

# KLASIFIKASI TANAMAN HORTIKULTURA BERBASIS CITRA MULTISPEKTRAL UNMANNED AERIAL VEHICLE DENGAN PENDEKATAN K-NEAREST NEIGHBOR DAN MINIMUM DISTANCE

## *Classification of Horticultural Plants based on Multispectral Imagery of Unmanned Aerial Vehicle with K-Nearest Neighbor and Minimum Distance Approaches*

**Arieza Andriani Nur Aina<sup>1)\*</sup>, Khursatul Munibah<sup>2)</sup>, dan Muhammad Ardiansyah<sup>2)</sup>**

<sup>1)</sup> Program Studi Manajemen Sumberdaya Lahan, Departemen Ilmu Tanah dan Sumberdaya Lahan, Fakultas Pertanian, IPB University, Jl. Meranti – Kampus IPB Dramaga, Bogor, Jawa Barat 16680

<sup>2)</sup> Departemen Ilmu Tanah dan Sumberdaya Lahan, Fakultas Pertanian, IPB University, Jl. Meranti – Kampus IPB Dramaga, Bogor, Jawa Barat 16680

### ABSTRACT

*Remote Sensing satellite imagery with medium such as Landsat or Sentinel 2 imagery is commonly used in agriculture, but its application to monitor the condition and growth of horticultural plants is still limited, especially for cultivation on narrow land. For horticultural land with narrow land, multispectral unmanned aerial vehicle (UAV) imagery can be used as an alternative because it has high resolution. In addition to the use of UAV imagery, mapping horticultural crops requires a classification approach that is able to group pixels into land cover and use elements accurately such as machine learning. This study aims to analyze the spectral response of horticultural crops based on multispectral UAV imagery, map horticultural crops using the k-Nearest Neighbor (k-NN) and Minimum Distance Classification (MDC) methods and analyze the level of accuracy of horticultural crop classification using both methods. Spectral response analysis was carried out by taking sample areas from 11 classes including horticulture and nonhorticulture. UAV image classification with k-NN using the DZetsaka plugin, while MDC using the Semi-Automatic Classification plugin in QGIS 3.10.6-A Coruña. The results showed that the spectral response of horticulture in the visible wavelength was low, where the green band was slightly higher than the red band. On the other hand, the spectral response from the red edge band to the NIR band showed a sharp increase. The classification of horticultural plants in both methods showed differences in terms of area and accuracy. The order of the largest to smallest area in k-NN was chili, carrot, potato, banana, cabbage, onion, and tomato; while in MDC it was chili, banana, carrot, cabbage, potato, onion, and tomato. The overall accuracy of k-NN and MDC was 89.37% and 51.48%, respectively.*

**Keywords:** accuracy, parrot sequoia sensor, spectral response

### ABSTRAK

Citra satelit Penginderaan Jauh resolusi sedang seperti citra Landsat atau Sentinel 2 umum digunakan di bidang pertanian, tetapi penggunaannya untuk memantau kondisi dan pertumbuhan tanaman hortikultura masih terbatas terutama pada budidaya di lahan yang sempit. Untuk lahan hortikultura dengan lahan sempit dapat digunakan citra *unmanned aerial vehicle* (UAV) multispektral sebagai alternatif karena memiliki resolusi tinggi. Selain penggunaan citra UAV, pemetaan tanaman hortikultura memerlukan pendekatan klasifikasi yang mampu mengelompokkan piksel kedalam unsur penutupan dan penggunaan lahan secara akurat seperti *machine learning*. Penelitian ini bertujuan menganalisis respon spektral tanaman hortikultura berdasarkan citra UAV multispektral, memetakan tanaman hortikultura dengan metode *k-Nearest Neighbor* (k-NN) dan *Minimum Distance Classification* (MDC), dan menganalisis tingkat ketelitian klasifikasi tanaman hortikultura menggunakan kedua metode tersebut. Analisis respon spektral dilakukan dengan mengambil area sampel dari 11 kelas yang meliputi hortikultura dan nonhortikultura. Klasifikasi citra UAV dengan k-NN menggunakan *plugin* DZetsaka, sedangkan MDC menggunakan *plugin* *Semi-Automatic Classification* pada QGIS 3.10.6-A Coruña. Hasil penelitian menunjukkan bahwa respon spektral hortikultura pada gelombang tampak mata terlihat rendah, dimana *band* hijau sedikit lebih tinggi daripada *band* merah. Di sisi lain, respon spektral dari *band* tepi merah menuju *band* infra merah dekat menunjukkan peningkatan tajam. Klasifikasi tanaman hortikultura pada kedua metode menunjukkan perbedaan dalam hal luasan dan ketelitian. Urutan luas terbesar sampai terkecil pada k-NN adalah cabai, wortel, kentang, pisang, kubis, bawang merah, dan tomat; sedangkan pada MDC adalah cabai, pisang, wortel, kubis, kentang, bawang merah, dan tomat. Akurasi keseluruhan klasifikasi k-NN dan MDC masing-masing sebesar 89.37% dan 51.48%.

**Kata kunci:** akurasi, respon spektral, sensor *parrot sequoia*

### PENDAHULUAN

Sektor pertanian di Indonesia menjadi salah satu modal perekonomian nasional dan dapat diandalkan dalam

perekonomian Indonesia. Hortikultura merupakan salah satu subsektor pertanian yang berkembang pesat di Indonesia, meliputi berbagai jenis tanaman seperti buah-buahan, sayur-sayuran, bunga, dan tanaman hias. Tanaman

\*) Penulis Korespondensi: Telp. +6281219561174; Email. ariezaandrr@gmail.com

DOI: <http://dx.doi.org/10.29244/jilt.27.1.32-40>

hortikultura memiliki nilai ekonomi dan permintaan pasar yang tinggi, khususnya cabai dan bawang merah yang memiliki konsumsi rata-rata yang signifikan di masyarakat Indonesia. Menurut BPS (2022), konsumsi rata-rata cabai per kapita mencapai 0.15 kg per bulan, sementara konsumsi bawang merah mencapai 2.49 kg per bulan. Provinsi Sumatera Utara, Sumatera Barat, Jawa Barat, Jawa Tengah, Jawa Timur, Sulawesi Selatan, dan NTB tercatat memiliki luas panen tanaman hortikultura terbesar (Oktaviani *et al.* 2021). Berdasarkan data BPS (2022), Jawa Barat merupakan salah satu produsen terbesar untuk cabai, kentang, tomat, wortel, dan pisang.

