

PEMETAAN EKOSISTEM LAMUN DENGAN DAN TANPA KOREKSI KOLOM AIR DI PERAIRAN PULAU PAJENEKANG, SULAWESI SELATAN

SEAGRASS ECOSYSTEM MAPPING WITH AND WITHOUT WATER COLUMN CORRECTION IN PAJENEKANG ISLAND WATERS, SOUTH SULAWESI

Turissa Pragunanti Ilyas^{1*}, Bisman Nababan², Hawis Madduppa², & Dony Kushardono³

¹Program Studi Teknologi Kelautan, FPIK, Sekolah Pascasarjana IPB, Bogor, 16680, Indonesia

²Departemen Ilmu dan Teknologi Kelautan, FPIK-IPB, Bogor, 16680, Indonesia

³Pusat Pemanfaatan Penginderaan Jauh, LAPAN, Jakarta, 13710, Indonesia

*E-mail: turissa_pragunanti@apps.ipb.ac.id

ABSTRACT

Previous studies showed that water column correction in habitat benthic mapping using remote sensing data can increase the accuracy of the information produced. This study aims to look at the distribution of seagrasses with and without water column correction using object-based classification (OBIA) on the Pajenekang Island. Field data on the distribution of seagrass and non-seagrass of a total of 347 points were taken in July-August 2018 with a transect 1x1 m². The satellite data used was SPOT-7 imagery acquired on March 27, 2017, with a spatial resolution of 6x6 m². Within the OBIA classification method, we used several algorithms such as Support Vector Machine (SVM), Bayes, K-Nearest Neighbor (KNN), and Decision Tree (DT) to map benthic and seagrass habitats. The results showed that the treatment of with and without water column correction in mapping benthic and seagrass ecosystem habitats using several classification algorithms produced no significant difference in the accuracy of classification image product. However, from the four algorithms used, the Bayes algorithm without water column correction produced the highest accuracy value for benthic habitat mapping of 70.36% and seagrass habitat of 66.47%. The results showed that water column correction did not provide better results in the classification of benthic and seagrass habitats of digital satellite imagery than that of without water column correction.

Keywords: algorithm, OBIA classification, Pajenekang Island, seagrass, water column

ABSTRAK

Koreksi kolom air dalam pemetaan habitat bentik menggunakan data satelit dapat meningkatkan nilai akurasi informasi yang dihasilkan, seperti yang telah dilakukan oleh peneliti sebelumnya. Penelitian ini bertujuan untuk melihat distribusi lamun dengan perlakuan dengan dan tanpa koreksi kolom air menggunakan klasifikasi berbasis objek (OBIA) di Pulau Pajenekang. Data sebaran padang lamun dan non lamun sebanyak 347 titik diambil pada Juli-Agustus 2018 dengan transek 1x1 m². Data satelit yang digunakan adalah citra satelit SPOT-7 akuisisi pada 27 Maret 2017 dengan resolusi 6x6 m². Pada penelitian ini metode klasifikasi OBIA menggunakan beberapa algoritma klasifikasi seperti *Support Vector Machine (SVM)*, *Bayes*, *K-Nearest Neighbour (KNN)*, dan *Decision Tree (DT)* untuk memetakan habitat bentik dan lamun. Hasil penelitian menunjukkan bahwa penerapan perlakuan dengan koreksi kolom air dan tanpa koreksi kolom air pada pemetaan ekosistem habitat bentik dan lamun dengan menggunakan beberapa algoritma klasifikasi menunjukkan hasil akurasi yang tidak berbeda nyata. Namun demikian, dari empat algoritma yang digunakan, algoritma *Bayes* tanpa koreksi kolom air memberikan nilai akurasi tertinggi untuk pemetaan habitat bentik sebesar 70,36% dan habitat lamun sebesar 66,47%. Hal tersebut menunjukkan bahwa koreksi kolom air tidak selamanya memberikan hasil yang lebih baik dalam klasifikasi habitat bentik dan lamun dari citra satelit digital.

Kata kunci: algoritma, klasifikasi OBIA, kolom air, lamun, Pulau Pajenekang

I. PENDAHULUAN

Lamun merupakan tumbuhan tingkat tinggi (Anthophyta) yang hidup dan tumbuh terbenam di lingkungan laut yang memiliki rimpang (rhizome), akar, dan berkembang biak secara generatif yaitu perkembangbiakan secara kawin atau seksual pada tumbuhan berbiji satu (monokotil) dan vegetatif yang merupakan perkembangbiakan secara aseksual (Sjafrie *et al.*, 2018), serta tersebar secara luas di seluruh perairan pesisir tropis dan subtropis, dan beriklim sedang (Hossain *et al.*, 2015). Lamun berperan sebagai produsen primer dalam rantai makanan di perairan, habitat bagi biota-biota laut, perlindungan terhadap daerah pesisir, menjaga sumberdaya alam (Waycott *et al.*, 2004), memproduksi karbon organik melalui penyerapan dan pembusukan (Macreadie *et al.*, 2104), serta dapat mendukung pendapatan ekonomi lokal bagi masyarakat di daerah pesisir (Hossain *et al.*, 2015). Selain itu ekosistem lamun juga memiliki peranan penting dalam ekosistem pesisir karena dapat membentuk padang rumput yang luas untuk mendukung keanekaragaman hayati yang tinggi (Traganos *et al.*, 2018). Akan tetapi, menurut Sjafrie *et al.* (2018) ekosistem lamun juga merupakan ekosistem yang rentan mengalami kerusakan akibat dari manusia ataupun faktor alam dan perubahannya sangat dinamis. Oleh karena itu, untuk manajemen ekosistem padang lamun yang baik, diperlukan informasi spasial dan temporal yang lebih akurat.

