

SEGMENTASI VEGETASI LAHAN BASAH BERBASIS *MODIFIED-CAMERA DRONE*

Oni Soesanto^{1,*}, Moch Idris², Hudchon Doyo Hastomo³

¹ Prodi Statistika FMIPA Universitas Lambung Mangkurat, Banjarbaru, Indonesia

² Prodi Matematika FMIPA Universitas Lambung Mangkurat, Banjarbaru, Indonesia

³ Mahasiswa Prodi Fisika FMIPA Universitas Lambung Mangkurat, Banjarbaru, Indonesia

*Penulis korespondensi: osoesanto@ulm.ac.id

Abstrak. Perkembangan teknologi informasi telah berkembang pesat di berbagai bidang pada dekade terakhir ini, Salah satu bidang yang berkembang adalah penginderaan jauh (*remote sensing*) dimana salah satu aplikasinya di bidang pertanian yang banyak dikenal dengan *smart farming* atau *precision agriculture*. *Precision agriculture* bergantung pada penggunaan teknologi informasi yang berkembang saat ini seperti drone. Platform umum dalam *remote sensing* adalah teknologi *Global Navigation Satellite System* (GNSS) yang terdapat pada pesawat terbang dan satelit serta drone sebagai alternatif berbiaya rendah. Pencitraan dengan menggunakan drone mampu memberikan resolusi spasial yang lebih tinggi, *real time* dan fleksibel. Pemrosesan citra hasil pencitraan dengan drone bergantung pada penggunaan *computer vision* dalam pemrosesan citra untuk mengekstraksi informasi yang sesuai dengan tujuan yang ditargetkan, seperti ekstraksi citra vegetasi. Beberapa ukuran indeks vegetasi (*greenness index*) yang sering diterapkan antara lain adalah *Normalized Difference Vegetation Index* (NDVI), *Excessive Green Index* (ExG), *Excessive Green Red Index* (ExGR), *Visible Band Difference Vegetation Index* (VDVI), *Visible Atmospherically Resistant Index* (VARI), dan *Green Ratio Vegetation Index* (GRVI). Penggunaan kamera multispektral berbasis indeks vegetasi untuk sistem citra drone terkendala mahalnya sensor jika dibandingkan dengan webcam digital RGB (*red green blue*) biasa. Untuk itu diperlukan modifikasi webcam digital RGB pada drone serta pengembangan kemampuan algoritma dalam melakukan proses akuisisi, ekstraksi dan segmentasi citra vegetasi. Dalam penelitian ini modifikasi kamera dilakukan dengan penambahan *super blue* dan *red filter Infragram* untuk memblokir spektrum cahaya *blue* dan *red* dalam proses akuisisi citra. Ekstraksi citra dilakukan dengan beberapa model *greenness index* (NDVI, ExG, ExGR, VDVI, VARI, GRVI) serta proses segmentasi citra menggunakan *threshold binarization* pada cluster *kmeans segmentation* guna menentukan luasan vegetasi dari citra. Hasil pengujian menggunakan menunjukan bahwa ekstraksi citra RGB menggunakan model *greenness index* yang diujikan memiliki rata-rata *accuracy* sebesar 84,7887% dan rata-rata *sensitivity* 92,6952%. Hal ini memberikan pengertian bahwa secara umum modifikasi camera pada drone pada akuisisi citra, *image processing* dan segmentasi citra dalam penelitian ini cukup bagus digunakan untuk segmentasi vegetasi di lahan basah.

