

Instance Segmentation Rumput Laut dengan Metode *Longline* Menggunakan Citra UAV dan *Detectron2*

Faisal Akbar¹, Lulu Chaerani M², Nuryuliani³, Elfitrin Syahrul³ dan Nur Azmi Ratna Setyawidati⁴

¹Magister Manajemen Sistem Informasi ³Fakultas Teknologi Industri

²Fakultas Sistem Informasi

³Fakultas Teknologi Industri

Universitas Gunadarma ,Jl. Margonda Raya No. 100, Depok 16424, Jawa Barat

⁴Pusat Riset Kelautan, Badan Riset Sumber Daya Manusia Kelautan dan Perikanan,

KP II. Jl. Pasir Putih II, Ancol Timur, Jakarta Utara 14430

E-mail: fabarj4@gmail.com, lulu@staff.gunadarma.ac.id, nryulia@staff.gunadarma.ac.id,

elfitrin@staff.gunadarma.ac.id, wida20@gmail.com

Abstrak

Target produksi budidaya rumput laut di Indonesia saat ini terus meningkat, didukung oleh luas lahan yang masih berpotensi dimanfaatkan sebagai lahan budidaya rumput laut dan kebutuhan pasar baik di dalam maupun luar negeri. Dukungan teknologi untuk memonitoring secara intensif dan ekstensif diperlukan agar produksi dapat tercapai untuk memenuhi kebutuhan pasar tersebut. Tujuan dari penelitian ini adalah untuk mendeskripsikan hasil akuisisi dan mengetahui sejauh mana kemampuan *unmanned aerial vehicle* (UAV) jenis multirotor untuk mendeteksi pertumbuhan rumput laut yang ditinjau dari efisiensi teknologi, tingkat akurasi dan biaya. Daerah yang akan dikaji merupakan daerah budidaya dengan karakteristik perairan dangkal (< 10 m) dengan substrat dasar perairan pasir berlumpur. Metodologi penelitian terdiri atas akuisisi data menggunakan UAV jenis multirotor, visualisasi dan proses pengolahan citra menggunakan *deep learning framework* detectron2 dengan algoritma *mask RCNN* dan *platform cloud base*. Hasil penelitian ini menunjukkan dengan iterasi sebanyak 600 detectron2 mampu untuk mendeteksi rumput laut dengan baik walaupun akurasi yang didapatkan masih lebih rendah dibandingkan dengan iterasi lebih dari 600 tetapi dengan waktu pelatihan yang lebih singkat dan belum terjadi *overfitting* menjadi nilai lebih. Selanjutnya dalam tulisan ini akan disampaikan kelebihan dan kekurangan dari pemanfaatan *deep learning* dengan *framework* detectron2 menggunakan citra UAV ini dalam mendeteksi rumput laut dan bagaimana mengoptimalkan kemampuan dan menyiasati kelemahan *framework* tersebut.

Kata kunci : Rumput Laut, UAV, Detectron2, Mask-RCNN, *Aerial Photography*

Pendahuluan

Target produksi budidaya rumput laut di Indonesia saat ini terus meningkat untuk memenuhi kebutuhan pasar baik di dalam maupun luar negeri. Upaya pemenuhan target produksi didukung oleh luas lahan yang masih berpotensi dimanfaatkan sebagai lahan budidaya rumput laut. Metode budidaya di lapangan dilakukan dengan tiga macam metode berdasarkan posisi tanam terhadap perairan yakni metode dasar, metode lepas dasar dan metode apung [1]. Jenis rumput laut *Eucheumoids* (*Kappaphycus alvarezii*, *Eucheuma sp*) merupakan jenis rumput laut yang paling banyak dikembangkan melalui proses budidaya. Masa tanam rumput laut ini selama 25 - 30 hari [2].