Informasi ekosistem padang lamun secara spasial dan temporal dapat diketahui dengan melakukan pemetaan perairan dangkal menggunakan teknologi penginderaan jauh dengan memanfaatkan berbagai sensor optik dari berbagai resolusi spasial mulai dari resolusi rendah, sedang, dan tinggi (Yang & Yang, 2009; Hedley *et al.*, 2009; Dekker *et al.*, 2005). Pemetaan perairan dangkal dengan teknologi penginderaan jauh diperlukan koreksi data untuk mengurangi kesalahan atau efek yang

ditimbulkan dari perekaman citra satelit. Hafitz & Danoedoro (2015) berpendapat bahwa koreksi data citra dilakukan untuk mengurangi kesalahan pada nilai piksel yang terekam, diantaranya adalah pengaruh atmosfer, posisi matahari, dan pengaruh kondisi perairan saat akuisisi data citra. Kondisi perairan merupakan salah satu kesalahan yang cukup berpengaruh terhadap pantulan spektral objek dasar perairan laut dangkal akibat atenuasi pada kolom perairan. Pengaruh kondisi perairan tersebut dapat dikoreksi dengan koreksi kolom air untuk mengurangi kesalahan informasi yang diekstraksi dari substrat dasar perairan (Budhiman *et al.*, 2013). Koreksi kolom air juga secara eksponensial berpengaruh terhadap penambahan kedalaman perairan. Intensitas cahaya yang masuk ke dalam kolom air akan mengalami proses absorpsi dan hamburan, yang kemudian disebut proses atenuasi, disebabkan oleh adanya komponen optik air yang menyebabkan menurunnya intensitas cahaya secara eksponensial dengan kedalaman kolom air sehingga terjadi reduksi terhadap nilai radiasi pada kolom perairan (Bukata *et al.*, 2018).

Adanya pengaruh kedalaman terhadap deteksi citra satelit merupakan fungsi dari panjang gelombang dan kecerahan perairan, yang secara langsung dapat mempengaruhi efek dari koreksi kolom air terhadap penggunaan data penginderaan jauh (Setiawan *et al.*, 2019). Penerapan koreksi kolom air dengan menggunakan algoritma Lyzenga merupakan salah satu metode yang sangat populer digunakan, selain itu menurut beberapa penelitian penerapan metode ini dapat meningkatkan akurasi dari klasifikasi citra digital yang dilakukan (Zoffoli *et al.*, 2014).

Metode klasifikasi multispektral merupakan salah satu metode yang digunakan dalam pemetaan ekosistem lamun yang masuk dalam kategori ekosistem perairan dangkal. Salah satu teknik dari metode klasifikasi multispektral yang cukup berkembang saat ini dalam memetakan

ekosistem padang lamun adalah dengan menggunakan analisis berbasis objek atau biasa disebut OBIA (*Object Based Image Analysis*) yang menunjukkan hasil yang efektif dalam teknik ekstraksi citra dengan memanfaatkan algoritma *machine learning* dalam proses pengklasifikasiannya (Phinn *et al.*, 2011).

Beberapa penelitian sebelumnya secara spasial telah menerapkan metode berbasis objek dengan menggunakan beberapa algoritma *machine learning* dan menunjukkan hasil yang cukup baik dalam memetakan habitat bentik dasar perairan laut dangkal (Anggoro *et al.*, 2017; Aziizah *et al.*, 2016). Hasil penelitian Mastu *et al.*, (2018) menyebutkan bahwa pemetaan habitat bentik perairan dangkal dengan menggunakan metode OBIA dan penerapan koreksi kolom air menghasilkan tingkat akurasi sebesar 60,04% untuk 12 kelas dan 64,1% untuk 9 kelas habitat bentik dengan algoritma SVM. Selain itu penelitian Hafitz & Danoedoro (2015) juga menunjukkan pengaruh koreksi kolom air terhadap akurasi pemetaan habitat bentik dengan nilai akurasi sebesar 26,01%, tanpa koreksi kolom air meningkat menjadi 30,34% dengan koreksi kolom air. Berdasarkan hal tersebut maka diasumsikan bahwa dengan penerapan koreksi kolom air dapat meningkatkan nilai akurasi pada pemetaan habitat bentik perairan dangkal termasuk ekosistem lamun. Pengaruh koreksi kolom air terhadap hasil klasifikasi ekosistem padang lamun dan penggunaan algoritma klasifikasi OBIA yang tepat masih perlu dikaji untuk mendapatkan hasil pemetaan yang lebih akurat dan optimum. Tujuan penelitian ini adalah menentukan tingkat akurasi pemetaan ekosistem padang lamun dengan penerapan koreksi kolom air dan tanpa koreksi kolom air pada metode klasifikasi OBIA dan penerapan beberapa algoritma klasifikasi SVM, *Bayes*, KNN, dan DT di perairan pesisir pulau Pajeneang, Sulawesi Selatan.

II. METODE PENELITIAN

2.1. Waktu dan Tempat

Penelitian ini dilakukan pada bulan Agustus-September 2018 di ekosistem padang lamun yang berada di perairan pesisir Pulau Pajeneang, Provinsi Sulawesi Selatan. Secara geografis lokasi penelitian ini terletak pada 04°56'12''-04°57'07''LS dan 119°20'02''-119°21'06''BT. Area titik sampling pada penelitian ini mengelilingi pulau dari arah utara sampai ke selatan (*Figure 1*).

2.2. Pengumpulan Data

Pengumpulan data lapangan menggunakan metode *systematic random sampling*. Metode tersebut dipilih berdasarkan beberapa pertimbangan di lapangan dan pengetahuan akan kondisi di lokasi penelitian, dipilih secara acak dengan penentuan interval (jarak) tertentu secara berurutan (Congalton & Green, 2009). Penelitian ini juga menggunakan teknik foto transek yang diambil tegak lurus dari atas. Teknik foto transek ini dilakukan untuk mengidentifikasi objek yang terambil pada setiap transek, menentukan tutupan lamun pada transek kuadran dan dapat juga digunakan sebagai dasar dalam membuat skema klasifikasi habitat bentik dasar perairan pada lokasi penelitian. Pada dasarnya teknik foto transek yang digunakan pada penelitian ini untuk menunjukkan keterwakilan dari ukuran spasial citra yang digunakan pada habitat bentik yang dominan.

Mengingat pemetaan yang kami lakukan adalah pemetaan habitat bentik dan habitat lamun maka kami menggunakan citra satelit resolusi spasial tinggi yang tersedia agar informasi yang dihasilkan lebih detail dan menghasilkan akurasi yang optimum. Berdasarkan hal tersebut citra satelit yang digunakan dalam penelitian ini adalah citra satelit SPOT 7 yang diakuisisi pada tanggal 27 Maret 2017.