Kata kunci: segmentasi vegetasi, *precision agriculture*, *modified-camera drone*

1. PENDAHULUAN

Perkembangan bidang teknologi pertanian pada dekade terakhir menunjukkan perkembangan yang sangat pesat, tidak hanya peran dan kepentingannya dalam penyediaan bahan dan produk turunannya saja namun telah berkembang pada sistem pertanian yang berbasis pengetahuan dan teknologi informasi. Salah satu aspek yang menjadi perhatian selain aspek teknis dan produksi adalah aspek sistem manajemen guna dapat mencapai pembangunan secara ekonomi dan lingkungan untuk proses pertanian (Hassanein *et al.*, 2018). Untuk kebutuhan tersebut, diperlukan sistem manajemen khusus untuk mendistribusikan input yang berbeda berdasarkan kebutuhan masing-masing tempat di bidang pertanian yang dapat menghindari penyalahgunaan sumber daya serta menghindari efek kerusakan pada lingkungan sekitarnya. Sistem manajemen seperti itu dinamakan *smart farming* atau *precision agriculture*, yang dapat diartikan sebagai penggunaan teknologi yang tepat untuk melakukan kegiatan pertanian yang tepat pada waktu dan lokasi yang tepat (Andritoio *et al.*, 2018; Guo *et al.*, 2017; Artizzu *et al.*, 2011).

Penggunaan *precision agriculture* sebagai sistem manajemen untuk industri pertanian telah menjadi salah satu dari sepuluh revolusi teratas di bidang pertanian terutama distribusi data input secara intensif menyesuaikan kebutuhan di lapangan (Mulla, 2013; Xu *et al.*, 2018). Oleh karena itu, sistem manajemen *precision agriculture* bergantung pada penggunaan teknologi dalam mengumpulkan informasi yang sesuai dan mendeteksi



kebutuhan setiap zona dengan pengendalian proses distribusi input (Hassannein *et al.*, 2018). Contoh utama untuk teknologi ini adalah penginderaan jauh (*remote sensing*) yang memiliki kemampuan besar untuk memberikan informasi penting untuk aktivitas tersebut. Platform umum yang sering dipakai adalah satelit dan pesawat terbang yang menyediakan teknologi *Global Navigation Satellite System* (GNSS) dengan kemampuan untuk memperoleh gambar yang mencakup area yang luas dalam waktu singkat. Dalam hal ini citra digunakan untuk memantau pertumbuhan tanaman, stres tanaman, dan memprediksi hasil panen. GNSS mampu meningkatkan resolusi spasial bersama dengan mengontrol resolusi temporal namun memiliki keterbatasan lain terutama biaya dan akses dengan waktu yang dibutuhkan untuk mencakup bidang pertanian yang luas. Oleh karena itu, kendaraan udara tak berawak (*unmanned aerial vehicles* (UAV)) atau drone telah diperkenalkan dan digunakan sebagai solusi alternatif yang lebih murah dan fleksibel (Hassannein *et al.* (2018); Xu *et al.* (2018)).

Penggunaan drone dalam pencitraan dianggap sebagai alternatif berbiaya rendah untuk sistem penginderaan jauh dibandingkan dengan penggunaan pesawat udara dan satelit. Citra dari drone memberikan resolusi spasial yang lebih tinggi karena terbang di ketinggian yang lebih rendah, di mana resolusi spasial tersebut mampu memberikan informasi yang diperlukan untuk aplikasi pertanian yang berbeda, seperti deteksi gulma, deteksi baris tanaman, dan pemantauan kesehatan tanaman. Selain itu, sistem kamera drone dapat menyediakan sistem pencitraan resolusi temporal tinggi yang mampu memperoleh citra secara *real-time* dan fleksibel (Rokmana dan Nuha, 2019; Hassannein *et al.*, 2018).

Pemrosesan citra hasil pencitraan dengan drone bergantung pada penggunaan *computer vision* dalam pemrosesan citra untuk mengekstraksi informasi yang sesuai dengan tujuan yang ditargetkan, seperti ekstraksi citra vegetasi, atau segmentasi vegetasi. Segmentasi vegetasi bertujuan untuk mengklasifikasikan piksel yang berbeda pada citra yang diperoleh menjadi dua kelas yaitu kelas vegetasi dan kelas non-vegetasi. Kelas vegetasi menyertakan semua objek tanaman dalam gambar sebagai tanaman dan gulma, sedangkan objek lainnya termasuk dalam kelas non-vegetasi (Hassannein *et al.*, 2018). Untuk menghindari kesalahan klasifikasi yang dapat mempengaruhi kualitas output yang ditargetkan, sehingga cara yang tepat diperlukan ekstraksi vegetasi, segmentasi vegetasi, ataupun proses reduksi *background* citra vegetasi. Beberapa ukuran indeks vegetasi (*greenness index*) yang sering digunakan adalah *Normalized Difference Vegetation Index* (NDVI), *Normalized Red* (NR), *Normalized Green* (NG), *Difference Vegetation Index* (DVI) (Netto *et al.*, 2019; Xu *et al.*, 2017).

