



Perbandingan Klasifikasi SVM dan *Decision Tree* untuk Pemetaan *Mangrove* Berbasis Objek Menggunakan Citra Satelit Sentinel-2B di Gili Sulat, Lombok Timur

Comparison of SVM and Decision Tree Classifier with Object Based Approach for Mangrove Mapping to Sentinel-2B Data on Gili Sulat, Lombok Timur

Septiyan Firmansyah^a, Jonson Gaol^b, Setyo Budi Susilo^b

^a Mayor Teknologi Kelautan, FPIK, Pascasarjana Institut Pertanian Bogor, Kampus IPB Darmaga, Bogor 16680

^b Departemen Ilmu dan Teknologi Kelautan, FPIK, Institut Pertanian Bogor, Kampus IPB Darmaga, Bogor 16680

Article Info:

Received: 04 - 06 - 2018

Accepted: 11 - 10 - 2019

Keywords:

Classification, decision tree, mangrove, OBIA, remote sensing, SVM

Corresponding Author:

Septiyan Firmansyah
Mayor Teknologi Kelautan,
FPIK, Pascasarjana Institut
Pertanian Bogor;
Email: septiyan_f@gmail.com

Abstract: *Mangrove is one of the most important objects in wetland ecosystems. Mangrove research has been done, one of them is using remote sensing technology. This study aims to assess accuracy of object based image analysis (OBIA) approach on both Support Vector Machine (SVM) and Decision Tree classification methods to classify mangrove and estimate mangrove area in the field study. We selected Kawasan Konservasi Laut Daerah (KKLD) Gili Sulat as a research site. This research used Sentinel-2B satellite imagery. We took field data using stratified random sampling and the amount of the data we collected were 121 points. The classification analysis result with object based showed that SVM had an overall accuracy of 95 % ($kappa = 0.86$) and Decision Tree classification had an overall accuracy of 93 % ($kappa = 0.82$). It is caused SVM can reduce the error of classification than Decision Tree. Estimation result based on assessment showed that mangrove using SVM had 634.62 Ha while using Decision Tree had 590.47 Ha.*

How to cite (CSE Style 8th Edition):

Firmansyah S, Gaol J, Susilo SB. 2019. Perbandingan klasifikasi SVM dan *decision tree* untuk pemetaan *mangrove* berbasis objek menggunakan citra satelit sentinel-2b di Gili Sulat, Lombok Timur. JPSL 9(3): 746-757. <http://dx.doi.org/10.29244/jpsl.9.3.746-757>.

PENDAHULUAN

Latar Belakang

Pemanfaatan citra satelit multispektral untuk pengelolaan sumber daya alam sudah banyak dilakukan (Tunggadewi *et al.* 2014 dan Putra *et al.* 2016). Bentuk pemanfaatan yang digunakan salah satunya ialah untuk kawasan pesisir yaitu *monitoring mangrove*. Beberapa jenis citra multispektral yang umum digunakan diantaranya adalah Landsat, QuickBird dan IKONOS. Aziz *et al.* (2015) menggunakan citra Landsat untuk memetakan *mangrove* yang dikaitkan dengan produktivitasnya di Peninsular, Malaysia. Penelitian lainnya menggunakan citra yang berbeda yaitu Quickbird oleh Neukermans *et al.* (2008) untuk memetakan *mangrove* beserta jenis *mangrove* di Teluk Gazi, Kenya. Wang *et al.* (2004) mencoba membandingkan citra satelit IKONOS dan QuickBird untuk memetakan spesies *mangrove* di pesisir Karibian, Panama. Setiap citra satelit

memiliki spesifikasi yang berbeda-beda baik itu resolusi spasial, temporal dan spektral (jumlah saluran kanal *band*). Beberapa tahun terakhir, *European Space Agency* (ESA) mengembangkan beberapa citra satelit, salah satu diantaranya adalah citra satelit multispektral yakni Sentinel-2. Menurut Drusch *et al.* (2012) Sentinel-2 memiliki misi untuk melakukan *monitoring* sumber daya alam. Kemunculan Sentinel-2 dengan resolusi 10 m, memberikan tambahan pilihan bagi praktisi untuk dapat memanfaatkan data satelit yang tersedia. Menurut Laurin *et al.* (2016) citra satelit ini cukup baik, namun belum banyak publikasi terkait pemanfaatannya. Beberapa publikasi yang ditemukan dengan memanfaatkan data ini adalah oleh Du *et al.* (2016) tentang pemetaan badan air dengan memodifikasi *Normalized Difference Water Index* (NDWI), Li *et al.* (2017) mengenai analisis global dari citra satelit Sentinel-2A, Sentinel-2B dan Landsat-8 terhadap jarak temporal dan dampaknya terhadap pemantauan di Bumi, serta oleh Kolokoussis *et al.* (2018) meneliti tentang pemetaan tumpahan minyak menggunakan citra Sentinel-2 yang dikombinasikan dengan Sentinel-1.

Teknologi penginderaan jauh (*remote sensing*) biasa digunakan untuk memperoleh data spasial secara efektif, akurat, praktis, dan juga murah (Giri *et al.* 2011). Pada awal kemunculannya, teknologi ini menggunakan pendekatan berbasis piksel untuk mengklasifikasikan citra. Namun, pendekatan ini sering menimbulkan efek *salt and pepper* dimana akan memberikan efek variasi spektral yang berlebih sehingga akan berdampak pada rendahnya akurasi yang dihasilkan (Liu *et al.* 2010). Berawal dari hal tersebut, klasifikasi pemetaan berbasis objek (OBIA) dikembangkan. Menurut Blasckhe (2010) klasifikasi OBIA lebih baik dalam memberikan nilai akurasi daripada klasifikasi berbasis piksel. Hal ini dikarenakan klasifikasi berbasis piksel hanya melihat nilai digital dari piksel ataupun yang dipengaruhi oleh piksel sekitarnya (Myint *et al.* 2011). Sedangkan OBIA memisahkan citra dengan berbagai segmen setiap kelas berdasarkan kesamaan spektral, tekstur, bentuk, dan beberapa parameter lainnya (Blaschke *et al.* 2014). Penelitian menggunakan OBIA untuk pemetaan dengan berbagai macam objek klasifikasi sudah mulai banyak dilakukan (Myint *et al.* 2011, Kamal *et al.* 2015 dan Son *et al.* 2015).

