

PENGEMBANGAN MODEL IDENTIFIKASI HABITAT BENTIK MENGGUNAKAN PENDEKATAN SEGMENTASI *OBJECT-BASED IMAGE ANALYSIS* (OBIA) DAN ALGORITMA *MACHINE LEARNING* (STUDI KASUS: PULAU PARI, KEPULAUAN SERIBU)

A MODEL DEVELOPMENT FOR BENTHIC HABITAT IDENTIFICATION USING OBJECT-BASED IMAGE ANALYSIS (OBIA) SEGMENTATION APPROACH AND MACHINE LEARNING ALGORITHM (CASE STUDY: PARI ISLAND, KEPULAUAN SERIBU)

Anang Dwi Purwanto^{1,2}, Andi Ibrahim¹, Azura Ulfa¹, Ety Parwati¹, & Achmad Supriyono¹

¹Pusat Riset Penginderaan Jauh, OR Penerbangan dan Antariksa, Badan Riset dan Inovasi Nasional (BRIN)
Jl. Kalisari No.8, Pekayon, Pasar Rebo, Jakarta Timur, Jakarta, DKI Jakarta

²Departemen Teknik Geodesi dan Geomatika, Fakultas Ilmu dan Teknologi Kebumihan, Insitut Teknologi Bandung
Jl. Ganesa 10, Bandung, Jawa Barat

e-mail : anang_depe@yahoo.com

Diterima tanggal: 27 September 2021 ; diterima setelah perbaikan: 11 Juli 2022 ; Disetujui tanggal: 19 Agustus 2022

ABSTRAK

Identifikasi dan klasifikasi habitat bentik di perairan dangkal menggunakan citra satelit semakin berkembang. Pengembangan model dalam mengidentifikasi objek habitat bentik sangat penting untuk mengisi kebutuhan pemetaan habitat bentik dengan akurasi yang memadai. Penelitian ini bertujuan untuk mengembangkan model identifikasi habitat bentik dari data citra satelit penginderaan jauh menggunakan metode segmentasi berbasis objek dan algoritma klasifikasi machine learning. Tiga pendekatan klasifikasi digital yang digunakan adalah *Support Vector Machine* (SVM), *Decision Tree* (DT), dan *Random Forest* (RF). Ketiga algoritma tersebut diterapkan pada hasil segmentasi citra berbasis objek untuk menguji akurasi dari hasil klasifikasi habitat bentik. Data yang digunakan adalah citra satelit resolusi tinggi SPOT 6 yang diakuisisi pada wilayah Gugus Pulau Pari pada 20 Mei 2020. Hasil penelitian menunjukkan pendekatan segmentasi berbasis objek membentuk pola segmen yang lebih rapat pada obyek heterogen dibandingkan dengan obyek yang relatif homogen (misalnya obyek daratan dan perairan). Algoritma *machine learning* yang diterapkan pada hasil segmentasi berbasis objek menghasilkan nilai akurasi keseluruhan (*overall accuracy*) lebih dari 70% untuk setiap algoritma, dengan rincian hasil adalah 75,83% untuk SVM, 74,17% untuk DT, dan 83,33% untuk RF. Dari ketiga algoritma *machine learning* yang diterapkan pada hasil segmentasi berbasis objek terlihat algoritma RF memiliki nilai akurasi yang paling baik dibandingkan dengan algoritma lainnya.

Kata kunci: Habitat bentik, klasifikasi, SPOT-6, *random forest*, *support vector machine*, *decision tree*.

ABSTRACT

Identification and classification of benthic habitats in shallow waters using satellite imagery is growing. Model development in identifying benthic habitat objects is critical to fill benthic habitat mapping with adequate accuracy. This study aims to develop a benthic habitat identification model using object-based segmentation methods and machine learning classification algorithms from remote sensing satellite imagery data. The three digital classification approaches used Support Vector Machine (SVM), Decision Tree (DT), and Random Forest (RF). The three algorithms are applied to the object-based image segmentation results to test the accuracy of the benthic habitat classification results. This study uses high-resolution SPOT 6 satellite imagery acquired in the Pari Island Cluster on May 20, 2020. The results show that the object-based segmentation approach forms denser segment patterns on heterogeneous objects than relatively homogeneous objects (e.g., land and water objects). The machine learning algorithm applied to the object-based segmentation results produces an overall accuracy value of more than 70% for each algorithm, with detailed results of 75.83% for SVM, 74.17% for DT, and 83.33% for RF. Among the three machine learning algorithms applied to object-based segmentation results to identify benthic habitats, the RF algorithm is known to have the best accuracy value compared to other algorithms.

Keywords: *Bentic habitat, classification, SPOT-6, random forest, support vector machine, decision tree.*

PENDAHULUAN

Habitat bentik memiliki peranan penting di zona estuari dalam menyumbangkan ekosistem pendukung untuk makhluk hidup di zona tersebut sebagai ruang untuk berlindung, tempat pengasuhan, tempat mencari makan (*foraging grounds*), tempat perlindungan untuk spesies ikan pesisir dan *invertebrate* air lainnya (Kritzer *et al.*, 2016). Kesehatan ekosistem perairan dangkal berdampak pada keberlangsungan hidup masyarakat pesisir dari sisi ekonomi dan sosial. Sayangnya kondisi habitat bentik yang juga mencakup terumbu karang dan lamun saat ini mengalami tekanan dan ancaman akibat perubahan lingkungan baik karena faktor alam maupun faktor antropogenik. Karenanya, diperlukan pemantauan secara berkelanjutan untuk mendapatkan informasi terbaru dari kondisi habitat bentik, salah satunya adalah dengan identifikasi habitat bentik secara spasial. Penginderaan jauh dapat digunakan untuk analisis, pemantauan, dan klasifikasi informasi habitat bentik. Ketersediaan data penginderaan jauh menyediakan beragam variasi dari sisi *spectral*, spasial, dan temporal, sehingga dapat diandalkan untuk mendeteksi perubahan pada permukaan bumi (Yulianto *et al.*, 2020). Selain itu, dalam memanfaatkan data penginderaan jauh untuk menghasilkan informasi pemantauan bumi, diperlukan metode klasifikasi yang efektif, dimana saat ini metode klasifikasi citra penginderaan jauh terus berkembang.

Klasifikasi objek habitat bentik di perairan dangkal berbasis penginderaan jauh secara umum dapat diproses dengan dua pendekatan yaitu berbasis piksel dan berbasis objek atau *Object-Based Image Analysis* (OBIA). Pada klasifikasi berbasis piksel, semua piksel di sebuah citra dianalisis berdasarkan informasi spektral yang ada di dalamnya dengan pendekatan otomatis (Settoui *et al.*, 2020). Klasifikasi berbasis objek membuat "*image object*" menjadi elemen utama (*central*) dari metode ini dan sebagai sebuah investigasi objek. Selain itu, segmentasi juga menjadi elemen krusial pada penerapan metode ini dalam klasifikasi citra (Lang, 2008). Metode OBIA menyegmentasikan gambar berdasarkan nilai piksel yang homogen dalam beberapa dimensi dan lokasi sehingga membentuk objek berdasarkan kesamaan bentuk, ukuran, orientasi dan distribusi (Blaschke, 2010; Baumstark *et al.*, 2016), sehingga menjadi kelas di mana setiap objek dianggap sebagai satu unit individu (Mori, *et al.*, 2014). Metode klasifikasi berbasis objek telah dibuktikan para ahli bahwa metode klasifikasi berbasis objek memberikan akurasi yang lebih baik dalam pemetaan komposisi vegetasi dan penggunaan lahan dibanding metode

klasifikasi berbasis piksel (Aryaguna *et al.*, 2014; Pratiwi *et al.*, 2020). Identifikasi obyek yang berada di daratan dan perairan menggunakan teknik penginderaan jauh membutuhkan pendekatan dan perlakuan yang berbeda. Energi gelombang elektromagnetik yang masuk ke dalam objek perairan akan lebih banyak terserap sehingga energi yang dipantulkan juga lebih sedikit (Kulsum *et al.*, 2018). Pemilihan data citra satelit dan metode klasifikasi yang tepat juga sangat menentukan tingkat akurasi dari hasil klasifikasi suatu obyek.