Rata - rata kecepatan pertumbuhannya 2,36 % per hari [3]. Teknologi untuk memonitoring secara intensif dan ekstensif diperlukan agar proses budidaya di laut dapat tercapai untuk memenuhi kebutuhan pasar tersebut. Salah satu teknologi yang digunakan untuk memonitoring yaitu menggunakan citra satelit. Namun, terbatasnya jumlah pita spektral dari citra satelit membatasi kemungkinan pemetaan yang akurat [4]. Drone adalah pesawat tanpa awak atau *Unmanned Aerial Vehicle* (UAV) solusi untuk mendapatkan data dengan efisien dan efektif (sitasi). Drone adalah wahana yang dilengkapi sistem pengendali terbang melalui gelombang, navigasi presisi (*Ground Positioning System* (GPS)), dan elektronik kontrol penerbangan sehingga mampu terbang sesuai

perencanaan terbang autopilot [5]. *Deep Learning* adalah bagian dari kecerdasan buatan dan *machine learning* yang merupakan pengembangan dari *neural network multiple layer* untuk memberikan ketepatan tugas seperti deteksi objek, pengenalan suara, terjemahan bahasa dan lain – lain [6]. Dalam penelitian ini bertujuan memanfaatkan citra UAV untuk deteksi rumput laut jenis *Eucheuma Cottonii* menggunakan metode *deep learning*

tar line 80 cm. Waktu penelitian dimulai pada agustus 2019 hingga oktober 2020. Proses pengambilan citra dilakukan pada pukul 08.00 - 11.00 WIB.



Gambar 1: Peta Lokasi

Metode Penelitian

Lokasi dan Waktu Studi

Pengambilan data dilakukan di Pantai Lontar, Kp Berambang Desa Lontar Tirtayasa Provinsi Banten (lihat Gambar 1). Lokasi memiliki karakteristik perairan dangkal dengan substrat dasar perairan pasir berlumpur dengan dasar perairan pasir berlumpur. Budidaya rumput laut di daerah ini menggunakan metode *longline* dengan jarak an-

Bahan Penelitian

UAV yang digunakan pada penelitian ini bertipe *multirotor*. Tabel 1 adalah drone yang digunakan DJI Mavic Mini, DJI Mavic 2 Pro, dan DJI Phantom 4 Multispektral.

Tabel 1: Spesifikasi UAV

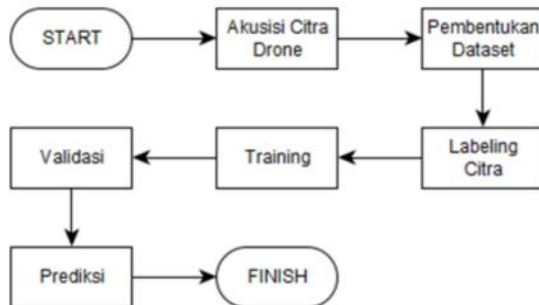
	Mavic mini	Mavic 2 Pro	Phantom 4 Multispectral
Sensor	CMOS 1 / 2,3" : 12 MP	CMOS 1" : 20 MP	Six 1/2.9" CMOS, including one RGB sensor for visible light imaging and five monochrome sensors for multispectral imaging. Each Sensor: Effective pixels 2.08 MP (2.12 MP in total)
Resolusi	Resolusi Gambar 4: 3: 4000 × 3000 ; 16: 9: 4000 × 2250 Resolusi Video 2,7 K: 2720 × 1530 25/30 p FHD: 1920 × 1080 25/30/50/60 hal	Resolusi Gambar 5472 x 3648 Resolusi Video 4K: 3840×2160 24/25/30p 2.7K: 2688×1512 24/25/30/48/50/60p FHD: 1920×1080 ;24/25/30/48/50/60/120p	Resolusi Gambar 1600×1300 (4:3.25)
Flight time	30 minutes (measured while flying at 14 kph in windless conditions)	31 minutes (at a consistent 25 kph) (windless conditions)	Approx. 27 minutes
Mapping Support	No	Yes	Yes
Weight	289 gram	907 gram	1487 gram

Keterangan :

- Sensor : Bertugas untuk mengubah gambar yang ditangkap oleh lensa
- Resolusi : Tingkat ketelitian yang tampak pada citra atau banyak pixel dalam suatu citra
- Flight time : Lama waktu terbang didasarkan pada kapasitas sekali waktu operasional baterai
- Mapping support : Fitur untuk membuat peta yang dimana uav akan diterbangkan secara otomatis.
- Weight : bobot dari uav

Metodologi Penelitian

Metodologi penelitian terdiri atas akuisisi data menggunakan UAV jenis *multirotor*, pemrosesan data UAV, pembentukan dataset, *labeling* citra, *training dataset*, validasi dataset, dan prediksi, lihat Gambar 2.




