

KLASIFIKASI HABITAT BENTIK BERBASIS OBJEK DENGAN ALGORITMA SUPPORT VECTOR MACHINES DAN DECISION TREE MENGGUNAKAN CITRA MULTISPEKTRAL SPOT-7 DI PULAU HARAPAN DAN PULAU KELAPA

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

Nico Wantona Prabowo^{1*}, Vincentius P. Siregar², dan Syamsul Bahri Agus²

¹Program Studi Teknologi Kelautan, Institut Pertanian Bogor, Bogor

²Departemen Ilmu dan Teknologi Kelautan, FPIK-IPB, Bogor

*E-mail: prabowonico95@gmail.com

ABSTRACT

The research of object based image classification (OBIA) with machine learning algorithm for high resolution image in Indonesia is still limited especially for coral reef mapping, therefore further research needed for comparison in method and application of algorithms as alternative of classification. This research aims to map benthic habitat based on multiscale classification using OBIA method with support vector machine and decision tree algorithm in Harapan Island and Kelapa Island, Kepulauan Seribu. Segmentation was performed using a multiresolution segmentation algorithm with a scale factor of 15. The OBIA method is applied to atmospheric corrected images with a predefined benthic habitat classification scheme. The overall accuracy of SVM and DT algorithm implementations are 76.68% and 60.62%, respectively. The Z statistic value analysis obtained from the application of two algorithms used is 2.23, where this value indicates that the classification with SVM algorithm is significantly different from the DT algorithm. This research suggest that the OBIA technique could be a promise approach for mapping benthic habitats.

Keywords: OBIA, Harapan and Kelapa Island, segmentation, DT algorithm, SVM algorithm

ABSTRAK

Teknik klasifikasi berbasis objek dengan algoritma *machine learning* SVM untuk citra resolusi tinggi di Indonesia sampai saat ini masih terbatas khususnya untuk pemetaan terumbu karang, oleh karena itu diperlukan kajian lebih lanjut mengenai perbandingan metode maupun penerapan algoritma sebagai alternatif dari proses klasifikasi. Penelitian ini bertujuan memetakan habitat bentik berdasarkan klasifikasi menggunakan metode OBIA dengan algoritma *support vector machine* dan *decision tree* di Pulau Harapan dan Kelapa. Segmentasi dilakukan menggunakan algoritma *multiresolution segmentation* dengan faktor skala 15. Metode OBIA diterapkan pada citra terkoreksi atmosfer dengan skema klasifikasi habitat bentik yang telah ditentukan sebelumnya. Akurasi keseluruhan dari penerapan algoritma SVM dan DT masing-masing sebesar 75,11% dan 60,34%. Analisis nilai Z statistik yang diperoleh dari penerapan dua algoritma yang digunakan yakni sebesar 2,23, dimana nilai ini menunjukkan bahwa klasifikasi dengan algoritma SVM berbeda nyata dengan hasil dari penggunaan algoritma DT.

Kata kunci: algoritma DT, algoritma SVM, OBIA, Pulau Harapan dan Pulau Kelapa, segmentasi

I. PENDAHULUAN

Informasi spasial tentang komposisi, kondisi, dan dinamika habitat bentik pada skala spasial yang tepat merupakan prasyarat mendasar dalam pemahaman dan pengelola-

an ekosistem perairan dangkal (Phinn *et al.*, 2011). Pemetaan ekosistem perairan dangkal yang akurat dengan skala spasial dan label fitur objek yang sesuai dengan komunitas bentik yang ada di dalamnya masih menjadi tantangan dalam aplikasi penginderaan jauh

saat ini. Akurasi peta habitat bentik dan ketidakpastian dalam penerapan algoritma serta metode klasifikasi yang digunakan masih menjadi kendala dalam menghasilkan peta habitat bentik yang akurat sehingga dibutuhkan berbagai alternatif dalam pengembangan algoritma serta metode klasifikasinya.

Peta habitat bentik, umumnya dihasilkan dengan menggunakan metode klasifikasi berbasis piksel (Zhang *et al.*, 2013). Pendekatan lain yang berkembang saat ini yang diharapkan mampu meningkatkan akurasi adalah metode klasifikasi citra berbasis objek (*Object Base Image Analysis/ OBIA*). OBIA telah berkembang dan banyak diaplikasikan pada penelitian - penelitian dalam beberapa dekade terakhir (Roelfsema *et al.*, 2010a; Roelfsema *et al.*, 2010b; Phinn *et al.*, 2011). Penerapan metode OBIA diharapkan dapat meningkatkan akurasi hasil klasifikasi citra untuk objek di perairan.

Teknik klasifikasi OBIA yang digunakan untuk pemetaan terumbu karang telah dilakukan menggunakan citra satelit resolusi tinggi, namun belum menerapkan algoritma klasifikasi *machine learning* (Roelfsema *et al.*, 2008; Phinn *et al.*, 2011). Perbandingan antara teknik klasifikasi parametrik (*maximum likelihood*) dan klasifikasi non-parametrik atau *machine learning* seperti SVM, *neural network* dan DT juga menunjukkan hasil yang cukup signifikan. Masing-masing pendekatan mempunyai kelebihan dan kekurangan (Franklin *et al.*, 2003). Beberapa algoritma *machine learning* yang digunakan pada metode klasifikasi OBIA menggunakan citra resolusi menengah (Landsat 8 OLI) diantaranya *support vector machine* (SVM), *random tree* (RT), *Bayesian*, *k-nearest neighbor* (KNN) dan *decision tree* (DT) menunjukan bahwa algoritma SVM mempunyai kemampuan lebih baik dibandingkan dengan algoritma lainnya dengan tingkat akurasi mencapai 73% (Wahiddin *et al.*, 2015). Mehta *et al.* (2007) juga menguji kemampuan algoritma SVM untuk klasifikasi tekstur beberapa jenis

karang dan menghasilkan akurasi tinggi dengan tipe kernel rbf. Penelitian tersebut menunjukkan bahwa klasifikasi berbasis objek dengan algoritma SVM mampu meningkatkan akurasi pemetaan yang lebih baik dibandingkan dengan algoritma klasifikasi tradisional berbasis piksel.

