extracting urban impervious surfaces from Sentinel-2 and Landsat-8 satellite data for urban planning and environmental management,” *Environ. Sci. Pollut. Res.*, vol. 28, no. 6, pp. 6572–6586, 2021, doi: 10.1007/s11356-020-11007-4.
34. J. T. Leonard and K. Roy, “On Selection of Training and Test Sets for the Development of Predictive



- QSAR Models,” *QSAR Comb. Sci.*, vol. 25, no. 3, pp. 235–251, 2006, doi: 10.1002/qsar.200510161.
35. E. W. Steyerberg, F. E. H. Jr, G. J. J. M. Borsboom, M. J. C. (Rene) Eijkemans, Y. Vergouwe, and J. D. F. Habbema, “Internal Validation of Predictive Models: Efficiency of Some Procedures for Logistic Regression Analysis,” *J. Clin. Epidemiol.*, vol. 54, pp. 774–781, 2001.
 36. M. Kuhn and K. Johnson, “Over-Fitting and Model Tuning,” in *Applied Predictive Modeling*, 2013, pp. 1–600. doi: 10.1007/978-1-4614-6849-3.
 37. H. Shafizadeh-Moghadam, R. Valavi, H. Shahabi, K. Chapi, and A. Shirzadi, “Novel forecasting approaches using combination of machine learning and statistical models for flood susceptibility mapping,” *J. Environ. Manage.*, vol. 217, pp. 1–11, 2018, doi: 10.1016/j.jenvman.2018.03.089.
 38. A. M. Youssef, H. R. Pourghasemi, Z. S. Pourtaghi, and M. M. Al-Katheeri, “Landslide susceptibility mapping using random forest, boosted regression tree, classification and regression tree, and general linear models and comparison of their performance at Wadi Tavyah Basin, Asir Region, Saudi Arabia,” *Landslides*, vol. 13, no. 5, pp. 839–856, 2016, doi: 10.1007/s10346-015-0614-1.
 39. Y. Wang, Z. Fang, H. Hong, R. Costache, and X. Tang, “Flood susceptibility mapping by integrating frequency ratio and index of entropy with multilayer perceptron and classification and regression tree,” *J. Environ. Manage.*, vol. 289, pp. 1–20, 2021, doi: 10.1016/j.jenvman.2021.112449.
 40. L. Breiman, J. Friedman, R. A. Olshen, and C. J. Stone, *Classification and regression trees*. New York: Chapman and Hall/CRC, 1984.
 41. G. M. Foody, “Status of Land Cover Classification Accuracy Assessment,” *Remote Sens. Environ.*, vol. 80, pp. 185–201, 2002, doi: 10.1007/978-981-16-5149-6_6.
 42. D. Krstinić, M. Braović, L. Šerić, and D. Božić-Štulić, “Multi-label Classifier Performance Evaluation with Confusion Matrix,” *Comput. Sci. Inf. Technol.*, vol. 1, pp. 01–14, 2020, doi: 10.5121/csit.2020.100801.
 43. J. Esteban, R. E. McRoberts, A. Fernández-Landa, J. L. Tomé, and M. Marchamalo, “A model-based volume estimator that accounts for both land cover misclassification and model prediction uncertainty,” *Remote Sens.*, vol. 12, pp. 1–24, 2020, doi: 10.3390/rs12203360.