Algoritma yang digunakan dalam proses klasifikasi berperan penting dalam menghasilkan nilai akurasi yang tinggi, sehingga hasil klasifikasi yang dihasilkan dapat mewakili kondisi di lapangan. Zhang *et al.* (2013) memetakan 12 kelas habitat bentik menggunakan citra AVIRIS (*airborne visible/infrared imaging spectrometer*) algoritma *Random Forest* (RF) menghasilkan akurasi keseluruhan yaitu 75,1-87,9%. Anggoro *et al.*, (2015) menjelaskan metode OBIA dapat memetakan dengan baik dan bahkan menjadi metode alternatif pada pemetaan zona geomorfologi ekosistem terumbu karang suatu wilayah. Ardiyanto *et al.*, (2015) melakukan pemetaan kesehatan dan jenis *lifeform* terumbu karang dari citra Quickbird-2 menggunakan metode klasifikasi berbasis objek dan menghasilkan akurasi cukup tinggi. Mastu *et al.*, (2018) juga berhasil memetakan habitat bentik perairan dangkal dengan baik menggunakan metode klasifikasi berbasis objek (OBIA) dengan algoritma *Support Vector Machine* (SVM). Kombinasi metode OBIA dan data *WorldView-2* dapat digunakan untuk memetakan terumbu karang dengan empat kelas yaitu karang, pecahan karang, pasir, dan lamun dengan tingkat kepercayaan 76% (Selgrath *et al.*, 2016). Wahiddin *et al.*, 2015 juga menambahkan penjelasan bahwa metode klasifikasi OBIA dapat meningkatkan hasil klasifikasi sebesar 18-25% lebih baik dibandingkan teknik klasifikasi berbasis piksel. Ilyas *et al.* (2020) menggunakan klasifikasi OBIA dengan pemilihan beberapa algoritma klasifikasi diantaranya *Support Vector Machine* (SVM), *Bayes*, *K-Nearest Neighbour* (KNN), dan *Decision Tree* (DT) yang digunakan untuk melihat sebaran habitat bentik dan lamun dimana algoritma Bayes memberikan nilai akurasi tertinggi untuk pemetaan habitat bentik sebesar 70,36%.

Berdasarkan penjelasan dari uraian di atas menunjukkan penggunaan metode klasifikasi OBIA mampu memberikan tingkat akurasi klasifikasi yang cukup baik. Tujuan dari penelitian ini adalah untuk mengembangkan model identifikasi habitat bentik dari

data citra satelit penginderaan jauh menggunakan metode pendekatan segmentasi berbasis objek dan algoritma *machine learning*. Penelitian ini mencoba mengoptimalkan kemampuan metode klasifikasi OBIA dalam mengidentifikasi habitat bentik dengan menggunakan 3 (tiga) algoritma *machine learning* sekaligus diantaranya *Support Vector Machine* (SVM), *Decision Tree* (DT) dan *Random Forest* (RF) Kombinasi metode segmentasi dengan algoritma *machine learning* memberikan alternatif metode yang menghasilkan akurasi lebih tinggi daripada metode klasifikasi lainnya. Penelitian ini diharapkan dapat menghasilkan model identifikasi habitat bentik dari data citra satelit penginderaan jauh dengan akurasi yang sangat memadai.

BAHAN DAN METODE

Area Studi

Gugus Pulau Pari merupakan salah satu pulau dari rangkaian pulau kecil yang ada di Kepulauan Seribu, DKI Jakarta. Gugus Pulau Pari terdiri dari pulau-pulau kecil yang mencakupnya, meliputi Pulau Pari, Pulau Tengah, Pulau Burung, Pulau Kongsu, dan Pulau Tikus. Keberadaan pulau tersebut disatukan oleh terumbu karang sebagai pembatas bagian terluar antara pesisir dan laut lepas (Wouthuyzen & Abrar, 2020). Kondisi geomorfologi yang unik membuat Gugus Pulau Pari memiliki ekosistem pesisir yang cukup kompleks karena adanya ekosistem padang lamun, terumbu karang, dan juga mangrove.

Lokasi penelitian ini dibatasi dengan koordinat $106^{\circ}32'53''$ - $106^{\circ}39'41''$ BT dan $5^{\circ}49'20''$ - $5^{\circ}53'16''$ LS. Survei lapangan dilakukan pada 24-28 Mei 2021 di

Pulau Pari, Kepulauan Seribu. Data lapangan yang diambil berupa titik koordinat habitat bentik dan kondisi lingkungan perairan di sekitarnya serta data wawancara terhadap penduduk lokal setempat terkait kondisi sebaran habitat bentik di Pulau Pari. Hasil titik pengambilan sampel dapat dilihat pada Gambar 1. Total titik sampel yang berhasil dikumpulkan sebanyak 240 titik.

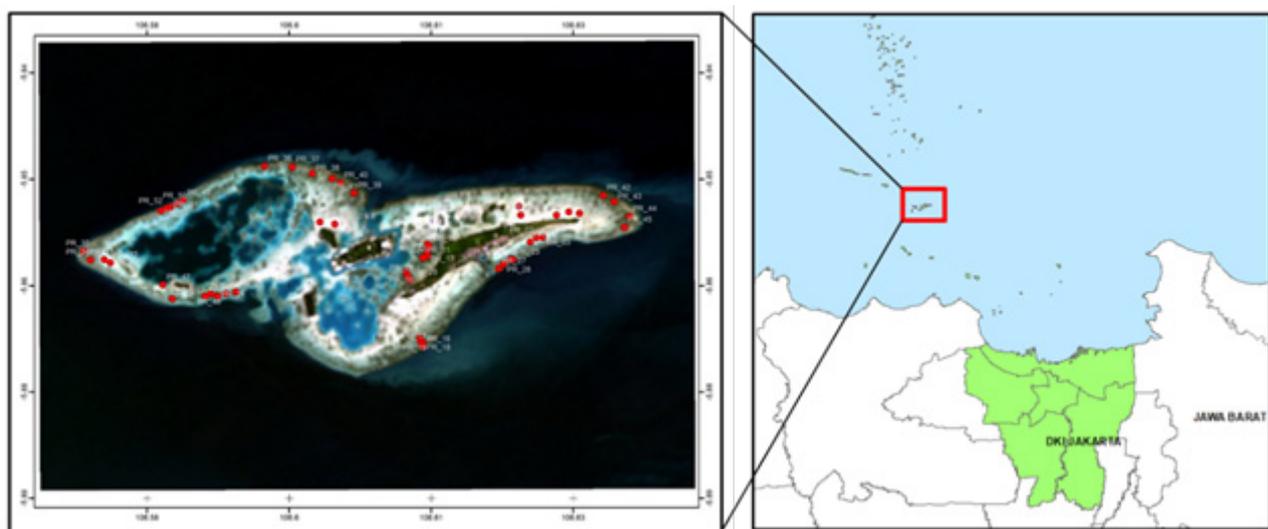
Data Satelit Penginderaan Jauh

Data yang digunakan dalam penelitian ini adalah citra SPOT 6 yang diakuisisi pada 20 Mei 2020 yang diperoleh dari Pusat Teknologi dan Data Penginderaan Jauh (Pustekdata) LAPAN. Data citra SPOT-6 memiliki resolusi spasial 6 meter untuk kanal *multispectral* dan 1,5 meter untuk kanal pankromatik, sedangkan untuk resolusi radiometrik sebesar 12 bit dan resolusi temporal selama 1-3 hari (Astrium, 2013). Karakteristik panjang gelombang dari masing-masing kanal citra SPOT-6 ditampilkan dalam Tabel 1.

Tabel 1. Karakteristik Panjang Gelombang Citra SPOT-6 (Astrium, 2013)

Table 1. Wavelength characteristics of SPOT-6 image (Astrium, 2013)

Kanal	Panjang Gelombang (μm)
Biru	0,450 - 0,520
Hijau	0,530 - 0,590
Merah	0,625 - 0,695
NIR 1	0,760 - 0,890
Pankromatik	0,450 - 0,745



Gambar 1. Lokasi Penelitian. Titik merah merupakan titik pengambilan sampel.

Figure 1. Study area. Red points are the sample points.

Pengolahan Data

Proses pengolahan data pada penelitian ini secara umum dapat dibagi menjadi tiga tahapan yaitu: (1) proses koreksi pada citra yang mencakup koreksi radiometrik, atmosferik, sunglint, dan kolom air; (2) proses segmentasi dan klasifikasi; dan (3) pengujian akurasi. Diagram alir penelitian secara komprehensif ditampilkan pada Gambar 2.

Pra-pemrosesan citra

Pengolahan awal citra meliputi koreksi radiometrik, pemotongan citra, koreksi atmosferik dan koreksi sunglint. Proses koreksi radiometrik bertujuan untuk mengubah nilai *digital number* (DN) menjadi nilai *spectral reflektan* ($L\lambda$) (Pons *et al.*, 2014). Tahapan awal adalah melakukan konversi nilai DN menjadi nilai radian menggunakan informasi Gain dan Bias dari sensor pada setiap kanal, kemudian melakukan konversi nilai dari nilai radian menjadi nilai reflektan menggunakan persamaan 1 dan persamaan 2 (Astrium, 2013):