Citra Satelit SPOT 7 memiliki resolusi spasial $6 \times 6 \text{ m}^2$ dan terdiri dari empat *band* citra multispektral (biru, hijau, merah, dan inframerah) ditambah satu *band* pankromatik. Data citra satelit diperoleh dari Lembaga Penerbangan dan Antariksa Nasional (LAPAN) dalam bentuk level terkoreksi Ortho. Sistem proyeksi yang digunakan adalah sistem koordinat geografik WGS-1984. Data lapangan dikumpulkan dengan menggunakan teknik foto transek $1 \times 1 \text{ m}^2$ (Prabowo, 2018; Anggoro *et al.*, 2017; Roelfsema *et al.*, 2013) pada 196 titik observasi lapangan (*Figure 1*). Penggunaan transek kuadrat dengan ukuran tersebut dimaksudkan untuk memaksimalkan dalam penentuan atau identifikasi objek dominan yang dilihat secara visual di lapangan ataupun hasil dari foto transek.

2.3. Analisis Data

Data lapangan yang dikumpulkan diidentifikasi dan dicatat langsung berdasarkan acuan dari *Seagrass Watch* (McKenzie *et al.*, 2003). Setelah itu dilakukan pengolahan data citra satelit yang terdiri dari

beberapa tahap, pertama preprosesing citra yang terdiri koreksi atmosferik, koreksi geometrik, dan *cropping* citra untuk lokasi penelitian.

Proses klasifikasi menggunakan metode OBIA dilakukan melalui dua tahapan yaitu segmentasi citra dan klasifikasi pada tiap segmen (Zhang, 2015). Proses segmentasi pada penelitian ini menggunakan algoritma *multiresolution segmentation* (MRS) dengan besar skala yang digunakan berbeda pada level 1, level 2, dan level 3. Klasifikasi citra yang terdiri dari 3 level tersebut berdasarkan komposisi lamun adalah level 1 (*reef level*) yang terbagi atas darat, perairan dangkal, dan laut dalam; level 2 (*benthic zones*) terdiri dari empat kelas habitat yaitu bentik karang, lamun, pasir, dan *rubble*; dan level 3 (*seagrass cover*) merupakan persen tutupan padang lamun yang juga terbagi menjadi tiga kelas tutupan yaitu kaya/sehat, kurang kaya dan miskin. Struktur hierarki skema klasifikasi dari masing-masing level selengkapnya disajikan pada *Figure 2*.




Figure 1. The coastal waters of Pajenekang Island in Pangkep Regency, South Sulawesi Province. The sampling point area is marked by a green dot around the island from north to south.




Figure 2. The image classification hierarchy structure consists of 3 levels.

Perbedaan skala pada proses segmentasi ini nantinya akan menghasilkan kumpulan layer objek citra dalam suatu jaringan hierarki. Adapun parameter yang terdapat dalam algoritma MRS ini merupakan parameter pengaturan homogenitas objek yaitu *scale*, *shape*, dan *compactness* (Trimble, 2014).

Tahapan selanjutnya adalah perlakuan dengan koreksi kolom air (*Depth Invariant Index*, DII) dan tanpa koreksi kolom air. Komposit untuk perlakuan tanpa koreksi kolom air (DII) menggunakan *band* merah (*band* 3), *band* hijau (*band* 2), dan *band* biru (*band* 1) yang kemudian dianalisis secara digital menggunakan klasifikasi berbasis objek dengan menggunakan *input feature mean* dari *band* 1, *band* 2 dan *band* 3. Sementara untuk koreksi kolom air digunakan kombinasi antara *band* hijau dan *band* biru. Berdasarkan penelitian Hafitz & Danoedoro (2015) variasi *band* yang paling banyak menyerap nilai pantulan spektral pada perairan adalah kombinasi *band* biru dan hijau. Teknik koreksi kolom air DII menerapkan metode Lyzenga menggunakan nilai kemiringan regresi (k_i/k_j) yang dihitung berdasarkan persamaan dari Green *et al.* (2000). Hasil dari DII tersebut dimasukkan sebagai variabel *input feature* ke dalam analisis klasifikasi OBIA.

Pada proses klasifikasi level 2 dan level 3 dilakukan pendekatan algoritma klasifikasi menggunakan algoritma *machine learning* yaitu SVM, *Bayes*, DT, dan KNN. SVM memiliki *vector* yang berfungsi sebagai pemisah atau pembatas diantara dua kelas dengan memaksimalkan *margin* dari masing-masing kelas (Wahidin *et al.*, 2015).

Bayesian adalah algoritma yang mengasumsikan bahwa vektor fitur dari masing-masing kelas terdistribusi normal (meskipun tidak harus didistribusikan secara independen) dan juga termasuk dalam klasifikasi sederhana (Fukunaga, 1990; Bradski & Kaehler, 2008). KNN memiliki teori dasar bahwa dalam dataset kalibrasi terdapat sekelompok sampel k yang terdekat dengan sampel yang tidak diketahui, misalnya berdasarkan fungsi dari jarak dan pada prinsipnya setiap sampel yang dipilih untuk setiap kelas akan mencari objek sampel terdekat dalam ruang fitur untuk setiap objek gambar. Jika objek gambar adalah objek sampel terdekat milik kelas A, maka objek akan didefinisikan ke dalam kelas A (Wei *et al.*, 2005). DT diasumsikan sebagai dasar dalam klasifikasi pada pengamatan label objek yang hampir sama dalam variabel yang berbeda. Konsep utama dalam algoritma DT ini adalah tabel yang dinyatakan dalam bentuk atribut dan *data*

record (Sartika & Senses, 2017). Penggunaan semua algoritma *machine learning* tersebut dimaksudkan untuk mencari hasil yang optimum dalam memetakan ekosistem lamun dalam hal ini untuk melihat hasil klasifikasi, kondisi, dan sebaran jenis lamun. Adapun *input feature* yang digunakan pada klasifikasi OBIA ini adalah *Mean* dari *band 1*, *band 2*, *band 3* dan DII atau tanpa DII.