Hasil akhir akurasi yang baik dapat diperoleh dengan berbagai macam klasifikasi yang saat ini tersedia dan dapat digunakan dengan mudah. Klasifikasi yang digunakan merupakan sekumpulan perhitungan matematika yang akan mengelompokkan nilai tertentu dan menghasilkan kelas-kelas klasifikasi yang diinginkan. *Support vector machines* (SVM) yang pertama kali diperkenalkan oleh Vapnik pada tahun 1992 merupakan salah satu algoritma klasifikasi yang dinilai dapat memberikan hasil yang cukup baik dalam pemetaan *mangrove* (Vidhya *et al.* 2014 dan Madanguit *et al.* 2017). Hal ini terlihat dari tingginya nilai akurasi yang dihasilkan. Selain itu klasifikasi lainnya yang umum digunakan pada pemetaan *mangrove* adalah *decision tree* (Vo *et al.* 2013, Kamarudin dan Fujii 2017).

Tujuan Penelitian

Penelitian ini bertujuan untuk membandingkan hasil klasifikasi antara SVM dan *decision tree* menggunakan klasifikasi berbasis objek pada citra satelit Sentinel-2B. Selain itu penelitian ini juga akan menampilkan estimasi luasan dari *mangrove* yang dihasilkan dari klasifikasi citra satelit.

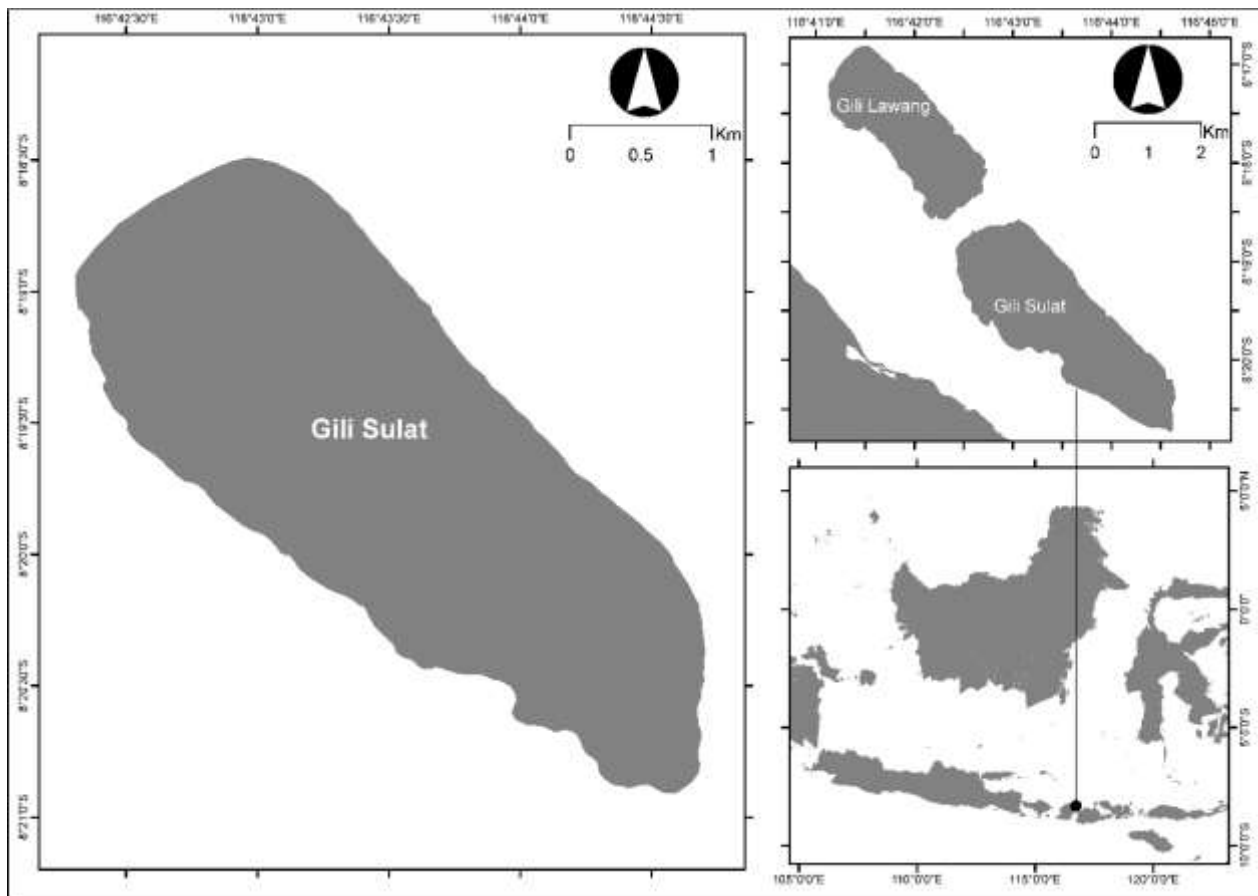
METODE

Lokasi dan Waktu Penelitian

Penelitian ini dilakukan di Kawasan Konservasi Laut Daerah (KKLD) Gili Sulat yang terletak di Desa Sambelia, Kecamatan Sambelia, Kabupaten Lombok Timur, Provinsi Nusa Tenggara Barat. Pulau Sulat atau lebih dikenal dengan sebutan Gili Sulat terletak di sebelah timur laut Pulau Lombok dengan jarak sekitar 1.5 km. Secara geografis terletak pada 8°16'46" – 8°20'44" LS dan 116°41'06" – 116°44'35" BT.