Pemantauan pertumbuhan hortikultura merupakan salah satu langkah penting untuk memastikan kualitas panen, meningkatkan produktivitas dan mengurangi kerugian akibat hama penyakit. Pemanfaatan teknologi Penginderaan Jauh dapat secara signifikan meningkatkan efisiensi dan efektivitas pengelolaan tanaman hortikultura karena menurut Dulam *et al.* (2025) sistem Penginderaan Jauh dapat menyediakan basis data yang akurat tentang perilaku spektral tanaman dan lingkungan tumbuhnya. Informasi ini digunakan secara luas di pertanian seperti untuk penilaian kondisi tanaman, peramalan produksi tanaman, evaluasi kualitas panen, pemantauan pertumbuhan dan kesehatan tanaman hortikultura.

Citra satelit Penginderaan Jauh untuk aplikasi pertanian tersedia dalam berbagai sensor dan resolusi spasial seperti Landsat dan Sentinel, tetapi penggunaannya untuk hortikultura masih terbatas karena resolusi spasial dari citra satelit gratis tersebut belum memadai dan sulit untuk memantau pertumbuhan hortikultura yang umumnya ditanam di lahan yang relatif sempit seperti di kebun atau lahan pekarangan. Sebagai alternatif, *Unmanned Aerial Vehicle* (UAV) menawarkan solusi dengan kemampuannya menghasilkan citra beresolusi sangat tinggi hingga di bawah 1 cm (Ruwaimana *et al.*, 2017). Selain itu, UAV dapat dilengkapi dengan berbagai sensor, seperti kamera RGB, multispektral, atau hiperspektral, yang memungkinkan untuk identifikasi tanaman hortikultura yang lebih akurat berdasarkan pola spektral yang berbeda (Chen *et al.*, 2023).

Identifikasi tanaman hortikultura pada citra Penginderaan Jauh memerlukan pendekatan klasifikasi yang mampu mengelompokkan piksel kedalam unsur penutupan dan penggunaan lahan secara akurat. Selain itu, klasifikasi citra memberikan informasi distribusi spasial terkait penutupan dan penggunaan lahan (Sampurno dan Thoriq, 2016). Identifikasi dan klasifikasi penting untuk memantau kondisi dan pertumbuhan tanaman hortikultura. Menurut Cao *et al.* (2021) pendekatan *machine learning*

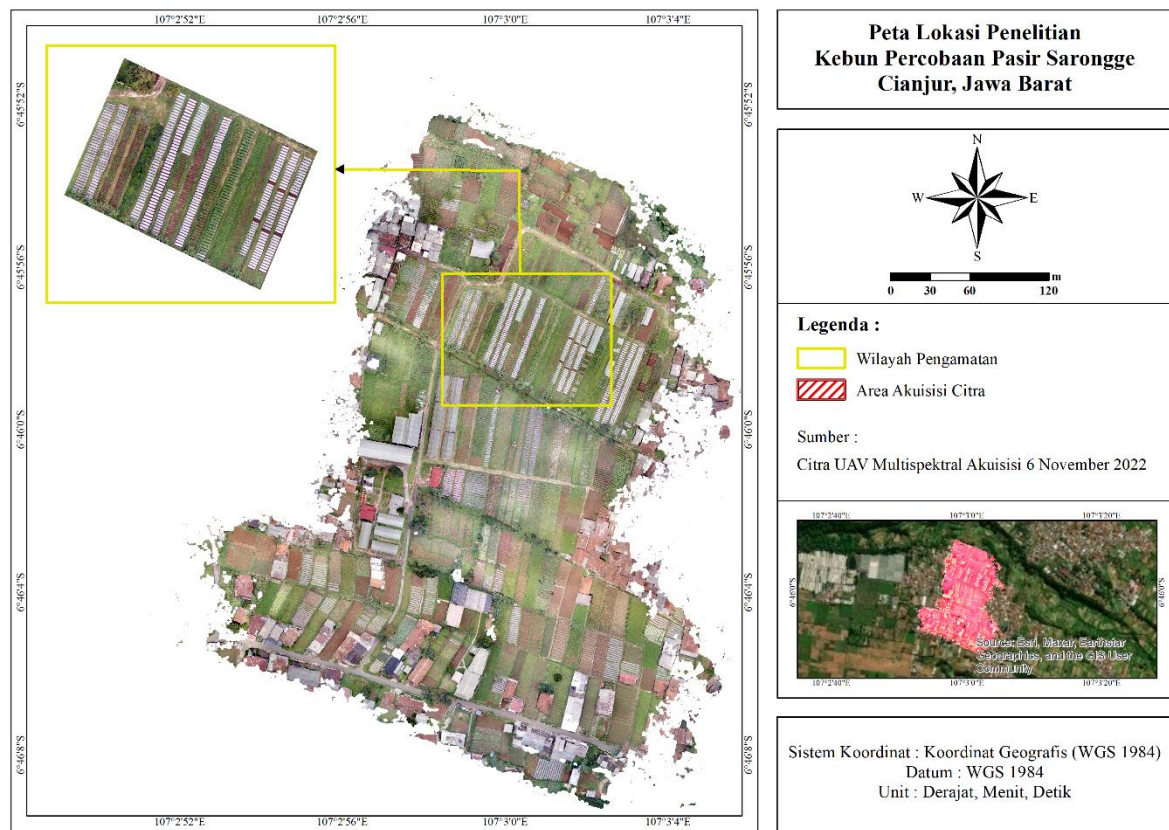
(pembelajaran mesin) memiliki performa prediksi yang lebih akurat dibanding metode statistik klasik dalam identifikasi dan pemetaan tanaman hortikultura.