Gambar 2: Langkah-langkah penelitian

Akuisisi Citra Drone

Metode Pengambilan Citra

Pada penelitian ini metode yang digunakan dalam pengambilan citra menggunakan *vertical aerial fotografi* yang dimana drone ditempatkan di atas objek yang akan diambil. Skala yang digunakan yaitu *Large Scale Photographs*, dimana drone diterbangkan rendah dimaksudkan untuk mendapatkan objek yang terlihat dalam dimensi yang lebih besar. Metode ini digunakan untuk memetakan fitur atau mengukur objek tertentu. *Vertical aerial fotografi* dapat dilihat pada Gambar 3 [7].



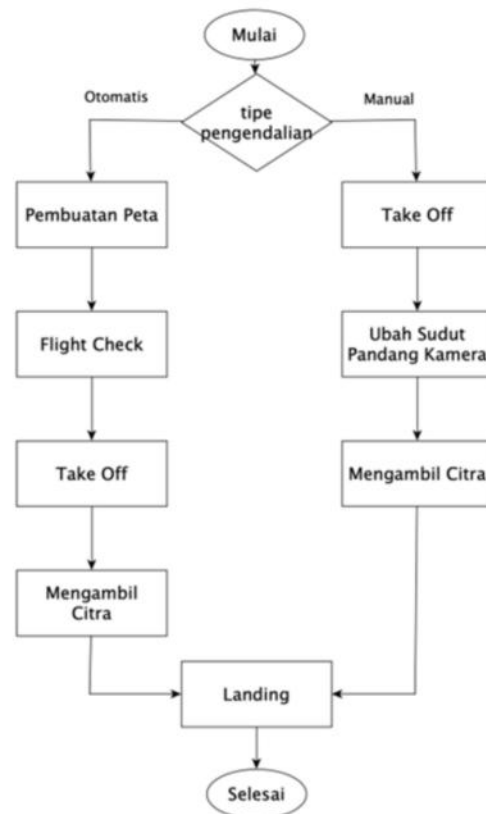
Gambar 3: *Vertical aerial fotografi* (NCERT Book Class 11 Geography Practical Work In Geography Chapter 6 Introduction to Aerial Photographs)

Teknik Pengambilan Citra

Tinggi drone saat melakukan pengambilan citra :

- Dji Mavic 2 Pro dan Dji Phantom 4 Multi-spectral dari permukaan air > 3m
- Dji Mavic Mini dari permukaan air > 2 m

minimum ketinggian ini bertujuan untuk mengurangi efek riak air yang dihasilkan oleh propeller saat pengambilan citra. Cara menerbangkan drone dapat dilihat pada Gambar 4.



Gambar 4: Teknik Pengambilan Citra

Hasil Akuisisi Citra

Setelah melakukan pengambilan citra maka hal yang dilakukan selanjutnya adalah melakukan pemotongan citra tersebut.

- Citra berbentuk gambar Untuk citra berbentuk gambar citra tersebut diolah dengan cara melakukan pemotongan citra
- Citra berbentuk video Untuk citra berbentuk video maka harus dilakukan pengambilan citra dengan cara memotong video tersebut berdasarkan interval waktu. Interval waktu yang dipilih yaitu 2 detik [8].

Pembentukan Dataset

Dataset adalah sebuah himpunan data yang akan dikelola menjadi sebuah informasi. Citra yang terkumpul akan dibagi menjadi dua buah subset, yaitu data training dan validation. Data *training* digunakan untuk sebagai model pembelajaran saat dilakukan *training*. Data validation digunakan untuk proses validasi model dari hasil *training*.