2.4. Uji Akurasi

Tahap terakhir yang dilakukan selanjutnya adalah uji akurasi dengan menggunakan *confusion matrix* dan nilai koefisien Kappa. Uji akurasi ini dilakukan pada level 2 dan level 3 untuk melihat hasil yang optimum dari masing-masing algoritma *machine learning* yang digunakan dan melihat hasil pemetaan lamun dengan menggunakan DII atau tanpa DII.

Kushardono (2017) menjelaskan bahwa *confusion matrix* merupakan salah satu metode pengujian akurasi untuk mengetahui nilai *overall accuracy* dari hasil pengolahan klasifikasi dengan membandingkan kelas-kelas hasil klasifikasi dengan kelas-kelas *training data*. Sedangkan indikator lain yaitu nilai koefisien Kappa yang diperoleh dengan cara membandingkan nilai akurasi keseluruhan dengan nilai akurasi yang diharapkan.

Formula uji akurasi yang digunakan berdasarkan Congalton & Green (2009) merupakan matriks kesalahan (*confusion matrix*) yang menghasilkan nilai *Overall Accuracy* (OA), *User Accuracy* (UA), *Producer Accuracy* (PA), koefisien Kappa dan nilai Z statistika. Uji akurasi tersebut dapat dihitung dengan persamaan berikut:

$$OA = \sum_{i=1}^k n_{ii} \dots\dots\dots (1)$$

$$PA = \frac{n_{jj}}{n + j} \dots\dots\dots (2)$$

$$UA = \frac{n_{ii}}{n_{i+}} \dots\dots\dots (3)$$

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} merupakan jumlah pengamatan pada kolom ke-j dan baris ke-j. Sedangkan perhitungan nilai koefisien Kappa berada pada rentang 0-1 dan lebih kecil dari nilai akurasi keseluruhan yang dapat dihitung dengan rumus sebagai berikut:

$$K = \frac{N \sum_{i=1}^r x_{ii} - \sum_i (x_{i+} x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} x_{+i})} \dots\dots\dots (4)$$

Keterangan: menurut Whiteside *et al.* (2011) r merupakan jumlah baris pada matriks, x_{ii} adalah jumlah pengamatan baris i dan kolom i, x_{i+} dan x_{+i} merupakan total margin baris i dan kolom i, sedangkan N adalah jumlah total pengamatan (keseluruhan akurasi). Nilai koefisien Kappa inilah yang digunakan dalam penilaian akurasi untuk menentukan secara statistik apakah suatu matriks kesalahan berbeda secara signifikan dari yang lain (Congalton & Green, 2009).

Jika $\hat{K}1$ dan $\hat{K}2$ merupakan estimasi Kappa statistik dari masing-masing matriks kesalahan #1 dan #2, $\widehat{var}(\hat{K}1)$ dan $\widehat{var}(\hat{K}2)$ adalah estimasi varian sebagai hasil dari perhitungan yang tepat, maka uji statistik menggunakan persamaan:

$$Z = \frac{\hat{K}_1 - \hat{K}_2}{\sqrt{\widehat{var}(\hat{K}_1) + \widehat{var}(\hat{K}_2)}} \dots\dots\dots (5)$$

Keterangan: Z adalah standarisasi dan distribusi normal (standar deviasi) dengan hipotesis $H0: K1 = 0$ dan $H1: K1 \neq 0$, $H0$ ditolak jika $Z \geq Z_{\alpha/2}$, dimana $\alpha/2$ adalah tingkat kepercayaan uji Z dan derajat bebas diasumsikan tidak terhingga (∞). Uji statistik untuk menguji jika dua eror matriks independen berbeda secara signifikan menggunakan persamaan:

$$Z = \frac{|\hat{K}_1 - \hat{K}_2|}{\sqrt{\hat{v}\hat{a}r(\hat{K}_1) + \hat{v}\hat{a}r(\hat{K}_2)}} \dots\dots\dots (6)$$

Keterangan: Z adalah standarisasi distribusi normal nilai Kappa dengan hipotesis $H_0: (K_1-K_2) = 0$, alternatif $H_1: (K_1-K_2) \neq 0$, H_0 ditolak jika $Z \geq Z\alpha/2$.

III. HASIL DAN PEMBAHASAN

3.1. Skema Klasifikasi

Hasil analisis dari data lapangan menunjukkan bahwa habitat bentik perairan laut dangkal di lokasi penelitian terdiri dari empat kelas yaitu lamun, pasir, karang, dan rubble. Penentuan kelas habitat bentik didasarkan atas dominasi objek yang teramati di lapangan. Mastu *et al.* (2018) menjelaskan bahwa sampai saat ini belum ada dasar dalam pembuatan skema klasifikasi sehingga skema klasifikasi yang dibuat dalam menentukan kelas objek yang teramati untuk klasifikasi citra disesuaikan berdasarkan komposisi penyusun habitat bentik dominan yang ditemui di lapangan.

Data lapangan menunjukkan bahwa terdapat lima jenis lamun yang terdistribusi di perairan pesisir Pulau Pajenekang yang diidentifikasi berdasarkan status padang lamun di Indonesia sesuai dengan pengelasan oleh Sjafrie *et al.* (2018). Jenis-jenis lamun tersebut antara lain adalah *Enhalus acoroides*, *Thalassia hemprichii*, *Cymodocea rotundata*, *Halophila ovalis*, dan *Halodule uninervis* (Figure 3).

Menurut Romimohtarto & Juwana (2001), ada tiga marga yang banyak dijumpai di perairan pantai yaitu *Halophila*, *Enhalus*, dan *Cymodocea*. Sedangkan untuk dominasi kemunculan *Thalassia* di area penelitian dapat disebabkan karena kondisi substrat yang sesuai dengan jenis lamun tersebut yaitu bersubstrat pasir sampai dengan pecahan karang. Hasil penelitian sebelumnya menjelaskan bahwa lamun jenis *Thalassia hemprichii* umumnya banyak ditemukan di daerah rata-rata terumbu dengan substrat pasir dan pecahan-pecahan karang yang kasar baik yang tumbuh secara monospesifik maupun yang tumbuh dengan lamun atau tumbuhan jenis lain (Coremap, 2007).




Figure 3. Types of seagrass in the waters of Pajenekang Island.