Pendekatan klasifikasi terbimbing yang umumnya digunakan dalam pembelajaran mesin adalah *Random Forest* (RF), *Support Vector Machine* (SVM), dan *Decision Tree*. Dalam penelitian ini digunakan pendekatan pembelajaran mesin dari *k-Nearest Neighbor* (k-NN) dan pendekatan klasik *Minimum Distance Classification* (MDC). K-NN adalah metode sederhana dalam *data mining* yang mengasumsikan piksel berdekatan tergolong ke dalam kelas yang sama, lalu menentukan kelas berdasarkan mayoritas dari k tetangga terdekat (Iswanto *et al.*, 2022). MDC juga metode yang sederhana karena mencari jarak terdekat ke rata-rata kelas. Penelitian terkait identifikasi dan pemetaan dengan membandingkan pendekatan k-NN dan MDC belum banyak dilakukan di Indonesia khususnya untuk tanaman hortikultura. Berdasarkan hal yang telah disebutkan sebelumnya, penelitian ini bertujuan untuk menganalisis pola spektral tanaman hortikultura berdasarkan citra UAV multispektral, mengidentifikasi dan memetakan tanaman hortikultura dengan metode klasifikasi k-NN dan MDC, dan juga membandingkan hasil dan ketelitian klasifikasi hortikultura menggunakan kedua metode tersebut.

## BAHAN DAN METODE

### Lokasi Penelitian

Penelitian dilaksanakan di Kebun Percobaan Pasir Sarongge, Kabupaten Cianjur (Gambar 1) yang memiliki variasi panjang dan kemiringan lereng dengan jenis tanah yang seragam yaitu tanah andosol. Lokasi penelitian terletak pada ketinggian  $\pm 1000$  mdpl dengan curah hujan rata-rata per tahun sebesar 3,036 mm pada rentang tahun 2018 hingga 2022. Kebun ini memiliki luas mencapai 71.265 m<sup>2</sup> yang didominasi oleh penggunaan lahan tanaman hortikultura. Tanaman hortikultura yang ditanam di kebun percobaan meliputi kubis, cabai, wortel, bawang merah, tomat, dan kentang. Pemberian pupuk dilakukan secara berbeda sesuai dengan jenis tanaman. Pada tanaman kubis, pupuk yang diberikan terdiri dari petroganik, phonska, dan urea, sedangkan pada tanaman cabai dan kentang, pemberian pupuk menggunakan kombinasi pupuk kandang dan phonska. Analisis dan interpretasi data dilakukan di Divisi Penginderaan Jauh dan Informasi Spasial, Departemen Ilmu Tanah dan Sumberdaya Lahan, Fakultas Pertanian, IPB University.



Gambar 1 Peta lokasi penelitian

### Alat dan Bahan

Alat yang digunakan adalah *Drone DJI Inspire 1* (SZ DJI Technology Co., Ltd.) yang digunakan untuk mengambil citra UAV, sensor *Parrot Sequoia* (Parrot Inc., France) untuk menangkap citra drone multispektral, iPad Air 2 yang sudah terinstall *Litchi for DJI Drones* untuk mempermudah perencanaan terbang, dan *Global Positioning System* (GPS) untuk menentukan koordinat titik sampel pengamatan hortikultura. Pengolahan data menggunakan seperangkat komputer yang dilengkapi dengan beberapa *software*, yaitu QGIS 3.10.6-A Coruña, Agisoft Metashape 2.1.4, dan Microsoft Excel 2021. Bahan penelitian yang digunakan merupakan data primer berupa data observasi lapangan dan citra UAV akuisisi 6 November 2022.

### Pengambilan Data Lapangan

Persiapan pengambilan data dilakukan dengan memulai perencanaan misi terbang menggunakan aplikasi *Litchi for DJI Drones* yang sudah terpasang di iPad. Perencanaan terbang dibuat dengan *sidelap* dan *overlap* masing-masing 80%. Langkah berikutnya memastikan kondisi UAV dan memasang sensor multispectral *Parrot Sequoia* dengan bagian sensor utama Parrot Sequoia ada di bawah UAV dan dalam posisi horizontal, lalu menghubungkan sensor utama dengan sumber daya (*power bank*). Setelah pemasangan, melakukan pengujian di darat dan memastikan sensor terhubung dengan baik. Setelah itu, menghubungkan UAV dengan aplikasi *Litchi for DJI Drones*. Akuisisi data dilaksanakan pukul 09.00 – 12.00 WIB ketika intensitas cahaya matahari tidak terlalu terik

dan diambil dari ketinggian 50 meter di atas permukaan tanah untuk menghindari rintangan terbang.

### Pengolahan Citra UAV

Pengolahan citra UAV dimulai dengan pembuatan mosaik citra UAV yang merupakan proses penggabungan dua atau lebih citra yang saling bertampalan dan disusun menjadi kesatuan yang berkesinambungan. Pembuatan mosaik citra menggunakan *software* Agisoft Metashape 2.1.4 melalui tahap *add photos* yang dilakukan dengan memasukkan foto ke dalam *software*, *align photos* digunakan untuk menentukan titik mana yang merupakan termasuk ke dalam gambar, *build mesh* mengacu pada proses memecah ruang tiga dimensi menjadi bagian yang lebih kecil dan lebih mudah dikelola, *build DEM* merupakan model digital dalam format raster/grid, *build orthomosaic* melakukan perbaikan kesalahan geometris menggunakan data DEM sehingga dapat digunakan untuk kepentingan pemetaan, dan *export orthomosaic* yang bertujuan untuk menyimpan hasil orthomosaic.