$$L_b(p) = \frac{DC(p)}{Gain(b)} + BIAS(b) \dots\dots\dots 1)$$

$$\rho_b(p) = \frac{\pi L_b(p)}{E_0(b)\cos(\theta_s)} \dots\dots\dots 2)$$

dimana,

$DC(p)$ = *pixel digital value*

$Gain(b)$ = *gain coeficient*

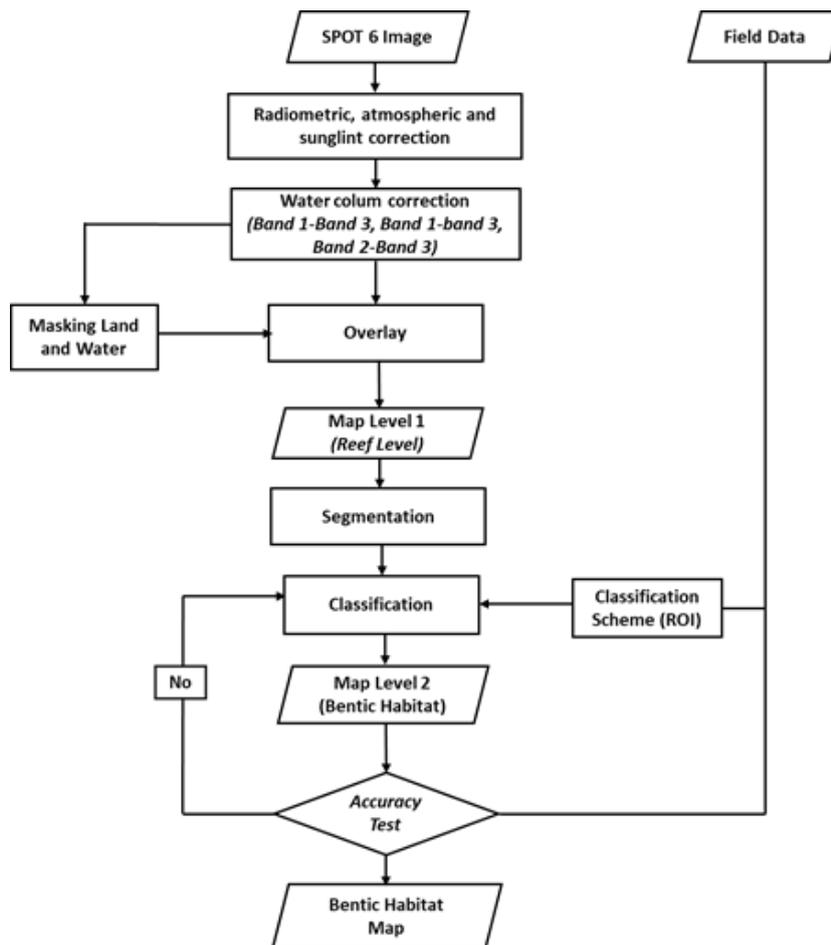
$BLAS(b)$ = *bias coeficient*

$\rho_b(p)$ = *reflectance value*

$Lb(p)$ = *radiance value*

θ = *elevation angle*

Pemotongan citra dilakukan agar lebih fokus pada lokasi kajian dan mengurangi beban kerja dari perangkat komputer yang digunakan. Koreksi atmosferik menggunakan metode paling sederhana yaitu *Dark of Substraction* (DOS). Metode DOS ini akan mengkonversi nilai spektral satelit menjadi nilai *surface reflectance* yang menggunakan asumsi pada obyek yang memiliki pantulan mendekati nol (Chavez Jr, 1996; Akbari, 2016). Tahapan awal koreksi



Gambar 2. Diagram alir penelitian.
Figure 2. Research flowchart.

atmosferik diantaranya membuat beberapa *training area* pada obyek perairan relatif dalam (Purwanto *et al.*, 2020).

Koreksi Sunglint

Koreksi *sunglint* dilakukan untuk meminimalisir *noise* yang ada yaitu berupa nilai piksel tinggi akibat pantulan sinar matahari oleh permukaan air laut yang membentuk sudut balik sempurna ke arah sensor sehingga obyek yang berada di bawah kolom air menjadi kabur atau tidak terlihat (LIPI, 2014). Proses koreksi *sunglint* menggunakan kanal-kanal *visible* (biru, hijau, merah) dan inframerah dekat (Kay *et al.*, 2009; Hafizt *et al.*, 2017) dengan persamaan sebagai berikut:

$$R_i'' = R_i - B_i * (RNIR - MinNIR) \dots\dots\dots 3)$$

Keterangan:

- R_i = Nilai reflektan pada masing-masing kanal tampak mata (*visible*)
- B_i = Nilai *regression slope* hasil statistik (kanal tampak mata (*visible*) vs kanal inframerah dekat)
- RNIR = Nilai reflektan pada kanal inframerah dekat
- MinNIR = Nilai minimum reflektan kanal inframerah dekat dari seluruh sampel yang digunakan

Koreksi Kolom Air

Gelombang elektromagnetik yang memasuki obyek perairan akan mengalami pelemahan energi sehingga dapat menyebabkan perbedaaan nilai piksel pada obyek yang sama (Green *et al.*, 2000; Hafizt *et al.*, 2017). Oleh karena itu dibutuhkan proses koreksi kolom air dalam ekstraksi habitat bentik menggunakan citra optis untuk meminimalisir pengaruh dari kolom air tersebut (Zoffoli *et al.*, 2014). Proses koreksi kolom perairan dengan menghitung nilai *Depth Invariant Index* (DII) yang menggunakan informasi dari rasio koefisien atenuasi tiap pasangan kanal sinar tampak (kanal biru, hijau dan merah) sehingga akan diperoleh tiga pasangan kanal yaitu DII biru-hijau, DII biru-merah dan DII hijau-merah. Metode koreksi kolom perairan ini menggunakan persamaan metode *Depth Invariant Index* (DII) yang dikembangkan oleh Green *et al.*, (2000) sebagai berikut:

$$Y = \ln(L_i) - \left[\left(\frac{k_i}{k_j}\right) \times \ln(L_j)\right] \dots\dots\dots 4)$$

$$\left(\frac{k_i}{k_j}\right) = \alpha + \sqrt{(\alpha^2 + 1)} \dots\dots\dots 5$$

$$\alpha = \frac{(\sigma_i + \sigma_j)}{2\sigma_j} \dots\dots\dots 6)$$

Keterangan:

- Y_{ij} = indeks kedalaman invarian
- L (λ) _i = mewakili nilai spektral dalam kanal i
- L (λ) _j = menunjukkan nilai spektral dari kanal j
- k_i / k_j = koefisien atenuasi air pada pita i dan j
- σ_{ii} = varian dari kanal i
- σ_{jj} = varian dari kanal j
- σ_{ij} = kovarians antara kanal i dan kanal j

Klasifikasi Citra

Proses klasifikasi menggunakan metode OBIA dengan algoritma klasifikasi *machine learning* diantaranya *Support Vector Machine* (SVM), *Decision Tree* dan *Random Forest*. Proses klasifikasi menggunakan input citra komposit dari 3 (tiga) pasangan kanal hasil dari koreksi kolom air (biru-hijau, biru-merah dan hijau-merah).

Skema kerja dari algoritma SVM adalah menemukan *hyperplane* (pemisah) yang terbaik untuk memisahkan dua kelas obyek yang membutuhkan *training set* positif dan negatif. Algoritma SVM ini mencoba memaksimalkan ukuran margin atau jarak antara *hyperplane* dengan titik terdekat dari masing-masing kelas dan meminimalkan kesalahan yang dicapai pada fase pelatihan (*training*) (Herdiyeni *et al.*, 2007; Pratama *et al.*, 2018, Maulik dan Chakraborty, 2017).

Algoritma *Decision Tree* menggunakan strategi pencarian *hill-climbing* untuk menemukan pohon keputusan yang akan mengklasifikasikan sampel data secara akurat dan tanpa kesalahan berdasarkan data pelatihan yang ada (Suyanto, 2011). Struktur dari algoritma ini terdiri dari beberapa tingkatan simpul (*nodes*): simpul akar (*root node*), simpul internal bercabang (*branches node*), dan simpul terminal (*leaves node*) (Berhan *et al.*, 2018). Seperti pohon yang membagi titik data ke dalam kelas yang berbeda berdasarkan apakah titik data memenuhi kriteria dalam simpul yang ada. Tujuan utama *Decision Tree* adalah menggunakan sifat dari titik data pelatihan sebagai kriteria untuk melakukan klasifikasi (Gao & Elzarka, 2021).

Random Forest adalah kumpulan dari pohon keputusan (*Decision Tree*) untuk meningkatkan akurasi pengenalan pola secara signifikan (Breiman, 2001). Setiap pengklasifikasi dibuat menggunakan vektor acak dari sampel secara independen. Selanjutnya, setiap pohon

keputusan memberikan perhitungan pada unit kelas yang paling dominan untuk mengklasifikasikan kelas-kelas tertentu yang sesuai dengan input data pelatihan (Kulkarni & Lowe 2016; Phan *et al.*, 2020) Algoritma ini sering dikenal dengan istilah *combination classifier* yang terbukti efektif dalam pengenalan pola dan dapat digunakan untuk masalah regresi dan klasifikasi dengan kumpulan data yang berukuran besar. Algoritma *Random Forest* mampu menghasilkan akurasi yang lebih tinggi dan dapat mengatasi data training sampel dalam jumlah yang besar secara lebih cepat dan efisien (Rodriguez-Galiano *et al.*, 2012; Song *et al.*, 2021; Xi *et al.*, 2022).