Kawasan ini merupakan pulau yang tidak berpenghuni, sehingga keasrian pulau ini tetap terjaga. Beberapa aktivitas masyarakat sekitar yang ditemukan di Gili Sulat adalah masyarakat yang memanfaatkan alang-alang sebagai atap rumah tradisional. Adapun tutupan lahan Gili Sulat didominasi oleh vegetasi *mangrove* yang cukup rapat. Berbagai jenis *mangrove* tumbuh di tempat ini seperti *Rhizophora apiculata*, *R. stylosa*,

R.mucronata, *Bruguiera gemnorhiza*, *Sonneratia alba*, *Ceriops tagal*, *Lumnitzera recemosa*, dan *Avicenia marina* (KKP 2013). Peta lokasi penelitian ditampilkan pada Gambar 1.



Gambar 1 Peta lokasi penelitian.

Pengambilan titik selama di lapangan menggunakan *global positioning system* (GPS) Garmin etrax 30x dengan presisi sebesar ± 3.5 meter. Pengamatan serta pengumpulan data lapangan menggunakan metode *stratified random sampling* yang umum digunakan dalam penginderaan jauh (Jensen 2005). Untuk memudahkan navigasi selama di lapangan, sebelum pengamatan telah dibuat peta kerja. Pengolahan data dilakukan menggunakan beberapa perangkat lunak yang diperuntukkan dalam menganalisis citra dan menerapkannya pada klasifikasi berbasis objek.

Data Citra Multispektral

Data citra satelit yang digunakan pada penelitian ini adalah Sentinel-2 yang dapat diunduh melalui website dari *European Space Agency* (ESA) yaitu (<https://scihub.copernicus.eu/>). Sentinel-2 memiliki jumlah kanal panjang gelombang sebanyak 13 *band* dengan rentang panjang gelombang dari 0.443 – 2.190 μm . Sebagai tambahan informasi bahwa Sentinel-2 terbagi menjadi dua seri yaitu Sentinel-2A yang dirilis pada tahun 2015 dan Sentinel-2B yang dirilis pada tahun 2017. Secara umum, keduanya tidak memiliki banyak perbedaan, hanya saja saat perekaman lokasi yang sama memiliki rentang waktu 5 hari secara bergantian. Citra satelit yang digunakan pada penelitian ini merupakan citra satelit Sentinel-2B yang meliputi 1 *scene* citra yang diakuisisi pada 25 Oktober 2017. Pertimbangannya adalah karena disesuaikan dengan pengambilan data lapangan dan juga faktor tutupan awan yang menutupi citra lokasi penelitian.

Koreksi Atmosferik

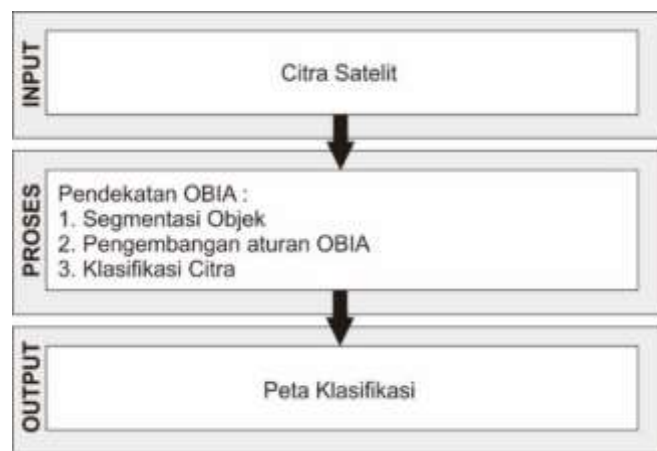
Koreksi atmosferik sangat penting untuk dilakukan guna memaksimalkan nilai reflektan yang dihasilkan oleh objek di bumi. Berdasarkan definisinya, koreksi atmosferik adalah proses untuk memperoleh reflektansi permukaan dari citra penginderaan jauh dengan menghilangkan efek atmosferik seperti uap air dan debu (Lantzanakis *et al.* 2016). Penelitian ini menerapkan *dark object subtraction* (DOS) yang mudah dan efisien untuk koreksi atmosferik sebagaimana penelitian sebelumnya (Kamal *et al.* 2016 dan Lantzanakis *et al.* 2016). Adapun persamaan dari DOS dalam Cui *et al.* (2017) adalah :

$$R_{\lambda} = \pi \times D^2 \times (L_{\lambda sat} - L_{\lambda p}) / (E_{sun\lambda} \times \cos(\theta_z))$$

dimana : R_{λ} = reflektansi permukaan; D = jarak bumi dan matahari; $L_{\lambda sat}$ = nilai spektral radian pada sensor; $L_{\lambda p}$ = Garis edar radians; $E_{sun\lambda}$ = nilai spektral radian dari matahari; θ_z = Sudut kemiringan matahari.

Segmentasi Objek

Langkah awal dalam pendekatan OBIA adalah segmentasi. Segmentasi akan membagi atau memisahkan citra kedalam bentuk poligon berdasarkan parameter yang memiliki kesamaan nilai spektral dan spasial (Stow *et al.* 2008). Proses segmentasi menggunakan algoritma *multiresolution segmentation* yang sering digunakan (Cao *et al.* 2018). Pembuatan aturan atau *rule set* terkait *scale parameter*, *shape*, dan *compactness* tidak memiliki aturan pasti, sehingga *trial and error* oleh *user* yang menentukan. Untuk menambah pemahaman terkait aturan yang dibuat dapat dilihat pada Gambar 2.