Skema klasifikasi yang digunakan dalam penelitian ini terdiri dari 3 level. Level 1 yaitu *reef level* yang terdiri dari pengkelasan darat, laut dalam, dan perairan dangkal. Level 2 merupakan pengkelasan habitat bentik dasar perairan laut dangkal (lamun, pasir, karang, dan *rubble*). Sedangkan level 3 merupakan pengkelasan kondisi tutupan lamun (rapat, kurang rapat, dan jarang). Penentuan kondisi ini berdasarkan dari Kepmen Lingkungan Hidup No.200 Tahun 2004 tentang Kriteria Baku Kerusakan dan Pedoman Penentuan Status Padang Lamun.

3.2. Klasifikasi Citra dengan Penerapan Koreksi Kolom Air (*Depth Invariant Index*) dan Tanpa Koreksi Kolom Air

Proses utama yang dilakukan dalam penerapan metode ini adalah mencari nilai koefisien atenuasi (K_i/K_j) dari lokasi penelitian untuk perairan Pulau Pajeneang dengan mengekstrak nilai digital dari kombinasi kanal biru dan hijau, karena kanal biru dan hijau sangat baik untuk penetrasi (Suwargana, 2014). Setelah itu dicari nilai *covarian* dan *varian* dari *training* sampel pada masing-masing kanal, kemudian didapatkan nilai koefisien atenuasi yang diterapkan ke dalam klasifikasi digital citra satelit. Nilai koefisien atenuasi (K_i/K_j) yang diperoleh sebesar 0,53501. *Training* sampel yang dilakukan pada substrat dasar perairan berdasarkan metode Lyzenga (1981) berada pada kedalaman yang berbeda dan homogen agar mendapatkan nilai korelasi yang linier dengan DII.

Hasil DII yang diperoleh pada penelitian ini juga diterapkan pada beberapa algoritma *machine learning* (SVM, DT, KNN, dan *Bayes*) untuk klasifikasi kelas habitat bentik dan kondisi tutupan lamun. Selain itu, masing-masing algoritma *machine learning* yang ada diujikan dengan perlakuan tanpa koreksi kolom air (tanpa DII), sehingga dapat diketahui penerapan metode dan algoritma *machine learning* yang digunakan

pada lokasi penelitian. Hasil klasifikasi level 2 dan level 3 untuk tiap algoritma yang diujikan pada masing-masing perlakuan dapat dilihat pada *Figure 4* dan *5*.

Secara spasial hasil klasifikasi masing-masing algoritma pada *Figure 4* menunjukkan hasil yang tidak jauh berbeda untuk tiap level dan perlakuan. Pada *Figure 3* dilakukan klasifikasi kelas habitat bentik yang terdiri dari kelas lamun, karang, *rubble* dan pasir. Masing-masing algoritma yang diujikan pada perlakuan tanpa koreksi dan dengan koreksi kolom air secara visual tidak menunjukkan perbedaan yang cukup signifikan. Selain itu, hasil klasifikasi pada level 2 juga menunjukkan bahwa untuk masing-masing objek yang dikelaskan, kelas *rubble* terlihat lebih dominan dibandingkan kelas lainnya pada penerapan algoritma *Bayes*.

Hasil perbandingan beberapa algoritma yang ditampilkan pada kedua gambar diatas (*Figure 3*) secara umum juga dapat menjelaskan bahwa penggunaan algoritma klasifikasi pada suatu lokasi atau kasus penelitian tidak serta merta dapat disamakan. Faktor kemiripan nilai spektral menurut Mastu (2018) tidak dapat dihindari oleh algoritma klasifikasi, terutama kelas habitat bentik yang disusun oleh beberapa kelas habitat bentik dalam lokasi pengamatan.

Figure 5 terlihat bahwa klasifikasi objek lamun berdasarkan kelas kondisi tutupan lamun terbagi menjadi tiga kelas, yaitu kaya/sehat, kurang kaya, miskin. Berdasarkan hasil perlakuan yang telah dilakukan yaitu tanpa penerapan koreksi kolom air dan dengan koreksi kolom air tidak terjadi penambahan ataupun pengurangan kelas untuk masing-masing kondisi tutupan lamun. Akan tetapi, secara visual dapat dilihat bahwa pada masing-masing kelas kondisi tutupan lamun yang telah dilakukan koreksi kolom air terdapat perbedaan dalam hal distribusi kelas kondisi tutupan lamun pada beberapa area tertentu. Distribusi kelas kaya/sehat dan kurang kaya terlihat lebih




Figure 4. The results of image classification level 2 (benthic habitat class) with the application of water column correction and without water column correction on SVM, Bayes, KNN and DT classification algorithms.

mendominasi setelah dilakukan koreksi kolom air dibandingkan dengan kelas miskin (rusak). Perbedaan perlakuan pada kondisi tutupan lamun terlihat jelas pada pengujian menggunakan algoritma SVM, dimana sebelum dilakukan koreksi kolom air kelas dominan adalah kelas dengan kondisi tutupan kurang kaya. Setelah dilakukan koreksi kolom air terlihat terjadi perubahan dan kelas yang dominan adalah kelas dengan kondisi tutupan kaya/sehat.

Perubahan tersebut dapat diakibatkan karena tidak adanya pengaruh koreksi kolom air pada refleksi *spectral*, pada kelas tutupan kurang kaya dan setelah dilakukan koreksi kolom air kejelasan objek pada kelas kaya/sehat lebih jelas, serta adanya pengaruh dari variasi kekeruhan dan kedalaman terhadap koreksi kolom air. Thalib *et al.*

(2018) menjelaskan bahwa variasi kedalaman dan kekeruhan dapat mempengaruhi kolom air sehingga di-perlukan koreksi kolom air untuk mengurangi pengaruh kolom air dengan algoritma Lyzenga yang diasumsikan dapat memberikan informasi karakteristik dasar perairan dangkal dengan lebih jelas.

3.3. Uji Akurasi

Berdasarkan hasil perhitungan *confusion matrix* nilai akurasi yang diperoleh dari penerapan koreksi kolom air dan tanpa koreksi kolom air untuk masing-masing algoritma klasifikasi menunjukkan nilai akurasi yang secara signifikan tidak berbeda jauh (Table 1). Umumnya nilai akurasi masing-masing algoritma klasifikasi yang diterapkan menunjukkan nilai yang baik, sesuai perlakuan atau inputan yang diberikan.