Penerapan algoritma *machine learning* dalam menghasilkan informasi habitat bentik menggunakan data penginderaan jauh dengan pendekatan teknik OBIA masih sangat terbatas (Anggoro *et al.*, 2015; Phinn *et al.*, 2011; Duro *et al.*, 2012; Myint *et al.*, 2011), sehingga diperlukan kajian yang komprehensif untuk mengetahui kemampuan algoritma tersebut sehingga dapat diterapkan pada teknik klasifikasi ekosistem terumbu karang untuk menghasilkan peta-peta tematik yang lebih baik. Penelitian ini bertujuan mengetahui kemampuan teknik klasifikasi OBIA untuk pemetaan habitat bentik menggunakan algoritma klasifikasi *machine learning* SVM dan DT di Pulau Harapan dan Kelapa, Kepulauan Seribu.

II. METODE PENELITIAN

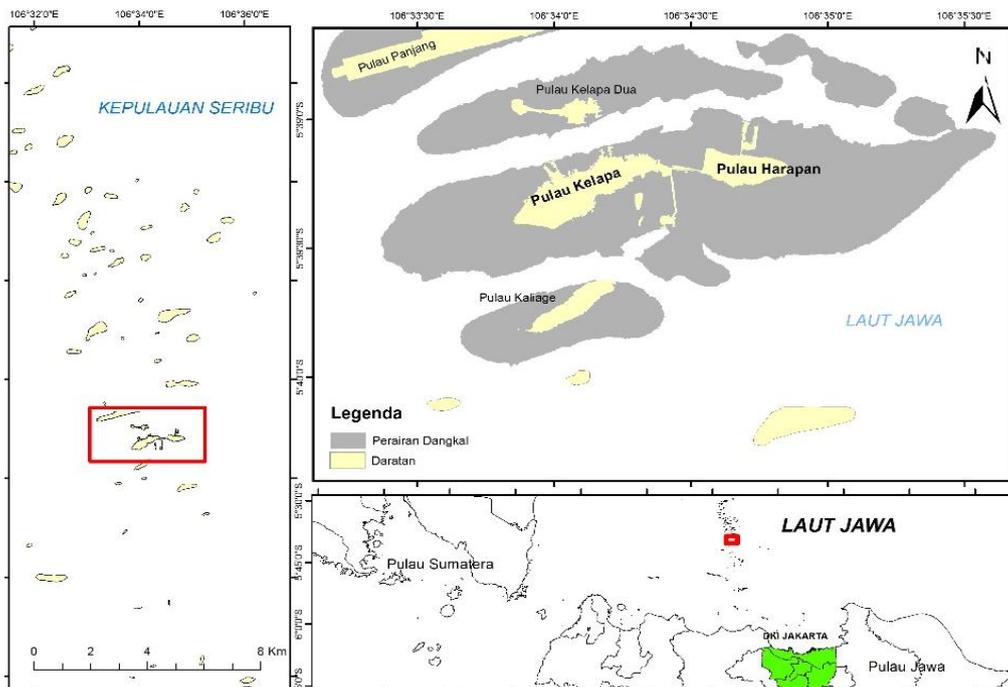
2.1. Waktu dan Tempat Penelitian

Penelitian ini dilakukan pada bulan April tahun 2017 di wilayah perairan dangkal Pulau Harapan dan Kelapa, Kabupaten Administrasi Kepulauan Seribu, DKI Jakarta (Gambar 1). Gugusan Pulau Harapan menunjukkan tipologi khas ekosistem pulau karang (*coral cays*), yang memiliki beragam habitat yaitu terumbu karang, padang lamun, goba, dan pasir (Agus, 2012).

2.2. Bahan dan Alat

2.2.1. Data

Perangkat keras yang digunakan untuk pengolahan data adalah Personal Computer prosesor Intel Core i3, RAM 4 GB dengan media penyimpanan 750 GB. Perangkat lunak digunakan untuk membantu proses pengolahan data terdiri dari microsoft office 2013, XLSTAT, DNR Garmin Versi 5.4, ArcGIS Desktop 10.4, perangkat lunak



Gambar 1. Peta lokasi penelitian (sumber data : citra SPOT 7 akuisisi tanggal 12 Juni 2016).

pemrosesan citra dan klasifikasi berbasis objek. Peralatan yang digunakan pada saat survei lapangan terdiri dari peralatan perekaman data koordinat, dokumentasi dan pencatatan objek habitat bentik. Data yang digunakan adalah citra multispektral SPOT-7 daerah Kepulauan Seribu dan data survei habitat bentik. Citra multispektral SPOT-7 diakuisi pada tanggal 12 Juni tahun 2016 dengan sistem proyeksi koordinat UTM zona 48S WGS84. Karakteristik citra SPOT 7 terdiri dari 4 kanal (saluran) multispectral (*Blue, Green, Red, NIR*) dengan resolusi spasial 6 meter dan pankromatik 1,5 meter.

2.2.2. Survei Lapang

Survei lapang dilakukan untuk mengamati secara langsung (*in situ*) objek yang ada pada citra dan menghubungkan realitas objek habitat bentik dengan hasil klasifikasi citra. Teknik pengumpulan data dilakukan dengan menggunakan transek kuadrat berukuran 1x1 m, setiap titik pengambilan data dibantu dengan menggunakan GPS *handheld* dan *geodetic* serta kamera *underwater* untuk memudahkan identifikasi masing-masing data set. Pengambilan data

habitat bentik dilakukan dengan metode *systematic random sampling* dengan jarak setiap titik sampling sekitar 20 m dan dilakukan menyebar pada lokasi penelitian agar setiap objek dapat terwakili dengan baik. Teknik ini didasarkan pada pengetahuan tentang lokasi penelitian yang dibagi dalam kelompok-kelompok dipilih secara acak (Congalton dan Green, 2009).