Penggunaan kamera atau webcam multispektral berbasis indeks vegetasi untuk sistem citra drone terkendala mahalanya sensor jika dibandingkan dengan webcam digital RGB biasa. Untuk itu diperlukan modifikasi webcam digital RGB pada drone dengan menambahkan filter *super blue* dan *super red* untuk memblokir sebagian cahaya warna biru dan merah serta pengembangan kemampuan dalam melakukan proses ekstraksi vegetasi dengan kombinasi pendekatan berbasis indeks warna dan metode klustering untuk segmentasi vegetasi.

Ekosistem lahan basah tidak hanya berfungsi sebagai habitat bagi tumbuhan dan hewan yang beradaptasi secara khusus, tetapi juga langsung bermanfaat bagi lingkungan masyarakat, seperti penyimpanan air, retensi dan transformasi hara (Xu *et al.*, 2017). Habitat lahan basah di Kalimantan dimana lahan rawa pasang surut dengan rezim air yang dikelola dengan baik dapat dialihkan menjadi lahan pertanian yang produktif (Hatta, 2016). Sementara itu, dengan mengetahui kondisi vegetasi penutupan lahan serta arahan pengendaliannya dapat meningkatkan produktivitas lahan untuk kesejahteraan masyarakat (Kadir dan Badaruddin, 2015). Mengingat pentingnya mengetahui vegetasi tutupan lahan terutama penerapannya pada lingkungan lahan basah, maka segmentasi vegetasi pada lahan basah diharapkan mampu untuk menunjang informasi tentang kondisi vegetasi maupun pertanian di lingkungan lahan basah.

2. METODE

2.1. Deskripsi Data Penelitian


Data dalam penelitian ini adalah data citra yang diambil menggunakan drone dengan beberapa variasi ketinggian menyesuaikan kemampuan drone. Survey dan pemilihan lokasi dipilih disekitar wilayah Kota Banjarbaru dan Kabupaten Banjar Propinsi Kalimantan Selatan yang memiliki spesifikasi lahan gambut yaitu di daerah Landasan Ulin Kota Banjarbaru (3°13'19.20"LU, 114°26'34.08"BT) dan Sungai Rangas Kabupaten

Banjar ($3^{\circ}14'4.20''\text{LU}$, $114^{\circ}26'43.08''\text{BT}$). Data citra diambil pada ketinggian 15 m dengan kecepatan terbang drone 4 m/s dengan resolusi citra 2250x4000 *pixel* dalam format RGB dan skala kalibrasi luasan 50 *pixel*/0.5 meter.

Digital kamera yang digunakan dalam penelitian ini kamera *DJI Mavic Mini* dengan sensor 1/2.3" yang telah dimodifikasi dengan penambahan *super blue/red filter* dari *Infagram Public Lab*. Kamera standar drone dirancang untuk mengambil citra cahaya tampak dalam format RGB, sedangkan modifikasi kamera drone dengan menambahkan filter *super blue/super red* akan menyebabkan filter secara selektif memblokir sebagian warna merah demikian sebaliknya.

Ada dua tipe data yang digunakan dalam penelitian ini yaitu citra *ground truth (real image)* dan citra *raw (filtered image)*. Sampel citra diambil dari 4 lokasi penelitian dengan mempertimbangkan detail objek citra dan posisi presisi koordinat antara *ground truth image* dan *raw image*. Hal ini perlu dilakukan pada proses validasi guna menghitung luasan *vegetation cover* antara *ground truth image* dan *raw image*. Keterbatasan perangkat drone yang menyediakan dua kamera sekaligus dalam proses akuisisi citra bisa disiasati dengan menggunakan aplikasi *mapping planner* dimana lokasi koordinat area disetting agar rute terbang yang sama dapat dilakukan pada saat pengambilan data *ground truth* dan *raw*, dimana pada saat pengambilan data *ground truth*, filter kamera drone harus dilepas.