Figure 5. Level 3 image classification results (seagrass cover conditions) by applying water column correction and without water column correction on SVM, Bayes, KNN and DT classification algorithms.

Table 1. The total accuracy value of benthic habitat class classification (level 2) and seagrass cover conditions (level 3) SPOT 7 2017 images with and without DII correction on several classification algorithms.

No.	Classification Algorithm	Level 2		Level 3	
		Without DII (%)	With DII (%)	Without DII (%)	With DII (%)
1.	SVM	66.8	66.8	60.69	56.07
2.	Bayes	70.36	69.17	66.47	65.89
3.	KNN	66.8	66.8	63.01	63.01
4.	DT	67.19	67.19	55.49	55.49

Pada umumnya hasil akurasi dari beberapa algoritma klasifikasi yang diujikan dengan penerapan koreksi kolom air dan tanpa

koreksi kolom air masing-masing menunjukkan bahwa nilai akurasi pada klasifikasi habitat bentik (level 2) cukup baik

(>65%) dan nilai terbaik diperoleh pada algoritma *Bayes* dengan nilai akurasi 70,36% pada perlakuan tanpa koreksi kolom air dan 69,17% dengan perlakuan koreksi kolom air. Pada level 3 untuk klasifikasi kondisi lamun juga menunjukkan hasil yang optimal dan terbaik dihasilkan oleh algoritma klasifikasi *Bayes* tanpa perlakuan koreksi kolom air sebesar 66,47% dan dengan koreksi kolom air sebesar 65,89%. Menurut Putri *et al.* (2004) algoritma *Bayes* merupakan algoritma pengkelasan yang berdasarkan probabilitas sederhana dan dirancang untuk dipergunakan dengan alasan bahwa antar satu kelas dengan kelas yang lain tidak saling tergantung (independen). Selain itu Han & Kamber (2006) juga menjelaskan bahwa keuntungan pengklasifikasian dengan menggunakan pendekatan ini dapat memperkecil nilai eror atau kesalahan klasifikasi. Kayabol & Kutluk (2016) dalam penelitiannya memberikan kesimpulan bahwa *Bayes* dapat digunakan dalam jumlah sampel data yang kecil dan memberikan hasil yang baik dalam melakukan klasifikasi. Sementara itu rendahnya nilai akurasi dari algoritma lainnya menurut Mastu (2018) dapat dipengaruhi oleh kompleksitas habitat bentik dalam hal ini lamun yang terdapat di lokasi penelitian dan jumlah titik pengamatan.

Beberapa kasus algoritma klasifikasi tertentu dapat menghasilkan nilai akurasi yang tinggi apabila input data dan pemrosesan citra yang dilakukan sesuai. Selain itu tingginya kompleksitas habitat dan ketidaksesuaian antara akurasi GPS dan resolusi spasial citra juga dapat menyebabkan rendahnya akurasi (Anggoro *et al.*, 2017). Selain hasil dari nilai *overall accuracy*, Congalton & Green (2009) menjelaskan bahwa untuk mengetahui perbedaan signifikan dari nilai akurasi hasil klasifikasi dapat dilakukan dengan analisis melalui nilai Kappa dan Z statistika. Nilai Z statistika yang diperoleh menggambarkan seberapa signifikan perbedaan yang diperoleh dari masing-masing perlakuan (Table 2 dan 3).

Table 2. Test values are significant comparisons of several classification algorithms at level 2 with and without water column correction (DII).

Algorithm	Z Level 2	Z Table ($\alpha=0.05$)
	statistics without DII and with DII	
SVM	0.01	1.96
Bayes	0.46	1.96
KNN	0.00	1.96
DT	0.00	1.96

Table 3. Test values are significant comparisons of several classification algorithms at level 3 with and without water column correction (DII).

Algorithm	Z Level 3	Z Table ($\alpha=0.05$)
	statistics without DII and with DII	
SVM	0.31	1.96
Bayes	0.12	1.96
KNN	0.00	1.96
DT	0.00	1.96

Table 2 dan 3 memperlihatkan nilai hasil Z statistik yang telah diuji pada level 2 dan level 3. Pada Table 3 dihasilkan nilai Z statistik lebih kecil dari nilai Z tabel dengan nilai alpha yang ditentukan adalah $\alpha/2$ ($0.05/2 = 0.025$). Nilai *alpha* (α) merupakan taraf signifikan yang nilainya tetap dan tidak berubah-ubah berapapun jumlah sampel yang dilihat dari nilai Z dari luas di bawah nilai kurva normal baku. Hal yang sama juga terlihat pada Table 4, dimana nilai Z statistik yang dihasilkan pada level 3 nilainya lebih kecil dari nilai Z tabel. Nilai Z statistik yang diperoleh dari kedua tabel diatas (Table 2 dan 3) adalah hasil yang dihitung berdasarkan nilai akurasi dari masing-masing algoritma yang diuji dengan perlakuan tanpa koreksi kolom air dan dengan koreksi kolom

air untuk mengetahui jika dua matriks kesalahan independen berbeda secara signifikan.

Hasil dari nilai Z statistika dari masing-masing perlakuan menjelaskan bahwa hasil akurasi masing-masing algoritma dengan kedua perlakuan tersebut dikategorikan terdistribusi normal tetapi tidak menunjukkan perbedaan yang signifikan. Perbandingan nilai Z tabel dengan nilai Z hitung yang didapat dari masing-masing algoritma menunjukkan bahwa nilai Z hitung atau Z statistik lebih kecil dari nilai Z tabel, yang artinya hipotesis awal diterima dan tidak ada perbedaan yang nyata (sama) antara masing-masing algoritma yang diujikan dengan perlakuan tanpa koreksi kolom air dan dengan koreksi kolom air pada tiap level. Hal ini sesuai hipotesis awal yang telah ditentukan dan berlaku pada rumus uji statistik (uji Z) yang menentukan kriteria bahwa Z adalah standarisasi distribusi normal nilai Kappa dengan hipotesis $H_0: (K_1 - K_2) = 0$, alternatif $H_1: (K_1 - K_2) \neq 0$, H_0 ditolak jika $Z \geq Z_{\alpha/2}$ (Congalton & Green, 2009).