2.3. Analisis Data

2.3.1. Deskripsi Kelas Habitat

Deskripsi kelas habitat didasarkan pada persen tutupan komponen bentik hasil pengamatan lapangan foto kuadrat 1x1 m. Persentase tutupan komponen bentik dihitung berdasarkan jumlah titik objek komponen penyusun bentik terumbu karang yang ditumpang susun dengan foto kuadrat dengan skema tumpang susun titik uniform grid menggunakan perangkat lunak *Coral Point Count with Excel extensions* (CPCe) (Kohler dan Gill, 2006). Nilai persentase tutupan komponen penyusun bentik hasil analisis dikonversi (*export*) dari perangkat lunak CPCe ke perangkat pengolahan data (*spreadsheet*) Microsoft Excel 2013 untuk

diperoleh data tabulasi seluruh stasiun pengamatan. Kemudian dilanjutkan dengan analisis data multivarian (analisis hirarki *cluster*) menggunakan perangkat lunak XLSTAT sehingga dihasilkan dendrogram pengelompokan objek habitat bentik. Skema klasifikasi dikembangkan menggunakan data persentase tutupan penyusun habitat bentik dengan mengeliminasi komponen yang memiliki frekuensi kehadiran kurang dari 4% berdasarkan analisis hirarki *cluster* (Green *et al.*, 2000).

2.3.2. Pra Pemrosesan Citra

Pengolahan citra satelit SPOT-7 diawali dengan beberapa tahapan diantaranya koreksi citra yang meliputi koreksi atmosferik, geometrik, dan radiometrik. Proses koreksi atmosferik dilakukan menggunakan modul koreksi FLAASH (*Fast Line-of-sight Atmospheric Analysis of Spectral Hypercube*) yang terdapat pada perangkat lunak ENVI 5.1 (Felde *et al.*, 2003). Selanjutnya proses *masking* dilakukan untuk menghilangkan efek wilayah daratan, perairan dalam, dan objek-objek lain yang tidak diperlukan untuk proses pengolahan citra lebih lanjut. *Masking* dilakukan dengan memanfaatkan kanal 4 (NIR). Pemilihan kanal ini disebabkan karena respon spektral yang cukup kontras antara wilayah darat dan laut pada kanal tersebut. Kemudian citra yang telah terkoreksi digunakan sebagai input pada proses klasifikasi citra.

2.3.3. Segmentasi

Klasifikasi berbasis objek terdiri dari dua tahap yaitu segmentasi dan klasifikasi. Segmentasi adalah konsep membangun objek/segmen dari piksel-piksel menjadi segmen atau objek-objek yang memiliki sifat yang sama (Navulur, 2007). Algoritma segmentasi yang digunakan pada penelitian ini adalah multiresolusi/MRS (*multi-resolution segmentation*). Algoritma ini dimulai dengan segmen piksel tunggal dan menggabungkan segmen tetangga (*neighbouring segments*) hingga ambang batas

(*threshold*) heterogenitas tercapai. Proses segmentasi sangat bergantung pada tiga faktor yakni *shape*, *compactness*, dan *scale* sehingga menciptakan homogenitas pada segmen yang dihasilkan (Trimble, 2014). Segmentasi dilakukan menggunakan parameter *shape* dan *compactness* dengan nilai masing-masing sebesar 0,1 dan 0,5. Segmentasi dilakukan menggunakan algoritma *multiresolution segmentation* dengan faktor skala 15.

2.3.4. Klasifikasi

Citra yang digunakan sebagai *input layer* pada proses klasifikasi adalah citra yang telah terkoreksi atmosferik. Saluran yang digunakan yaitu kanal sinar tampak (*blue*, *green*, *red* dan saluran inframerah dekat (NIR)). Kemudian dilanjutkan dengan membuat *rule set* klasifikasi dalam komponen *process tree*. Algoritma klasifikasi yang digunakan adalah algoritma *support vector machines* (SVM) dan *decision tree* (DT) SVM merupakan algoritma klasifikasi terbimbing yang dapat mencari sebuah *vector* atau garis yang berfungsi sebagai pemisah dua kelas dengan memaksimalkan margin antar kelas tersebut (Wahidin *et al.*, 2015). Algoritma klasifikasi ini berdasarkan prinsip *linear classifier* yang tergolong klasifikasi *machine learning*. (Nugroho *et al.*, 2003). Fungsi kernel rbf SVM dilakukan menggunakan persamaan (Vapnik, 1982):

$$k = \exp\left(-\frac{\|x-x'\|^2}{2\sigma^2}\right) \dots\dots\dots(1)$$

Keterangan: *x* merepresentasikan vektor dari setiap data, σ merepresentasikan jumlah derajat dari fungsi polinomial.

Algoritma DT merupakan struktur diagram yang setiap node nya merepresentasikan data dalam atribut. Asumsi dasar untuk klasifikasi ini adalah pengamatan label objek yang mirip satu sama lain dalam variabel yang berbeda. Konsep data dalam *decision tree* dinyatakan dalam bentuk tabel yang terdiri dari atribut dan data record.

