

## KLASIFIKASI HABITAT DASAR BERBASIS OBJEK DI PERAIRAN DANGKAL KARANG LEBAR DAN PULAU LANCANG

### CLASSIFICATION OF BENTHIC HABITAT BASED ON OBJECT IN SHALLOW WATERS OF KARANG LEBAR AND LANCANG ISLAND

Pria Wibawa Utama<sup>1\*</sup>, Vincentius P. Siregar<sup>2</sup>, & Bisman Nababan<sup>2</sup>

<sup>1</sup>Program Studi Teknologi Kelautan, Sekolah Pascasarjana, IPB University, Bogor 16680, Indonesia

<sup>2</sup>Departemen Ilmu dan Teknologi Kelautan, Fakultas Perikanan dan Ilmu Kelautan, IPB University,  
Bogor, 16680, Indonesia

\*E-mail: priawibawautama@gmail.com

#### ABSTRACT

*The object-based classification technique (OBIA) is one of the benthic habitat mapping techniques besides the conventional (pixel-based) method. The mapping of the OBIA method using machine learning algorithms is limited to the waters of Karang Lebar and Lancang Island. This study aims to determine the performance of machine learning algorithms (support vector machine (SVM), decision tree (DT), random forest (RF), and k-nearest neighbor (KNN)) in classifying shallow water benthic habitats based on objects using Sentinel satellite data. -2. The classification method used is the OBIA method with two levels of analysis. A total of 6 benthic habitat classes were obtained from field observations and Agglomerative Hierarchical Clustering analysis, namely coral, rubble, seagrass, rubble sand, and sand. The results obtained include the first level separating land, shallow sea and deeper sea. The second level is classification using a machine learning algorithm, the results of the classification show that the SVM algorithm gets a higher accuracy value than other algorithms with an accuracy of 84% in Karang Lebar waters, then in Lancang Island waters it gets an accuracy of 80% with the SVM algorithm. The bottom habitat of the shallow waters of Karang Lebar and Lancang Island can be well mapped using the OBIA method. The difference in the level of accuracy between the waters of Karang Lebar and Pulau Lancang is caused by the level of turbidity of the waters.*

**Keywords:** benthic habitat, Karang Lebar, Lancang Island, mapping, OBIA

#### ABSTRAK

Teknik klasifikasi berbasis objek (OBIA) merupakan salah satu teknik pemetaan habitat bentik selain metode konvensional (berbasis piksel). Pemetaan metode OBIA dengan memanfaatkan algoritma *machine learning* terbatas pada perairan Karang Lebar dan Pulau Lancang. Penelitian ini bertujuan untuk mengetahui performa algoritma *machine learning* (*support vector machine* (SVM), *decision tree* (DT), *random forest* (RF), dan *k-nearest neighbour* (KNN)) dalam mengklasifikasikan habitat bentik perairan dangkal berdasarkan objek menggunakan data satelit Sentinel-2. Metode klasifikasi yang digunakan adalah metode OBIA dengan dua tingkatan analisis. Hasil analisis *Agglomerative Hierarchical Clustering* diperoleh sebanyak 6 kelas habitat bentik yaitu karang, patahan karang (*rubble*), lamun, pasir *rubble*, dan pasir. Tingkat pertama adalah memisahkan darat, laut dangkal dan laut lebih dalam. Tingkat kedua adalah klasifikasi menggunakan algoritma *machine learning*, hasil klasifikasi menunjukkan algoritma SVM mendapatkan nilai akurasi yang lebih tinggi dibandingkan algoritma lainnya dengan akurasi sebesar 84% di perairan Karang Lebar, kemudian pada perairan Pulau Lancang mendapatkan akurasi sebesar 80% dengan algoritma SVM. Habitat dasar perairan dangkal Karang Lebar dan Pulau Lancang mampu dipetakan dengan baik menggunakan metode OBIA. Perbedaan tingkat akurasi antara perairan Karang Lebar dan Pulau Lancang disebabkan oleh tingkat kekeruhan perairan.

**Kata kunci:** habitat bentik, Karang Lebar, Pulau Lancang, pemetaan, OBIA

## I. PENDAHULUAN

Habitat penyusun perairan dangkal seperti terumbu karang, lamun maupun pasir memiliki peranan penting pada biota penghuninya, selain itu juga organisme dan biota laut dapat memberikan manfaat bagi masyarakat pesisir seperti sumberdaya makanan (Yusuf, 2013). Pengelolaan dan pemahaman ekosistem perairan dangkal membutuhkan informasi spasial seperti komposisi, kondisi dan dinamika yang tepat juga relevan (Phinn *et al.*, 2012). Teknologi penginderaan jauh sangat berguna untuk mengamati wilayah pesisir yang luas maupun pulau-pulau kecil tanpa menghabiskan banyak biaya dan waktu (Hedley *et al.*, 2016). Pemanfaatan pengindraan jauh untuk mendeteksi atau memetakan wilayah pesisir dapat menghasilkan informasi yang dapat digunakan untuk pemantauan perubahan yang terjadi di perairan dangkal.

Pemanfaatan penginderaan jauh dalam pemetaan habitat bentik dasar perairan dangkal umumnya dilakukan dengan metode klasifikasi berbasis piksel (Zhang, 2015; Ben-Romdhane *et al.*, 2016; Wilson *et al.*, 2019; Siregar *et al.*, 2020). Kelebihan metode klasifikasi berbasis piksel adalah pendeteksian objek yang lebih mendetail dengan piksel tunggal, sedangkan kekurangan pada klasifikasi metode piksel adalah hasil yang kasar dan terdapat *noise* (Rastner *et al.*, 2014). Pendekatan lainnya adalah dengan metode klasifikasi citra berbasis objek (OBIA). Pendekatan ini menghasilkan peta multi-skala, ataupun hierarki ketika digabungkan dengan citra beresolusi tinggi. Pendekatan OBIA memungkinkan integrasi segmentasi dan proses klasifikasi (Phinn *et al.*, 2012). Kelebihan metode klasifikasi berbasis objek adalah tingkat akurasi yang dihasilkan lebih baik dibandingkan klasifikasi piksel, terdapat *rule-set* yang memudahkan dalam pengaturan parameter klasifikasi, kemampuan transfer yang lebih tinggi, serta

kurang bergantung pada data tambahan, sedangkan kekurangan dari klasifikasi ini adalah waktu komputasi yang tinggi pada data yang besar, dibutuhkan spesifikasi komputer yang baik, pengetahuan pada perangkat lunak, dan dibutuhkan perangkat lunak penginderaan jauh untuk pengolahan data setelah proses klasifikasi (Cai & Liu, 2013; Rastner *et al.*, 2014). Pemetaan terumbu karang (habitat bentik) menggunakan teknik klasifikasi OBIA pada citra satelit resolusi menengah dan tinggi, dan menerapkan algoritma klasifikasi *machine learning* seperti *Support Vector Machine* (SVM), *Random Tree* (RT), *Decision Tree* (DT), dan *k-Nearest Neighbour* (KNN) sudah pernah dilakukan sebelumnya oleh Phinn *et al.* (2012); Wahiddin *et al.* (2015); Mastu *et al.* (2018), klasifikasi OBIA menggunakan algoritma SVM mendapatkan hasil akurasi yang paling baik.

Perairan dangkal di gugusan pulau di Kepulauan Seribu memiliki beragam habitat yang dasar seperti terumbu karang, padang lamun, alga, patahan karang (*rubble*) dan pasir. Berbagai habitat bentik tersebut juga dapat ditemukan di perairan dangkal Pulau Lancang dan gugus Karang Lebar. Pulau Lancang merupakan basis perikanan tangkap untuk komoditas rajungan dan teri (Agus *et al.*, 2016). Gugus Karang Lebar merupakan kawasan konservasi laut (KKL) serta daerah wisata yang memiliki perairan yang cukup jernih dan ekosistem yang beragam (KKP, 2015). Penelitian terkait pemetaan habitat bentik masih sangat terbatas pada perairan dangkal Karang Lebar dan Pulau Lancang. Klasifikasi yang dilakukan oleh Kurniawati (2020) di Pulau Lancang dengan klasifikasi OBIA menggunakan algoritma DT pada citra Worldview-2 menghasilkan akurasi keseluruhan 74,44% pada dengan sembilan kelas habitat bentik. Penelitian lain oleh Sangadji *et al.* (2018), di Karang Lebar menggunakan klasifikasi berbasis piksel dengan algoritma Logika Fuzzy dan *maximum likelihood* (MLH) pada citra

SPOT 7 dan Sentinel-2 mendapatkan akurasi keseluruhan berturut-turut sebesar 76,4% untuk fuzzy dan 70,5% untuk ML pada citra SPOT 7 dan 72,3% untuk logika fuzzy dan 63,1% untuk MLH pada citra Sentinel-2. Sementara itu, klasifikasi habitat bentik dengan metode OBIA dengan algoritma SVM dan DT pada citra SPOT 7 yang dilakukan di Pulau Harapan dan Kelapa oleh Prabowo *et al.* (2018) mendapatkan akurasi keseluruhan sebesar 75% untuk SVM dan 60% untuk DT dengan 11 kelas klasifikasi. Siregar *et al.* (2020) di Pulau Sebaru Besar melakukan klasifikasi habitat bentik menggunakan pendekatan piksel dengan algoritma MLH pada citra Worldview-2 dan SPOT 6 mendapatkan akurasi keseluruhan sebesar 61,29% untuk Worldview-2 dan 51,61% untuk SPOT 6 dengan 8 kelas klasifikasi.