Kalibrasi citra juga dilakukan terhadap beberapa variasi ketinggian dan kecepatan terbang drone untuk mendapatkan citra hasil terbaik. Faktor lain yang sangat menentukan adalah intensitas cahaya matahari dan kecepatan angin. Intensitas cahaya matahari sangat menentukan terhadap kualitas citra, sedangkan kecepatan angin akan berpengaruh terhadap presisi koordinat lokasi antara *ground truth image* dan *raw image*. Citra *ground truth* digunakan sebagai pembanding luasan vegetasi real dengan luasan vegetasi hasil segmentasi dari citra *raw* pada proses validasi seperti di gambarkan pada Gambar 1.



Gambar 1. Data citra

2.3. Greenness Index

Segmentasi citra vegetasi secara umum merupakan proses pemisahan indeks *greenness* antara objek pada citra yang terindikasi sebagai vegetasi dengan non vegetasi sebagai *background*. Indeks *greenness* pada vegetasi sendiri dikarakterisasi dengan citra yang berwarna *green*. Formulasi *greenness index* dalam penelitian ini diadaptasi dari beberapa peneliti sebelumnya (Netto *et al.*, 2018; Xue J. dan Su B., 2017; Netto *et al.*, 2019). Beberapa *greenness index* dinyatakan dalam persamaan berikut:

2.3.1. Excessive Green Index (ExG)

ExG adalah nilai *chromatic coordinates* yang diperoleh dari selisih antara normalisasi indeks *green color* dengan *red color* dan *blue color* terhadap nilai maksimum masing-masing *color*. Nilai ExG diperoleh dari persamaan berikut:

$$ExG = 2g - r - b, \quad (1)$$

dengan, $r = \frac{Rn}{Rn+Gn+Bn}; g = \frac{Gn}{Rn+Gn+Bn}; b = \frac{Bn}{Rn+Gn+Bn}$

$$Rn = \frac{R}{Rmax}; Gn = \frac{G}{Gmax}; Bn = \frac{B}{Bmax}$$

dimana $[r, g, b] \approx [0,1]$ dan $Rmax = Gmax = Bmax = 255$

2.3.2. Excessive Green Red Index (ExGR)

ExGR merupakan kombinasi antara dua *color index* yaitu ExG dan ExR. Kedua metode digunakan secara simultan untuk memisahkan citra vegetasi dan citra *background*. ExG digunakan untuk ekstraksi region vegetasi dan ExR digunakan untuk mengeliminasi noise dari *background* non vegetasi. Persamaan ExGR diberikan sebagai berikut:

$$ExGR = ExG - ExR, \text{ dimana } ExR = 1.4r - g \quad (2)$$

2.3.3. Visible Band Difference Vegetation Index (VDVI)

VDVI ditentukan berdasarkan tiga band *visible light* yaitu *red*, *green*, dan *blue* sekaligus. Pada VDVI menggunakan indeks *green color* dengan faktor pengali 2, dan menggunakan *green color* dan NIR untuk menghitung NDVI, $(\rho_r + \rho_b)$ dibandingkan *red color*, sedangkan *color green* dikalikan 2 untuk $(\rho_r + \rho_b)$. Nilai indeks VDVI berkisar pada rentang [-1, 1]. Persamaan VDVI diberikan sebagai berikut:

$$VDVI = \frac{(2*\rho_g - \rho_r - \rho_b)}{(2*\rho_g + \rho_r + \rho_b)}; \quad VDVI \approx [-1,1] \quad (3)$$