Atribut digunakan sebagai parameter yang dibuat untuk kriteria dalam pembuatan hirarki (Sartika dan Sensuse, 2017). Banyak pendekatan yang dapat digunakan untuk menentukan atribut terpilih, pada penelitian ini menggunakan perhitungan *gainratio* dari setiap kriteria dengan data sampel. Untuk menghitung nilai *gainratio* dapat dilakukan dengan persamaan sebagai berikut (Sartika dan Sensuse, 2017):

$$Gainratio(S,A) = \frac{Gain(S,A)}{SplitInformation(S,A)} \dots\dots\dots(2)$$

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). Kemudian tahapan selanjutnya yakni mengubah model pohon menjadi *rule*. Simpul akar dan cabang menjadi premis dari aturan, sedangkan simpul daun menjadi bagian dari konklusinya (solusi). Tiap premis yang terdapat dalam satu atribut dihubungkan dengan hubungan disjungsi, sedangkan premis yang memiliki lanjutan premis pada cabang selanjutnya dihubungkan dengan konjungsi. Kemudian dilanjutkan dengan proses penyederhanaan *rule* yang telah dibuat dengan terlebih dahulu membuat membuat tabel distribusi terpadu dengan menyatakan semua nilai kejadian pada setiap *rule* lalu disederhanakan menggunakan persamaan sebagai berikut (Sartika dan Sensuse 2017):

$$X^2_{hitung} = \sum_{i=1}^r \sum_{j=1}^r \frac{(n_{ij} - e_{ij})^2}{e_{ij}} \dots\dots\dots(3)$$

Keterangan = n_{ij} adalah nilai record baris ke i kolom ke j dari tabel distribusi terpadu. Sedangkan e_{ij} adalah hasil pembagian nilai margin baris ke i kolom ke j dengan nilai *record* data.

2.3.5. Akurasi Citra

Uji akurasi dilakukan menggunakan matriks kesalahan (*confusion matrix*). Matrik tersebut membandingkan kelas-kelas habitat dari hasil klasifikasi citra terhadap kelas yang sebenarnya dari hasil survei lapang (Agus, 2012). Tiga parameter umum yang diperoleh dari matriks kesalahan yaitu *overall accuracy* (OA), *producer’s accuracy* (PA), dan *user’s accuracy* (UA) (Green *et al.*, 2000). Perhitungan masing-masing akurasi dilakukan dengan persamaan sebagai berikut (Cangalton dan Green, 2009):

$$Overall\ accuracy = \frac{\sum_{i=1}^k n_{ii}}{n} \dots\dots\dots(3)$$

$$Producer\ accuracy = \frac{n_{jj}}{n+j} \dots\dots\dots(4)$$

$$User\ accuracy = \frac{n_{ii}}{n_i+} \dots\dots\dots(5)$$

Keterangan: k = jumlah baris pada matriks, n = jumlah pengamatan, n_{ii} = jumlah pengamatan pada kolom ke-i dan baris ke-i, n_{jj} = jumlah pengamatan pada kolom ke-j dan baris ke-j, n_{i+} = total marginal baris ke-I, n_{+j} = total kolom.

Uji Kappa dilakukan untuk menentukan nilai dua matriks kesalahan yang secara signifikan berbeda. Z statistik dari hasil klasifikasi dengan dua metode yang berbeda dihitung kemudian dilakukan *pairwise comparison* untuk melihat signifikansi dari setiap metode. Nilai $K1$ dan $K2$ merupakan estimasi *Kappa statistic* dari masing-masing matriks kesalahan. Z adalah nilai standarisasi dan distribusi normal (standar deviasi). Uji statistik untuk mengetahui jika dua matriks kesalahan independen berbeda secara signifikan dilakukan menggunakan persamaan:

$$Z = \frac{k1-k2}{\sqrt{var\ k1+var\ k2}} \dots\dots\dots(6)$$

III. HASIL DAN PEMBAHASAN

3.1. Skema Klasifikasi

Hasil pengamatan lapangan yang diperoleh dari survei dikelompokkan ke dalam kelas habitat bentik dengan merujuk kelas habitat yang dilakukan oleh beberapa peneliti sebelumnya (Anggoro *et al.*, 2015; Siregar *et al.*, 2013; Phinn *et al.*, 2011; Roelfsema *et al.*, 2008; Andrefouet *et al.*, 2003). Karakteristik komponen penyusun habitat bentik di wilayah Pulau Harapan dan Kelapa diidentifikasi sebanyak 8 habitat yaitu *hardcoral*, *sponge*, makroalga, *dead coral*, *alga*, *soft coral*, pasir, *rubble*, dan lamun. Masing-masing habitat memiliki presentase nilai kehadiran yang berbeda-beda tergantung kondisi wilayah dan jumlah titik pengamatan di lapangan.

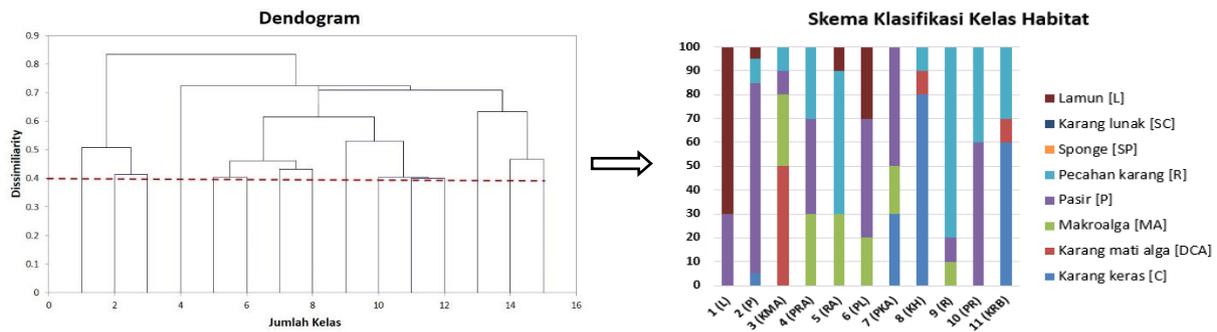
Skema klasifikasi dikembangkan berdasarkan data persentase tutupan penyusun habitat bentik dengan mengeliminasi komponen yang memiliki frekuensi kehadiran kurang dari 4%. Jumlah frekuensi kehadiran habitat bentik lebih dari 4% selanjutnya dilakukan analisis kluster untuk memperoleh kelas-kelas habitat bentik yang ditunjukkan pada dendrogram. Sumbu x dendrogram menunjukkan kelas-kelas objek yang terbentuk. Deskripsi skema klasifikasi selanjutnya diturunkan dari nilai persentase delapan komponen bentik berdasarkan nilai ketidakmiripan koefisien *Bray-Curtis* sebesar 40%. Tidak ada ketentuan dalam menggunakan nilai kemiripan untuk mendefinisikan skema klasifikasi berdasarkan analisis pengelompokan karena disebabkan oleh kondisi dan variasi lokasi pengamatan yang berbeda-beda serta disesuaikan dengan *platform* citra satelit yang digunakan (Green *et al.*, 2000). Nilai ketidakmiripan (*dissimilarity*) 40% menunjukkan bahwa setiap kelas habitat yang dibangun memiliki kemiripan komponen penyusun habitat bentik minimal 60%. Jumlah kelas habitat yang dihasilkan berdasarkan analisis pengelompokan yang ditunjukkan pada dendrogram yakni sebanyak 15 kelas (Gambar 2).