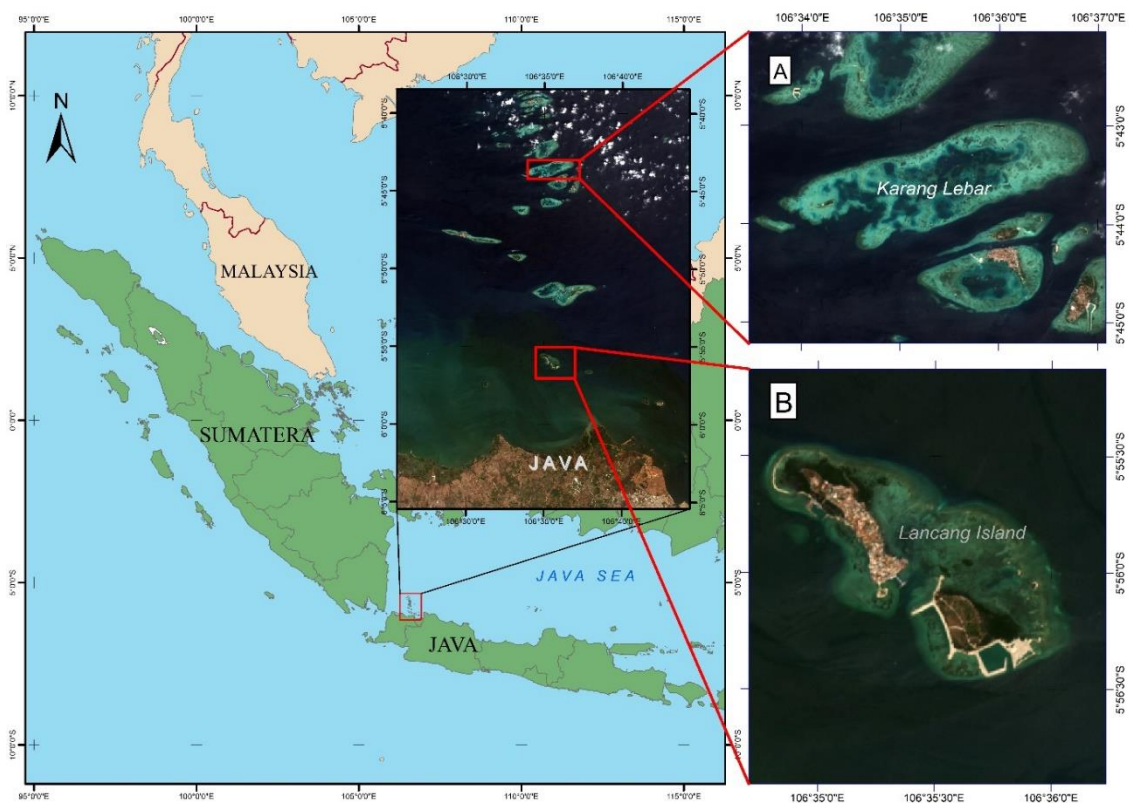
Penggunaan citra satelit Sentinel-2 dalam pemetaan habitat bentik pada perairan dangkal Karang Lebar dan Pulau Lancang

dengan menggunakan Klasifikasi OBIA masih belum banyak dilakukan. Oleh karena itu, penelitian ini bertujuan untuk memetakan habitat bentik dan mengetahui tingkat akurasi klasifikasi berdasarkan pendekatan objek (OBIA) dengan menggunakan beberapa algoritma klasifikasi seperti SVM, DT, RF dan KNN di perairan Karang Lebar dan Pulau Lancang.

## II. METODE PENELITIAN

### 2.1. Waktu dan Lokasi Penelitian

Pengamatan habitat dasar perairan dangkal dilaksanakan pada tanggal 2-6 Maret 2020 di gugus Karang Lebar dan Pulau Lancang, Kepulauan Seribu, Jakarta (Gambar 1). Karang Lebar terletak antara  $106^{\circ} 33' 45''$  -  $106^{\circ} 36' 60''$  Bujur Timur dan  $5^{\circ} 42' 55''$  -  $5^{\circ} 44' 15''$  Lintang Utara, sedangkan Pulau Lancang terletak antara  $106^{\circ} 34' 22''$  -  $106^{\circ} 57' 40''$  Bujur Timur dan  $5^{\circ} 46' 15''$  -  $5^{\circ} 59' 22''$  Lintang Selatan.



Gambar 1. Lokasi Penelitian (Karang Lebar dan Pulau Lancang). Kotak merah menggambarkan lokasi pengamatan. (A) Karang Lebar. (B) Pulau Lancang.

Kedalaman perairan saat pengambilan data berkisar dari 20 cm sampai 350 cm. Kondisi perairan cukup jernih. Habitat dasar perairan yang ditemukan di perairan dangkal Pulau Lancang dan Karang Lebar yakni karang, lamun, pasir, dan patahan karang.

## 2.2. Data dan Alat

Data yang digunakan adalah data pengamatan lapang, serta data citra satelit Sentinel-2A yang diakuisisi pada tanggal 10 Maret 2020 dengan resolusi spasial sebesar 10x10 meter dan dapat diperoleh secara gratis di <https://scihub.copernicus.eu/>. Data tambahan untuk nilai rata-rata klorofil-a (Chl-a) dan muatan padatan tersuspensi (MPT) pada bulan Maret 2020 didapatkan dari website: [marine.copernicus.eu](http://marine.copernicus.eu).

Peralatan yang digunakan untuk pengambilan data di lapang adalah alat dasar selam, alat tulis, kertas *data sheet*, meteran, transek kuadrat ukuran 1x1 meter, *Global Positioning System* (GPS) Garmin 60 Csx, dan kamera bawah air. Pengolahan dan analisis data menggunakan Laptop dengan perangkat lunak erMapper, ArcGIS, eCognition, dan Ms. Excel.

## 2.3. Pengumpulan Data

Pengamatan habitat bentik dilakukan secara langsung (*in situ*) untuk mengidentifikasi zona geomorfologi dan komponen habitat bentik dasar perairan dangkal. Penentuan stasiun lapangan dilakukan dengan menggunakan teknik *systematic random sampling*, agar stasiun pengamatan tersebar merata pada wilayah kajian. Teknik ini merupakan metode yang menempatkan titik pengamatan secara sistematis pada interval tertentu, sampel pertama dipilih secara acak kemudian sampel setelahnya diambil mengikuti transek pada interval tertentu (Congalton & Green, 2009). Sebanyak 436 titik pengamatan ditentukan di Karang Lebar, diantaranya 220 titik digunakan untuk titik klasifikasi dan 216 untuk titik akurasi. Terdapat 215 titik

pengamatan tersebar di Pulau Lancang, sebanyak 110 titik sebagai titik klasifikasi dan 105 titik akurasi (Gambar 2).

## 2.4. Pengolahan Data

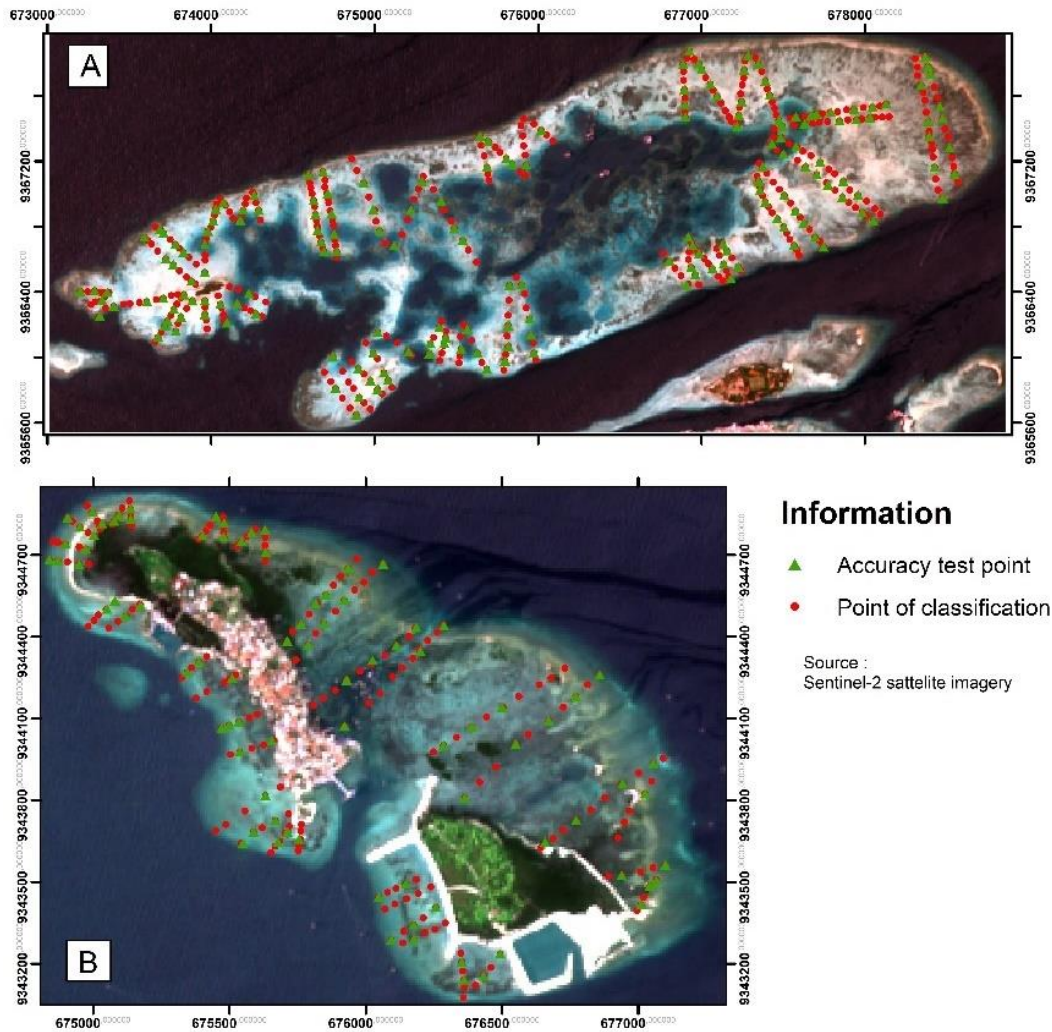
Proses pengolahan data satelit dilakukan dengan beberapa tahapan, dimulai dengan pemisahan antara darat dan laut (*masking*) koreksi radiometrik, serta perencanaan pengambilan data. Klasifikasi habitat bentik dilakukan saat data lapangan telah diperoleh, menggunakan metode berbasis objek (OBIA). Langkah terakhir adalah melakukan uji akurasi dari hasil klasifikasi citra menggunakan data lapang sebagai validasi serta uji signifikansi (Green *et al.*, 2000).