Gambar 2 Diagram alir proses OBIA.


Terkait aturan klasifikasi berbasis objek, selanjutnya digunakan *normalized difference vegetation index* (NDVI) untuk memisahkan wilayah daratan dan lautan. NDVI bekerja dengan memanfaatkan rasio *band near infra red* (NIR) dan *red* pada citra Sentinel-2 dengan batasan darat dan laut adalah 0.3. Nilai ini diperoleh melalui *trial and error* dari hasil NDVI yang dibandingkan dengan citra *red, green, blue* (RGB) citra Sentinel-2. Berikut persamaannya :

$$NDVI = \frac{(NIR - red)}{(NIR + red)}$$

Penerapan algoritma klasifikasi yaitu SVM dan *decision tree* dilakukan untuk menghasilkan kelas klasifikasi. Kelas yang dihasilkan merupakan hasil dari titik klasifikasi yang telah diperoleh sebelumnya di lapangan yang meliputi kelas tutupan lahan yang terdapat di Gili Sulat, Lombok Timur.

Klasifikasi SVM


SVM merupakan klasifikasi terbimbing non-parametrik yang sering digunakan untuk mengelaskan citra satelit, yang diperuntukkan untuk berbagai macam pemetaan. SVM menggunakan sekumpulan fungsi matematika yang disebut dengan *kernel* sebagai data masukan. Klasifikasi SVM yang digunakan pada penelitian ini merupakan RBF *kernel* yang banyak digunakan dalam klasifikasi OBIA (Duro 2012). Klasifikasi SVM pada penelitian ini digunakan untuk memisahkan kelas utama yang ada pada lokasi penelitian yaitu *mangrove*, belukar, alang-alang, serta laut. Berdasarkan teori statistik, SVM bekerja dengan melakukan klasifikasi terhadap dua kelas atau lebih dengan mencari *hyperlane* terbaik yang memanfaatkan data pada titik pemisah (*super vector*) bahkan untuk jumlah sampel yang terbatas (Zhu *et al.* 2002). Seperti pada penelitian ini menggunakan sampel klasifikasi sebanyak 30. Prinsip kerja SVM disajikan pada Gambar 3.



Gambar 3 Cara kerja SVM (Nugroho 2003).

Klasifikasi Decision Tree

Decision Tree merupakan algoritma yang umum digunakan untuk pengambilan keputusan dengan membentuk cabang-cabang dari setiap keputusan (Sartika *et al.* 2017). Prosedur klasifikasi *Decision Tree* bekerja dengan cara membagi data kedalam sub bagian yang lebih kecil berdasarkan kriteria yang dibuat dari setiap cabang (Gambar 4). Stuktur diagram setiap node nya merepresentasikan data dalam atribut (Larose *et al.* 2005).



Gambar 4 Cara kerja *Decision Tree* (Friedl dan Broedly 1997).

Decision tree dibangun dengan melibatkan banyak data yang kemudian dibagi ke dalam beberapa nilai yang sama. 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.

Atribut digunakan sebagai parameter yang dibuat untuk kriteria dalam pembuatan hirarki (Sartika dan Sensuse 2017). Dalam penelitian ini *decision tree* mengelaskan atribut yang terdapat pada citra sentinel-2, seperti informasi spektral dari objek yang akan dikelaskan. Tiap premis yang terdapat dalam satu atribut dihubungkan dengan hubungan disjungsi, sedangkan premis yang memiliki lanjutan premis pada cabang selanjutnya dihubungkan dengan konjungsi (Sartika dan Sensuse 2017). Bagian yang membangun *decision tree* adalah ID3 yang menggunakan informasi dari entropi dan *information gain* (Gupta et al. 2017)

Penguji Akurasi

Peta klasifikasi yang dihasilkan dari klasifikasi SVM dan *Decision Tree* menggunakan citra satelit Sentinel-2B akan dilakukan uji akurasi. Jumlah titik referensi yang diperoleh di lapangan adalah sebanyak 121 titik. Pengambilan titik harus mewakili setiap kelas agar menghasilkan peta yang memiliki nilai akurasi yang tinggi. Uji akurasi menjadi bagian penting untuk melihat hasil ekstraksi data penginderaan jauh. Pengukuran akurasi pada penelitian ini menggunakan *Confusion matrix* dan koefisien kappa yang biasa digunakan dalam dunia pemetaan (Congalton dan Green 2008) (Tabel 1).

Tabel 1 *Confussion Matrix*.

Klasifikasi	Referensi				Jml Baris	User's Accuracy
	A	B	C	D		
A	X_{ii}				X_{+k}	X_{kk}/X_{+k}
B						
C						
D				X_{kk}		
Jml Kolom	X_{k+}				N	
Producers Accuracy	$X_{kk}X_k$					