Jumlah titik sampel tiap kelas berkisar antara 6 hingga 94 sampel. Kelas 1 dan 2 merupakan kelas dengan jumlah sampel terbanyak yaitu 46 dan 94 sampel, sedangkan kelas 11, 12, dan 13 mempunyai jumlah sampel yang kurang dari 16 sampel dengan frekuensi kehadiran kurang dari 4%. Green *et al.* (2000) menyatakan bahwa pengelompokan kurang dari 4% sebaiknya dihilangkan dan tidak digunakan dalam penentuan jumlah kelas habitat pada proses klasifikasi dan validasi objek. Berdasarkan sebaran total 15 kelas habitat yang terbentuk dari hasil analisis kluster, hanya 11 kelas yang memenuhi frekuensi kehadiran minimal 4% sedangkan 4 kelas yaitu kelas 11 hingga kelas 14 memiliki frekuensi kehadiran kurang dari 4% sehingga tidak digunakan dalam proses klasifikasi. Penamaan 11 kelas habitat bentik terdiri dari: pasir campur *rubble* campur alga (PRA), karang mati campur makroalga (KMA), karang hidup campur *rubble* (KRB), lamun (L), pasir (P), pasir campur lamun (PL), pasir campur karang hidup (PKA), pasir campur *rubble* (PR), karang hidup (KH), *rubble* (R), dan *rubble* campur alga (RA) (Gambar 2).

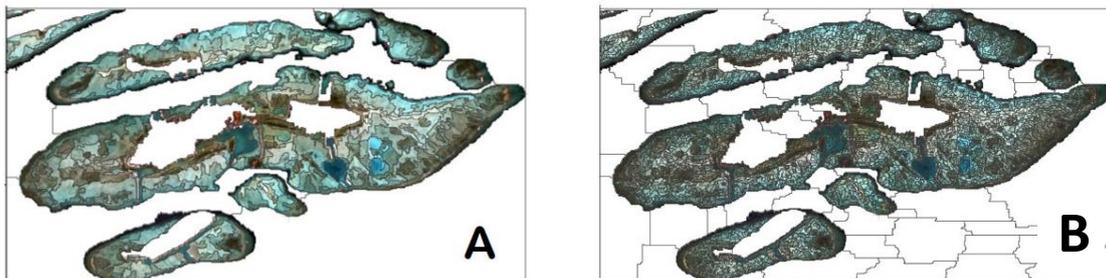
3.2. Klasifikasi Berbasis Objek

3.2.1. Optimasi Skala Segmentasi

Optimasi skala segmentasi klasifikasi berbasis objek mengacu pada hasil penelitian sebelumnya (Siregar *et al.*, 2016) dengan faktor skala segmentasi 15. Segmentasi citra pada masing-masing *scale* yang diterapkan menghasilkan jumlah polygon yang berbeda. *Scale* yang dimaksud adalah ukuran rata-rata objek yang dihasilkan pada proses segmentasi (Trimble, 2014), semakin besar ukuran *scale* yang diberikan maka semakin besar ukuran rata-rata objek dalam satu poligon hasil segmentasi, dengan demikian terdapat beberapa fitur pada *scale* lebih detil yang tergabung menjadi satu objek pada *scale* yang lebih besar (Gambar 3). Penelitian ini dilakukan dengan *scale factor* 15 (Siregar *et al.*, 2016).



Gambar 2. Dendrogram dan skema klasifikasi habitat dari komponen penyusun bentik.