Labeling Citra

Labeling adalah suatu proses pemberian label yang sama pada sekumpulan pixel pembentuk objek yang saling berdekatan pada suatu citra. Citra rumput laut akan diberi label dengan nama kategori "rumput laut". *Polygon* dipilih saat proses *labeling* dikarenakan bentuk rumput laut yang tidak presisi satu dengan yang lainnya. Label yang dibuat bersifat acak mengikuti alur rumput laut dengan menghindari pantulan sinar matahari, menghindari botol penampung, dan menghindari rumput laut yang samar dikarenakan tenggelam atau terdapat objek lain yang menutupi rumput laut. Aplikasi yang digunakan untuk melakukan labeling yaitu Coco Annotator.

Training Dataset

Training dataset adalah suatu proses melatih sebagian dataset yang bertujuan untuk membuat prediksi. Contoh untuk dapat mengenali sebuah objek diperlukan citra yang menggambarkan objek tersebut. *Training* dataset dilakukan menggunakan detectron2 dengan berfokus pada *batch size per image* dan *max* iterasi. Hasil yang dikeluarkan pada proses *training* ini yaitu bobot (*weight*) dan data laporan *training*.

Validasi Dataset

Validasi dataset adalah suatu proses untuk menguji dataset bertujuan untuk memperkirakan seberapa baik model yang telah dilatih saat tahap *training* dataset. Validasi dilakukan setelah proses *training* selesai dan bobot yang dihasilkan dari proses *training* akan digunakan untuk melakukan prediksi terhadap data yang ada pada dataset validasi. Hasil dari validasi ini yaitu gambar yang telah diberi warna pada objek yang terdeteksi dan tabel berisi *average precision* dan *average recall*.

Prediksi

Prediksi adalah suatu proses untuk mengenali suatu objek menggunakan bobot yang dihasilkan dari proses *training*. Hasil dari citra ini adalah citra baru yang dimana dalam citra tersebut jika terdeteksi maka akan diberi warna berbeda dari objek lainnya.

Hasil dan Pembahasan

Kemampuan UAV

Tabel 2: Kemampuan UAV Yang Digunakan

	Dji mavic mini	Dji Mavic 2 Pro	Dji Phantom 4 Multispectral
Ketinggian minimal	>2m	> 3m	> 3m
Ketinggian optimal	< 15 m	> 3m	> 3m
Waktu terbang	25 menit	25 menit	20 menit

Keterangan :

Ketinggian minimal : ketinggian yang harus tercapai saat dilakukan pengambilan citra. Hal ini harus dilakukan agar citra yang dihasilkan tidak menghasilkan noise berupa riak di permukaan air.

Ketinggian optimal : ketinggian yang disarankan saat dilakukan pengambilan citra. Hal ini harus dilakukan agar dapat menangkap objek secara jelas.


Waktu terbang : Didasarkan pada kapasitas sekali waktu operasional baterai.

Selain kriteria tersebut ada satu kriteria lagi yaitu pilot, kehandalan pilot sangat berguna dalam pengambilan citra. salah satu kehandalannya yaitu *takeoff* dan *landing* dari dan menuju ke tangan. Tetapi hal ini hanya dapat dilakukan pada Dji Mavic Mini dan Dji Mavic 2 Pro.

Hasil Citra

Dari penelitian ini didapatkan 3 hasil citra yaitu :


1. Citra Berdasarkan Interval Pemotongan




Gambar 5: Perbandingan interval

Dari hasil ini untuk pemotongan video menggunakan interval 0,1 detik untuk citra yang dihasilkan akan menghasilkan citra yang serupa hal, untuk interval 1 detik citra yang dihasilkan akan ada sedikit perbedaan dalam hal ini dapat dilihat dari ubur-ubur yang berwarna putih mengalami perpindahan mendekati lamun, untuk interval 2 detik citra yang dihasilkan akan sangat berbeda, karena hasil tersebut dipilih interval 2 detik dikarenakan citra yang dihasilkan terdapat perubahan yang tidak terlalu cepat ataupun tidak mirip dengan citra sebelumnya, lihat Gambar 5.

2. Citra Berdasarkan Ketinggian




Gambar 6: Ketinggian 2 m



Gambar 7: Ketinggian 3 m



Gambar 8: Ketinggian 4,7 m




Gambar 9: Ketinggian 15,5 m


Gambar 6 diambil dari ketinggian 2 meter dari permukaan air laut. Gambar 7 diambil dari ketinggian 3 meter dari permukaan air laut. Gambar 8 diambil dari ketinggian 4,7 meter dari permukaan air laut. Gambar 9 diambil dari ketinggian 15,5 meter dari permukaan air laut. Pada ketiga ketinggian tersebut rumput laut dapat terlihat dengan jelas.