Pengujian akurasi akan menghasilkan nilai *overall accuracy*, *producer's accuracy*, *user's accuracy* dan *kappa accuracy*. *Overall accuracy* adalah banyaknya jumlah piksel yang terklasifikasi secara benar pada tiap kelas dibanding jumlah sampel yang digunakan untuk uji akurasi pada semua kelas, sedangkan *producer's accuracy* adalah peluang rata-rata (%) suatu piksel yang menunjukkan sebaran dari masing-masing kelas yang telah diklasifikasi di lapangan dan *user's accuracy* adalah peluang rata-rata (%) suatu piksel secara aktual yang mewakili kelas-kelas tersebut. Secara matematis ukuran akurasi tersebut diformulasikan sebagai berikut:

$$Producer's\ accuracy = \frac{X_{kk}}{X_{k+}} \times 100\%$$

$$User's\ accuracy = \frac{X_{kk}}{X_{+k}} \times 100\%$$

$$Overall\ accuracy = \frac{\sum X_{kk}}{N} \times 100\%$$

Kappa statistik merupakan sebuah perhitungan yang digunakan untuk mengevaluasi akurasi dari tutupan lahan yang dihasilkan oleh matriks kesalahan dengan persamaan berikut Congalton dan Green (2008):

$$Kappa\ accuracy = \frac{N \sum_k^r X_{kk} - \sum_k^r X_{k+} X_{+k}}{N^2 - \sum_k^r X_{k+} X_{+k}}$$

HASIL DAN PEMBAHASAN

Koreksi Atmosferik

Perbedaan citra satelit sebelum dan sesudah dikoreksi akan menunjukkan perbedaan interpretasi secara visual di mana dapat dilihat pada Gambar 5.




Gambar 5 Koreksi atmosferik citra Sentinel-2 (a) citra sebelum dikoreksi, (b) citra setelah dikoreksi.

Berdasarkan gambar diatas, terlihat perbedaan antara kedua gambar yang menunjukkan pengaruh atmosferik di Gili Sulat. Pengaruh atmosferik seperti uap air, *aerosol*, beserta gangguan atmosferik lainnya banyak mempengaruhi nilai pantulan objek di bumi yang diterima oleh citra satelit Sentinel-2. Perbedaan secara visual ini diakibatkan perbedaan nilai citra yang telah dikoreksi di mana citra yang telah dikoreksi terlihat lebih cerah bila dibandingkan citra yang belum dikoreksi.

Hasil akhir koreksi atmosferik menggunakan DOS diasumsikan akan menghasilkan nilai nol atau mendekati nol. Total 4 *band* yang diproses, yaitu *band red*, *green*, *blue*, dan *near infra red* (NIR) menunjukkan nilai hasil koreksi atmosferik lebih rendah ataupun mendekati nilai nol dari pada nilai citra sebelum dikoreksi. Hal ini terjadi karena nilai reflektan yang terdapat pada citra satelit telah dilakukan penghapusan efek atmosferik (Chavez 1988).

Segmentasi Objek

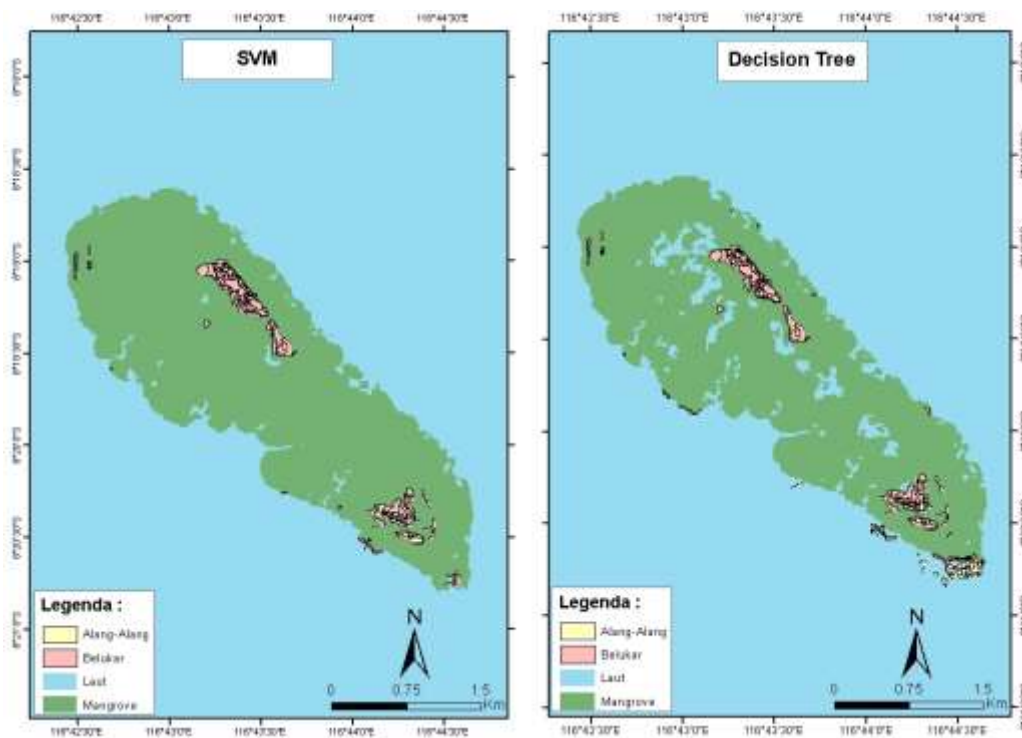
Terkait *input* parameter, tidak ada aturan pasti mengenai proses segmentasi. Namun, selama pengolahan data, parameter *scale*, *shape*, dan *compactness* yang terbaik adalah 20, 0.5 dan 0.1 secara berurutan. Ukuran *scale* sangat mempengaruhi segmentasi yang dihasilkan. Semakin tinggi angka *scale* (misalnya 100) maka tingkat homogenitas yang dihasilkan juga akan semakin besar. Sebaliknya semakin kecil angka *scale* (misalnya 10) akan menghasilkan segmentasi yang kecil dan cenderung heterogen. Selain itu, angka *scale* yang kecil mempengaruhi jumlah poligon segmentasi yang dihasilkan dan begitu juga sebaliknya. Perlu ditekankan bahwa informasi spektral masih memainkan peran penting dalam pembentukan segmentasi (Myint *et al.* 2011). Hasil segmentasi objek dapat dilihat pada Gambar 6.