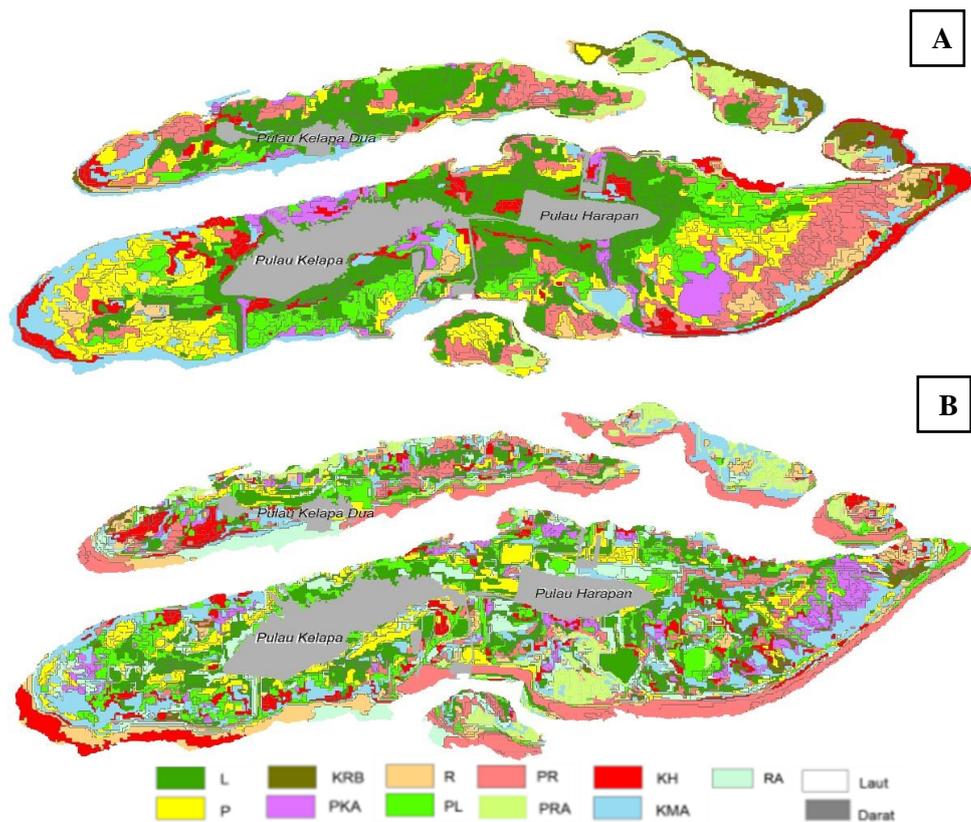


Gambar 3. Variasi ukuran objek yang dihasilkan dari besaran skala segmentasi; skala segmentasi (a) 100 dan (b) 15.

3.2.2. Klasifikasi Habitat Bentik Berbasis Objek

Klasifikasi OBIA menunjukkan habitat bentik terdistribusi di perairan dangkal Pulau Harapan dan Kelapa (Gambar 4a dan Gambar 4b). Berdasarkan hasil klasifikasi menggunakan algoritma SVM, distribusi kelas karang hidup (KH) dan karang campur rubble (KRB) mendominasi zona geomorfologi kelas *reef slope*. Kelas pasir campur rubble (PR) dan karang mati campur alga (KMA) mendominasi pada zona geomorfologi kelas *reef crest*. Sedangkan habitat bentik kelas pasir, lamun, dan campuran tersebar di zona geomorfologi kelas *reef flat* dan sekitar *lagoon*. Klasifikasi menggunakan algoritma DT menunjukkan habitat lamun (L) mendominasi zona geomorfologi *reef flat*. Habitat pasir (P) juga terdapat pada zona ini namun tidak terlalu luas. Habitat karang mati campur alga (KMA) mendominasi hampir di seluruh zona *reef crest*, sedangkan zona *reef slope* didominasi oleh habitat pasir campur rubble (PR) dan karang hidup (KH).

Penerapan algoritma SVM menghasilkan luas habitat karang hidup sebesar 35,48 Ha (10%), pasir 61,53 Ha (17%), lamun 56,79 Ha (15%), dan rubble 34,38 (9%). Sedangkan klasifikasi dengan algoritma DT menghasilkan luas habitat karang hidup sebesar 28,92 Ha (8%), pasir 41,6 Ha (12%), lamun 50,42 Ha (14%), dan rubble 26,66 (7%). Perbedaan luasan yang dihasilkan menunjukkan implikasi dari penerapan kedua metode klasifikasi yang digunakan. Perbedaan luasan tersebut dapat disebabkan karena adanya tumpang tindih (*overlap*) antar kelas habitat bentik yang telah terklasifikasi serta adanya kekeliruan fitur segmen yang tidak terklasifikasi dengan benar. Hal ini sangat bergantung pada pemilihan metode klasifikasi yang digunakan. Menurut Green *et al.* (2000), perbedaan hasil klasifikasi pemetaan dari beberapa penelitian disebabkan oleh perbedaan metode klasifikasi, jumlah titik pengamatan lapangan, jumlah kelas habitat bentik dan citra yang digunakan. Kesalahan dalam melakukan klasifikasi akan mempengaruhi luasan pada tiap kelas yang mengakibatkan rendahnya akurasi.



Gambar 4. Klasifikasi habitat bentik Pulau Harapan dan sekitarnya dengan algoritma SVM (a) dan algoritma DT (b).

3.3. Akurasi Klasifikasi OBIA Menggunakan Algoritma SVM dan DT

Pendugaan akurasi klasifikasi dihitung menggunakan matriks kesalahan (*confusion matrix*) dari 237 titik pengamatan. Akurasi keseluruhan (OA) dari hasil klasifikasi menggunakan algoritma SVM dan DT sebesar 75,11% dan 60,34% (Tabel 1). Nilai PA serta UA yang dihasilkan berkisar antara 30%-80%. Akurasi peta tematik yang dihasilkan dengan teknik klasifikasi berbasis objek menggunakan algoritma SVM lebih tinggi daripada penggunaan algoritma DT dengan peningkatan nilai OA sebesar 15,7%. Akurasi peta tematik yang dihasilkan dengan teknik klasifikasi OBIA menggunakan algoritma *machine learning* menunjukkan bahwa habitat bentik telah dapat dipetakan dengan baik.

Berdasarkan hasil pendugaan akurasi klasifikasi dengan algoritma SVM menunjukkan bahwa akurasi pengguna (UA) tertinggi terdapat pada kelas lamun, sedangkan nilai UA terendah terdapat pada kelas campuran *rubble* alga, hal ini menunjukkan bahwa kelas habitat bentik campuran *rubble* alga belum dapat dipetakan dengan baik. Variabilitas objek yang cukup tinggi pada setiap segmen terkait dapat mempengaruhi nilai akurasi. Hasil klasifikasi berdasarkan nilai PA dan UA menunjukkan bahwa kelas yang disusun oleh komponen habitat bentik terumbu karang dengan tingkat heterogenitas yang tinggi tidak mampu dipisahkan dengan baik dari citra satelit. Kemiripan spektral antar kelas-kelas habitat bentik terumbu karang tidak dapat dihindari oleh algoritma klasifikasi, khususnya kelas-kelas habitat bentik yang disusun oleh komponen yang bercampur dengan pasir dan habitat *rubble*.