3. Citra Berdasarkan Sensor


Gambar 10 sampai Gambar 12 adalah citra yang didapatkan dari drone multispectral, dengan berbagai mode indeksasi :



Gambar 10: NDVI



Gambar 11: GNDVI



Gambar 12: NDRE

(a) Mode NDVI

Indeks vegetasi atau NDVI adalah indeks yang menggambarkan atau memperhitungkan tingkat kehijauan suatu vegetasi yang diperoleh dari kombinasi antara band merah dan band inframerah [9]. Pada mode ini rumput laut diberi warna hitam pekat hal ini dikarenakan rumput laut tidak secara langsung menyerap radiasi, tetapi secara kasat mata rumput laut dapat diidentifikasi. dikarenakan waktu pengambilan data yang dilakukan pada pukul 11.00 riak air sangat mengganggu citra.

(b) b. Mode GNDVI

Green Normalized Difference Vegetation Index atau GNDVI adalah indeks yang menggambarkan tingkat kehijauan suatu vegetasi. Hal yang membedakan antara NDVI dan GNDVI terletak pada penggantian potongan merah dengan pita cahaya yang sangat spesifik dalam kisaran hijau [10]. Pada mode ini rumput laut diberi warna putih sedangkan air diberi warna abu menuju hitam. warna hijau pada citra tersebut adalah pantulan dari sinar matahari. Dari citra ini rumput laut dapat teridentifikasi dengan sangat jelas karena warna dari rumput laut sangat berbeda dengan lainnya. Oleh karena itu mode ini sangat disarankan untuk mendeteksi rumput laut jika menggunakan drone phantom 4 multispectral.

(c) Mode NDRE

NDRE adalah indeks yang dibangun menggunakan perpaduan band infra merah dan band yang menggunakan spektral sempit antara merah dan infra merah [11]. Pada mode ini rumput laut diberi warna putih tetapi terdapat noise yang cukup banyak dihasilkan.

Hasil Training Dataset

Training dataset dengan pembagian 100 gambar dengan total instance sebanyak 1806. Training

menggunakan dua *batch size per image* yaitu 128 dan 512 dengan iterasi sebanyak 300, 600, dan 1000 untuk mengetahui akurasi, *false negatif* dan *false positif* dari *mask rcnn* yang didapatkan pada setiap skema. Tabel 3 dan Tabel 4 adalah hasil dari skema tersebut : Tabel hasil *training dataset* detectron2, (Tabel 3) *batch size per image* 128; (Tabel 4) *batch size per image* 512;

Keterangan :

False Positif = prediksi bernilai benar tetapi kenyataannya salah, contoh bambu terdeteksi sebagai rumput laut;

False Negatif = prediksi bernilai salah tetapi kenyataannya benar contoh ada rumput laut yang tidak terdeteksi padahal rumput laut itu terlihat oleh mata

Tabel 3: *Batch Size Per Image 128*

Iterasi	Akurasi	False Positif	False Negatif	Waktu Training
300	85,69%	8%	19%	0:08:30
600	88,49%	13,5%	12%	0:15:22
1000	89,66%	10%	12%	0:20:00

Dari Tabel 3 dapat dilihat ketika iterasi dinaikan akurasi yang awalnya hanya 85,69% naik hingga 89,66%. Selain dari peningkatan akurasi menambah jumlah iterasi menyebabkan waktu *training* juga meningkat dan terjadi *overfitting* dikarenakan nilai *false positif* yang naik lalu turun secara terus menerus.

Tabel 4: *Batch Size Per Image 512*

Iterasi	Akurasi	False Positif	False Negatif	Waktu Training
300	86,63%	8%	19%	0:11:07
600	88,79%	13,5%	12%	0:21:26
1000	89,48%	10%	11%	0:36:16

Dari Tabel 4 dapat dilihat ketika iterasi dinaikan akurasi yang awalnya hanya 86,63% naik hingga 89,48%. Selain dari peningkatan akurasi menambah jumlah iterasi menyebabkan waktu *training* juga meningkat dan terjadi *overfitting* dikarenakan nilai *false positif* yang naik lalu turun secara terus menerus.