*Masking* dilakukan untuk memberikan batas wilayah pengamatan yang tidak memerlukan darat dan laut dalam dalam proses pengolahan citra. Proses ini menggunakan perangkat lunak ErMapper, *masking* darat dilakukan memanfaatkan kanal inframerah dekat (*near infrared/NIR*) karena memiliki respons spektral atau sensitifitas untuk membedakan batas darat dan laut. Sedangkan untuk memisahkan laut dalam dengan perairan dangkal, memanfaatkan kanal biru pada citra untuk membedakan antara laut dalam dengan perairan dangkal (Green *et al.*, 2000).

Koreksi radiometrik bertujuan untuk memperbaiki kualitas visual citra dan nilai digital yang kurang sesuai. Metode yang digunakan adalah melakukan *dark pixel subtraction* (pengurangan nilai piksel gelap), metode ini dilakukan dengan mengurangi nilai piksel dari semua kanal pada citra dengan radiansi rata-rata atau nilai piksel yang di sampling dari area laut dalam pada citra. Persamaan untuk metode *dark pixel subtraction* ditulis sebagai berikut (Green *et al.*, 2000) :

$$Li' = Li - Lsi \dots\dots\dots(1)$$

$Li'$  adalah nilai piksel yang terkoreksi pada kanal  $i$ ,  $Li$  adalah nilai piksel awal pada



Gambar 2. Titik Pengamatan pada perairan (A) Karang Lebar, dan (B) Pulau Lancang.

kanal  $i$ , dan  $Lsi$  adalah nilai piksel sampling di laut dalam pada kanal  $i$ .

Survei lapang dilakukan setelah membuat rancangan pengambilan data lapang dari citra satelit yang telah *dimasking* dan terkoreksi radiometrik. Hasil survei lapang mendapatkan data titik pengamatan habitat bentik yang digunakan untuk membuat skema klasifikasi habitat bentik. Skema klasifikasi penelitian ini dibentuk berdasarkan analisis *Agglomerative Hierarchical Clustering* (AHC), yang mengelompokkan kelas habitat bentik berdasarkan persentase tutupan komponen penyusun dari data lapang. Parameter yang digunakan dalam analisis AHC adalah nilai ketidakmiripan koefisien Bray-Curtis,

sedangkan dalam pemilihan skala nilai ketidakmiripan belum memiliki standar baku karena kondisi dan variasi lokasi pengamatan yang berbeda (Green *et al.*, 2000). Analisis AHC dilakukan menggunakan statistik XLSTAT di dalam *microsoft excel*. Titik pengamatan habitat bentik dibagi menjadi data titik untuk klasifikasi dan data titik untuk uji akurasi.

Tahapan pertama dalam klasifikasi berbasis objek (OBIA) adalah segmentasi multiskala. Konsep segmentasi adalah membentuk beberapa objek dari piksel-piksel pada citra menjadi objek-objek yang memiliki sifat yang mirip seperti tekstur, warna, bentuk dan ukuran (Hossain & Chen, 2019). Parameter yang digunakan dalam

segmentasi untuk membentuk homogenitas pada objek atau segmen yang dibentuk adalah *shape*, *compactness*, dan *scale*. Ketiga parameter segmentasi dapat diatur oleh pengguna untuk mendapatkan segmentasi yang tepat untuk kelas yang dibutuhkan dalam klasifikasi. Nilai skala yang digunakan dalam segmentasi ini adalah 50, nilai *shape* adalah 0,1 dan nilai *compactness* adalah 0,5. Algoritma yang digunakan dalam segmentasi adalah segmentasi multiresolusi (MRS).

Klasifikasi level 1 dilakukan setelah melakukan segmentasi multiskala. Klasifikasi ini dilakukan untuk memisahkan antara darat, laut dangkal dan laut yang lebih dalam. Wilayah laut dangkal disegmentasi dengan nilai skala 15 untuk perairan Karang Lebar dan nilai skala 10 untuk perairan Pulau Lancang, dengan nilai *shape* sebesar 0,1 dan *compactness* sebesar 0,5 untuk masing-masing perairan. Nilai skala segmentasi didapatkan dari optimasi segmentasi, untuk mendapatkan hasil terbaik dari klasifikasi. Optimasi terhadap parameter segmentasi dilakukan dengan metode *try and error* sehingga didapatkan parameter segmentasi yang tepat. Hal ini dikarenakan tidak ada standar nilai untuk parameter segmentasi dalam klasifikasi berbasis objek (Benfield *et al.*, 2007; Blaschke, 2010; Phinn *et al.*, 2011).

Hasil segmentasi pada perairan dangkal digunakan untuk melakukan klasifikasi level 2, yaitu klasifikasi habitat bentik perairan dangkal dengan penerapan algoritma *machine learning*. Algoritma untuk klasifikasi berbasis objek yang digunakan adalah *support vector machine* (SVM), *decision tree* (DT), *random forest* (RF), dan *k-nearest neighbour* (kNN). Algoritma SVM merupakan klasifikasi terbimbing yang bertujuan untuk membentuk sebuah bidang datar atau garis lurus sebagai pemisah antara dua dataset yang berbeda dengan sempurna (Wahiddin, 2015; Osisanwo *et al.*, 2017). Pengujian efektivitas SVM dapat diukur dengan

menghitung kernel fungsi terhadap nilai parameter margin (C) (Wahiddin, 2015), kernel fungsi yang digunakan adalah *radial basis function* (rbf). Fungsi kernel rbf SVM dilakukan dengan menggunakan persamaan (Cortes & Vapnik, 1995):

$$K(u,v) = \exp\left\{-\frac{|u-v|^2}{\sigma^2}\right\} \dots\dots\dots(2)$$

Nilai *K* adalah fungsi kernel radial, nilai *u* merepresentasikan vektor dari setiap data,  $\sigma$  adalah jumlah derajat dari fungsi polinomial, dan *v* merepresentasikan rentangan pada kurva gaussian.

Algoritma DT memungkinkan untuk menjadikan kriteria dalam data atribut sebagai node yang saling berhubungan membentuk seperti struktur pohon. Algoritma ini membentuk model pohon prediksi terhadap suatu keputusan menggunakan struktur hirarki. Studi yang dilakukan oleh Sartika & Sensuse (2017) menggunakan perhitungan gainratio dari setiap kriteria dengan data sampel, untuk menghitung nilai gainratio dapat menggunakan persamaan :

$$\text{Gainratio}(S,A) = \frac{\text{Gain}(S,A)}{\text{SplitInformation}(S,A)} \dots\dots\dots(3)$$

Nilai *information gain* bermakna seberapa banyak informasi yang diperoleh dengan mengetahui nilai suatu atribut, sedangkan nilai *split information* digunakan untuk suatu atribut yang memiliki banyak *instance* (lebih dari dua dan beragam). Setelah bentuk data diubah, maka model pohon akan diubah menjadi *rule*, dengan formula untuk membangkitkan *rule* adalah (Sartika & Sensuse, 2017):

$$\text{IF premis THEN konklusi} \dots\dots\dots(4)$$

Simpul akar dan cabang akan menjadi simpul premis dari aturan, sedangkan simpul daun akan menjadi bagian dari konklusinya (solusi).

Algoritma RF merupakan gabungan dari pengelompokan pohon seperti pada algoritma DT, untuk menumbuhkan pohon pengklasifikasian sehingga membentuk suatu hutan pengklasifikasian maka vektor acak dibentuk berdasarkan data sampel yang dimasukkan dalam proses pengklasifikasian (Wu et al., 2017). Perhitungan matematis pohon-pohon untuk membentuk estimasi hutan pengklasifikasian adalah (Biau & Scornet, 2016):

$$m_{M,n}(\mathbf{x} = \theta_1, \dots, \theta_M, D_n) = \frac{1}{M} \sum_{j=1}^M m_n(\mathbf{x}; \theta_j, D_n) \dots\dots\dots(5)$$

Nilai  $\theta_1, \dots, \theta_M$  adalah variabel acak independen,  $D_n$  adalah sampel *training*,  $M$  adalah jumlah pohon dalam hutan klasifikasi, dan  $x$  adalah vektor acak.