Gambar 6 Hasil segmentasi dengan nilai *scale* yang berbeda.

Perbandingan Hasil Klarifikasi

Pendekatan OBIA yang digunakan pada penelitian ini cukup efektif untuk memisahkan tiap kelas. Klasifikasi OBIA dikembangkan dengan menggabungkan spasial hirarki dan informasi pada citra satelit. Objek pada citra dapat diartikan sebagai kumpulan dari beberapa piksel yang memiliki kesamaan spektral dan spasial (Blaschke 2010). Kombinasi antara *band-band* pada citra dan aturan yang dibuat pada pendekatan OBIA mampu memisahkan dengan baik antara kelas *mangrove*, alang-alang belukar, dan laut (Gambar 7). Hasil klasifikasi oleh citra satelit menunjukkan bahwa kedua klasifikasi menghasilkan kelas *mangrove* sebagai kawasan terluas. Ini menunjukkan kemiripan dengan pengamatan lapangan yang diperoleh bahwa tutupan lahan terluas ialah *mangrove*, sedangkan alang-alang merupakan kawasan dengan luasan paling sedikit.



Gambar 7 Hasil klasifikasi citra satelit Sentinel-2B.

Berdasarkan hasil pengolahan data terlihat perbedaan secara visual antara klasifikasi SVM dan *decision tree*. Perbedaan terlihat pada kelas laut yang muncul ditengah-tengah *mangrove*. Selain itu juga kelas alang-alang pada klasifikasi *decision tree* yang terdapat pada salah satu sisi pulau. Hasil pengamatan lapangan menunjukkan bahwa klasifikasi SVM paling mendekati kondisi lapangan yang sebenarnya. Sedangkan klasifikasi *decision tree* cenderung lebih banyak kesalahan dalam melakukan klasifikasi. Hal ini juga terlihat pada hasil uji akurasi. Setelah dilakukan uji akurasi dengan *confusion matrix* dan nilai kappa, klasifikasi SVM memperoleh nilai akurasi lebih baik sebesar 95 % (kappa = 0.86). Klasifikasi *decision tree* menghasilkan nilai *overall accuracy* lebih rendah sebesar 93 % (kappa = 0.82). Klasifikasi SVM cenderung memberikan nilai akurasi yang lebih baik dibandingkan *decision tree*. Kemampuan SVM dalam mencari *hyperlane* pemisah terbaik dan mencari titik maksimal inilah yang dinilai mampu menghasilkan klasifikasi dengan nilai akurasi yang tinggi. Sebaliknya, *decision tree* pada penelitian ini, secara prinsip kerja membutuhkan jumlah sampel yang banyak karena akan memudahkan proses pengambilan keputusan dalam sebuah klasifikasi. Menurut Cao *et al.* (2018) bahwa SVM mampu menghasilkan nilai akurasi yang lebih baik karena mampu meminimalisir kesalahan interpretasi citra. Cao *et al.* (2018) memperoleh *overall accuracy* sebesar 89.55% dan (kappa 0.82). Penelitian lainnya oleh Noi *et al.* (2017) menghasilkan akurasi sebesar 95% menggunakan klasifikasi SVM. Penelitian Shafri *et al.* (2009) pada klasifikasi SVM menghasilkan nilai *overall accuracy* sebesar 73 % (kappa=0.66) dan *decision tree* sebesar 69 % (kappa=0.60). Berikut ini tabel uji akurasi yang dihasilkan oleh kedua klasifikasi (Tabel 2 dan 3).

Tabel 2 Hasil pengujian akurasi untuk semua kelas dengan klasifikasi SVM.

Klasifikasi	Referensi				Total	User's Accuracy
	Belukar	<i>Mangrove</i>	Alang-alang	Laut		
Belukar	11	5			16	68.75 %
<i>Mangrove</i>		91			91	100 %
Alang-alang			3		3	100 %
Laut		1		10	11	90.91 %
Total	11	97	3	10	121	
<i>Producer's Accuracy</i>	100%	93.81%	100%	100%		

Tabel 3 Hasil pengujian akurasi untuk semua kelas dengan klasifikasi *Decision Tree*.

Klasifikasi	Referensi				Total	User's Accuracy
	Belukar	<i>Mangrove</i>	Alang-Alang	Laut		
Belukar	11	5			16	68.75%
<i>Mangrove</i>		90			90	100%
Alang-alang			3	1	4	75%
Laut		2		9	11	81.81%
Total	11	97	3	10	121	
<i>Producer's Accuracy</i>	100%	92.78%	100%	90%		
<i>Overall accuracy = 93 %; Kappa =0.82</i>						

Secara umum kedua klasifikasi memberikan nilai akurasi yang tinggi. Selain karena pendekatan berbasis objek, penggunaan citra satelit juga mempengaruhi hasil akurasi. Sentinel-2 dengan resolusi spasial 10 x 10 meter mampu memberikan nilai akurasi yang lebih baik. Penelitian Mallinis *et al.* (2017) yang

membandingkan penggunaan citra satelit multispektral Sentinel-2 dan Landsat-8, mampu menghasilkan akurasi yang lebih baik bagi Sentinel-2 dengan akurasi mencapai 73.33% dan Landsat-8 sebesar 71.11%. Faktor lain yang mempengaruhi tingginya akurasi yang diperoleh adalah karena jumlah kelas yang sedikit. Dwiputra *et al.* (2016) dalam penelitiannya tentang perbandingan jumlah kelas terhadap nilai akurasi bahwa 4 kelas yang dibuat menghasilkan akurasi tertinggi dibandingkan 7 dan 10 kelas, dengan *overall accuracy* sebesar 87.27 ($\kappa = 0.80$), 79.80 % ($\kappa = 0.72$), dan 73.34 ($\kappa = 0.64$).