Hasil Validasi Dataset

Hasil dari validasi dataset detectron menghasilkan dua hasil yaitu bbox dan segm.

Tabel hasil validasi dataset detectron (Tabel 5) bbox *batch size per image* 128; (Tabel 6) bbox *batch size per image* 512; (Tabel 7) segm 128; (Tabel 8) segm 512. Ket: AP=*average precision* (rata-rata presisi, dimana presisi adalah persentase prediksi positif yang benar diantara semua prediksi yang dibuat) peningkatan nilai AP mengakibatkan semakin akuratnya prediksi box dengan kotak pembatas yang sebenarnya; bbox (*bounding box*) adalah

kotak area yang didefinisikan oleh dua bujur dan dua lintang, Lintang adalah angka desimal antara -90.0 dan 90.0. Bujur adalah angka desimal antara -180.0 dan 180.0. ; segm (*segmentation*) adalah jenis pelabelan dimana setiap pixel dalam diberi label dengan konsep tertentu.

Tabel 5: *bbox 128*

Iterasi	AP	AP50	AP75	APs	APm	API
300	13,246	31,419	8,470	nan	0,000	13,453
600	34,169	65,269	28,161	nan	4,876	34,702
1000	42,207	72,713	43,079	nan	2,190	42,950

Pada validasi bbox menggunakan *batch size per image* 128 dapat dilihat semakin banyaknya iterasi yang dilakukan nilai dari AP akan meningkat. Terdapat nilai “nan” pada APs dikarenakan label yang dibuat tidak ada yang ukurannya kurang dari 32x32 pixel hal ini mengakibatkan jika ada rumput laut yang ukurannya kurang dari atau sama dengan 32 x 32 pixel tidak akan terdeteksi. Pada iterasi 300 nilai AP secara keseluruhan kurang baik dikarenakan cakupan ukuran box prediksi maksimal 31% dari total box yang seharusnya terprediksi. Pada iterasi 600 nilai AP terjadi peningkatan, secara keseluruhan ukuran box prediksi sudah mengingat hampir lebih 2 kali lipat dibandingkan dengan iterasi 300 hal ini cukup baik. Pada iterasi 1000 nilai AP sudah baik dikarenakan cakupan ukuran box prediksi maksimal 72% dari ukuran box yang harusnya terprediksi

Tabel 6: *bbox 512*

Iterasi	AP	AP50	AP75	APs	APm	API
300	42,207	72,713	43,709	nan	2,190	42,950
600	30,628	61,014	27,676	nan	1,538	31,147
1000	34,287	65,697	32,691	nan	2,552	34,869

Pada validasi bbox menggunakan *batch size per image* 512 dapat dilihat semakin banyaknya iterasi yang dilakukan nilai dari AP akan meningkat. Terdapat nilai “nan” pada APs dikarenakan label yang dibuat tidak ada yang ukurannya kurang dari 32x32 pixel hal ini mengakibatkan jika ada rumput laut yang ukurannya kurang dari atau sama dengan 32 x 32 pixel tidak akan terdeteksi. Pada iterasi 300 nilai AP secara keseluruhan sudah baik dikarenakan cakupan ukuran box yang terprediksi maksimal 72% dari total box yang seharusnya terprediksi. Pada iterasi 600 nilai AP terjadi penurunan yang mengakibatkan cakupan ukuran box prediksi hanya bisa maksimal 61% dari total box yang harusnya terprediksi. Pada iterasi 1000 terjadi peningkatan sebanyak 2 - 4 % tetapi ukuran box yang terprediksi belum mencakup ukuran box yang diprediksi saat iterasi 300.