Algoritma kNN merupakan metode klasifikasi yang umum digunakan dalam berbagai bidang karena implementasinya yang sederhana, kejelasan teori dan klasifikasi yang baik. Namun nilai galat klasifikasi akan meningkat ketika data pengamatan terdistribusi secara tidak merata atau jumlah sampel setiap kelas sangat berbeda. Metode kNN menentukan suatu kelas klasifikasi dengan memprediksi sampel yang diuji dengan sampel *training* yang terdekat (Deng et al., 2016). Metode kNN perlu menghitung jarak atau kesamaan dari semua sampel *training* untuk setiap sampel yang diuji dalam proses klasifikasi, dengan menggunakan perhitungan jarak Euclidean yaitu (Zhang, 2016):

$$D(p, q) = \frac{\sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots + (p_n - q_n)^2}}{\dots\dots\dots} (6)$$

nilai  $p$  dan  $q$  adalah sampel *training* dan sampel yang diuji.

Pengujian akurasi hasil klasifikasi dilakukan untuk mendapatkan tingkat informasi yang dapat dipercaya dari sebuah peta (Congalton & Green, 2009). Uji akurasi dilakukan menggunakan matriks kesalahan (*confusion matrix*), membandingkan kelas-kelas habitat yang dihasilkan dari klasifikasi dengan kelas yang sebenarnya dari hasil survei lapangan. Tiga parameter umum yang diperoleh dari matriks kesalahan adalah *overall accuracy* (OA), *producer's accuracy* (PA), dan *user's accuracy* (UA) (Green et al., 2000). Perhitungan masing-masing akurasi ditunjukkan dalam persamaan berikut (Congalton & Green, 2009):

$$Overall\ accuracy = \frac{\sum_{i=1}^k n_{ii}}{n} \dots\dots\dots(7)$$

$$Producer's\ accuracy = \frac{n_{ij}}{n_{+j}} \dots\dots\dots (8)$$

$$User's\ accuracy = \frac{n_{ii}}{n_{i+}} \dots\dots\dots(9)$$

$k$  adalah jumlah baris pada matriks,  $n$  adalah jumlah pengamatan,  $n_{ii}$  adalah jumlah pengamatan pada kolom ke- $i$  dan baris ke- $i$  dan  $n_{ij}$  adalah jumlah pengamatan pada kolom ke- $j$  dan baris ke- $j$ . Selanjutnya dilakukan uji Z untuk menentukan nilai dua matriks kesalahan berbeda secara signifikan atau tidak. Z statistik didapatkan dari hasil klasifikasi dengan dua metode yang berbeda, kemudian dilakukan *pairwise comparison* untuk melihat signifikansi setiap metode. Nilai  $K1$  dan  $K2$  merupakan estimasi statistik kappa dari masing-masing matriks kesalahan. Z adalah nilai standarisasi dan distribusi normal (standar deviasi). Persamaan yang dilakukan untuk uji statistik dua matriks kesalahan independen berbeda secara signifikan adalah (Congalton & Green, 2009):

$$Z = \frac{K1 - K2}{\sqrt{var\ K1 + var\ K2}} \dots\dots\dots(10)$$

### III. HASIL DAN PEMBAHASAN


#### 3.1. Skema Klasifikasi

Analisis *Agglomerative Hierarchical Clustering* (AHC) merupakan metode klasifikasi berdasarkan presentaseutupan komponen penyusun habitat bentik dari data lapang. Penelitian ini menggunakan nilai ketidakmiripan objek koefisien Bray-Curtis sebesar 30%-35% yang menunjukkan klasifikasi habitat bentik dengan kemiripan 65%-70%. Nilai ketidakmiripan (*dissimilarities*) belum memiliki ketetapan dalam pemilihan skala untuk pendefinisian skema klasifikasi, karena kondisi dan variasi lokasi pengamatan yang berbeda (McGarigal *et al.*, 2016). Masing-masing wilayah yaitu Karang Lebar dan Pulau Lancang menghasilkan enam kelas habitat bentik. Penamaan kelas-kelas habitat bentik didasarkan pada kelas yang paling dominan dari persentasiutupan habitat bentik, yakni Karang (K), Lamun (L), Pasir (P), *Rubble*

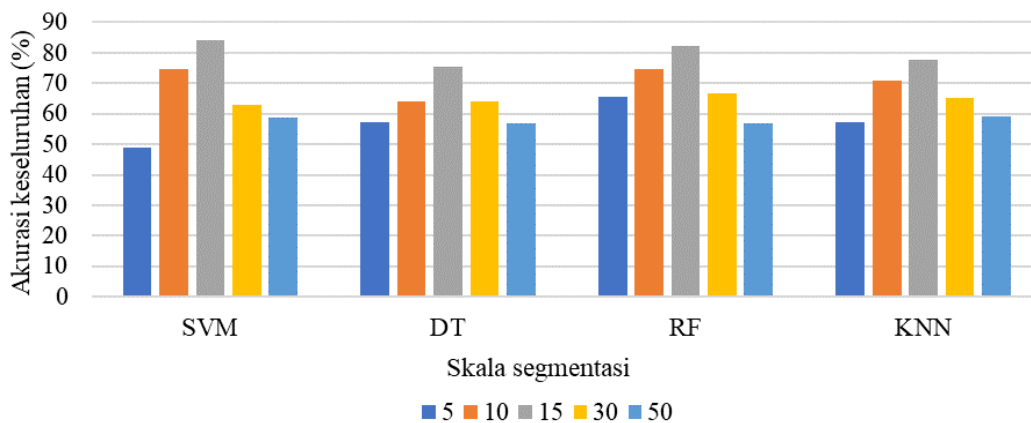
(R), Pasir Lamun (PL), dan Pasir *Rubble* (PR) (Gambar 3).

#### 3.2. Pemetaan Habitat Dasar Perairan

Nilai skala segmentasi pada level 2 didapatkan dari proses optimasi segmentasi. Proses segmentasi tidak memiliki standar baku terkait nilai parameter yang digunakan, sehingga pengguna harus melakukan optimasi skala untuk mendapatkan hasil yang terbaik. Optimasi skala yang digunakan dalam penelitian ini adalah 3, 5, 15, 30, dan 50 dengan nilai *shape* 0,1 dan *compactness* 0,5. Pada Gambar 4 dan 5 terlihat nilai akurasi yang didapatkan dari skala segmentasi yang berbeda dari algoritma *machine learning* yang digunakan di Karang Lebar dan Pulau Lancang. Semakin kecil nilai skala maka akurasi keseluruhan yang didapatkan cenderung meningkat. Nilai skala 15 mendapatkan akurasi tertinggi pada Karang Lebar dan nilai skala 10 pada Pulau Lancang.

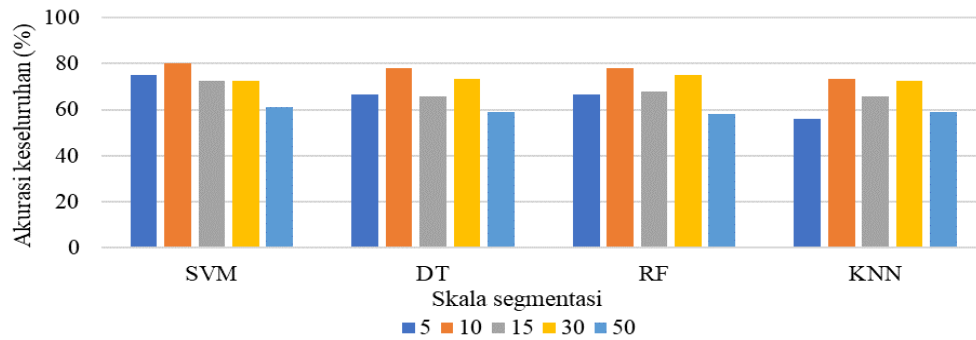


Gambar 3. Skema klasifikasi habitat bentik dasar perairan Karang Lebar.



Gambar 4. Nilai akurasi dari skala segmentasi yang berbeda di Karang Lebar.