### Analisis Karakteristik Spektral

Penentuan area sampel penutupan/penggunaan lahan pada citra UAV dilakukan melalui interpretasi visual citra yang dipandu oleh data titik observasi objek di lapangan. Satu area sampel mewakili satu kelas penutupan/penggunaan lahan. Sejumlah sampel dikumpulkan untuk mewakili setiap kelas dari 11 kelas penutupan/penggunaan lahan, yaitu mulsa, tanaman pisang, tanah, jalan, tanaman kentang berumur 40 hari setelah tanam (hst), tanaman tomat (15 hst), rumput, tanaman kubis (33 hst), tanaman wortel, tanaman cabai (35 hst), dan



bawang merah (33 hst). Total jumlah sampel diambil untuk 11 kelas penutupan/penggunaan lahan adalah 73 poligon yang dibuat dengan menyesuaikan bentuk penutupan/penggunaan lahan. Kemudian, 70% digunakan untuk membangun model (data latih) dan 30% untuk validasi hasil (data validasi). Proses ekstraksi nilai rata-rata, minimum, maksimum, dan standar deviasi masing-masing sampel dilakukan menggunakan QGIS 3.10.6-A Coruña dengan fitur *zonal statistics*. Selanjutnya, dibuat kurva karakteristik spektral dalam nilai *digital number* (DN) untuk setiap kelas penutupan lahan. Sebaran area sampel ditunjukkan pada Gambar 2 dengan poligon berwarna kuning.

### Klasifikasi *k-Nearest Neighbor*

Klasifikasi citra UAV multispektral dengan k-NN dilakukan pada QGIS 3.10.6-A Coruña dengan *plugin* Dzetsaka. Algoritma ini mengklasifikasikan piksel-piksel berdasarkan jaraknya ke data latih. Penentuan jarak dihitung dengan *euclidean distance* antara vektor data baru dan semua vektor data latih. Kemudian mengidentifikasi jumlah (*k*) tetangga terdekatnya dan data baru diklasifikasikan ke kelas mayoritas tetangga terdekat. Dalam penentuan jarak (*d*), di mana *i* merepresentasikan variabel data dan *n* adalah dimensi data, jarak antara sampel data ( $x_i$ ) dan data uji ( $y_i$ ) dihitung sebagai berikut:

$$d_i = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

### Klasifikasi *Minimum Distance Classification*


Klasifikasi dilakukan dengan menggunakan *plugin* *Semi-Automatic Classification* (SCP) pada QGIS 3.10.6-A Coruña. Algoritma ini dilakukan berdasarkan jarak minimum dari nilai rata-rata data training ke nilai yang ada di setiap piksel pada citra. Nilai rata-rata setiap kelas dengan jarak yang paling terdekat akan ditetapkan ke dalam kelas tersebut.. Untuk mengukur jarak kedekatan (*d*) antara sampel data  $x_i$  dan data uji  $y_i$  dalam ruang dimensi-*n*, dengan *i* sebagai indeks variabel data, formula yang digunakan adalah sebagai berikut:

$$d_i = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

Perbedaan kedua algoritma klasifikasi disebabkan oleh perbedaan pendekatan algoritma dan sensitivitas terhadap parameter tertentu, seperti ukuran *k* dan metrik jarak. k-NN lebih rentan terhadap pengaruh ukuran sampel yang kecil yang dapat memengaruhi hasil klasifikasi. Sebaliknya, MDC cenderung kurang mampu menangkap variasi lokal dalam data (Gou *et al.*, 2019).

### Uji Akurasi Klasifikasi

Pengujian akurasi dilakukan untuk mengevaluasi tingkat kesalahan klasifikasi pada data validasi. Nilai akurasi yang dapat diterima menurut standar USGS (2019), adalah di atas 85%. Hasil dari pengujian akurasi klasifikasi dinyatakan dalam *overall accuracy* (OA) atau akurasi keseluruhan, yang menunjukkan persentase piksel yang diklasifikasikan dengan benar dibandingkan dengan total sampel yang digunakan dalam pengujian. Dengan kata lain, OA menggambarkan seberapa baik model klasifikasi mengklasifikasikan piksel secara tepat ke dalam kelas yang sesuai.



Gambar 2 Sebaran sampel penelitian


## HASIL DAN PEMBAHASAN

### Analisis Karakteristik Sampel


Pola spektral vegetasi menunjukkan pola yang berbeda dibandingkan dengan non vegetasi, terutama pada *band* tampak mata (RGB) dan inframerah dekat seperti yang terlihat di Gambar 3. Vegetasi menyerap lebih banyak cahaya tampak mata dan memantulkan lebih banyak Cahaya inframerah. Pola spektral vegetasi khususnya tanaman hortikultura, dipengaruhi oleh komposisi spesies, orientasi dan struktur daun, kerapatan area daun, serta kemampuan daun untuk memantulkan dan mentransmisikan cahaya (Feilhauer *et al.*, 2017). Sementara itu, objek non hortikultura seperti tanah atau permukaan keras memiliki pola yang lebih konsisten tanpa puncak pada *band* inframerah (Huete *et al.*, 1985).

Berdasarkan Gambar 4, nilai DN tanaman hortikultura pada *band* hijau dan merah cenderung rendah, tetapi nilai DN pada *band* hijau sedikit lebih tinggi daripada *band* merah. Tanaman memantulkan lebih banyak cahaya hijau, sementara cahaya merah lebih banyak diserap oleh klorofil untuk proses fotosintesis (Wiratmoko *et al.*, 2016).