Penggunaan ketiga algoritma *machine learning* tersebut untuk proses klasifikasi citra sudah tersedia dalam sebuah paket algoritma klasifikasi pada aplikasi GEOBIA, sehingga dapat langsung dipilih dan digunakan untuk proses klasifikasi. Keseluruhan proses dilakukan dalam pohon proses (*process tree*) yang di dalamnya terdapat beberapa aturan utama (*rule set*) (Jhonnerie, 2015). Tahapan awal adalah melakukan segmentasi objek dengan pemilihan algoritma *Multiresolution Segmentation* (berdasarkan level piksel citra) dan dilanjutkan dengan memasukkan nilai parameter skala, *shape* dan kekompakan dimana setting parameter ini bersifat *trial and error* dan perlu dilakukan berulang-ulang untuk memperoleh hasil segmentasi yang paling optimal. Kemudian melakukan pengambilan *training area* berdasarkan poligon-poligon hasil segmentasi pada 4 (empat) kelas yang berbeda diantaranya kelas karang, lamun, *mixed-object* dan substrat. Tahapan terakhir adalah penerapan algoritma klasifikasi dengan pemilihan 3 (tiga) jenis *classifier* yang berbeda yaitu SVM (*setting kernel type linear* dengan jumlah C adalah 2), *Decision Tree* (*setting max categories* 16 dan *cross validation fold* 3) dan *Random Forest* (*setting max categories* 16, *max tree number* 50, *forest accuracy*

0,01). Algoritma-algoritma tersebut akan melatih objek yang telah ditetapkan sebagai *training area* dan juga mengeksekusi aturan klasifikasi yang telah dibuat sebelumnya (Jhonnerie, 2015).

Uji Akurasi

Uji akurasi dilakukan untuk mengetahui tingkat kesesuaian antara hasil analisis citra dengan kondisi sebenarnya di lapangan. Perhitungan uji akurasi menggunakan metode *confusion matrix* seperti yang disajikan dalam Tabel 2 (Purwadi *et al.*, 2013).

$$\text{Overall accuracy} = \frac{\sum X_{kk}}{N} \times 100\% \quad \dots\dots\dots 7)$$

$$\text{kappa} = \frac{N \sum X_{kk} - \sum X_k + X + k}{N^2 - \sum X_k + X + k} \times 100\% \quad \dots\dots\dots 8)$$

Keterangan :

- $\sum X_k$ = Total sampel diagonal yang terlaksana
- Xkk = kelas yang terlaksana
- Xk = Total kolom
- X+k = Total Baris
- N = Total sampel keseluruhan

HASIL DAN PEMBAHASAN

Pengambilan data lapangan di Pulau Pari, Kepulauan Seribu telah dilaksanakan pada 24-28 Mei 2021. Data yang diambil dalam pengamatan habitat bentik meliputi data koordinat dan data spektral untuk objek pengamatan karang, lamun, makroalga, dan substrat/pasir. Perolehan data koordinat objek pada habitat bentik dilakukan dengan mengamati objek secara langsung, lalu perekaman data koordinat menggunakan GPS dan dicatat koordinat beserta objek yang teramati. Kenampakan obyek karang (dominasi ukuran kecil dan sedang) memiliki kemiripan dengan obyek lamun, akan tetapi yg membedakan adalah dominasi sebaran

Tabel 2. Contoh table confusion matrix
Table 2. The example of confusion matrix table

Hasil Klasifikasi	Data Referensi			Total baris	Producer's Accuracy
	A	B	C		
A	X _{kk}	X+k	X _{kk} / X+ k
B	...	X _{kk}	'''
C	X _{kk}	...	'''
Total Kolom	X _k +	N	
User's accuracy	X _{kk} /		
	X _k +				

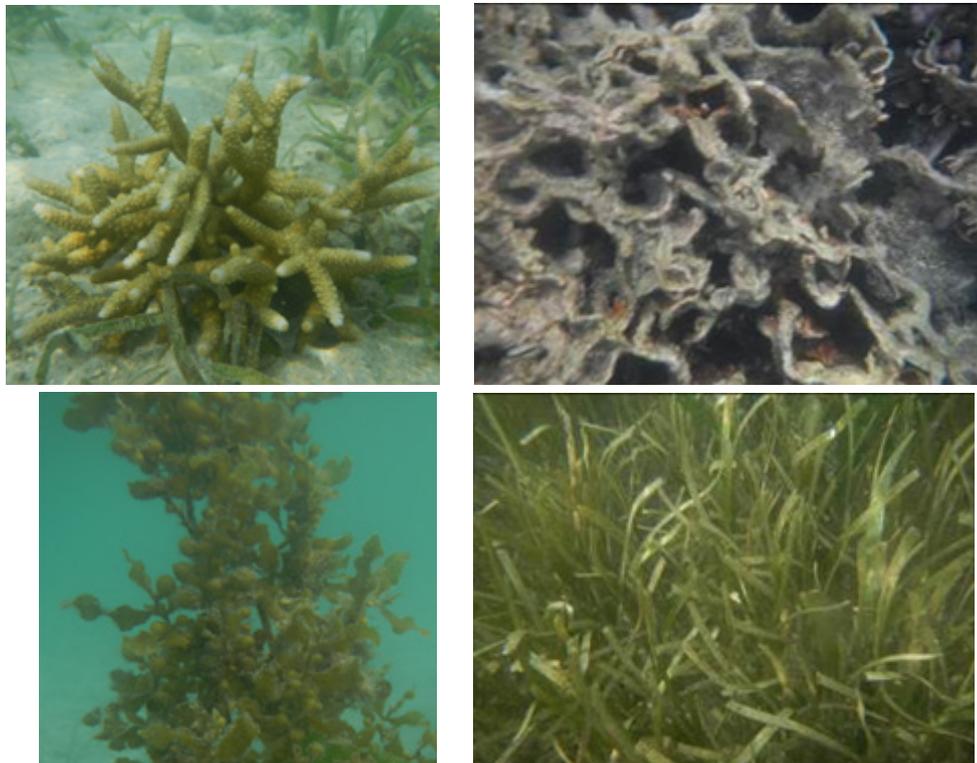
obyek lamun cenderung ditemukan pada area yang berdekatan dengan daratan pulau, sedangkan sebaran obyek terumbu banyak ditemukan pada perairan goba besar (bagian barat Pulau Pari). Obyek substrat yg terdeteksi adalah mulai kedalaman di bawah 0-2 meter. Habitat bentik di sekitar Pulau Tikus didominasi oleh lamun dimana sebaran lamun cenderung berasosiasi dengan obyek substrat. Perbandingan hasil pengamatan di lapangan dengan pengamatan menggunakan citra satelit menunjukkan kenampakan obyek yang sama antara lamun, batu hitam dan terumbu karang sehingga hal ini menjadi tantangan tersendiri bagi penulis untuk memisahkan obyek-obyek dengan kenampakan

yang sama tersebut. Obyek substrat didominasi oleh pasir, pecahan batu, pecahan karang dan batu yang berasosiasi dengan pasir putih. Makroalga banyak ditemukan di sebelah utara Pulau H akan tetapi pola sebarannya sangat tidak beraturan dan cenderung berasosiasi dengan obyek lainnya. Jenis makroalga yang paling banyak ditemukan adalah *sargassum* (alga coklat). Dokumentasi survei lapangan di Pulau Pari, Kepulauan Seribu ditampilkan pada Gambar 3.

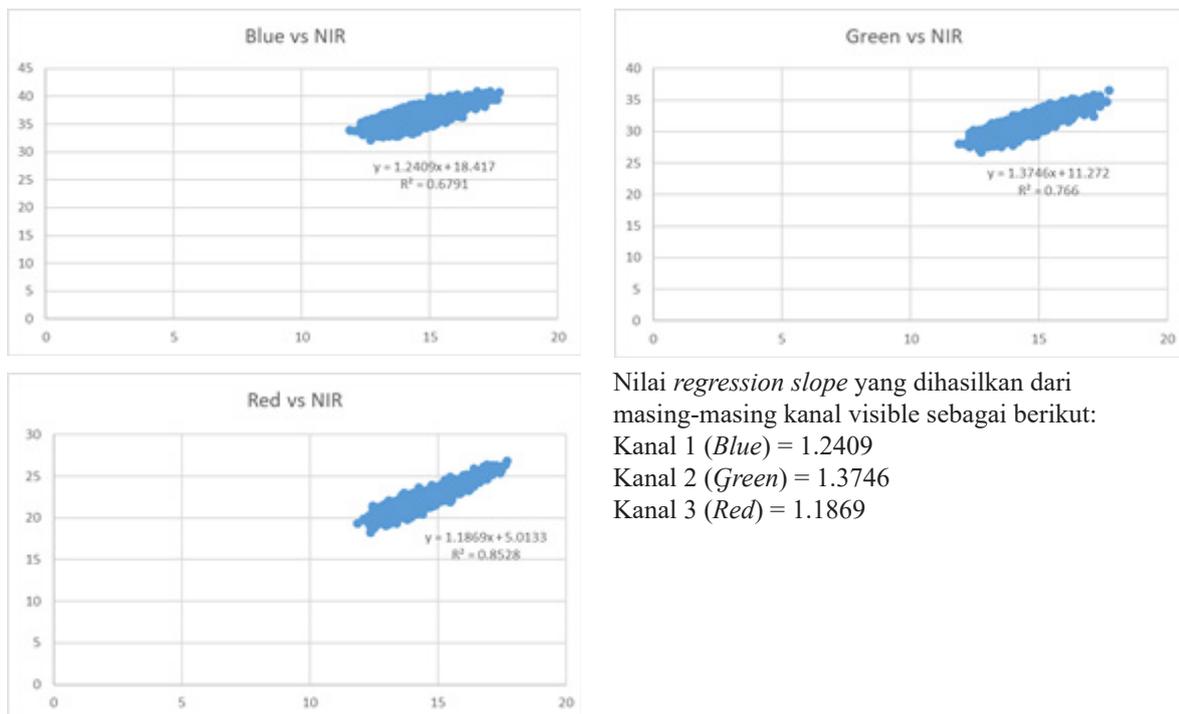
Berdasarkan hasil pengamatan lapangan, ditemukan terumbu karang dengan berbagai tipe pertumbuhan seperti *encrusting* (menyerupai batu), *branching*



Gambar 3. Proses pengambilan data lapangan.
Figure 3. Field data collection.