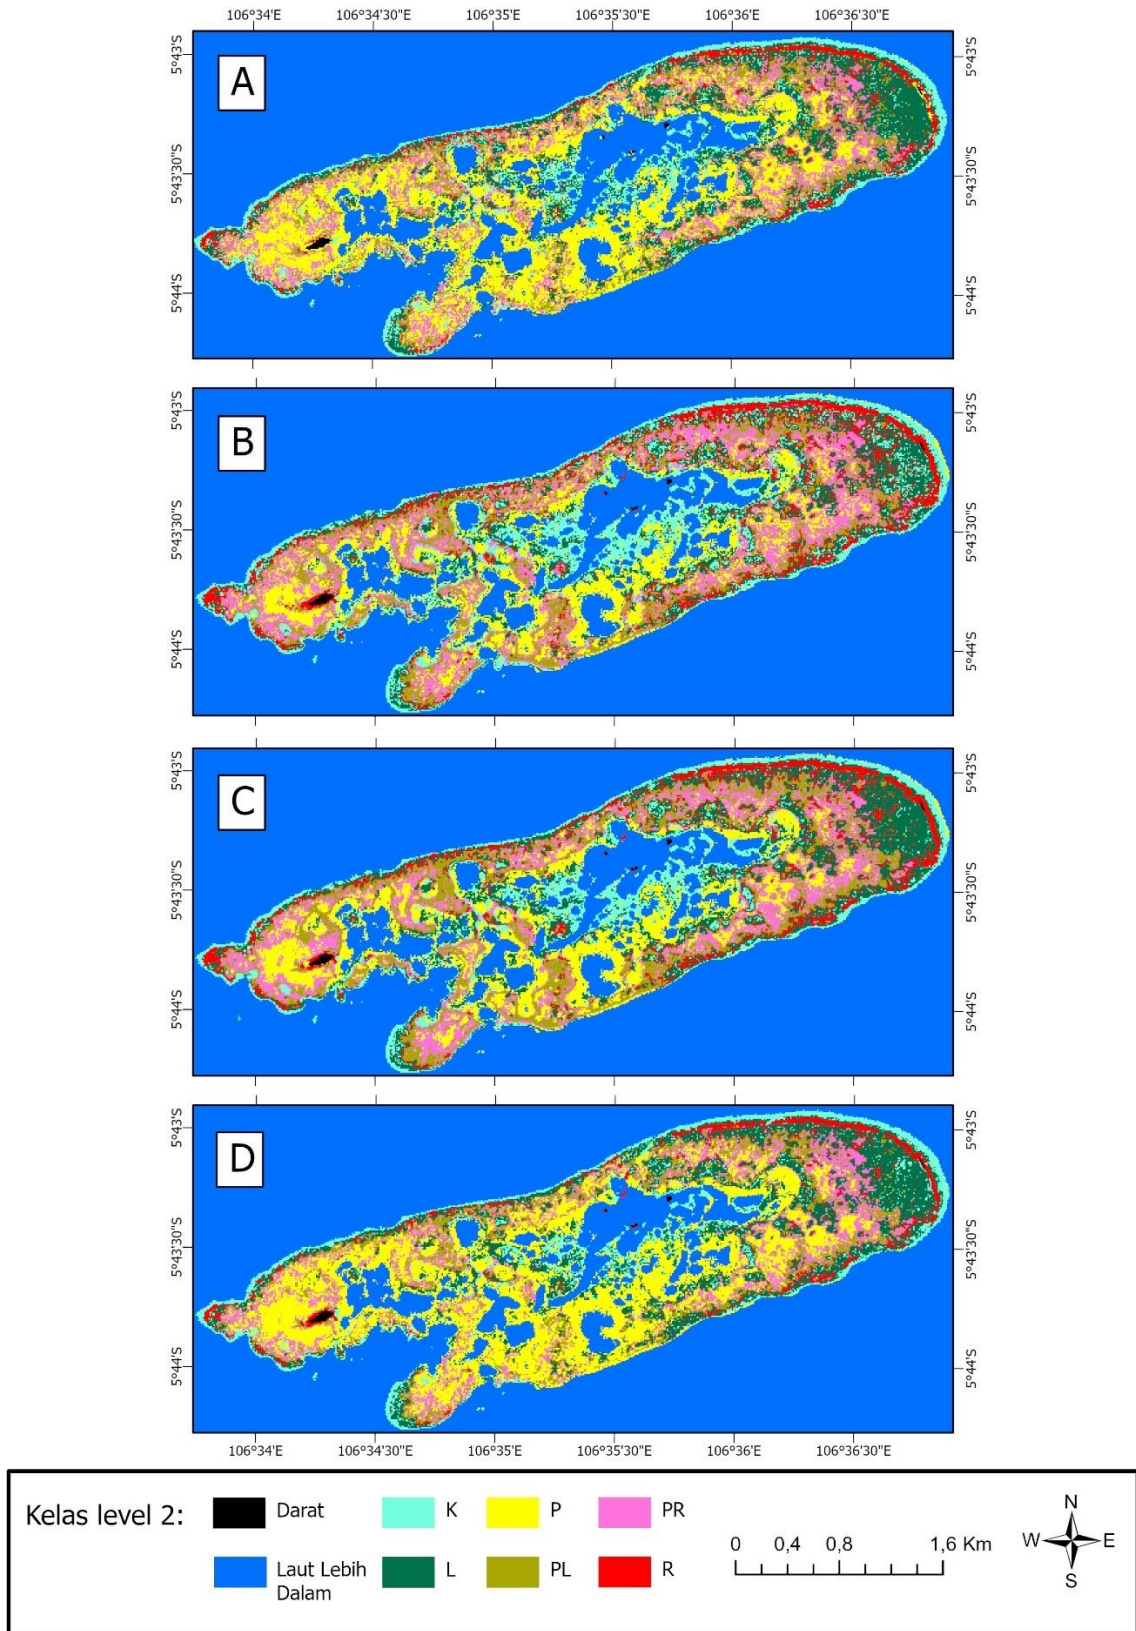
Gambar 5. Nilai akurasi dari skala segmentasi yang berbeda di Pulau Lancang.

Peta klasifikasi habitat benthik untuk perairan dangkal Karang Lebar diperlihatkan pada Gambar 6. Kelas karang (K) terklasifikasi di wilayah yang sama di setiap hasil algoritma klasifikasi, yaitu pada daerah tubir. Tabel 1 menunjukkan luas area kelas K pada algoritma DT lebih tinggi dibandingkan algoritma lainnya. Pada hasil klasifikasi algoritma DT terlihat kelas pasir lamun (PL), pasir *rubble* (PR) dan *rubble* (R) lebih banyak dibandingkan hasil klasifikasi algoritma yang lain (Tabel 1). Kelas lamun (L) lebih banyak terdistribusi pada perairan di timur Karang Lebar disetiap hasil klasifikasi, namun juga tersebar pada perairan di tengah wilayah Karang Lebar dekat dengan goba pada algoritma DT dan RF, sebaran kelas pasir lamun lebih tersebar dekat dengan kelas lamun. Pada Tabel 1, kelas pasir (P) terklasifikasi lebih banyak pada algoritma SVM dan KNN.

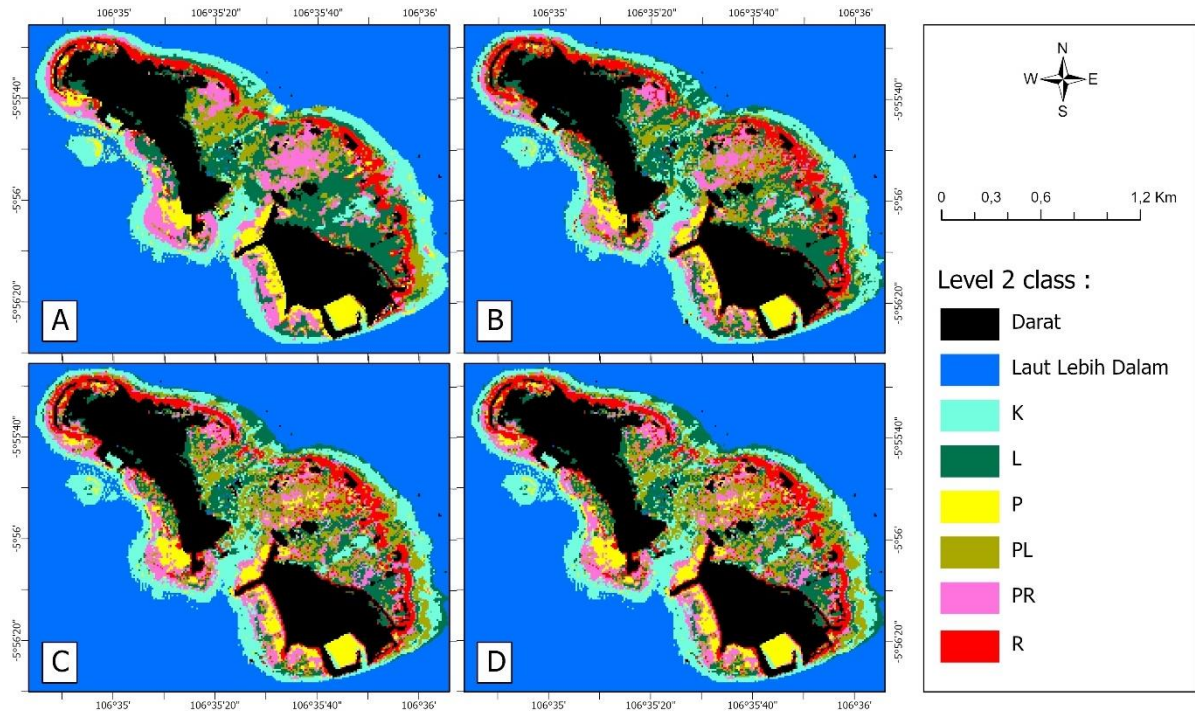
Hasil klasifikasi Pulau Lancang diperlihatkan pada Gambar 7. Kelas *rubble* (R) lebih banyak terdistribusi pada wilayah utara Pulau Lancang disetiap hasil klasifikasi, dan kelas pasir *rubble* (PR) terdistribusi lebih di bagian selatan Pulau Lancang. Hasil klasifikasi algoritma SVM dan KNN menunjukkan perairan di antara Pulau Lancang kecil dan besar lebih banyak terdistribusi kelas PR, sedangkan pada hasil klasifikasi algoritma DT dan RF terdapat kelas pasir lamun (PL) yang lebih mendominasi area tersebut. Pengaruh dari campuran pasir dengan tutupan benthik yang lain seperti lamun dan *rubble* dapat

menyulitkan algoritma untuk mengklasifikasi tutupan pada satu area, selain itu *noise* dari citra, dan kekeruhan dapat menjadi penyebab perbedaan identifikasi tutupan benthik (Mohamed *et al.*, 2020). Tabel 2 menunjukkan luas area kelas karang lebih banyak teridentifikasi oleh algoritma SVM dan KNN. Kelas lamun dan *rubble* teridentifikasi lebih tinggi oleh algoritma RF, dan kelas pasir lamun teridentifikasi lebih tinggi pada algoritma DT (Tabel 2).