Tabel 1. Perbandingan hasil uji akurasi klasifikasi menggunakan algoritma SVM dan DT.

Class	SVM		DT	
	PA	UA	PA	UA
L	69,70	87,10	65,85	64,52
KMA	58,82	71,43	56,25	90,48
P	69,39	85,71	85,29	57,14
KH	70,83	82,61	68,75	43,48
KRB	72,22	76,42	77,78	41,18
PR	43,48	80,00	38,46	86,67
PL	62,50	74,29	69,44	68,57
PKA	50,00	50,00	35,71	70,00
R	47,37	56,25	38,46	50,00
PRA	45,45	55,56	40,00	33,33
RA	80,00	45,45	83,33	36,36
OA	75,11		60,34	

Keterangan : pasir+rubble +algae (PRA) karang hidup + algae (KMA), karang hidup+rubble (KRB), lamun (L), pasir (P), pasir+lamun (PL), pasir + karang hidup (PKA), pasir+rubble (PR), karang hidup (PH), rubble (R) dan rubble +algae (RA).

Banyak faktor yang dapat mempengaruhi kesalahan dalam klasifikasi, salah satunya adalah kesalahan dalam mengidentifikasi objek berdasarkan definisi yang digunakan serta terdapat kesalahan dalam penentuan *training area* masing-masing kelas habitat yang dapat mempengaruhi hasil klasifikasi. Teknik klasifikasi dengan algoritma SVM menghasilkan nilai UA yang lebih baik pada habitat lamun, karang hidup, dan pasir. Faktor utama yang mempengaruhi peningkatan akurasi dengan algoritma SVM adalah kemampuan dalam membedakan objek dengan baik dari data yang bersifat linear maupun non linear, sedangkan algoritma DT sangat rentan terhadap *overlap* terutama ketika kelas-kelas dan fitur yang digunakan jumlahnya sangat banyak (Zhang *et al.*, 2013). Algoritma SVM dalam bidang penginderaan jauh mempunyai kemampuan yang baik untuk menangani data dengan jumlah yang kecil dan menghasilkan ketepatan akurasi yang lebih baik dibandingkan dengan teknik klasifikasi lainnya (Mountrakis *et al.*, 2011). Congalton dan Green (2009) menyatakan bahwa untuk mengetahui perbandingan antara dua atau lebih akurasi pemetaan pada klasifikasi citra

adalah dengan menganalisis Kappa dan Z-test. Tabel 2 menunjukkan nilai Z statistik yang diperoleh dari dua algoritma yang digunakan yakni 2,23, dimana nilai ini menunjukkan bahwa klasifikasi dengan algoritma SVM berbeda nyata dengan hasil dari penggunaan algoritma DT.

Tabel 2. Nilai akurasi (OA) dan nilai KAPPA-test pada dua pendekatan klasifikasi.

Klasifikasi	KAPPA	Akurasi (OA)
SVM	0,692	75,11
DT	0,506	60,34

IV. KESIMPULAN

Ekosistem habitat benthik mampu dipetakan dengan baik untuk penerapan metode klasifikasi berbasis objek (OBIA) dengan penerapan algoritma SVM dan DT pada citra SPOT-7 di wilayah Pulau Harapan dan Kelapa. Skema klasifikasi habitat yang digunakan yakni sebanyak 11 kelas habitat benthik. Akurasi hasil klasifikasi yang diperoleh masing-masing sebesar 75,11%

dan 60,34% untuk penerapan algoritma SVM dan DT. Akurasi keseluruhan tertinggi dihasilkan dari penerapan algoritma SVM dan berdasarkan Z test berbeda signifikan sebesar 2,23 dengan penerapan algoritma DT. Penerapan algoritma SVM pada pemetaan habitat bentik berbasis objek memiliki akurasi yang lebih tinggi sebesar 15,7% sehingga dapat dijadikan sebagai teknik alternatif dalam pemetaan habitat bentik. Perbedaan akurasi pemetaan habitat bentik disebabkan perbedaan metode klasifikasi, jumlah titik pengamatan lapangan, jumlah kelas habitat bentik dan citra yang digunakan.

UCAPAN TERIMA KASIH

Ucapan terima kasih ditujukan kepada Ditjen Dikti, Kementerian Riset Teknologi dan Pendidikan Tinggi yang telah membiayai penelitian ini melalui program BOPTN dengan skema penelitian PUPT Tahun Anggaran 2016 atas nama Prof. Dr. Ir. Vincentius P. Siregar, DEA serta seluruh pihak yang telah membantu kelancaran pelaksanaan penelitian ini.

DAFTAR PUSTAKA

Agus, S.B. 2012. Kajian konektivitas habitat ontogeni ikan terumbu menggunakan pemodelan geospasial di perairan Kepulauan Seribu. Disertasi. Fakultas Perikanan dan Ilmu Kelautan. Institut Pertanian Bogor. 411hlm.

Andrefouet, S., P. Kramer, D. Torres-Pulliza, K.E. Joyce, E.J. Hochberg, R. Garza-Pérez, P.J. Mumby, B. Riegl, H. Yamano, and W.H. White. 2003. Multi-site evaluation of ikonos data for classification of tropical coral reef environments. *J. of Remote Sensing and Environment*, 88:128-143.

Anggoro, A., V.P. Siregar, dan S.B. Agus. 2015. Pemetaan zona geomorfologi ekosistem terumbu karang menggunakan metode obia, studi kasus Pulau

Pari. *J. Penginderaan Jauh*, 12(1):1-12.