Gambar 4. Lamun dan Terumbu di Pulau Pari.
Figure 4. Seagrass and Reefs on Pari Island.



Nilai *regression slope* yang dihasilkan dari masing-masing kanal visible sebagai berikut:

- Kanal 1 (*Blue*) = 1.2409
- Kanal 2 (*Green*) = 1.3746
- Kanal 3 (*Red*) = 1.1869

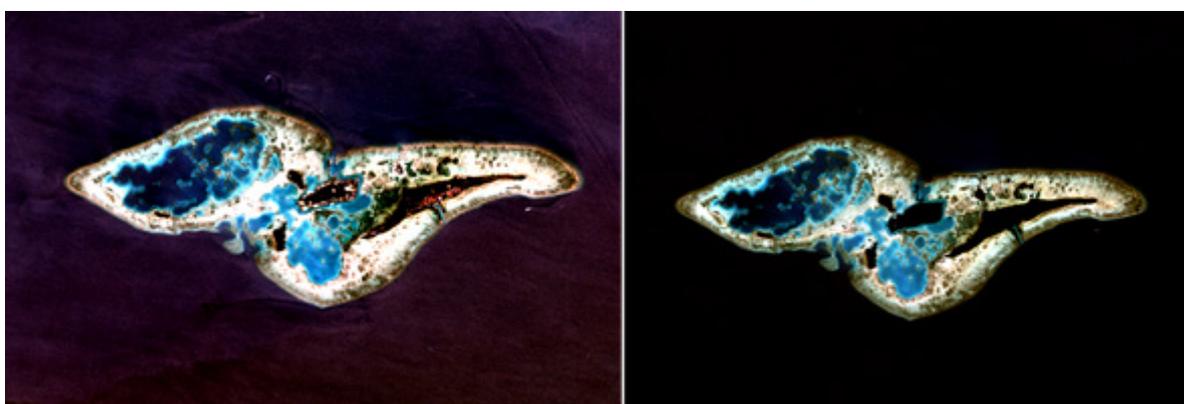
Gambar 5. Garis persamaan regresi dari koreksi *sunglint*.
 Figure 5. Regression slope of *sunglint* correction.

(bercabang), *massive* (bongkahan batu besar), dan *foliose* (lembaran). Jenis lamun yang ditemukan di perairan dangkal Pulau Pari yaitu *Enhalus acroides*, *Thalassia hemprichii*, *Syringodium isoetifolium*, *Halophila minor*, dan *Halophila ovalis*. Berdasarkan pengamatan di beberapa stasiun, spesies *Enhalus acroides* dan *Thalassia hemprichii* lebih banyak ditemukan dari spesies lainnya. Selain itu juga ditemukan makroalga dengan jenis alga cokelat atau *Phaeophyceae* yang didominasi oleh genus *Sargassum*. Hasil pengambilan foto lapangan dengan menggunakan kamera *underwater* ditampilkan pada Gambar 4.

Pra-pemrosesan Citra

Proses koreksi *sunglint* dilakukan dengan terlebih dahulu membuat *training area* pada area piksel yang memiliki efek *glint* rendah, sedang dan tinggi serta pada area yang bebas dari efek *glint*. Nilai statistik pada *training area* yang telah dibuat digunakan untuk membangun persamaan regresi antara kanal tampak mata (*visible*) dan kanal NIR. Dari ketiga persamaan yang telah dibangun menunjukkan nilai koefisien korelasi yang cukup baik. Garis persamaan regresi yang telah dibuat ditampilkan pada Gambar 5.

Hasil koreksi *sunglint* menunjukkan adanya pengurangan efek *glint* yang cukup signifikan pada permukaan laut yang ditunjukkan dengan tekstur yang



Gambar 6. Hasil koreksi *sunglint* (a) sebelum, (b) setelah.
 Figure 6. The result of *sunglint* correction (a) before, (b) after.

lebih halus seperti yang ditunjukkan pada Gambar 6. Selain itu kondisi obyek perairan dan daratan juga terlihat lebih gelap dan lebih mudah dibedakan dengan obyek habitat bentik di sekitarnya. Kondisi awan tipis juga berhasil dieliminasi dengan optimal sehingga kenampakan obyek habitat bentik juga terlihat lebih jelas dan lebih tajam dibandingkan kenampakan sebelum dilakukan koreksi sunglint.

Koreksi Kolom Air

Proses koreksi kolom air dilakukan pada masing-masing pasangan kanal *visible* yaitu kanal Biru-kanal Hijau, kanal Biru-kanal Merah dan kanal Hijau-kanal Merah. Untuk mempermudah dalam identifikasi habitat bentik maka dilakukan *masking* untuk obyek daratan-perairan terlebih dahulu dan selanjutnya dilakukan *overlay* dengan dengan peta habitat bentik aktual (hasil koreksi kolom air yang telah dilakukan komposit kanal). Hasil *overlay* dari dari kedua data tersebut selanjutnya menjadi Reef Level Map Level 1. Hasil koreksi kolom air tiap pasangan kanal *visible* dan Reef Level Map Level 1 ditampilkan pada Gambar 7.

Hasil koreksi kolom air dari pasangan kanal Biru-kanal Hijau dan kanal Biru-kanal Merah menunjukkan kenampakan obyek dengan variasi lebih banyak dibandingkan pasangan kanal Hijau-kanal Merah. Penggunaan kanal biru sangat efektif dalam koreksi kolom air karena memiliki energi pantulan paling tinggi terhadap obyek perairan dan didukung dengan kemampuan penetrasi yang paling panjang sehingga mengalami pelemahan atenuasi yang relatif lebih lama dibandingkan kanal hijau dan merah (Nurkhayati *et al.*, 2013). Untuk mempermudah dalam identifikasi habitat bentik maka dilakukan komposit RGB dari tiap

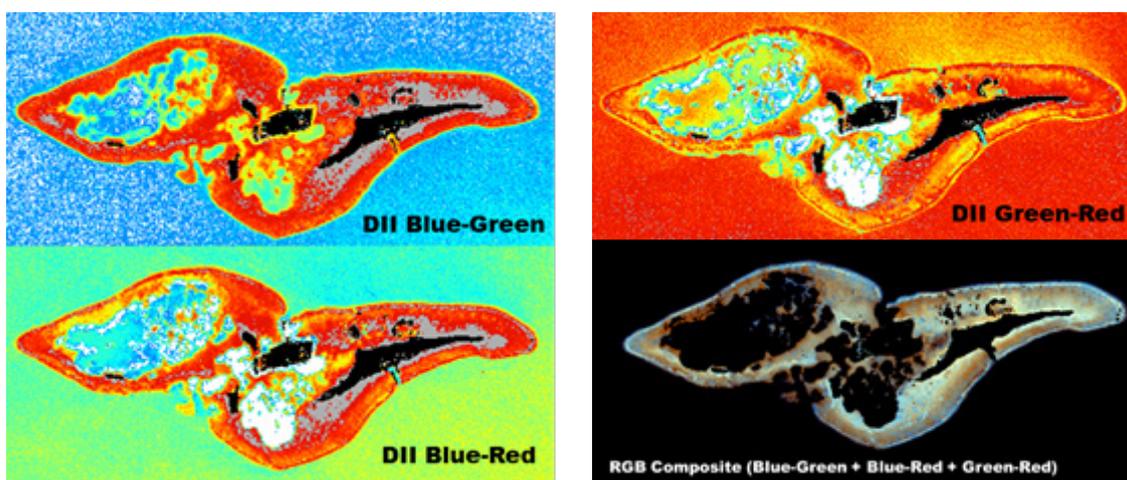
pasangan kanal tersebut. Kenampakan obyek habitat bentik pada citra komposit RGB dari ketiga pasangan kanal *visible* terlihat sangat jelas terutama pada obyek selain substrat/pasir. Proses koreksi kolom air sangat efektif dalam meminimalisir pengaruh atau gangguan yang terdapat pada area kolom perairan.

Segmentasi

Hasil dari proses segmentasi sangat mempengaruhi proses klasifikasi dalam penggunaan metode OBIA. Proses segmentasi habitat bentik dilakukan secara berulang-ulang atau bisa dikatakan *trial and error* sampai dengan diperoleh hasil yang paling optimal. Pada penelitian ini segmentasi dilakukan menggunakan algoritma *Multiresolution Segmentation* dengan nilai parameter skala 7, nilai parameter *shape* 0,2 dan nilai parameter kekompakan sebesar 0,8. Nilai parameter *shape* dan kekompakan pada penelitian ini tidak jauh berbeda dengan nilai parameter yang digunakan oleh Anggoro *et al.*, (2015) dalam melakukan proses segmentasi obyek habitat bentik di Pulau Pari yaitu sebesar 0,1 untuk parameter *shape* dan 0,9 untuk parameter kekompakan. Pola segmen yang terbentuk pada obyek yang heterogen terlihat lebih rapat dibanding pada obyek yang relatif homogen (misalnya obyek daratan dan perairan). Hasil proses segmentasi pada penelitian ini ditampilkan pada Gambar 8.