Objek yang paling dominan ditemukan pada perairan dangkal Karang Lebar jika dilihat dari luas kelas klasifikasi pada Tabel 1 adalah kelas pasir dan lamun, kedua kelas klasifikasi tersebut memiliki luas area yang tinggi dibandingkan dengan kelas lainnya di setiap algoritma klasifikasi yang digunakan. Sedangkan di perairan dangkal Pulau Lancang, objek yang paling dominan ditemukan adalah kelas Karang yang memiliki luas area paling tinggi dari hasil klasifikasi menggunakan algoritma SVM, DT dan KNN. Sementara itu dengan menggunakan algoritma RF, kelas lamun merupakan objek yang dominan ditemukan (Tabel 2). Perbedaan kelas yang dominan teridentifikasi di setiap algoritma dapat disebabkan adanya perbedaan konsep klasifikasi dari setiap algoritma yang digunakan sehingga dari algoritma yang digunakan mendapatkan hasil identifikasi kelas dominan yang berbeda (Zhang, 2015; Janowski *et al.*, 2018).



Gambar 6. Klasifikasi level 2 OBIA Karang Lebar dengan algoritma: (A) SVM, (B) DT, (C) RF, dan (D) dan KNN.



Gambar 7. Klasifikasi level 2 OBIA Pulau Lancang dengan algoritma: (A) SVM, (B) DT, (C) RF, dan (D) dan KNN.

Tabel 1. Luasan kelas klasifikasi habitat dasar perairan Karang Lebar.

Kelas/Algoritma	SVM (ha)	DT (ha)	RF (ha)	KNN (ha)
Karang	57,61	77,56	68,22	57,06
Lamun	136,36	151,67	141,64	158,1
Pasir	199,3	111,9	143,58	203,07
Pasir Lamun	78,28	100,44	92,99	64,31
Pasir <i>Rubble</i>	82,62	93,89	86,19	80,67
<i>Rubble</i>	36,72	55,43	58,27	27,68

Tabel 2. Luasan kelas klasifikasi habitat dasar perairan Pulau Lancang.

Kelas/Algoritma	SVM (ha)	DT (ha)	RF (ha)	KNN (ha)
Karang	49,63	44,71	39,12	51,95
Lamun	35,57	37,68	43,04	39,16
Pasir	26,45	25,15	21,02	18,68
Pasir Lamun	31,53	38,69	36,28	32,76
Pasir <i>Rubble</i>	27,01	18,92	19,05	24,93
<i>Rubble</i>	16,95	21,99	28,63	19,66

### 3.3. Akurasi Klasifikasi

Akurasi keseluruhan (OA) tertinggi didapat dari perairan dangkal di Karang Lebar sebesar 84% dengan menggunakan

algoritma SVM, diikuti dengan algoritma DT, RF, dan KNN yaitu sebesar 75%, 82%, dan 78%. Nilai akurasi pengguna (UA) dan akurasi pembuat (PA) hasil klasifikasi di

perairan dangkal Karang Lebar dengan algoritma SVM berkisar antara 74-100% (Tabel 3). Kelas habitat dasar perairan di Karang Lebar seperti karang (K), pasir (P), pasir lamun (PL), pasir *rubble* (PR), dan *rubble* (R) dapat dipetakan dengan baik, nilai UA berkisar pada 82-94% (Tabel 3). Sementara itu, hanya kelas lamun (L) mendapatkan nilai UA di bawah 80%. Kesalahan klasifikasi seperti kelas lamun yang teridentifikasi menjadi pasir lamun ataupun sebaliknya dikarenakan adanya kemiripan nilai piksel antara kedua objek tersebut (Lazuardi *et al.*, 2021).

Hasil OA pada perairan Pulau Lancang mendapatkan nilai tertinggi yaitu sebesar 80% juga dengan algoritma SVM, diikuti dengan algoritma DT, RF, dan KNN yaitu sebesar 78%, 78%, dan 73%. Nilai UA dan PA hasil klasifikasi habitat dasar perairan menggunakan algoritma SVM pada Pulau Lancang berkisar antara 57-95% (Tabel 4). Seluruh kelas klasifikasi di perairan dangkal Pulau Lancang dapat

dipetakan dengan baik, kecuali kelas pasir lamun yang mendapatkan nilai UA yang rendah yaitu sebesar 57% (Tabel 4). Terlihat pada Tabel 4, beberapa titik kelas pasir lamun teridentifikasi sebagai kelas lamun. Kompleksitas habitat bentik di perairan dangkal Pulau Lancang serta nilai spektral yang hampir mirip dapat menjadi pengaruh rendahnya nilai UA (Nababan *et al.*, 2021).

Nilai akurasi keseluruhan tertinggi dari penelitian ini didapatkan menggunakan algoritma SVM, hal ini sejalan dengan penelitian sebelumnya yang menunjukkan algoritma SVM menghasilkan akurasi yang terbaik. Prabowo *et al.* (2018) melakukan pemetaan habitat bentik di Pulau Harapan dan Pulau Kelapa mendapatkan OA algoritma SVM sebesar 75% dan DT 60% dengan 11 kelas yang digunakan, Wahiddin *et al.* (2015) melakukan pemetaan habitat bentik di Pulau Morotai mendapatkan nilai OA pada SVM sebesar 73%, RT sebesar 68%, KNN, sebesar 67%, bayesian sebesar 66% dan DT sebesar 56% pada 7 kelas

Tabel 3. Matriks kesalahan dari klasifikasi habitat dasar perairan Karang Lebar.

Lapang / Satelit	K	L	P	PL	PR	R	Total	UA
K	17	0	0	0	0	1	18	94
L	0	30	2	4	1	1	38	79
P	0	1	65	3	9	0	78	83
PL	0	0	1	28	1	1	31	90
PR	0	0	5	2	31	0	38	82
R	0	1	0	1	0	11	13	85
Total	17	32	73	38	42	14	216	
PA	100	94	89	74	74	79	OA	84

Tabel 4. Matriks kesalahan dari klasifikasi habitat dasar perairan Pulau Lancang.

Lapang / Satelit	K	L	P	PL	PR	R	Total	UA
K	16	2	1	1	0	2	22	73
L	1	21	0	0	0	0	22	95
P	1	0	8	0	1	0	10	80
PL	0	6	0	8	0	0	14	57
PR	1	1	1	1	17	1	22	77
R	0	0	0	1	0	14	15	93
Total	19	30	10	11	18	17	105	
PA	84	70	80	73	94	82	OA	80

klasifikasi yang digunakan (Tabel 5). SVM merupakan algoritma *machine learning* yang lebih kuat dibandingkan algoritma yang lainnya di penelitian ini maupun di penelitian yang dilakukan oleh Wahiddin *et al.* (2015) dan Prabowo *et al.* (2018).

Pengaturan parameter pada algoritma *machine learning* berpengaruh pada naik turunnya hasil akurasi klasifikasi terutama pada algoritma SVM dan DT (Qian *et al.*, 2015). Algoritma RF dapat bekerja lebih baik dibandingkan dengan SVM tergantung jumlah data yang diakses dan parameter pengaturan yang diberikan, algoritma SVM dapat mendapatkan hasil akurasi yang lebih tinggi pada model yang tepat (Statnikov *et al.*, 2008; Liu *et al.*, 2015). Tingkat kekeruhan yang relatif lebih rendah di perairan Karang Lebar dapat menjadi faktor yang menyebabkan tingkat akurasi yang dihasilkan lebih tinggi dibandingkan tingkat akurasi di perairan Pulau Lancang. Lokasi Pulau Lancang yang dekat dengan daratan Tanggerang serta terdapat muara sungai yang membawa sedimen ke lautan dapat menjadi penyebab tingkat kekeruhan di perairan Pulau Lancang yang lebih tinggi dibandingkan dengan perairan Karang Lebar.

Data yang didapatkan dari *marine.copernicus.eu*, perairan Karang Lebar pada bulan Maret 2020 memiliki tingkat konsentrasi klorofil-a (Chl-a) sebesar 1,61 mg/m<sup>3</sup> sedangkan perairan Pulau Lancang memiliki Chl-a sebesar 10,69 mg/m<sup>3</sup>. Selain itu, tingkat konsentrasi rata-rata partikel tersuspensi (SPM) di perairan Pulau Lancang sebesar 6,71 mg/l, dan di perairan Karang Lebar memiliki tingkat konsentrasi rata-rata SPM sebesar 3,61 mg/l. Tingginya tingkat kekeruhan pada perairan Pulau Lancang dapat disebabkan oleh dekatnya dengan daratan Banten yang terdapat muara sungai. Penelitian yang dilakukan oleh Kurniawati (2020) juga mendapatkan data yang menunjukkan tingkat Chl-a di perairan Pulau Lancang lebih tinggi dari pada di perairan Pulau

Sebaru Besar, masing-masing sebesar 9,8 µg/l dan 2,4 µg/l. Kandungan Chl-a, material tersuspensi dan terlarut pada air laut dapat menyebabkan perubahan sifat optik pada air laut (Susilo, 2017). Kandungan Chl-a dan SPM di suatu perairan memengaruhi tingkat kekeruhan perairan, kekeruhan memengaruhi kemampuan air untuk meneruskan cahaya ke dalam perairan sehingga informasi yang ditangkap oleh sensor satelit akan berkurang (Sarianto *et al.* 2016, Bohn *et al.* 2018, dan Suhendar *et al.* 2020).