Blaschke, T. 2010. Object based image analysis for remote sensing. *ISPRS J. of Photogrammetry and Remote Sensing*, 65:2-16.

Congalton, R.G. and K. Green. 2009. Assessing the accuracy of remotely sensed data principles and practices 2nd ed. CRC Press Indiana. 201p.

Duro, D.C., S.E. Franklin, M.G. and Dube. 2012. Comparison of pixel-based and object based image analysis with selected machine learning algorithms for the classification of agricultural lands-capes using SPOT-5 HRG imagery. *Remote Sensing of Environment*, 112:259-272.

Felde, G.W., G.P. Anderson, T.W. Coole, M.W. Matthew, S.M. Adler-Golden, A. Berk, and J. Lee. 2003. Analysis of hyperion data with the FLAASH atmospheric correction algorithm. *IEEE IGARSS: Learning from Earth's Shapes and Colours*. Toulouse. 92p.

Franklin, J., Rogan, J., Phinn, S., and Woodcock, C. 2003. Rationale and Conceptual Framework for Classification Approaches to Assess Forest Resources and Properties. *Remote Sensing of Forest Environments*. 'Dalam': Wulder M, Franklin S, 'editor', Springer US: 279-300p.

Green, E.P., P.J. Mumby, A.J. Edwards, and C.D. Clark. 2000. Remote sensing handbook for tropical coastal management. UNESCO. 56p.

Kohler, K.E. and S.M. Gill. 2006. Coral point count with excel extensions (cpce): A visual basic program for the determination of coral and substrate coverage using random point count methodology. *J. of Computers & Geosciences*, 32: 1259-1269.

Mehta, A., E. Ribeiro, J. Gilner, and R. V. Woesik. 2007. Coral reef texture classification using support vector

- machine. *In: Braz et al. (eds.) International Conference VISIGRA PP 2007*, Springer. Barcelona (SP). 48-56pp.
- Mountrakis, G., J. Im, and C. Ogole. 2011. Support vector machines in remote sensing: A review. *ISPRS J. of Photogramm.*, 66(3):247-259.
- Mumby, P.J., E.P. Green, A.J. Edwards, and C.D. Clark. 1999. The cost-effectiveness of remote sensing for tropical coastal resources assessment and management. *J. of Environmental Management*, 55:157-166.
- Myint, S.W., P. Gober, A. Brazel, S.G. Clarke, and Q. Weng. 2011. Per-pixel vs. object based classification of urban land cover extraction using high spatial resolution imagery. *Remote Sensing of Environment*, 115:1145-1161.
- Navulur, K. 2007. Multispektral image analysis using the object-oriented paradigm Taylor & Francis Group. LLC. 171p.
- Nugroho, A.S., A.B. Witarto, dan D. Handoko. 2003. Support vector machine teori dan aplikasinya dalam bioinformatika. *J. Ilmu Komputer*, 23: 145-151.
- Phinn, S.R., C.M. Roelfsema, and P.J. Mumby. 2011. Multi-scale. object-based image analysis for mapping geomorphic and ecological zones on coral reefs. *International J. of Remote Sensing*, 33:3768-3797.
- Roelfsema, C. and S. Phinn. 2008. Evaluating eight field and remote sensing approaches for mapping the benthos of three different coral reef environments in fiji. *Proc. of SPIE.*, 7510(75100F):4135-4142.
- Roelfsema, C., S. Phinn, S. Jupiter, J. Comley, M. Beger, and E. Paterson. 2010a. The application of object based analysis of high spatial resolution imagery for mapping large coral reef systems in the west pacific at geomorphic and benthic community spatial scales. *In: Bill and Franklin (eds.). Proc. of 2010 IEEE International Geoscience and Remote Sensing Symposium.* US. 4346-4349pp.
- Roelfsema, C., S. Phinn, S. Jupiter, M. Comley, M. Beger, and E. Peterson. 2010b. Object based analysis of high spatial resolution imagery for mapping large coral reef systems in the west pacific at geomorphic and benthic community scales. *In: Jonathan and William (eds.). Proc. of 2010 IEEE International Geoscience and Remote Sensing Symposium.* US. 4346-4349p.
- Sartika, D. dan D.I. Sensuse. 2017. Perbandingan Algoritma Klasifikasi Naive Bayes, Nearest Neighbour, dan Decision Tree pada Studi Kasus Pengambilan Keputusan Pemilihan. *Jatisi*, 1(2):151-161.
- Siregar, V.P., S. Wouthuyzen, A. Sunuddin, A. Anggoro, dan A.A. Mustika. 2013. Pemetaan habitat dasar dan estimasi stok ikan terumbu dengan citra satelit resolusi tinggi. *J. Ilmu dan Teknologi Kelautan Tropis*, 5(2):453-463.
- Siregar, V.P., S.B. Agus, T. Subarno, dan N.W. Prabowo. 2016 Mapping of shallow water benthic habitat on reef flat zone using object based and pixel based image classification in Harapan-Kelapa Islands, Kepulauan Seribu. *Proc. of 3rd International Symposium LISAT.* International Convention Center, Botani Square Bogor, 24-25 Oktober 2016. 39-50pp.
- Trimble. 2014. Ecognition developer: User guide. Trimble. Munich, Germany. 289p.
- Wahiddin, N., V.P. Siregar, B. Nababan, I. Jaya, and S. Wouthuyzen. 2015. Object-based image analysis for coral reef benthic habitat mapping with several classification algorithms.

- Proc. Environmental Sciences*, 24: 222-227.
- Zhang, C., D. Selch, Z. Xie, C. Roberts, H. Cooper, and G. Chen. 2013. Object-based benthic habitat mapping in the Florida Keys from hyperspectral imagery. *J. of Estuary Coast Shelf*, 134: 88-97.
- Diterima* : 13 Oktober 2017
Direview : 23 Oktober 2017
Disetujui : 23 Maret 2018