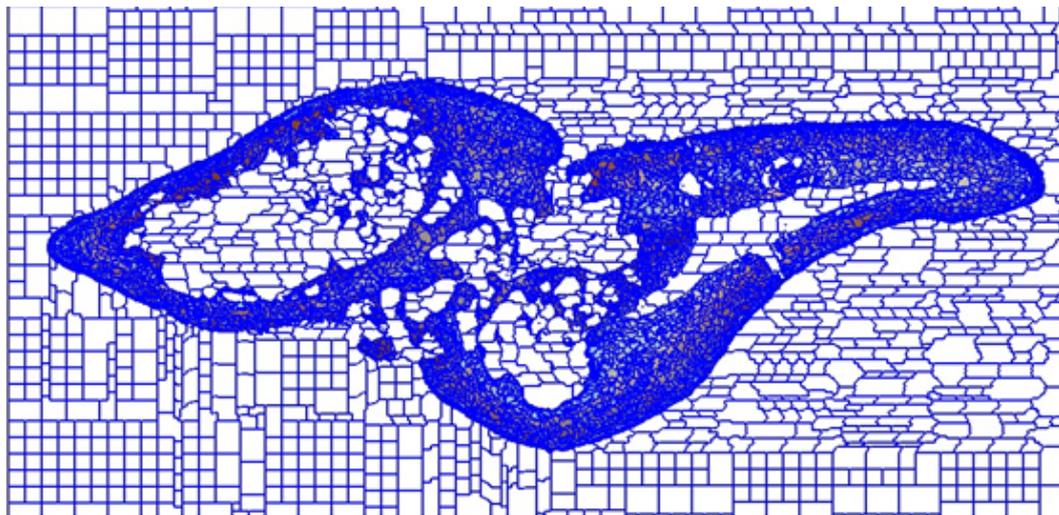
Klasifikasi OBIA Menggunakan Algoritma Machine Learning

Penelitian ini menggunakan metode klasifikasi berbasis obyek dan dengan menggunakan 3 (tiga) pendekatan algoritma *machine learning* yang berbeda diantaranya *Random Forest* (RF), *Support Vector Machine* (SVM) dan *Decision Tree* (DT). Hasil klasifikasi dari ketiga

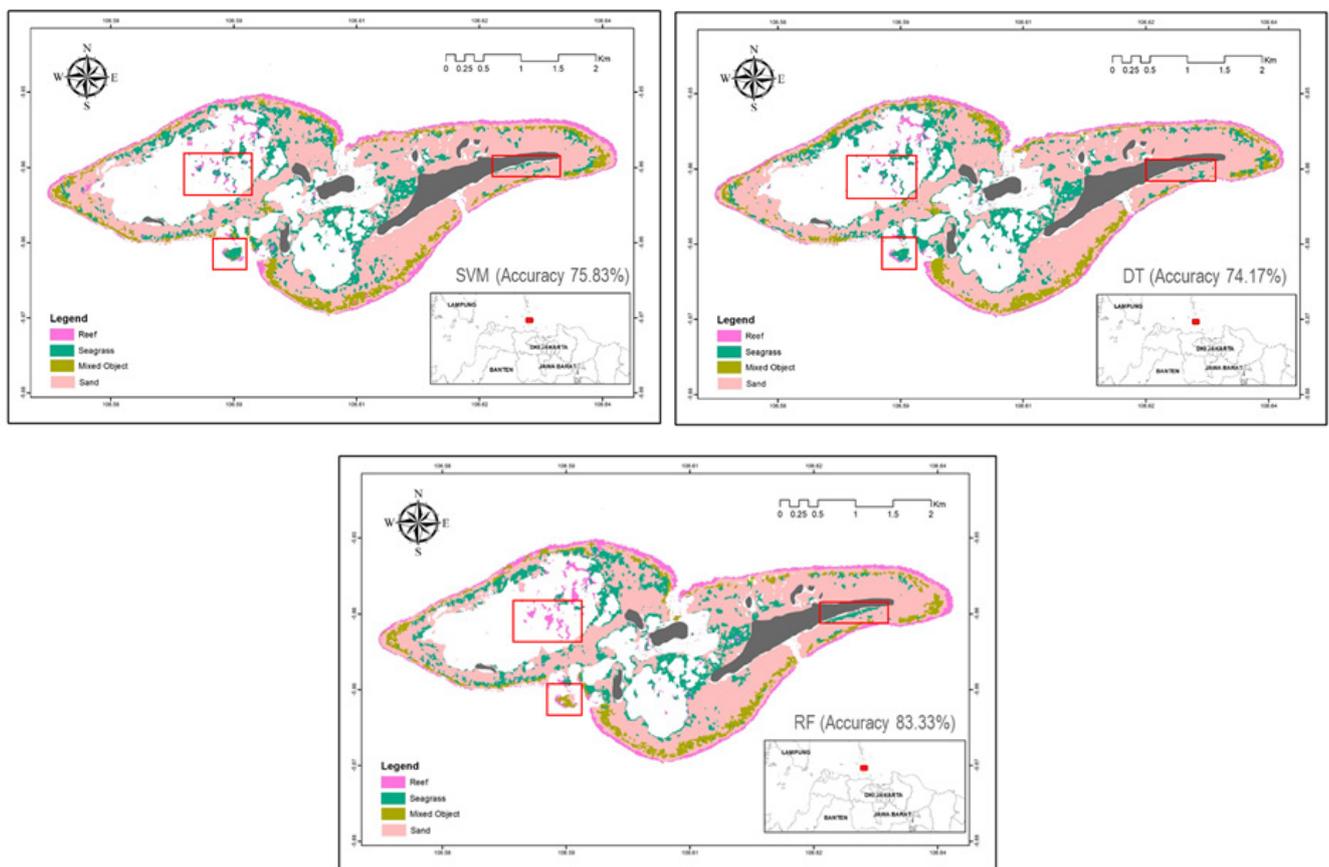


Gambar 7. Hasil koreksi kolom air.

Figure 7. The result of column water correction.



Gambar 8. Hasil proses segmentasi.
 Figure 8. The result of segmentation processing.



Gambar 9. Hasil proses klasifikasi berbasis obyek dengan menggunakan algoritma (a) *Support Vector Machine* (SVM), (b) *Decision Tree*, dan (c) *random forest*.

Figure 9. The result of object-based classification using algorithm (a) *Support Vector Machine* (SVM), (b) *decision tree*, and (c) *random forest*.

algoritma tersebut ditampilkan pada Gambar 9. Hasil klasifikasi menunjukkan obyek substrat mendominasi sebaran habitat bentik di Pulau Pari, kemudian berturut-turut diikuti oleh lamun, obyek campuran dan karang. Pola sebaran habitat bentik

relatif sama dari ketiga algoritma yang digunakan. Pola sebaran habitat bentik di Pulau Pari dari bagian terluar ke arah daratan dimulai dengan obyek terumbu, obyek campuran, obyek substrat dan obyek lamun. Obyek terumbu mendominasi pada bagian terluar

Pulau Pari dan sebagian ditemukan pada perairan goba besar yang berdekatan dengan Pulau Tikus. Obyek campuran terdiri dari asosiasi dari obyek lamun, substrat, pecahan karang, makroalga, batu, dan lain-lain mendominasi di belakang obyek terumbu, kemudian diikuti oleh substrat yang kondisi persebaran terlihat paling dominan di antara obyek lainnya. Obyek lamun berada pada bagian belakang yang berdekatan dengan daratan. Dalam penelitian ini sedikit terkendala oleh kenampakan obyek lamun yang relatif sama dengan obyek lainnya sehingga perlu digunakan pendekatan konsep asosiasi untuk identifikasi habitat bentik terutama obyek lamun.

Berdasarkan Gambar 9 juga terlihat hasil klasifikasi menggunakan algoritma *Random Forest* terlihat lebih mewakili dengan kondisi di lapangan dibandingkan algoritma SVM dan DT. Perbedaan cukup jelas dapat dilihat terutama pada pola sebaran obyek lamun dimana hasil klasifikasi menggunakan algoritma SVM dan DT menunjukkan sebaran lamun banyak ditemukan di area terluar yang berdekatan dengan karang. Selain itu, hasil klasifikasi dengan menggunakan SVM dan DT menunjukkan obyek lamun banyak ditemukan pada perairan goba besar dimana jika melihat hasil pengamatan yang ada seharusnya pada daerah tersebut

didominasi oleh obyek karang. Hasil klasifikasi menggunakan algoritma SVM dan DT juga berhasil mengidentifikasi obyek lamun dengan sebaran tipis pada sebelah timur Pulau Pari, akan tetapi hasil klasifikasi menggunakan algoritma RF menunjukkan sebaran obyek lamun dengan cakupan yang lebih luas. Beberapa kondisi perbedaan yang berkaitan dengan hasil klasifikasi dari ketiga algoritma ditampilkan dalam kotak merah pada Gambar 9.