Estimasi Luasan *Mangrove*

Estimasi luasan *mangrove* dilakukan menggunakan hasil klasifikasi SVM dan *decision tree*. Kedua klasifikasi menghasilkan estimasi yang berbeda-beda karena memiliki prinsip kerja yang tidak sama. Berikut ini hasil estimasi luasan *mangrove* dan penutup lahan lainnya yang disajikan pada Tabel 4.

Tabel 4 Hasil estimasi tutupan lahan.

Kelas Tutupan Lahan	Luasan (Ha)	
	SVM	Decision Tree
<i>Mangrove</i>	634.62	590.47
Alang-Alang	6.01	27.08
Belukar	63.21	45.09

Informasi sebelumnya mengenai tutupan lahan beserta luasannya di Gili Sulat sejauh ini belum ditemukan. Penelitian yang dilakukan umumnya berfokus pada komunitas *mangrove* dan berbagai biota penyusun didalamnya (Idrus *et al.* 2015). Berdasarkan hasil klasifikasi menggunakan SVM dan *decision tree* diperoleh hasil estimasi luasan. Klasifikasi SVM menghasilkan luasan *mangrove* sebesar 634.62 Ha, alang-alang sebesar 6.01 Ha dan belukar sebesar 63.21 Ha, sedangkan *decision tree* menghasilkan estimasi yang lebih rendah terhadap luasan *mangrove* yakni sebesar 590.47 Ha, diikuti oleh alang-alang sebesar 27.08 Ha dan belukar seluas 45.09 Ha.

SIMPULAN

Berdasarkan kajian ini, pendekatan berbasis objek cukup efektif untuk memetakan lahan *mangrove*. Klasifikasi SVM yang digunakan menghasilkan akurasi yang lebih baik daripada klasifikasi *decision tree* karena mampu meminimalisir kesalahan dalam interpretasi citra dengan nilai *overall accuracy* mencapai 95 % ($\kappa = 0.86$) dan 93 % ($\kappa = 0.82$), secara berurutan. Kedua, estimasi luasan *mangrove* yang diperoleh menggunakan SVM adalah sebesar 634.62 Ha sedangkan menggunakan *decision tree* menghasilkan luasan *mangrove* yang lebih kecil yaitu sebesar 590.47 Ha.

DAFTAR PUSTAKA

- [KKP] Kementerian Kelautan Perikanan. 2013. Kawasan Konservasi Laut Daerah Gili Sulat dan Gili Lawang [internet]. [di unduh 10 Apr 2017]. Tersedia pada: <http://kkji.kp3k.kkp.go.id/index.php/basisdata-kawasan-konservasi/details/1/85>.
- Aziz AA, Phinn S, Dargusch P. 2015. Investigating the decline of ecosystem services in a production mangrove forest using landsat and object-based image analysis. *Estuarine, Coastal and Shelf Science*. 164: 353-366.
- Blaschke T, Hay GJ, Kelly M, Lang S, Hofmann P, Addink E, Feitosa R, Van Der Meer F, Van Der Werff H, Van Coillie F *et al.* 2014. Geographic object-based image analysis: a new paradigm in remote sensing and geographic information science. *ISPRS Journal Photogrammetry Remote Sensing*. 87 (1): 180-191.

- Blaschke T. 2010. Object based image analysis for remote sensing. *ISPRS Journal Photogrammetry and Remote Sensing*. 65(1): 2-16.
- Cao J, Leng W, Liu K, He Z, Zhu Y. 2018. Object-based mangrove species classification using unmanned aerial vehicle hyperspectral images and digital surface models. *Remote Sens*. 10: 89
- Chavez PS. 1988. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. *Remote Sensing of Environment*. 24 (3): 459–479.
- Congalton RG, Green K. 2008. *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*. Boca Raton (US): CRC Press.
- Cui L, Li G, Ren H, He L, Liao H, Ouyang N, Zhang Y. 2014. Assessment of atmospheric correction methods for historical landsat tm images in the coastal zone: a case study in Jiangsu, China. *European Journal of Remote Sensing*. 47 (1): 701–716.
- Drusch M, Del-Bello U, Carlier S, Colin O, Fernandez V, Gascon F, Hoersch B, Isola C, Laberinti P, Martimort P et al. 2012. Sentinel-2: esa's optical high-resolution mission for gmes operational services. *Remote Sensing Environment*. 120: 25–36.
- Du Y, Zhang Y, Ling F, Wang Q, Li W, Li X. 2016. Water bodies' mapping from sentinel-2 imagery with modified normalized difference water index at 10-m spatial resolution produced by sharpening the swir band. *Remote Sensing*. 8: 1-19.
- Duro DC, Franklin SE, Dubé MG. 2012. Remote sensing of environment a comparison of pixel-based and object-based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using spot-5 hrg imagery. *Remote Sensing of Environment*. 118: 259–272.
- Friedl MA, Brodleyf CE. 1997. Decision tree classification of land cover from remotely sensed data. *Remote Sensing of Environment*. 61: 499–409.
- Giri C, Ochieng E, Tieszen LL, Zhu Z, Singh A, Loveland T, Masek J, Duke N. 2011. Status and distribution of mangrove forests of the world using earth observation satellite data. *Global Ecology and Biogeography*. 20 (1): 154-159.
- Gupta B, Rawat A, Jain A, Arora A, Dhama N. 2017. Analysis of various decision tree algorithms for classification in datamining. *Int. J. Comput. Appl*. 163(8): 15-19.
- Idrus AA, Hadiprayitno, Mertha IG, Ihamdi L. 2015. Potensi vegetasi dan arthropoda di kawasan mangrove Gili Sulat Lombok Timur. *Biologi Tropis*. 15 (2): 183–196.
- Jensen JR. 2005. *Introductory Digital Image Processing: A Remote Sensing Perspective, 3rd ed*. Sydney (AU): Pearson Prentice Hall.
- Kamal M, Phinn S, Johansen K. 2015. Object-based approach for multi-scale mangrove composition mapping using multi-resolution image datasets. *Remote Sensing*. 7: 4753-4783.
- Kamal M, Phinn S, Johansen K. 2016. Assessment of multi-resolution image data for mangrove leaf area index mapping. *Remote Sensing of Environment*. 176: 242–254.
- Kamaruddin NA, Fujii S. 2017. Mangrove forest classification using decision tree-learning method. *Journal World Applied Science*. 35 (9): 1821–1825.
- Lantzanakis G, Mitraka Z, Chrysoulakis N. 2016. Comparison of physically & image based atmospheric correction methods for sentinel-2 satellite imagery. *Proceeding of SPIE*. 9688: 1-6
- Larose DT. 2005. *Discovering Knowledge in Data: An Introduction to Data Mining*. New Jersey (US): John Wiley & Sons.
- Laurin GV, Puletti N, Hawthorne W, Liesenberg V, Corona P, Papale D, Chenf Q, Valentini R. 2016. Discrimination of tropical forest types, dominant species, and mapping of functional guilds by hyperspectral and simulated multispectral sentinel-2 data. *Remote Sensing Environment*. 176: 163–176.
- Li J, Roy DP. 2017. A global analysis of sentinel-2a, sentinel-2b and landsat-8 data revisit intervals and implications for terrestrial monitoring. *Remote Sensing*. 9(9): 1–17.