Pola spektral tanaman dipengaruhi oleh karakteristik daun yang meliputi orientasi dan struktur kanopi daun. Bagian yang dipantulkan berbeda tergantung dari pigmen daun, ketebalan daun, komposisi, dan kandungan air di dalam jaringan daun. Selain itu, umur tanaman juga dapat memengaruhi pola spektral. Hal ini terlihat pada tanaman tomat yang memiliki pola reflektan yang cenderung berbeda dibandingkan tanaman hortikultura lainnya. Umur tanaman tomat yang masih muda (15 hst) memengaruhi pola reflektan. *Band* hijau akan diserap dalam jumlah yang lebih sedikit, sehingga menyebabkan peningkatan dalam reflektansi pada gelombang ini. Pola spektral tanaman menunjukkan peningkatan tajam dari *band* tepi merah menuju inframerah dekat. Guo *et al.* (2016) menjelaskan bahwa cahaya pada *band* tepi merah mampu menembus lebih dalam ke tajuk tanaman, menyebabkan berkurangnya penyerapan cahaya oleh klorofil dan memantulkan lebih banyak cahaya tersebut. *Band* tepi merah yang merupakan transisi antara penyerapan cahaya merah oleh klorofil dan pantulan inframerah dekat oleh struktur jaringan daun, menyediakan informasi penting mengenai pertumbuhan dan status nitrogen pada tanaman.



Gambar 3 Karakteristik sampel terhadap *band* citra UAV

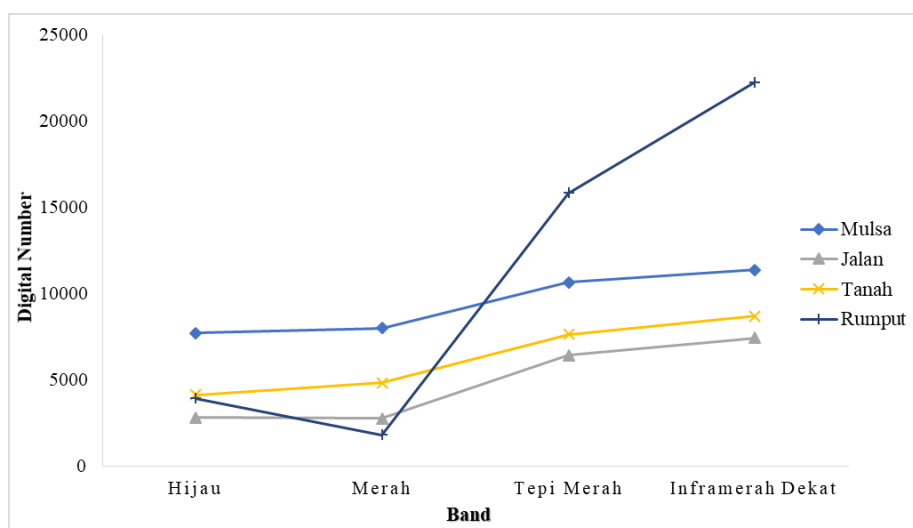


Gambar 4 Karakteristik sampel hortikultura terhadap *band* citra UAV

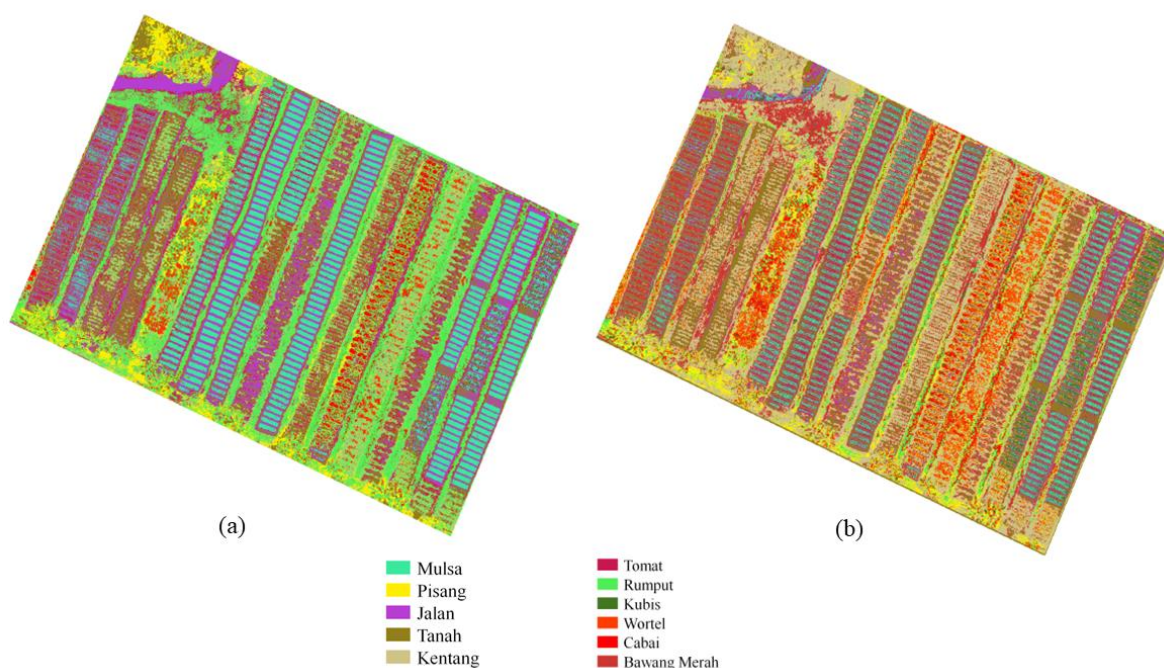
Pola spektral objek non-hortikultura, seperti jalan, mulsa, rumput, dan tanah, memperlihatkan disajikan pada Gambar 5. Tren peningkatan nilai DN secara konsisten pada *band* hijau, merah, tepi merah, dan inframerah dekat tanpa puncak. Dengan kata lain pada non-hortikultura tidak ditemukan penurunan nilai DN yang signifikan. Mulsa berwarna perak diketahui efektif memantulkan radiasi matahari, sehingga berdampak pada penurunan suhu tanah dan optimalisasi proses fotosintesis (Ismadi *et al.*, 2021; Hidayat *et al.*, 2018). Lebih lanjut, pola spektral tanah sangat dipengaruhi oleh karakteristik tanah itu sendiri, seperti jenis, komposisi, dan warna (Kataev *et al.*, 2024; Cheng *et al.*, 2008), yang menyebabkan variasi pola pantulan pada gelombang cahaya tampak dan inframerah dekat.