Untuk mengetahui keakuratan hasil klasifikasi dari masing-masing algoritma perlu dilakukan perhitungan akurasi menggunakan data hasil pengukuran di lapangan yang berupa data plotting koordinat sebaran habitat bentik di Pulau Pari, Kepulauan Seribu. Data lapangan yang berhasil dikumpulkan dan dapat digunakan dalam penelitian ini sebanyak 120 titik. Hasil perhitungan akurasi menunjukkan klasifikasi menggunakan algoritma RF memiliki tingkat akurasi keseluruhan yang paling tinggi yaitu sebesar 83,33%, kemudian berturut-turut diikuti dengan algoritma SVM sebesar 75,83% dan algoritma DT sebesar 74,17%. Hasil perhitungan kappa juga menunjukkan algoritma RF memiliki nilai kappa yang paling tinggi dibandingkan algoritma lainnya. Hasil klasifikasi habitat bentik menggunakan algoritma *machine learning* juga pernah

Tabel 3. Hasil perhitungan uji akurasi SVM
Table 3. SVM accuracy test calculation results

	<i>Support Vector Machine</i>	Pengukuran Lapangan				Total User	<i>Overall Accuracy</i>	Kappa
		Karang	Lamun	Lamun Campur	Substrat			
Klasifikasi	Karang	21	2	0	0	23	75,83%	0,623
	Lamun	5	49	3	1	58		
	Lamun Campur	2	4	1	0	7		
	Substrat	2	10	0	20	32		
	Total Producer	30	65	4	21	120		

Tabel 4. Hasil Perhitungan Uji Akurasi DT
Table 4. DT Accuracy Test Calculation Results

	<i>Decision Tree</i>	Pengukuran Lapangan				Total User	<i>Overall Accuracy</i>	Kappa
		Karang	Lamun	Lamun Campur	Substrat			
Klasifikasi	Karang	20	0	0	0	20	74,17%	0,603
	Lamun	6	48	0	3	57		
	Lamun Campur	1	4	4	1	10		
	Substrat	3	13	0	17	33		
	Total Producer	30	65	4	21	120		

Tabel 5. Hasil Perhitungan Uji Akurasi RF
 Table 5. RF Accuracy Test Calculation Results

Decision Tree	Pengukuran Lapangan				Total User	Overall Accuracy	Kappa
	Karang	Lamun	Substrat	Campur			
Klasifikasi	Karang	23	0	0	23	83,33%	0,739
	Lamun	2	55	0	59		
	Lamun Campur	2	0	4	7		
	Substrat 3	10	0	18	31		
Total Producer	30	65	4	21	120		

dilakukan oleh Wicaksono *et al.*, (2019) dimana hasil klasifikasi dari algoritma RF menunjukkan tingkat akurasi yang paling tinggi sebesar 88.54%, sedangkan hasil klasifikasi dari algoritma SVM menunjukkan tingkat akurasi sebesar 75.98%. Selanjutnya hasil klasifikasi habitat bentik oleh Prabowo *et al.*, (2018) juga menunjukkan algoritma SVM memiliki tingkat akurasi yang lebih tinggi daripada algoritma DT dimana tingkat akurasi dari algoritma SVM sebesar 75.11% dan akurasi dari algoritma DT sebesar 60.34%. Gislason *et al.*, 2006 juga menyatakan bahwa keunggulan algoritma RF mampu menghasilkan tingkat akurasi relatif lebih tinggi. Hasil perhitungan tingkat akurasi klasifikasi habitat bentik di Pulau Pari selengkapnya ditampilkan pada Tabel 3, 4, 5.

KESIMPULAN DAN SARAN

Identikasi habitat bentik menggunakan kombinasi pendekatan segmentasi objek dan algoritma *machine learning* sangat membantu dalam penelitian ini. Penambahan koreksi *sunlint* pada citra dan komposit RGB dari hasil koreksi kolom air memberikan kemudahan dalam identifikasi awal sebaran habitat bentik di Pulau Pari, Kepulauan Seribu. Nilai-nilai dari parameter skala, *shape* dan kekompakan yang tepat sangat mempengaruhi hasil dari proses segmentasi objek. Konsep interpretasi citra dari unsur asosiasi juga perlu diterapkan terutama untuk membedakan obyek habitat bentik dan obyek di sekitarnya yang memiliki kenampakan sama. Dari hasil klasifikasi obyek yang telah dilakukan terlihat obyek substrat mendominasi sebaran habitat bentik di lokasi penelitian. Algoritma klasifikasi RF menunjukkan tingkat akurasi paling tinggi yaitu sebesar 83.33% dibandingkan algoritma klasifikasi lainnya. Penelitian ini masih perlu dikembangkan lagi terutama untuk penambahan jumlah kelas dari klasifikasi yang dilakukan sehingga informasi habitat bentik yang dihasilkan semakin lengkap dan komprehensif. Hal ini

tentunya membutuhkan dukungan sumber daya yang tidak sedikit mulai dari personil yang terlibat, alokasi waktu, dukungan anggaran dan lain-lain.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Prof. Dr. M. Rokhis Khomarudin, M.Si atas bantuan dan dukungan selama kegiatan penelitian ini. Terima kasih kepada Dr. Lalu Muhamad Jaelani, M.Sc sebagai penelaah yang telah memberikan banyak saran dan masukan untuk perbaikan makalah ini. Ucapan terima kasih juga disampaikan kepada Badan Riset dan Inovasi Nasional (BRIN) yang telah menyediakan akses data citra SPOT 6, Pingkan Mayestika dan masyarakat Pulau Pari yang telah membantu dalam kegiatan survei lapangan. Kontributor utama dalam penulisan makalah ini adalah Anang Dwi Purwanto dan Andi Ibrahim.

DAFTAR PUSTAKA

- Akbari, F. R. (2016). *Evaluasi Pengaruh Koreksi Atmosferik Dalam Algoritma Untuk Perhitungan Total Suspended Solid Menggunakan Citra Satelit Landsat 8*. Tesis. Faculty of Civil Engineering And Planning, Institut Teknologi Sepuluh Nopember.
- Anggoro, A, Siregar V. P., & Agus, S. B. (2015). Pemetaan Zona Geomorfologi Ekosistem Terumbu Karang Menggunakan Metode Obia, Studi Kasus Di Pulau Pari. *Jurnal Penginderaan Jauh dan Pengolahan Data Citra Digital*, 12(1).
- Ardiyanto, R., & Hartono. (2015). Pemetaan Terumbu Karang Menggunakan Metode Klasifikasi Berbasis Objek pada Citra Quickbird-2 Multispektral di Pulau Kemujan, Kepulauan Karimunjawa, Jepara, Jawa Tengah. *Jurnal Bumi Indonesia*, 4(1), 327-335.