Tabel 7: *segm 128*

Iterasi	AP	AP50	AP75	APs	APm	API
300	9,112	27,319	2,141	nan	0,000	9,323
600	30,103	64,592	21,957	nan	0,904	30,743
1000	37,189	73,612	34,507	nan	1,012	38,239

Pada validasi segm menggunakan *batch size per image* 128 dapat dilihat semakin banyaknya iterasi yang dilakukan nilai dari AP akan meningkat. Terdapat nilai “nan” pada APs dikarenakan label yang dibuat tidak ada yang ukurannya kurang dari 32x32 pixel hal ini mengakibatkan jika ada rumput laut yang ukurannya kurang dari atau sama dengan 32 x 32 pixel tidak akan terdeteksi. Pada iterasi 300 nilai AP secara keseluruhan kurang baik karena ukuran segmentasi yang terprediksi hanya dapat mencakup maksimal 27% dari total keseluruhan ukuran, hal ini mengakibatkan tidak terdeteksinya rumput laut. Pada iterasi 600 terjadi peningkatan nilai AP yang cukup signifikan hal ini sudah cukup baik dikarenakan ukuran segmentasi yang terprediksi dapat mencakup maksimal 64% dari ukuran yang harusnya terprediksi. Pada iterasi 1000 terjadi peningkatan AP dan ini sudah baik dikarenakan ukuran segmentasi yang terprediksi dapat mencakup maksimal 73% dari ukuran yang harusnya terprediksi.

Tabel 8: *segm 512*

Iterasi	AP	AP50	AP75	APs	APm	API
300	37,189	73,612	34,507	nan	1,012	38,239
600	27,012	59,472	16,332	nan	0,367	27,676
1000	28,798	64,915	22,699	nan	0,696	29,447

Pada validasi segm menggunakan *batch size per image* 128 dapat dilihat semakin banyaknya iterasi yang dilakukan nilai dari AP akan meningkat. Terdapat nilai “nan” pada APs dikarenakan label yang dibuat tidak ada yang ukurannya kurang dari 32x32 pixel hal ini mengakibatkan jika ada rumput laut yang ukurannya kurang dari atau sama dengan 32 x 32 pixel tidak akan terdeteksi. Pada iterasi 300 nilai AP secara keseluruhan baik karena ukuran segmentasi yang terprediksi maksimal 73% dari total keseluruhan ukuran. Pada iterasi 600 terjadi penurunan nilai AP yang cukup signifikan hal ini kurang baik dikarenakan ukuran segmentasi yang terprediksi dapat mencakup maksimal 59% dari ukuran yang harusnya terprediksi. Pada iterasi 1000 terjadi peningkatan AP dan ini sudah cukup baik walau belum mendekati nilai yang diberikan ketika iterasi 300.

Hasil Prediksi

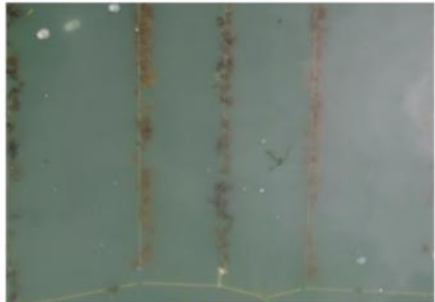
Batch size per image 128, lihat Tabel 9. Batch size per image 512, lihat Tabel 10.

Tabel 9: *Tabel Citra Prediksi 128*

Iterasi	Citra yang telah diprediksi
300	 <p>Hasil dari iterasi 300 dan <i>batch size per image</i> 128 hanya dua dari lima untai rumput laut saja yang dapat dikenali.</p>
600	 <p>Hasil dari iterasi 600 dan <i>batch size per image</i> 128 semua dapat dikenali tetapi terdapat tumpukan pada beberapa untai rumput laut.</p>
1000	 <p>Hasil dari iterasi 1000 dan <i>batch size per image</i> 128 semua dapat dikenali tetapi terdapat tumpukan pada beberapa untai rumput laut.</p>

matan lahan budidaya dan pertumbuhan rumput laut metode line Dari hasil training dan validasi bisa dipilih opsi batch size per image 128 dengan iterasi 600. Hal ini dikarenakan iterasi 600 memiliki selisih akurasi kurang dari 2% dan belum terjadi overfitting dan waktu training yang tidak terlalu lama dibandingkan menggunakan iterasi 1000.