### Klasifikasi dengan Metode k-NN dan MDC

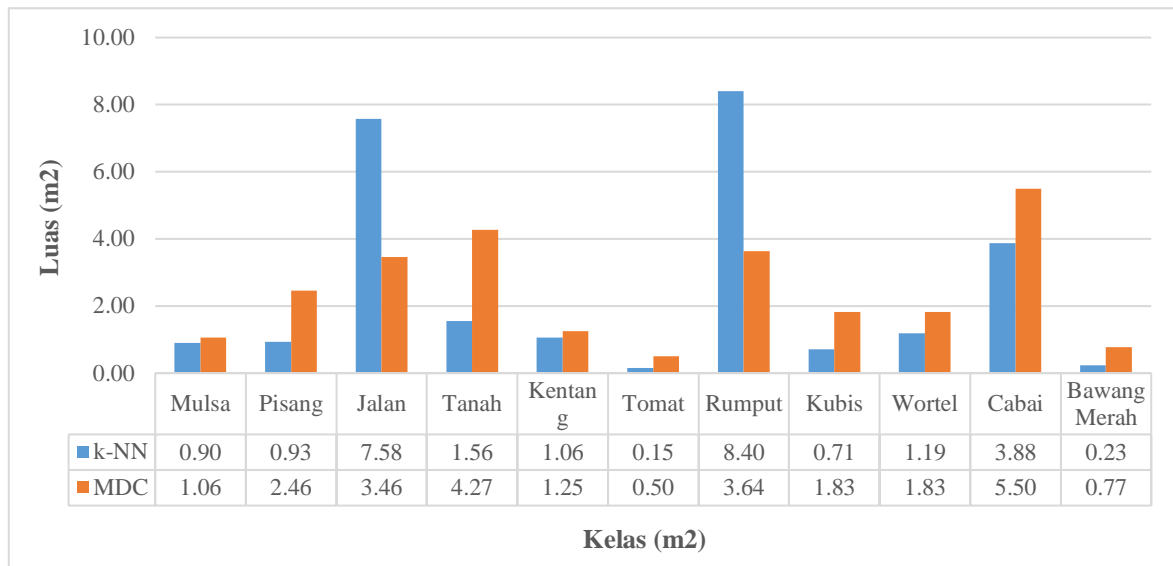
Analisis klasifikasi citra UAV (Gambar 6) menunjukkan bahwa metode k-NN memberikan akurasi keseluruhan yang lebih baik (89.37%) dibandingkan dengan MDC (51.48%). Luas area tiap kelas yang dihasilkan dari klasifikasi menggunakan metode k-NN dan MDC berbeda (Gambar 7). Pada hasil klasifikasi dengan k-NN, kelas dengan area terluas didominasi oleh rumput, jalan kerikil, dan cabai. Sebaliknya, pada klasifikasi MDC, kelas terluas adalah cabai, tanah, dan rumput. Luas area tanaman hortikultura selain cabai relatif lebih kecil dibandingkan dengan kelas non-hortikultura, yang disebabkan oleh ukuran petak yang sempit dan jarak antar petak yang berdekatan.



Gambar 5 Karakteristik sampel non hortikultura terhadap band citra UAV



Gambar 6 Hasil klasifikasi (a) k-NN; (b) MDC



Gambar 7 Luas hasil klasifikasi k-NN dan MDC

### Uji Akurasi Klasifikasi

Uji akurasi hasil klasifikasi dilakukan untuk menguji tingkat akurasi peta yang dihasilkan dari proses klasifikasi. Sampel yang digunakan pada uji akurasi adalah sampel yang berbeda dengan data *training*, sehingga keakuratan uji akurasi dapat diterima. Mengacu pada pernyataan Sutanto (2013), klasifikasi dengan akurasi keseluruhan di bawah 80% idealnya diulang hingga tiga kali dengan penentuan kelas contoh yang berbeda. Meskipun demikian, penelitian ini tetap melaporkan hasil akhir setelah proses *re-sampling* dan klasifikasi ulang, yang menghasilkan nilai OA 89.37% untuk k-NN dan 51.48% untuk MDC.

Evaluasi ketelitian klasifikasi juga dilakukan dengan membandingkan referensi lapangan dengan hasil prediksi klasifikasi menurut kelas penutupan/penggunaan lahan seperti yang disajikan pada Tabel 1 dan Tabel 2. *User's accuracy* (UA) mencerminkan proporsi piksel yang

diklasifikasikan dengan benar sesuai dengan kondisi di lapangan dan menunjukkan kemampuan algoritma untuk memprediksi piksel secara tepat. *Producer's accuracy* (PA) menunjukkan probabilitas piksel yang benar diklasifikasikan ke dalam kelas yang sesuai, dan merepresentasikan potensi kesalahan kelalaian dalam klasifikasi. Berdasarkan matriks kesalahan k-NN (Tabel 1), nilai UA tertinggi di antara tanaman hortikultura adalah wortel, yaitu 94.49% dan nilai UA terendah pada tomat yaitu sebesar 76.00%. Sementara nilai *Producer's Accuracy* (PA) tertinggi adalah kubis dengan nilai 96.23% dan nilai PA terendah adalah bawang merah yaitu 54.48%. Tabel 2 menyajikan matriks kesalahan MDC yang menunjukkan nilai UA tertinggi adalah kentang (66.92%) dan terendah adalah tomat (0.00%). Sementara nilai PA yang tertinggi adalah cabai (71.91%) dan terendah adalah tomat (0.00%). Kelas tomat konsisten memiliki akurasi yang 0% karena salah klasifikasi ke mulsa.