- Aryaguna, P. A., & Danoedor, P. (2014). *Perbandingan Efektivitas Klasifikasi Berbasis Pikel dan Klasifikasi Berbasis Objek Menggunakan Citra Resolusi Tinggi Dalam Pemetaan Komposisi Floristik (Studi Kasus Gunung Tidar Kota Magelang)*. Skripsi. Fakultas Geografi UGM.
- Astrium. (2013). SPOT 6 & SPOT 7 Imagery - User Guide. France.
- Baumstark, R., Duffey, R., & Pu, R. (2016). Mapping seagrass and colonized hard bottom in Springs Coast, Florida using WorldView-2 satellite imagery. *Estuarine, Coastal and Shelf Science*, 181, 83–92. doi:10.1016/j.ecss.2016.08.019.
- Berhane, T. M., Lane, C. R., Wu, Q., Autrey, B. C., Anenkhonov, O. A., Chepinoga, V. V., & Liu, H. (2018). Decision-Tree, Rule-Based, and *Random Forest* Classification of High-Resolution Multispectral Imagery for Wetland Mapping and Inventory. *Remote Sensing*, 10(4), 580. <https://doi.org/10.3390/rs10040580>.
- Blaschke, T. (2010). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1), 2-16. <https://doi.org/10.1016/j.isprsjprs.2009.06.004>.
- Breiman, L. (2001). *Random Forests*. *Machine Learning*, 45(1), 5-32. doi:10.2307/1010933404324.
- Chavez, P. S. (1996). Image-Based Atmospheric Corrections - Revisited and Improved. *Photogrammetric Engineering and Remote Sensing*, 62, 1025-1036.
- Gao, C., & Elzarka, H. (2021). The use of *Decision Tree* based predictive models for improving the culvert inspection process. *Advanced Engineering Informatics*, 47(January 2021), 101203. doi:10.1016/j.aei.2020.101203
- Gislason, P. O., Benediktsson, J. A., Sveinsson, J. R. (2006) *Random Forests* for land cover classification. *Pattern Recognition Letters*, 27(4), 294-300.
- Green, E., Mumby, P., Edwards, A. J., & Clark, C. D. (2000). *Remote Sensing Handbook for Tropical Coastal Management*. A. J. Edwards, editor. The United Nations Educational, Scientific and Cultural Organization, Paris.
- Hafizt, M., Iswari, M. Y., & Prayudha, B. (2017). Assessment of Landsat-8 Classification Method for Benthic Habitat Mapping in Padaido Islands, Papua. *Oceanologi Dan Limnologi Di Indonesia*, 2(1), 1–13.
- Herdiyeni, Y., Buono, A., & Noornawati, V. Y. (2007). Klasifikasi Citra Dengan *Support Vector Machine* Pada Sistem Temu Kembali Citra. *Seminar Nasional Sistem dan Informatika 2007*; Bali, 16 November 2007.
- Ilyas, T. P., Nababan, B., Madduppa, H., & Kushardono, D. (2020). Pemetaan Ekosistem Lamun Dengan Dan Tanpa Koreksi Kolom Air Di Perairan Pulau Pajene kang, Sulawesi Selatan. *Jurnal Ilmu dan Teknologi Kelautan Tropis*, 12(1), 9-23.
- Jhonnerie, R. (2015). *Klasifikasi Mangrove Berbasis Objek Dan Pikel Menggunakan Citra Satelit Multispektral Di Sungai Kumbang, Bengkalis, Provinsi Riau*. Disertasi Institut Pertanian Bogor, 2-5.
- Kay, S., Hedley, J. D., & Lavender, S. (2009). Sun Glint Correction of High and Low Spatial Resolution Images of Aquatic Scenes: a Review of Methods for Visible and Near-Infrared Wavelengths. *Remote Sensing*, 1(4), 697-730.
- Kritzer, J. P., DeLucia, Mari-Beth., Greene, E., Shumway, C., Topolski, M. F., Thomas-Blate, J., Chiarella, L. A., Davy, K. B., Smith, K. 2016. The Importance of Benthic Habitats for Coastal Fisheries. *BioScience*, Volume 66, Issue 4, Pages 274–284, <https://doi.org/10.1093/biosci/biw014>
- Kulkarni, A. D., & Lowe, B. (2016). *Random Forest* algorithm for land cover classification. *International Journal on Recent and Innovation Trends in Computing and Communication*, 4(3), 58–63.
- Kulsum, I. I., & Khakhim, N. (2018). Aplikasi Penginderaan Jauh dan Sistem Informasi Geografis Untuk Monitoring Perubahan Garis Pantai Di Pesisir Kabupaten Pasuruan, Kabupaten Sidoarjo Dan Kota Surabaya. *Jurnal Bumi Indonesia*, 7(3).
- Lang, S. (2008). *Object-based image analysis for*

- remote sensing applications: modeling reality – dealing with complexity*. In: Blaschke T., Lang S., Hay G.J. (eds) *Object-Based Image Analysis. Lecture Notes in Geoinformation and Cartography*. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-540-77058-9_1
- LIPI. (2014). Pemetaan habitat dasar perairan laut dangkal yang dikeluarkan oleh LIPI. 123-134. DOI: <http://dx.doi.org/10.29244/jitkt.v10i1.21670>
- Mastu, L. K., Nababan, B., & Panjaitan, J. P. (2018). Pemetaan habitat bentik berbasis objek menggunakan citra Sentinel-2 di perairan Pulau Wangi-Wangi, Kabupaten Wakatobi. *J. Ilmu dan Teknologi Kelautan Tropis*, 10(2), 381-396.
- Maulik, U., & Chakraborty, D. (2017). Remote Sensing Image Classification: A survey of support-vector-machine-based advanced techniques. *IEEE Geoscience and Remote Sensing Magazine*, 5(1), 33–52. doi:10.1109/mgrs.2016.2641240
- Mori, M., Hirose, Y., Akamatsu, Y., & Li, Y. (2004). Object-based classification of IKONOS data for rural land use mapping. *Proceedings of XXth ISPRS Congress 35*, 1682-1750.
- Nurkhayati, R., & Khakhim, N. (2013). Pemetaan Batimetri Perairan Dangkal Menggunakan Citra Quickbird Di Perairan Taman Nasional Karimun Jawa, Kabupaten Jepara, Jawa Tengah. *JURNAL BUMI INDONESIA*, 2(2), 140-148.
- Phan, T. N., Kuch, V., & Lehnert, L. W. (2020). Land cover classification using google earth engine and *Random Forest* classifier-the role of image composition. *Remote Sensing*, 12(15), 2411. DOI:10.3390/rs12152411
- Pons, X., Pesquer, L., Cristóbal, J., & González-Guerrero, O. (2014). Automatic and improved radiometric correction of Landsat imagery using reference values from MODIS surface reflectance images. *International Journal of Applied Earth Observation and Geoinformation*, 33(December 2014), 243-254. doi.org/10.1016/j.jag.2014.06.002
- Prabowo, N. W., Siregar, V. P., & Agus, S. B. (2018). Classification of Benthic Habitat Based on Object With *Support Vector Machines* And *Decision Tree* Algorithm Using Spot-7 Multispectral Imagery In Harapan And Kelapa Island. *Jurnal Ilmu dan Teknologi Kelautan Tropis*, 10(1), 123-134. DOI: <http://dx.doi.org/10.29244/jitkt.v10i1.21670>
- Pratama, A., Wihandika, R. C. & Ratnawati, D. E. (2018). Implementasi Algoritme *Support Vector Machine* (SVM) untuk Prediksi Ketepatan Waktu Kelulusan Mahasiswa. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 2(4), 1704-1708.
- Purwanto, A. D., Prayogo, T., & Marpaung, S. (2020). Identifikasi Gosong Karang Menggunakan Citra Satelit Sentinel 2A (Studi Kasus: Perairan Pesisir Nias Utara). *Jurnal Teknologi Lingkungan*, 21(1), 95-108.
- Purwadhi, S. H., F, Rokhmatuloh., & Haryani Nanik Suryo. (2013). *Aplikasi Teknologi Penginderaan Jauh Untuk Pengembangan Wilayah*. Jakarta: Departemen Geografi Fakultas MIPA - Universitas Indonesia.
- Rodriguez-Galiano, V. F., Chica-Olmo, M., Abarca-Hernandez, F., Atkinson, P. M., & Jeganathan, C. (2012). *Random Forest* classification of Mediterranean land cover using multi-seasonal imagery and multi-seasonal texture. *Remote Sensing of Environment*, 121, 93–107.
- Selgrath, J. C., Roelfsema, C., Gergel, A. E., & Vincent, A. C. J. (2016). Mapping for coral reef conservation: comparing the value of participatory and remote sensing approaches. *Ecosphere*, 7(5), e01325. DOI:10.1002/ecs2.1325
- Settouti, N., Bechar, M. E. A., Daho, M. E. H., & Chikh, M. A. (2020). An optimised pixel-based classification approach for automatic white blood cells segmentation. *International Journal of Biomedical Engineering and Technology*, 32(2), 144-160. doi:10.1504/ijbet.2020.105651
- Song, J., Gao, Y., Yin, P., Li, Y., Li Y., Zhang, J., Su, Q., Fu, X., & Pi, H. (2021). The *Random Forest* Model Has the Best Accuracy Among the Four Pressure Ulcer Prediction Models Using Machine Learning Algorithms. *Risk Management and Healthcare Policy*, 14, 1175-1187. <https://doi.org/10.2147/RMHP.S297838>.
- Suyanto. (2011). *Artificial Inteligent* (Cetakan kedua). Informatika: Bandung.

- Wahiddin, N. (2015). *Klasifikasi ekosistem terumbu karang berbasis objek dan piksel di Pulau Morotai*. Disertasi. Institut Pertanian Bogor. Bogor.
- Wicaksono, P., Aryaguna, P. A., & Lazuardi, W. (2019). Benthic Habitat Mapping Model and Cross Validation Using Machine-Learning Classification Algorithms. *Remote Sensing* 11(11), 1279. DOI:10.3390/rs11111279
- Wouthuyzen, S., & Abrar, M. Ed. (2020). *Gugusan Pulau Pari, Kepulauan Seribu*. Jakarta: LIPI Press.
- Xi, Y., Taha, A. M. M., Hu, A., & Liu, X. (2022). Accuracy Comparison of Various Remote Sensing Data in Lithological Classification Based on *Random Forest* Algorithm. *Geocarto International*. DOI: 10.1080/10106049.2022.2088859.
- Yulianto, F., Nugroho, U. C., Nugroho, N. P., Sunarmodo, W., & Khomarudin, M. R. (2020). Spatial-temporal dynamics land use/land cover change and flood hazard mapping in the upstream Citarum watershed, West Java, Indonesia. *Quaestiones Geographicae*, 39(1), 125-146. DOI:10.2478/quageo-2020-0010
- Zhang, C., Selch, D., Xie, Z., Roberts, C., Cooper, H., & Chen, G. (2013). Object based benthic habitat mapping in the Florida Keys from hyperspectral imagery. *Estuarine, Coastal and Shelf Science*, 134(1 December 2013), 88-97. <https://doi.org/10.1016/j.ecss.2013.09.018>
- Zoffoli, M., Frouin, R., & Kampel, M. (2014). Water Column Correction for Coral Reef Studies by Remote Sensing. *Sensors*, 14(9), 16881–16931. doi:10.3390/s140916881