### 3.4. Uji Signifikansi

Analisis kappa dan *Z-test* dilakukan untuk membandingkan secara statistik antara dua atau lebih akurasi pemetaan/klasifikasi, selain itu juga untuk mengukur seberapa baik hasil klasifikasi sesuai dengan data referensi. Congalton & Green (2009) menyatakan bahwa pada nilai Z statistik antara nilai -1,96 sampai dengan 1,96 merupakan kategori akurasi yang berada pada distribusi normal.

Nilai Z statistik yang diperoleh dari algoritma SVM, DT, RF, dan KNN pada citra di perairan dangkal Karang Lebar tidak berbeda signifikan dengan hasil di perairan dangkal Pulau Lancang (Tabel 6). Hasil uji signifikansi antara algoritma yang digunakan pada perairan dangkal di Karang Lebar dan Pulau Lancang hanya memiliki perbedaan signifikan pada perbandingan algoritma SVM dan DT di perairan dangkal Karang Lebar (Tabel 7).

Akurasi pemetaan bentik yang dapat diterima adalah dengan akurasi keakuratan sebesar >60% (Green *et al.*, 2000). Kemampuan teknik klasifikasi yang digunakan pada penelitian ini mampu memberikan hasil akurasi di atas 60%. Banyak faktor yang dapat memengaruhi hasil akurasi. Salah satunya adalah kesalahan dalam mengidentifikasi objek berdasarkan definisi yang digunakan, dan penentuan *training area* kelas habitat yang kurang tepat. Jumlah data dan keseimbangan

Tabel 5. Penelitian-penelitian sebelumnya.

Sumber	Lokasi	Metode	Hasil
Wahiddin <i>et al.</i> (2015)	Pulau Morotai	Pemetaan habitat karang dengan metode OBIA dengan 7 kelas klasifikasi	Akurasi keseluruhan algoritma SVM (73%), RT (68%), KNN (67%), Bayesian (66%), dan DT (56%)
Prabowo <i>et al.</i> (2018)	Pulau Harapan dan Kelapa	Pemetaan habitat bentik dengan metode OBIA dengan 11 kelas klasifikasi	Akurasi keseluruhan algoritma SVM (75%) dan DT (60%)

Tabel 6. Nilai kappa, varian dan Z statistik.

Algoritma	Karang Lebar		Pulau Lancang		Z
	Kappa	Var (K)	Kappa	Var (K)	
SVM	0,7987	0,0011	0,7561	0,0024	0,7192
DT	0,6926	0,0015	0,7351	0,0026	0,6658
RF	0,7784	0,0012	0,7332	0,0026	0,7353
KNN	0,7118	0,0014	0,6766	0,0030	0,5263

Tabel 7. Nilai uji signifikansi antara algoritma klasifikasi.

Algoritma	Karang Lebar	Pulau Lancang
SVM-DT	2,09	0,30
SVM-RF	0,43	0,32
SVM-KNN	1,73	1,08
DT-RF	1,67	0,03
DT-KNN	0,35	0,78
RF-KNN	1,31	0,75

antara data kelas-kelas habitat, dapat memengaruhi kemampuan dari algoritma klasifikasi yang digunakan (Noi & Kappas, 2017).

#### IV. KESIMPULAN

Klasifikasi berbasis objek dengan penerapan algoritma *machine learning* mampu memetakan dengan baik ekosistem habitat dasar perairan Karang Lebar dan Pulau Lancang dari citra Sentinel-2 dengan enam kelas habitat klasifikasi. Akurasi keseluruhan tertinggi di perairan dangkal Karang Lebar didapatkan dari algoritma SVM sebesar 84% dan di perairan dangkal

Pulau Lancang dari algoritma SVM 80%. Faktor seperti nilai piksel yang mirip antara dua objek yang berbeda dapat menyebabkan kesalahan identifikasi kelas, walaupun demikian penerapan algoritma SVM dalam pemetaan habitat dasar perairan dapat mewakili informasi sumber daya pesisir yang relevan untuk mendukung rencana pengelolaan pesisir yang efektif.

#### UCAPAN TERIMAKASIH

Terimakasih saya ucapkan kepada Balai Taman Nasional Kepulauan Seribu yang telah mengizinkan melakukan penelitian di sekitar wilayah Taman

Nasional Kepulauan Seribu, serta kepada para pembimbing, teman-teman Teknologi Kelautan Institut Pertanian Bogor angkatan 2018 yang telah ikut membantu melancarkan penelitian ini. Penelitian dan penulisan naskah ini telah berjalan dengan baik atas kerjasama yang telah diberikan.

## DAFTAR PUSTAKA

- Agus, S.B., N. Zulfainarni, A. Sunuddin, T. Subarno, A.H. Nugraha, I. Rahimah, A. Alamsyah, R. Rachmi, & Jihad. 2016. Distribusi spasial rajungan (*Portunus pelagicus*) pada musim timur di perairan pulau Lancang, Kepulauan Seribu. *J. Ilmu Pertanian Indonesia*, 21(3): 209-218.  
<https://doi.org/10.18343/jipi.21.3.209>
- Benfield, S.L., H.M. Guzman, J.M. Mair, & J.A.T. Young. 2007. Mapping the distribution of coral reefs and associated sublittoral habitats in Pacific Panama: a comparison of optical satellite sensors and classification methodologies. *International J. of Remote Sensing*, 28(22): 5047-5070.  
<https://doi.org/10.1080/01431160701258062>
- Ben-Romdhane, H., P.R. Marpu, T.B.M.J. Ouarda, & H. Ghedira. 2016. Corals & benthic habitat mapping using DubaiSat-2: A spectral-spatial approach applied to Dalma Island, UAE (Arabian Gulf). *Remote Sensing Letters*, 7(8): 781-789.  
<https://doi.org/10.1080/2150704X.2016.1187317>
- Biau, G. & E. Scornet. 2016. A random forest guided tour. *TEST*, 25(2): 197-227.  
<https://doi.org/10.1007/s11749-016-0481-7>
- Blaschke, T. 2010. Object based image analysis for remote sensing. *J. of Photogrammetry and Remote Sensing*, 65: 2-16.  
<https://doi.org/10.1016/j.isprsjprs.2009.06.004>
- Bohn, V.Y., F. Carmona, R. Rivas, L. Lagomarsino, N. Diovisalvi, & H.E. Zagarese. 2018. Development of an empirical model for chlorophyll-a and Secchi Disk Depth estimation for a Pampean shallow lake (Argentina). *Egyptian Journal of Remote Sensing and Space Science*, 21(2): 183-191.  
<https://doi.org/10.1016/j.ejrs.2017.04.005>
- Cai, S. & D. Liu. 2013. A comparison of object-based and contextual pixel-based classification using high and medium spatial resolution images. *Remote Sensing Letters*, 4(10): 998-1007.  
<https://doi.org/10.1080/2150704X.2013.828180>
- Congalton, R.G. & K. Green. 2009. Assessing the accuracy of remotely sensed data—principles and practices. 2<sup>nd</sup> ed. CRC Press. Boca Raton, 183 p.
- Cortes, C. & V. Vapnik. 1995. Support-vector networks. *Machine Learning*, 20: 273-297.  
<https://doi.org/10.1007/BF00994018>
- Deng, Z., X. Zhu, D. Cheng, M. Zong, & S. Zhang. 2016. Efficient kNN classification algorithm for big data. *Neurocomputing*, 195: 143-148.  
<https://doi.org/10.1016/j.neucom.2015.08.112>
- Green, E.P., P.J. Mumby, A.J. Edwards, & C.D. Clark. 2000. *Remote sensing handbook for tropical coastal management*: UNESCO, 109 p.
- Hedley, J.D., C.M. Roelfsema, I. Chollet, A.R. Harborne, S.F. Heron, S.J. Weeks, W.J. Skirving, A.E. Strong, C.M. Eakin, T.R.L. Christensen, V. Ticzon, S. Bejarano, & P.J. Mumby. 2016. Remote sensing of coral reefs for monitoring and management: a review. *J. Remote Sensing*, 8: 118-168.