Tabel 10: *Tabel Citra Prediksi 512*

Iterasi	Citra yang telah diprediksi
300	 <p>Hasil dari iterasi 300 dengan <i>batch size per image</i> 512 tidak ada untai rumput laut yang dapat dikenali.</p>
600	 <p>Hasil dari iterasi 600 dengan <i>batch size per image</i> 512 hanya satu untai yang tidak dapat dikenali tetapi terdapat tumpukan di salah satu untai rumput laut.</p>
1000	 <p>Hasil dari iterasi 1000 dengan <i>batch size per image</i> 512 semua dapat dikenali dan tidak ada tumpukan.</p>

Penutup

Kesimpulan kemampuan unmanned aerial vehicle (UAV) jenis multirotor, dengan 3 tipe drone telah diujicobakan dalam riset ini. Untuk pengamatan pertumbuhan rumput laut jenis eucheumoids, dji mavic 2 pro paling efisien dan efektif. Dikarenakan dji mavic 2 pro dapat melakukan terbang otomatis, sensor kamera yang mumpuni, dan ringkas untuk dibawa. Dari hasil akuisisi metode vertical aerial photography dengan Large Scale Photographs dengan interval 2 detik dan sensor RGB pada ketinggian 5 meter dapat dipergunakan dalam penga-

Daftar Pustaka

- [1] Bambang Priono, "Budidaya Rumput Laut Dalam Upaya Peningkatan Industrialisasi Perikanan", *Media Akuakultur*, 2016, Vol 8, No. 1, 1-8.

- [2] Anonim, "Produksi bibit rumput laut kotoni (*Eucheuma cottonii*)-Bagian 2: Metode long-line", SNI 7673.2:2011, BSN-Standar Nasional Indonesia, 2011.
- [3] Angga Dwi Hernanto, Sri Rejeki, Restiana Wisnu Ariyati, "Pertumbuhan Budidaya Rumput Laut (*Eucheuma Cottoni* Dan *Gracilaria SP.*) Dengan Metode Long Line Di Perairan Pantai Bulu Jepara", *Journal of Aquaculture management and Technology*, 2015, 4.2: 60-66.
- [4] Pramaditya Wicaksono, Ignatius Salivian Wisnu Kumara, Muhammad Kamal, Muhammad Afif Fauzan, Zhafirah Zhafarina, Dwi Agus Nurswantoro and Rifka Noviaris Yogyakarta, "Multispectral Resampling of Seagrass Species Spectra: WorldView-2, Quickbird, Sentinel-2A, ASTER VNIR, and Landsat 8 OLP", In: *IOP Conference Series: Earth and Environmental Science*. IOP Publishing, 2017. p. 012039.
- [5] Budi Utomo, "Drone untuk percepatan pemetaan bidang tanah", *Media Komunikasi Geografi*, 2017, 18.02: 146-15.
- [6] Eko Cahyono Putro, Rolly Maulana Awangga and Roni Andarsyah, "Tutorial Object Detection People with Faster region-Based Convolutional Neural Network (Faster R-CNN)", *Kreatif*, Vol. 1, 2020.
- [7] Team, "Practical Work in Geography", NCERT Books Class 11 Geography, India, ISBN 81-7450-595-4, 2020.
- [8] Elisa Casella, Antoine Collin, Daniel Harris, Sebastian Ferse, Sonia Bejarano, Valeriano Parravicini, James L. Hench & Alessio Rovere, "Mapping coral reefs using consumer-grade drones and structure from motion photogrammetry techniques", *Coral Reefs*, 2017, 36.1: 269-275.
- [9] Philiani, Intan, et al. "Pemetaan Vegetasi Hutan Mangrove Menggunakan Metode Normalized Difference Vegetation Index (NDVI) Di Desa Arakan, Minahasa Selatan, Sulawesi Utara." *Surya Octagon Interdisciplinary Journal Society and Technology* 1.2 (2016): 211-222.
- [10] Arhatin, Risti Endriani, and Prihatin Ika Wahyuningrum, "Algoritma Indeks Vegetasi Mangrove Menggunakan Satelit Landsat ETM+", *Buletin PSP* 21.2 (2013).
- [11] EOS, "Normalized Difference Rededge", <https://eos.com/industries/agriculture/ndre/>, diakses pada 26 oktober 2021.