2.3.4. Visible Atmospherically Resistant Index (VARI)

Indeks ini didasarkan pada ARVI dan digunakan untuk memperkirakan fraksi vegetasi dalam pemandangan dengan sensitivitas rendah terhadap efek atmosfer. Persamaan VARI diberikan sebagai berikut:

$$VARI = \frac{g-r}{g+r-b} \quad (4)$$

2.3.5. Green Ratio Vegetation Index (GRVI)

GRVI (*Green and Red ratio Vegetation Index*) adalah salah satu indeks vegetasi spektral yang dihitung dari reflektansi warna hijau dan warna merah. Indeks ini sensitif terhadap laju fotosintesis di kanopi hutan, karena reflektansi hijau dan merah sangat dipengaruhi oleh perubahan pigmen daun. Persamaan GRVI diberikan sebagai berikut

$$GRVI = \frac{g-r}{g} \quad (5)$$




2.3.6. Normalized Difference Vegetation Index (NDVI)

NDVI index banyak digunakan untuk mengidentifikasi sejumlah karakteristik dan ukuran indeks vegetasi, antara lain menghitung luasan daun, konsentrasi *chlorophyl* pada daun, produktivitas tanaman, luasan vegetation cover, ataupun akumulasi air di suatu area. Indeks ini adalah ukuran vegetasi hijau yang sehat. Kombinasi formulasi perbedaan yang dinormalisasi dan penggunaan daerah penyerapan dan reflektansi tertinggi. kondisi. Persamaan NDVI diberikan sebagai berikut:

$$NDVI = \frac{2g - (g + r)}{(b + r)} \quad (6)$$

Ekstraksi citra pada *raw image* untuk masing-masing *greenness index* digambarkan sebagai berikut:




Gambar 2. *greenness images*


2.4. Image Segmentation

Image segmentation secara umum merupakan proses pemisahan suatu objek yang dikehendaki dari background objek tersebut. Segmentasi vegetasi dalam penelitian ini adalah suatu proses pemisahan antara citra vegetasi dan non vegetasi. Citra vegetasi dikarakteristik dengan warna *green* yang dinyatakan dalam *greenness index*. Segmentasi vegetasi dapat dilakukan dengan beberapa metode segmentasi antara lain *clustering*. Segmentasi citra dalam penelitian ini digunakan *kmeans clustering* dengan binerisasi objek kluster hasil segmentasi menggunakan *Otsu Threshold binerization*. Proses segmentasi diawali dengan konversi *raw images* (Gambar 1 (b)) menjadi format *greenness index* yang dinyatakan dalam format warna RGB. Citra RGB selanjutnya dikonversi menjadi *grayscale image* (Gambar 3).

Penerapan *kmeans clustering* untuk segmentasi vegetasi dilakukan pada area-area yang perbedaan warna pada *image processing*. *Kmeans clustering* mengklasifikasi setiap piksel citra *grayscale* menjadi sejumlah kluster berdasarkan kemiripan intensitas *grayscale* setiap piksel dan menghitung jarak piksel tersebut terhadap *centroid*-nya. Setiap piksel citra akan diklasifikasi pada suatu kluster tertentu, manakala memiliki jarak minimum terhadap *centroid* kluster tersebut. Pada penelitian ini ditetapkan sejumlah 5 cluster dengan asumsi meliputi vegetasi (pohon, semak, rumput) dan non vegetasi (tanah, air) yang digambarkan sebagai citra biner hasil segmentasi *kmeans* setiap kluster.




Gambar 3. Grayscale Image



Gambar 4. Binarization Cluster Image

Hasil segmentasi *kmeans* dengan jumlah kluster 5 dapat dinyatakan dalam Gambar 4. Hasil segmentasi selanjutnya dibandingkan dengan hasil binerisasi dari citra *ground truth* yaitu model segmentasi manual berdasarkan *real image* dilapangan dalam proses validasi hasil segmentasi. Berdasarkan validasi hasil segmentasi dapat ditentukan persentase luas area yang ditutupi vegetasi (*vegetation cover*) dan *non vegetasi*. Evaluasi region juga dilakukan untuk mengetahui persentase *accuracy*, *sensitivity* pada metode segmentasi dengan beberapa variasi model *greenness index*.