- <https://doi.org/10.3390/rs8020118>  
Hossain, M.D. & D. Chen. 2019. Segmentation for Object-Based Image Analysis (OBIA): A review of algorithms and challenges from remote sensing perspective. *ISPRS Journal of Photogrammetry and Remote Sensing*, 150: 115–134. <https://doi.org/10.1016/j.isprsjprs.2019.02.009>
- Janowski, L., K. Trzcinska, J. Tegowski, A. Kruss, M. Rucinska-Zjadacz, & P. Pocwiardowski. 2018. Nearshore Benthic Habitat Mapping Based on Multi-Frequency, Multibeam Echosounder Data Using a Combined Object-Based Approach: A Case Study from the Rowy Site in the Southern Baltic Sea. *Remote Sensing*, 10(12): 1983-2003. <https://doi.org/10.3390/rs10121983>
- Kementerian Kelautan dan Perikanan (KKP). 2015. *Profil Kawasan Konservasi Provinsi DKI Jakarta*. KKP. Jakarta, 8 p.
- Kurniawati, E., V.P. Siregar, & I.W. Nurjaya. 2020. Klasifikasi habitat perairan dangkal berbasis objek menggunakan citra worldview 2 dan sentinel 2b di perairan kepulauan Seribu. *J. Ilmu dan Teknologi Kelautan Tropis*, 12(2): 421-435. <https://doi.org/10.29244/jitkt.v12i2.26089>
- Lazuardi, W., P. Wicaksono, & M.A. Marfai. 2021. Remote sensing for coral reef and seagrass cover mapping to support coastal management of small islands. *IOP Conference Series: Earth and Environmental Science*, 686(1): 012031-012040. <https://doi.org/10.3390/rs10121983>
- Liu, T., J. Im. & L.J. Quackenbush. 2015. A novel transferable individual tree crown delineation model based on Fishing Net Dragging and boundary classification. *Journal of Photogrammetry and Remote Sensing*, 110(1): 34-47. <https://doi.org/10.1016/j.isprsjprs.2015.10.002>
- Mastu, L.O.K., B. Nababan, & J.P. Panjaitan. 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. <https://doi.org/10.29244/jitkt.v10i2.21039>
- McGarigal, K., H.Y. Wan, K.A. Zeller, B.C. Timm, & S.A. Cushman. 2016. Multi-scale habitat selection modeling: a review and outlook. *Landscape Ecol*, 31: 1161-1175. <https://doi.org/10.1007/s10980-016-0374-x>
- Mohamed, H., K. Nadaoka, & T. Nakamura. 2020. Towards Benthic Habitat 3D Mapping Using Machine Learning Algorithms and Structures from Motion Photogrammetry. *Remote Sensing*, 12(1): 127-143. <https://doi.org/10.3390/rs12010127>
- Nababan, B., L.O.K. Mastu, N.H. Idris, & J.P. Panjaitan. 2021. Shallow-water benthic habitat mapping using drone with object based image analyses. *Remote Sensing*, 13(21): 4452-4475. <https://doi.org/10.3390/rs13214452>
- Noi, P.T. & M. Kappas. 2017. Comparison of random forest, k-nearest neighbor, and support vector machine classifiers for land cover classification using sentinel-2 imagery. *Sensors*, 18(1): 18-38. <https://doi.org/10.3390/s18010018>
- Osisanwo, F.Y., J.E.T. Akinsola, O. Awodele, J.O. Hinmikaiye, O. Olakanmi, & J. Akinjobi. 2017. Supervised Machine Learning Algorithms: Classification and Comparison. *International Journal of Computer Trends and Technology*, 48(3): 128–138.



- <https://doi.org/10.14445/22312803/IJCTT-V48P126>
- Prabowo, N.W., V.P. Siregar, & S.B. Agus. 2018. Klasifikasi habitat bentik berbasis objek dengan algoritma *support vector machine* dan *decision tree* menggunakan citra multispektral spot-7 di pulau Harapan dan pulau Tunda. *J. Ilmu dan Teknologi Kelautan Tropis*, 10(1): 123-124. <https://doi.org/10.29244/jitkt.v10i1.21670>
- Phinn, S.R., C.M. Roeflsem, & P.J. Mumby. 2012. Multi-scale, object-based image analysis for mapping geomorphic and ecological zones on coral reefs. *International Journal of Remote Sensing*, 33(12): 3768-3787. <https://doi.org/10.1080/01431161.2011.633122>
- Rastner, P., T. Bolch, C. Notarnicola, & F. Paul. 2014. A comparison of pixel- and object-based glacier classification with optical satellite image. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(3): 853-862. <https://doi.org/10.1109/JSTARS.2013.2274668>
- Sangadji, M.S., V.P. Siregar, & H.M. Manik. 2018. Klasifikasi habitat perairan dangkal menggunakan logika fuzzy dan *maximum likelihood*. *J. Ilmu dan Teknologi Kelautan Tropis*, 11(3): 667-681. <https://doi.org/10.29244/jitkt.v10i3.22859>
- Sarianto, D., D. Simbolon, & B. Wiryawan. 2016. Dampak Pertambangan Nikel Terhadap Daerah Penangkapan Ikan di Perairan Kabupaten Halmahera Timur. *Jurnal Ilmu Pertanian Indonesia*, 21(2): 104-113. <https://doi.org/10.18343/jipi.21.2.104>
- Sartika, D. & D.I. Sensuse. 2017. Perbandingan algoritma klasifikasi *naive bayes*, *nearest neighbour*, dan *decision tree* pada studi kasus pengambilan keputusan pemilihan pola pakaian. *Jatishi*, 1(2): 151-161. <https://doi.org/10.35957/jatishi.v3i2.78>
- Statnikov, A., L. Wang, & C.F. Aliferis. 2008. A comprehensive comparison of random forests and support vector machines for microarray-based cancer classification. *BMC Bioinformatics*, 9(1): 319-329. <https://doi.org/10.1186/1471-2105-9-319>
- Siregar, V.P., S.B. Agus, A. Sunuddin, R.A. Pasaribu, M.S. Sangadji, A. Sugara A, & E. Kurniawati. 2020. Benthic habitat classification using high resolution satellite imagery in Sebaru Besar Island, Kepulauan Seribu. *IOP Conference Series: Earth and Environmental Science*, 429(1): 01240-01248. <https://doi.org/10.1088/1755-1315/429/1/012040>
- Suhendar, D.T., S.I. Sachoemar, & A.B. Zaidy. 2020. Hubungan kekeruhan terhadap materi partikulat tersuspensi (MPT) dan kekeruhan terhadap klorofil dalam tambak udang. *Journal of Fisheries and Marine Research*, 4(3): 332-338. <https://doi.org/10.21776/ub.jfmr.2020.004.03.3>
- Susilo, S.B. 2017. *Penginderaan Jarak Jauh "Ocean Color"*. PT Penerbit IPB Press. Bogor, 2 p.
- Qian, Y., W. Zhou, J. Yan, W. Li, & L. Han. 2015. Comparing machine learning classifiers for object-based land cover classification using very high resolution imagery. *Remote Sensing*, 7(1): 153-168. <https://doi.org/10.3390/rs70100153>
- Wahiddin, N., V.P. Siregar, B. Nababan, I. Jaya, & S. Wouthuyzen. 2015. Object-based image analysis for coral reef benthic habitat mapping with several classification algorithms.

- Proceedings of The 1<sup>st</sup> International Symposium on LAPAN-IPB Satellite for Food Security and Environmental Monitoring, Bogor City, Indonesia. 24-26 November 2014, 222-227 pp. <https://doi.org/10.1016/j.proenv.2015.03.029>
- Wilson, K. L., M.A. Skinner, & H.K. Lotze. 2019. Eelgrass (*Zostera marina*) and benthic habitat mapping in Atlantic Canada using high-resolution SPOT 6/7 satellite imagery. *Estuarine, Coastal and Shelf Science*, 226: 106292. <https://doi.org/10.1016/j.ecss.2019.106292>
- Wu, Z., W. Lin, Z. Zhang, A. Wen, & L. Lin. 2017. An Ensemble Random Forest Algorithm for Insurance Big Data Analysis. Proceedings - 2017 IEEE International Conference on Computational Science and Engineering and IEEE/IFIP International Conference on Embedded and Ubiquitous Computing, CSE and EUC 2017, 531–536 pp. <https://doi.org/10.1109/CSE-EUC.2017.99>
- Yusuf, M., Y. Koniyo, & C. Panigoro. 2013. Keanekaragaman lamun di Perairan sekitar Pulau Dudepo Kecamatan Anggrek Kabupaten Gorontalo Utara. *Jurnal Ilmiah Perikanan dan Kelautan*, 1(1): 18-23. <https://ejournal.ung.ac.id/index.php/nike/article/viewFile/1212/962>
- Zhang, C. 2015. Applying data fusion techniques for benthic habitat mapping and monitoring in a coral reef ecosystem. *ISPRS Journal of Photogrammetry and Remote Sensing*, 104: 213-223. <https://doi.org/10.1016/j.isprsjprs.2014.06.005>
- Zhang, Z. 2016. Introduction to machine learning: k-nearest neighbors. *Annals and Translational Medicine*, 4(11): 1-7. <https://doi.org/10.21037/atm.2016.03.37>
- Submitted : 18 June 2021*  
*Reviewed : 14 May 2022*  
*Accepted : 12 July 2023*

#### FIGURE AND TABLE TITLES

- Figure 1. Research Location (Karang Lebar and Lancang Island). The red box describe the observation location. Karang Lebar (A). Lancang Island (B).*
- Figure 2. Observation points in Karang Lebar (A), and Lancang Island (B) waters.*
- Figure 3. Benthic habitat classification scheme of Karang Lebar.*
- Figure 4. Accuracy values of different segmentation scales in Karang Lebar.*
- Figure 5. Accuracy values of different segmentation scales in Lancang Island.*
- Figure 6. Level 2 OBIA classification in Karang Lebar with SVM (A) DT (B) RF (C) and KNN (D) algorithm.*
- Figure 7. Level 2 OBIA classification in Lancang Island with SVM (A) DT (B) RF (C) and KNN (D) algorithm.*
- Table 1. Karang Lebar benthic habitat classification class area.*
- Table 2. Lancang Island benthic habitat classification class area.*
- Table 3. Confusion matrix result of Karang Lebar benthic habitat classification.*
- Table 4. Confusion matrix result of Lancang Island benthic habitat classification.*
- Table 5. Previous research.*
- Table 6. kappa, variant and Z statistic values.*
- Table 7. Siginificance test value between classification algorithm.*