IV. KESIMPULAN

Penerapan perlakuan dengan koreksi kolom air dan tanpa koreksi kolom air pada pemetaan ekosistem habitat bentik dan lamun dengan menggunakan beberapa algoritma klasifikasi (SVM, Bayes, KNN, dan DT) menunjukkan hasil akurasi yang tidak berbeda nyata. Namun demikian, dari empat algoritma yang digunakan, algoritma Bayes tanpa koreksi kolom air memberikan nilai akurasi tertinggi untuk pemetaan habitat bentik dengan nilai 70,36% dan habitat lamun sebesar 66,47%.

UCAPAN TERIMA KASIH

Penelitian ini dibiayai oleh Kementrian Riset, Teknologi, dan Pendidikan Tinggi, Republik Indonesia sesuai dengan Perjanjian Penugasan

Pelaksanaan Penelitian dan Pengabdian kepada Masyarakat di Perguruan Tinggi Negeri Badan Hukum Tahun Anggaran 2019 antara Direktorat Jenderal Penguatan Riset dan Pengembangan, Kemenristekdikti dengan Insitut Pertanian Bogor Nomor:3/E1/KP. PTNBH/2019 tanggal 29 Maret 2019 dan Surat Perjanjian Penugasan Penelitian bagi Dosen IPB PMDSU No. 4253/IT3.L1/ PN/2019 tanggal 4 April 2019, dalam rangka pelaksanaan kegiatan Penelitian Pendidikan Magister Menuju Doktor untuk Sarjana Unggul (PMDSU) tahun ajaran 2019/2020. Penulis juga mengucapkan terima kasih kepada Lembaga Penerbangan dan Antariksa Nasional (LAPAN) dalam menyediakan data citra satelit SPOT-7.

DAFTAR PUSTAKA

- Anggoro, A., V.P. Siregar, & S.B. Agus. 2017. Klasifikasi multiskala untuk pemetaan zona geomorfologi dan habitat bentik menggunakan metode OBIA di Pulau Pari. *J. Penginderaan Jauh*, 14(2): 89-93.
<http://doi.org/10.30536/j.pjpdcd.1017.v14.a2622>
- Aziizah, N.N., V.P. Siregar, & S.B. Agus. 2016. Penerapan algoritma spectral angle mapper (SAM) untuk klasifikasi lamun menggunakan citra satelit Worldview-2. *J. Penginderaan Jauh*, 13(2): 61-72.
<http://doi.org/10.30536/j.pjpdcd.2016.v13.a2205>
- Bradski, G. & A. Kaehler. 2008. Learning opencv: Computer vision with the opencv library. O'Reilly Media, Inc. Sebastopol, CA, USA. 555 p.
- Budhiman, S., G. Winarso, & W. Asriningrum. 2013. Pengaruh pengambilan *training* sample substrat dasar berbeda pada koreksi kolom air menggunakan data penginderaan jauh. *J. Penginderaan Jauh*, 10(2): 83-92.

- Bukata, R.P., J.H. Jerome, A.S. Kondratyev, & D.V. Pozdnyakov. 2018. Optical properties and remote sensing of inland and coastal waters. CRC Press. Boca Raton. 384 p.
- Congalton, R.G. & K. Green 2009. Assessing the accuracy of remotely sensed data principles and practices (Second Edition). CRC Taylor & Francis Group. France. 183 p.
- COREMAP CTI. 2007. Lamun. <http://www.coremap.or.id/datin/seagrass>. [diunduh 23 Februari 2019].
- Dekker, A.G., V.E. Brando, & J.M. Anstee. 2005. Retrospective seagrass change detection in a shallow coastal tidal Australian lake. *Remote Sensing of Environment*, 97: 415-433. <https://doi.org/10.1016/j.rse.2005.02.017>
- Fukunaga, K. 1990. Introduction to statistical pattern recognition (2nd ed.). Academic Press. New York. 591 p.
- Green, E., A.J. Edwards, & C. Clark. 2000. Remote sensing handbook for tropical coastal management. Unesco Pub. Paris (FR). 316 p.
- Hafitz, M. & P. Danoedoro. 2015. Kajian pengaruh koreksi kolom air pada citra multispektral Worldview-2 untuk pemetaan habitat bentik di Pulau Kemujan Kepulauan Karimunjawa Kabupaten Jepara. Jogjakarta. Prosiding Pertemuan Ilmiah Tahunan XX 2015, Jogjakarta, Februari 2015. 566-575 pp.
- Han, J. & M. Kamber. 2006. *Data Mining Concepts and Techniques, second edition*. Morgan Kaufman. California. 135 p.
- Hedley, J., C. Roelfsema, & S.R. Phinn, 2009. Efficient radiative transfer model in- version for remote sensing applications. *Remote Sensing of Environment*, 113: 2527-2532. <https://doi.org/10.1016/j.rse.2009.07.008>
- Hossain, M.S., J.S. Bujang, M.H. Zakaria, & M. Hashim. 2015. Application of Landsat images to seagrass areal cover change analysis for Lawas, Terengganu and Kelantan of Malaysia. *Continental Shel Research*, 110: 124-148. <https://doi.org/10.1016/j.csr.2015.10.009>
- Kayabol, K. & S. Kutluk. 2016. Bayesian classification of hyperspectral image using spatially-varying Gaussian mixture model. *Digital Signal Processing*, 59: 106-114. <https://doi.org/10.1016/j.dsp.2016.08.010>
- Kushardono, D. 2017. Klasifikasi digital pada penginderaan jauh. IPB Press. Bogor. 76 p.
- Lyzenga, D.R. 1981. Remote sensing of bottom reflectance and water attenuation parameters in shallow water using aircraft and landsat data. *International J. Remote Sensing*, 2: 171-172. <https://doi.org/10.1080/01431168108948342>
- Macreadie, P.I., M.E. Baird, S.M. Trevathan, A.W.D. Larkum, & P.J. Ralph, 2014. Quantifying and modelling the carbon sequestration capacity of seagrass meadows — a critical assessment. *Mar. Pollut. Bull.*, 83: 430–439. <https://doi.org/10.1016/j.marpolbul.2013.07.038>
- Mastu, L.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. <http://doi.org/10.29244/jitkt.v10i2.21039>