Gambar 5. Perbandingan *ground truth image* dan *object cluster image*

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pengujian dan Testing

Secara teknis filter *super blue* dan *super red* yang ditambahkan pada kamera drone mampu mereduksi sekitar 50% cahaya tampak dari spektrum cahaya biru dan merah, sehingga citra RGB yang dihasilkan dominan kehijauan yang menjadi ciri warna vegetasi. Namun dari sisi *image processing* algoritma yang digunakan relatif lebih sederhana jika dibandingkan citra RGB dari kamera drone tanpa penambahan filter. Selain itu pada citra RGB biasa masih diperlukan algoritma *image enhancement* untuk meningkatkan kualitas citra, namun proses ini beresiko mereduksi detail vegetasi yang berakibat mempengaruhi *accuracy* dan *efficiency* pada proses ekstraksi dan segmentasi *image greenness*. Beberapa parameter harus diatur dan dikendalikan dalam algoritma-algoritma *image enhancement* akan membantu manakala objek segmentasinya selain vegetasi tanpa penambahan filter atau citra RGB biasa, sehingga dalam penelitian ini filter *super blue* dan *super red* tetap dibiarkan sebagaimana adanya sesuai dengan spesifikasinya namun dengan menggunakan kalibrasi terbaik pada proses *acquisition*.

Penggunaan salah satu filter *super blue* atau *super red* biasa digunakan pada kamera khusus *nearinfrared/near infra blue* dengan tujuan pada indeks kesehatan daun ataupun kesuburan tanah dengan spesifikasi kamera khusus tanpa filter cahaya tampak dengan filter yang telah terpasang secara *portable part* dan spesifikasi drone yang relatif lebih mahal. Untuk tujuan segmentasi vegetasi, hal tersebut dapat disiasati dengan drone

standar yang relatif murah dengan menambahkan filter *super blue* dan/atau *super red* untuk mereduksi warna merah dan biru pada filter cahaya tampak yang terpasang secara permanen pada kamera drone guna mendapatkan citra RGB tereduksi dengan filter *super blue* dan/atau *super red* yang dipasang.

Pengujian sampel citra dilakukan untuk mengetahui performansi beberapa *greenness index* terhadap 10 sampel citra hasil akuisisi citra. Ekstraksi warna RGB *raw image* menjadi *greenness index* menggunakan persamaan (1)-(6). Segmentasi citra *grayscale* dari *greenness image* dengan *kmean clustering* dan *threshold binerization* untuk setiap objek klusternya. Jumlah kluster ditetapkan 5 (lima) klas dalam proses validasi terdiri dari objek vegetasi (pohon, semak, rumput) dan non vegetasi (tanah, air). Hasil segmentasi dengan *kmeans clustering* digambarkan pada Gambar 4. Performansi segmentasi didasarkan pada nilai *accuracy* dan *sensitivity* untuk setiap model *greenness index* yang telah ditentukan dapat dilihat pada Tabel 1 berikut.

Tabel 1. *Accuracy* dan *Sensitivity* Segmentasi

Sampel		1	2	3	4	5	6	7	8	9	10
Ground Truth Cover (%)		58,13	63,03	31,67	64,12	51,52	64,61	63,57	65,43	63,69	76,67
Vegetation Cover (%)		75,00	70,92	25,16	54,81	42,19	50,38	53,88	56,20	53,77	64,70
ExG	85,69	82,51	90,10	87,57	85,73	74,72	82,10	89,77	90,70	83,05	83,05
ExG	95,05	73,72	86,58	85,01	89,01	77,43	85,91	89,74	90,98	85,82	85,82
R	91,10										
VDVI	85,69	80,14	87,64	87,64	85,73	75,34	80,56	89,71	89,92	80,98	80,98
VARI	85,93	82,51	90,10	87,57	85,73	74,72	82,10	89,77	90,70	83,05	83,05
GRVI	82,61	72,40	87,06	76,82	87,22	75,05	79,35	82,56	79,87	81,98	81,98
NDVI		80,41	92,43	87,66	89,35	82,85	88,42	88,86	88,38	86,22	86,22
ExG	99,80	97,79	91,16	88,58	82,07	91,92	90,09	91,49	92,60	96,49	96,49
ExG	97,60	88,77	98,34	94,39	92,74	87,80	93,51	89,58	90,96	96,33	96,33
R	87,50										
VDVI	99,80	98,37	89,30	89,30	97,22	90,76	90,90	92,01	94,74	96,90	96,90
VARI	85,55	97,79	91,16	88,58	82,07	91,92	90,09	91,49	92,60	96,49	96,49
GRVI	90,51	85,96	95,55	98,03	85,68	86,27	96,08	96,32	82,01	88,32	88,32
NDVI		80,62	97,89	97,24	98,44	97,10	98,24	98,30	98,42	98,60	98,60