- Liu D, Xia F. 2010. Assessing object-based classification: advantages and limitations. *Remote Sensing Letters*. 1(4): 187–194.
- Madanguit CJG, Oñez JPL, Tan HG, Villanueva MD, Ordaneza JE, Novero AU. 2017. Application of support vector machine (SVM) and quick unbiased efficient statistical tree (QUEST) algorithms on mangrove and agricultural resource mapping using lidar data sets. *International Journal of Applied Environmental Sciences*. 12(10): 1821–1830.
- Mallinis G, Mitsopoulos I, Chrysafi I. 2017. Evaluating and comparing sentinel 2a and landsat-8 operational land imager (OLI) spectral indices for estimating fire severity in a mediterranean pine ecosystem of Greece. *GIScience & Remote Sensing*. 55 (1): 1-18.
- Myint SW, Gober P, Brazel A, Grossman-Clarke S, Weng Q. 2011. Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery. *Remote Sensing of Environment*. 115: 1145–1161.
- Neukermans G, Dahdouh-Guebas F, Kairo JG, Koedam N. 2008. Mangrove species and stand mapping in Gazi Bay (Kenya) using quickbird satellite imagery. *Spatial Science* 53(1): 75–86.
- Noi PT, Martin K. 2009. Comparison of random forest, k-nearest neighbor, and support vector machine classifiers for land cover classification using sentinel-2 imagery. *Sensors*. 18 (18): 1-20.
- Nugroho AS, Witarto AB, Handoko D. 2003. Application of support vector machine in bioinformatics. *Proceeding Indonesia Scientific Meeting in Central Japan*. 1–11.
- Putra H, Prasetyo LB, Santoso N. 2016. Monitoring of coastline changes using satellite imagery in Muara Gembong, Bekasi. *Jurnal Pengelolaan Sumberdaya Alam dan Lingkungan*. 6 (2): 178–186.
- Sartika D, Sensuse DI. 2017. Perbandingan algoritma klasifikasi naive bayes, nearest neighbour dan decision tree pada studi kasus pengambilan keputusan pemilihan pola pakaian. *Jatsi*. 1(2): 151-161.
- Son NT, Chen CF, Chang N.Bin, Chen CR, Chang LY, Thanh BX. 2015. Mangrove mapping and change detection in Ca Mau Peninsula, Vietnam, using landsat data and object-based image analysis. *IEEE Transactions on Geoscience and Remote Sensing*. 8 (2): 503–510.
- Stow D, Hamada Y, Coulter LM, Anguelova Z. 2008. Monitoring shrubland habitat changes through object-based change identification with airborne multi-spectral imagery. *Remote Sensing of environment*. 112: 1051-1061.
- Tunggadewi AT, Syaufina L, Puspaningsih N, 2014. Pemanfaatan penginderaan jauh untuk estimasi stok karbon di area reklamasi pt. antam ubpe, Pongkor, Kabupaten Bogor. *Jurnal Pengelolaan Sumberdaya Alam dan Lingkungan*. 4 (1): 49–59.
- Vidhya R, Vijayasekaran D, Farook MA, Jai S, Rohini M, Sinduja A, Vi C, Vi WG. 2014. Improved classification of mangroves health status using hyperspectral remote sensing data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. 40: 9–12.
- Vo QT, Oppelt N, Leinenkugel P, Kuenzer C. 2013. Remote sensing in mapping mangrove ecosystems — an object based approach. *Remote Sensing* 5: 183–201.
- Wang L, Sousa WP, Gong P, Biging GS. 2004. Comparison of ikonos and quickbird images for mapping mangrove species on the Caribbean Coast of Panama. *Remote Sensing Environment*. 91: 432–440.
- Zhu G, Blumberg DG. 2002. Classification using aster data and svm algorithms: the case study of Beer Sheva, Israel. *Remote Sensing of Environment*. 80(2): 233–240.