Tabel 1. Matriks kesalahan k-NN

Referensi	Prediksi											Total	PA (%)
	1	2	3	4	5	6	7	8	9	10	11		
1	54	0	4	0	0	5	0	0	0	0	0	63	85.71
2	0	56	0	0	1	0	27	5	0	17	0	106	52.83
3	0	0	605	1	0	0	0	0	0	0	0	606	99.83
4	0	0	49	91	0	0	0	0	0	0	0	140	65.00
5	0	0	0	0	113	0	40	0	6	0	1	160	70.63
6	0	0	1	0	0	19	0	0	0	0	1	21	90.48
7	0	6	0	0	11	0	528	0	0	7	0	552	95.65
8	0	2	0	0	0	0	0	51	0	0	0	53	96.23
9	0	0	0	0	1	0	4	0	120	23	0	148	81.08
10	0	0	0	0	0	0	38	0	1	260	0	299	86.96
11	0	0	0	0	1	1	12	0	0	0	17	31	54.84
Total	54	64	659	92	127	25	649	56	127	307	19	2179	
UA (%)	100.00	87.50	91.81	98.91	88.98	76.00	81.36	91.07	94.49	84.69	89.47		

Keterangan: 1 = Mulsa, 2 = Pisang, 3 = Jalan, 4 = Tanah, 5 = Kentang, 6 = Tomat, 7 = Rumput, 8 = Kubis, 9 = Wortel, 10 = Cabai, 11 = Bawang Merah



Tabel 2. Matriks kesalahan MDC

Referensi	Prediksi											Total	PA (%)
	1	2	3	4	5	6	7	8	9	10	11		
1	35	0	3	0	0	13	0	8	0	0	4	63	55.56
2	0	36	0	0	0	0	11	28	4	27	0	106	33.96
3	61	0	345	41	0	0	0	158	0	0	1	606	56.93
4	0	0	46	88	0	0	0	0	0	0	6	140	62.86
5	0	9	0	0	87	0	4	0	54	6	0	160	54.38
6	3	0	1	0	1	0	0	0	0	0	16	21	0.00
7	0	57	0	0	31	0	386	0	5	73	0	552	69.93
8	0	4	0	0	0	0	0	49	0	0	0	53	92.45
9	0	16	0	0	0	0	0	21	19	92	0	148	12.84
10	0	55	0	0	0	0	8	7	14	215	0	299	71.91
11	0	0	0	0	11	0	0	0	0	0	20	31	64.52
Total	99	177	395	129	130	13	409	271	96	413	47	2179	
UA (%)	35.35	20.34	87.34	68.22	66.92	0.00	94.38	18.08	19.79	52.06	42.55		

Keterangan: 1 = Mulsa, 2 = Pisang, 3 = Jalan, 4 = Tanah, 5 = Kentang, 6 = Tomat, 7 = Rumput, 8 = Kubis, 9 = Wortel, 10 = Cabai, 11 = Bawang Merah

Pendekatan k-NN dalam klasifikasi hortikultura dan nonhortikultura memiliki nilai OA yang lebih tinggi (89.37%) daripada pendekatan MDC yang hanya mampu mengelompokkan piksel dengan benar sebesar 51.48%. Rata-rata nilai UA dan PA dari pendekatan k-NN juga lebih tinggi daripada pendekatan MDC, yaitu 89.48% dan 79.82% untuk k-NN dan 45.91% dan 52.30 untuk MDC. Hal ini menunjukkan bahwa pendekatan klasifikasi k-NN lebih handal dalam identifikasi hortikultura dan menghasilkan prediksi yang baik secara keseluruhan dibandingkan dengan MDC. Hal ini bisa dimengerti karena pendekatan k-NN mempertimbangkan pengaruh beberapa titik data yang berdekatan dan menentukan kelas penutupan/penggunaan lahan berdasarkan kelas mayoritas di antara k tetangga terdekat (Naufal *et al.*, 2021; Iswanto *et al.*, 2022), yang berpotensi menghasilkan prediksi yang lebih kuat dan akurat, terutama saat menangani data yang kompleks atau tidak jelas. Di sisi lain, MDC hanya bergantung pada jarak ke rata-rata kelas, yang berpotensi rentan terhadap pencilaan atau representasi batas kelas yang tidak akurat.

## SIMPULAN

Respon spektral tanaman hortikultura untuk *band* merah cenderung lebih rendah daripada *band* hijau pada citra UAV multispektral karena diserap oleh klorofil untuk proses fotosintesis. Respon spektral meningkat tajam dari *band* tepi merah hingga inframerah dekat karena berkurangnya penyerapan oleh klorofil dan pantulan tinggi oleh struktur jaringan daun pada *band* inframerah dekat. Pendekatan klasifikasi k-NN menunjukkan performa lebih baik dalam memetakan tanaman hortikultura daripada pendekatan MDC dengan akurasi keseluruhan masing-masing 89.37% dan 51.48%.

## UCAPAN TERIMA KASIH

Para penulis menyampaikan ucapan terima kasih kepada Divisi Penginderaan Jauh dan Informasi Spasial, Departemen Ilmu Tanah dan Sumber Daya Lahan, Fakultas Pertanian, Institut Pertanian Bogor yang telah memfasilitasi penelitian ini.