Pengujian secara statistik, data *accuracy* dan *sensitivity* dengan signifikansi 5% didapatkan hasil ANOVA menunjukkan bahwa secara statistik tidak ada perbedaan signifikan antar metode *greenness index* yang digunakan dalam segmentasi vegetasi. *Test of homogeneity of variances* untuk data *accuracy* dihasilkan probabilitas atau signifikansinya adalah 0,1651 yang berarti lebih besar dari 0.05 maka dapat disimpulkan bahwa varian populasi *greenness index* yang digunakan adalah homogen. Demikian pula pada data *sensitivity* dengan nilai probabilitas atau signifikansinya adalah 0,276. Sedangkan *mean square error greenness methods* untuk *accuracy* diperoleh 0,00241 dan untuk *sensitivity* didapatkan 0,0032.

Tabel 2. *Accuracy Performance*

	max	min	mean	SD	CV
ExG	90,70	74,72	85,19	4,61	0,0541
ExGR	95,05	73,72	85,93	5,96	0,0694
VDVI	91,10	75,34	84,88	5,01	0,0590
VARI	90,70	74,72	85,19	4,61	0,0541
GRVI	87,22	72,40	80,82	4,83	0,0598
NDVI	92,43	80,41	86,72	3,50	0,0404

Tabel 3. *Sensitivity Performance*

	max	min	mean	SD	CV
ExG	99,80	82,07	92,20	4,79	0,0519
ExGR	98,34	87,80	93,00	3,52	0,0378
VDVI	98,37	87,50	92,70	3,63	0,0392
VARI	99,80	82,07	92,20	4,79	0,0519
GRVI	98,03	82,01	89,98	5,55	0,0616
NDVI	98,60	80,62	95,54	5,47	0,0573

*

Berdasarkan Tabel 2, diperlihatkan bahwa rata-rata (*mean*) *accuracy* tertinggi pada metode *greenness* ExGR sekaligus memiliki *coefficient of variation* (CV) tertinggi sebesar 0.0694. Sedangkan pada Tabel 3 diperlihatkan rata-rata *sensitivity* tertinggi pada NDVI dan *coefficient of variation* terbesar pada GRVI.

Secara umum dari metode *greenness index* dalam penelitian ini memiliki tingkat *accuracy* dan *sensitivity* yang tinggi dengan rata-rata *accuracy* sebesar 84,79% dan rata-rata *sensitivity* 92,70%. Hal ini mengandung pengertian bahwa modifikasi kamera drone dengan penambahan filter *super blue* dan *super red* menghasilkan citra RGB yang bagus untuk segmentasi vegetasi.

4. SIMPULAN

Dalam penelitian ini modifikasi kamera dilakukan dengan penambahan *super blue* dan *super red filter* untuk memblokir sebagian spektrum cahaya blue dan red dalam proses akuisisi citra. Ekstraksi citra dilakukan dengan adaptasi beberapa model *greenness index* (ExG, ExGR, VDI, VARI, GRVI, NDVI) serta proses segmentasi citra menggunakan *threshold binarization* pada kluster *kmeans segmentation* guna menentukan luasan vegetasi. Hasil pengujian menunjukkan bahwa ekstraksi citra RGB termodifikasi filter *super blue* dan *super red* menggunakan model *greenness index* yang diujikan memiliki rata-rata *accuracy* sebesar 84,7887% dan rata-rata *sensitivity* 92,6952%. Hal ini memberikan pengertian bahwa secara umum modifikasi camera pada drone pada akuisisi citra, *image processing* dan segmentasi citra dalam penelitian ini sangat bagus digunakan untuk segmentasi vegetasi di lahan basah.