- McKenzie, L.J., S.J. Campbell, & C.A. Roder. 2003. Seagrass-watch: manual for mapping & monitoring seagrass resources by community (citizen) volunteers. 2nd Edition. (QFS, NFC, Cairns). 100 p.
- Phinn, S.R., C.M. Roelfsema, & P.J. Mumby. 2011. Multi scale object based image analysis for mapping geomorphic and ecological zones on coral reefs. *International J. Remote Sensing*, 33: 3768-3797.
<https://doi.org/10.1080/01431161.2011.633122>
- Putri, R.E., Suparti, & R. Rahmawati. 2014. Perbandingan metode klasifikasi Naibe Bayes dan K-Nearest Neighbour pada analisis data status kerja di Kabupaten Demak Tahun 2012. *J. Gaussian*, 3(4): 831-838.
- Prabowo, N.W., V.P. Siregar, & S.B. Agus. 2018. Klasifikasi habitat bentik berbasis objek dengan algoritma support vector machines dan decision tree menggunakan citra multispectral SPOT-7 di Pulau Harapan dan Pulau Kelapa. *J. Ilmu dan Teknologi Kelautan Tropis*, 10(1): 123-134.
<http://doi.org/10.29244/jitkt.v10i1.21670>
- Roelfsema, C., S. Phinn, S. Jupiter, J. Comley, & S. Albert. 2013. Mapping coral reefs at reef to reef-system scales, 10s-1000s km², using object-based image analysis. *International J. Remote Sensing*, 34(18): 6367-6388.
<https://doi.org/10.1080/01431161.2013.800660>
- Romimohtarto, K. & S. Juwana. 2001. Biologi Laut: Ilmu Pengetahuan Tentang Biota Laut. Djambatan. Jakarta. 540 p.
- Sartika, D. & D.I. Sensuse. 2017. Perbandingan algoritma klasifikasi *naive bayes*, *nearest neighbour*, dan *decision tree* pada studi kasus pengambilan keputusan pemilihan. *Jatiji*, 1(2): 151-161.
<https://doi.org/10.35957/jatiji.v3i2.78>
- Setiawan, K.T., M.D.M. Manessa, G. Winarso, N. Anggraini, G. Giarrastowo, W. Asriningrum, Herianto, S. Rosid, & A.H. Supardjo. 2019. Estimasi batimetri dari data spot 7 studi kasus perairan Gili Matra Nusa Tenggara Barat. *J. Penginderaan Jauh*, 15(2): 69-82.
<http://doi.org/10.30536/j.pjpdcd.2018.v15.a3008>
- Sjafrie, N.D.M., U.E. Hernawan, B. Prayudha, I.H. Supriyadi, M.Y. Iswari, Rahmat, K. Anggraini, S. Rahmawati, & Suyarso. 2018. Status padang lamun Indonesia Ver. 02. LIPI. Jakarta. 40 p.
- Suwargana, N. 2014. Analisis citra ALOS AVNIR-2 untuk pemetaan terumbu karang (studi kasus: Banyuputih, Kab. Situbondo). Prosiding Deteksi Parameter Geobiofisik Dan Diseminasi Penginderaan Jauh Seminar Nasional Penginderaan Jauh 2014. 588–596 pp.
- Thalib, M.S., N. Nurdin, & A. Aris. 2018. The ability of lyzenga's algorithm for seagrass mapping using sentinel-2a imagery on Small Island, Spermonde Archipelago, Indonesia. *Proceeding of IOP Conference Series: Earth and Environmental Science*, 165(1): 012028.
<https://doi.org/10.1088/1755-1315/165/1/012028>
- Traganos, D., B. Anggarwal, D. Poursanidis, K. Topouzelis, N. Chrysoulakis, & P. Reinartz. 2018. Towards global-scale seagrass mapping and monitoring using sentinel-2 on google earth engine: the case of the Aegean and Ionian Seas. *MDPI J.*, 10(8): 1227.
<https://doi.org/10.3390/rs10081227>
- Trimble. 2014. Ecognition developer: user guide. Trimble Germany GmbH. Munchen, Germany. 262 p.
- Wahidin, N., V.P. Siregar, B. Nababan, I. Jaya, & S. Wouthuyzend. 2015.

- Object based image analysis for coral reef benthic habitat mapping with several classification algorithms. *Procedia Environmental Sciences*, 24: 222-227.
<https://doi.org/10.1016/j.proenv.2015.03.029>
- Waycott, M., K. McMahon, J. Mellors, A. Calladine, & A.D. Kleine. 2004. A guide to tropical seagrasses of the Indo-West Pacific. James Cook University. Townsville. 72 p.
- Wei, W., X. Chen, & A. Ma. 2005. Object-oriented information extraction and application in high-resolution remote sensing image. *IEEE International Geoscience and Remote Sensing Symposium*, 8: 3803-3807.
<https://doi.org/10.1109/IGARSS.2005.1525737>
- Whiteside, T.G., G.S. Boggs, & S.W. Maier. 2011. Comparing object-based and pixelbased classifications for mapping savannas. *International J. of Applied Earth Observation and Geoinformation*, 13(6): 884-893.
<https://doi.org/10.1016/j.jag.2011.06.008>
- Yang, D. & C. Yang. 2009. Detection of seagrass distribution changes from 1991 to 2006 in Xincun Bay, Hainan, with satellite remote sensing. *Sensors*, 9:830-844.
<https://doi.org/10.3390/s90200830>
- Zhang, C. 2015. Applying data fusion techniques for benthic habitat mapping. *ISPRS J. of Photogrammetry and Remote Sensing*, 104: 213-223.
<https://doi.org/10.1016/j.isprsjprs.2014.06.005>
- Zoffoli, M.L., R. Frouin, & M. Kampel. 2014. Water Column for Coral Reef Studies by Remote Sensing. *Sensors J.*, 14(9): 16881–16931.
<https://doi.org/10.3390/s140916881>

Received : 10 July 2019
Reviewed : 02 September 2019
Accepted : 25 January 2020