## DAFTAR PUSTAKA

- Armitage, R., M. Kent, and R. Weaver. 2004. Identification of the spectral characteristics of British semi-natural upland vegetation using direct ordination: a case study from Dartmoor, UK. *International Journal of Remote Sensing*, 25: 3369 - 3388.
- [BPS] Badan Pusat Statistik. 2022. *Distribusi Perdagangan Komoditas Cabai Merah Indonesia 2022*. Jakarta.
- [BPS] Badan Pusat Statistik. 2022. *Produksi hortikultura sayur dan buah semusim provinsi Jawa Barat 2022*. Jawa Barat.
- Cao, J., Z. Zhang, F. Tao, L. Zhag, Y. Luo, J. Zhang, J. Han, and J. Xie. 2021. Integrating Multi-source Data for Rice Yield Prediction Across China Using Machine Learning and Deep Learning Approaches. *Agricultural and Forest Meteorology*, 297: 108275.
- Chen, F., W. Zhang, Y. Song, L. Liu, and C. Wang. 2023. Comparison of Simulated Multispectral Reflectance among Four Sensors in Land Cover Classification. *Remote. Sens.*, 15(2023): 2373.
- Cheng, J., Z. Shi, and H. Li. 2008. Observation and Simulation of Bi-Directional Spectral Reflectance on Different Type of Soils. *Spectroscopy and Spectral Analysis*, 28(5): 1007-1011.
- Dulam, F., P. Solanki, M. Yadav, K.V. Pandey, R. Rajput, M. Kumar, A.P. Singh, and S. Srishtty. 2025. Applications of remote sensing in horticulture: a review. *Plant Archives*, 25: 2552-2561
- Feilhauer, H., B. Somer, and S. Linden. 2017. Optical trait indicators for remote sensing of plant species composition: Predictive power and seasonal variability. *Ecological Indicators*, 73: 825-833.
- Guo, B.B., S.L. Qi, Y.R. Heng, J.Z. Duan, H.Y. Zhang, Y.P. Wu, W. Feng, Y.X. Xie, and Y.J. Zhu. 2016. Remotely assessing leaf N uptake in winter wheat based on canopy hyperspectral red-edge absorption. *European Journal of Agronomy*, 82: 113-124.
- Hidayat, Y.S., D. Efendi, dan Sulassih. 2018. Karakterisasi morfologi beberapa genotype kentang (*Solanum*



- tuberosum* L.) yang dibudidayakan di Indonesia. *Comm. Horticulturae J.*, 2(1): 28-34.
- Huete, A., R. Jackson, and D. Post. 1985. Spectral response of a plant canopy with different soil backgrounds. *Remote Sensing of Environment*, 17(1): 37-53.
- Ismadi, N.I. Yani, Rosninan, and M. Nazaruddin. 2021. Pengaruh jenis mulsa dan aplikasi pupuk organik cair terhadap pertumbuhan dan hasil tanaman kentang (*Solanum tuberosum* L.). *Jurnal Agrium.*, 18: 80-87.
- Iswanto, I., T. Tulus, and P. Poltak. 2022. Comparison of feature selection to performance improvement of k-nearest neighbor algorithm in data classification. *Jurnal Teknik Informatika (Jutif)*, 3(6): 1709-1716.
- Kataev, M.Y., E.Y. Kartashov, and I.B. Sorokin. 2024. Determination of soil color characteristics using RGB images. In *Ecological Aspects of Soil and Land Preservation*, Pp. 225-251.
- Lillesand, T.M., R.W. Kiefer, and J. Chipman. 2015. *Remote Sensing and Image Interpretation*. 7th Edition, Wiley, New York.
- Ma, S., Y. Zhou, P.H. Gowda, J. Dong, G. Zhang, V. Kakani, V. Wagle, L. Chen, K.C. Flynn, and W. Jiang. 2019. Application of the water-related spectral reflectance indices: A review. *Ecological Indicators*, 98: 68-79.
- Naufal, M.F., S.F. Kusuma, K.C. Tanus, R. Sukiwun, J. Kristiano, dan J.O. Lieyanto. 2021. Analisis Perbandingan Algoritma Klasifikasi Citra Chest X-ray untuk Deteksi Covid-19. *Teknika*, 10(2): 96-103.
- Oktaviani, A., dan Yarjohan. 2016. Perbandingan Resolusi Spasial, Temporal dan Radiometrik Serta Kendalanya. *Jurnal Enggano*, 1(2): 74-79.
- Ruwaimana, M., N. Atmaja, dan I.P. Yuda. 2017. Resolusi Spasial Optimum Pada Citra Drone Untuk Klasifikasi Spesies Mangrove Dengan Metode Maximum Likelihood. *Biota*, 2(2): 68-76.
- Sampurno, R.M., dan A. Thoriq. 2016. Klasifikasi penutupan lahan menggunakan citra landsat 8 operational land imager (OLI) di Kabupaten Sumedang. *Jurnal Teknotan*, 10(2): 61-70.
- Saputra, J., M. Kamal, dan P. Wicaksono. 2018. Pengaruh resolusi spasial citra terhadap hasil pemetaan kandungan hara nitrogen perkebunan karet. *Jurnal Penelitian Karet*, 36(1): 13-24.
- Sutanto. 2013. *Metode Penelitian Penginderaan Jauh*. Penerbit Ombak. Yogyakarta.
- Suwargana, N. 2013. Resolusi spasial, temporal dan spectral pada citra satelit landsat, spot, dan ikonos. *Jurnal Ilmiah WIDYA*, 1(2): 167-174.
- [USGS] United States Geological Survey. 2019. *Landsat 8 (L8) Data Users Handbook*. Edisi 5. Sioux Falls - Department of the Interior U.S. Geological Survey. United States (US).
- Wiratmoko, D., Hartono, dan S.H. Murti. 2016. Penghitungan indeks vegetasi citra worldview-2 untuk estimasi produksi kelapa sawit. *J. Pen. Kelapa Sawit*, 24(3): 143-156.
- Zhang, C., H. Ren, X. Dai, Q. Qin, J. Li, T. Zhang, Y. Sun. 2019. Spectral characteristics of copper-stressed vegetation leaves and further understanding of the copper stress vegetation index. *International Journal of Remote Sensing*, 40: 4473-4488.