5. UCAPAN TERIMA KASIH

Ucapan terima kasih disampaikan kepada Universitas Lambung Mangkurat melalui Program Dosen Wajib Meneliti dengan Pendanaan DIPA Universitas Lambung Mangkurat Tahun Anggaran 2021.

6. DAFTAR PUSTAKA

- Andritoiu, D., Bazavan, L.C., Besnea, F.L., Roibu, H., & Bizdoaca, N.G. (2018). *Agriculture Autonomous Monitoring and Decisional Mechatronic System*. IEEE: 241-246.
- Artizzu, X.P.B, Ribeiro, A., Guijarro, M., & Pajares, G. (2011). Real-Time Image Processing For Crop/Weed Discrimination In Maize fields. *Computers and Electronics in Agriculture* 75:337-346.
- cfastie, Public Lab: Superblue, 2013 (accessed October 10, 2020)). <https://publiclab.org/notes/cfastie/04-20-2013/superblue>.
- Guo, M., Li, J., Sheng, C., Xu, J., & Wu, L. (2017). A Review of Wetland Remote Sensing. *Sensors*. 17, 777: 1-36
- Hassanein, M., Lari, Z., & El-Sheimy, N. (2018). A New Vegetation Segmentation Approach for Cropped Fields Based on Threshold Detection from Hue Histograms. *Sensors* 18:1253: 1-25.
- Hatta, G.M. (2016). Lahan Basah, Kearifan Lokal, Dan Teknologi. *Prosiding Seminar Nasional Lahan Basah Tahun 2016 Jilid 1*: 7-13.
- Kadir, S. & Badaruddin. (2015). Pengayaan Vegetasi Penutupan Lahan Untuk Pengendalian Tingkat Kekritisitas Das Satui Provinsi Kalimantan Selatan. *Jurnal Hutan Tropis Volume 3 No. 2*: 145-152.
- Mulla, D.J. (2013). Twenty five Years Of Remote Sensing In Precision Agriculture: Key Advances And Remaining Knowledge Gaps. *Biosystems Engineering* 114 :358-371.
- Netto A, Martins R.N., Souza G.S.A., Araújo G.M., Almeida S.L.H., dan Capelini V.A. (2018). Segmentation of RGB images using different vegetation indices and thresholding methods, *Nativa, Sinop*, v. 6, n. 4, p. 389-394
- Netto, A., Martins, R.N., Souza, G.S.A., Santos, F.F.L., & Rosas, J.T.F. (2019). Evaluation of a Low-cost Camera for Agricultural Applications. *Journal of Experimental Agriculture International*, 32(5): 1-9
- Rabatel, G., Gorretta, N., & Labbé, S. (2011). *Getting NDVI spectral bands from a single standard RGB digital camera: a methodological approach*, 14th Conference of the Spanish Association for Artificial Intelligence, CAEPIA 2011:333-3432.
- Rokhmana, C.A., & Nuha, M.U. (2019). *Modification of Pocket Camera as A Sensor for UAV-Based Plant Health Detection System*, 5th International Conference on Science and Technology (ICST), Yogyakarta.
- Suryana. (2016). Potensi Dan Peluang Pengembangan Usaha Tani Terpadu Berbasis Kawasan Di Lahan Rawa. *Jurnal Litbang Pertanian*, Vol. 35:2:57-68.
- Xu, P., Niu, Z., & Tang, P. (2017). Comparison and assessment of NDVI time series for seasonal wetland classification. *International Journal Of Digital Earth* :1-30
- Xu, Y., Gao, Z., Khot, L., Meng, X., & Zhang, Q. (2018). A Real-Time Weed Mapping and Precision Herbicide Spraying System for Row Crops, *Sensors*, 18, 4245: 1-16.

