

KLASIFIKASI BERBASIS PIKSEL UNTUK IDENTIFIKASI DAN PEMETAAN GULMA PADA LAHAN PADI SAWAH MENGGUNAKAN CITRA DRONE MULTISPEKTRAL DAN PEMBELAJARAN MESIN

Pixel-Based Classification for Weed Identification and Mapping in Rice Paddy Fields Using Multispectral Drone Imagery and Machine Learning

Muhammad Ardiansyah^{1,2,*}, Khursatul Munibah¹, Syakira Rizqa Zakiyah¹

¹ Departemen Ilmu Tanah dan Sumberdaya Lahan, Fakultas Pertanian, IPB University, Jl. Meranti – Kampus IPB Dramaga, Bogor, Jawa Barat 16680

² Center for Climate Risk and Opportunity Management in Southeast Asia and Pacific, IPB University, Jl. Pajajaran – Kampus IPB Baranangsiang, Bogor, West Java 16143

ABSTRACT

Weeds are one of the major constraints in lowland rice cultivation because they compete with rice plants for essential growth resources and may reduce crop productivity. Rapid and accurate weed identification and mapping are therefore needed to support effective weed management. This study aimed to analyze the reflectance patterns of weeds and rice plants and to evaluate the performance of pixel-based classification using Random Forest (RF) and Support Vector Machine (SVM) algorithms on multispectral Unmanned Aerial Vehicle (UAV) imagery. The study was conducted in a 1,300 m² lowland rice field in Ciherang Village, Ciomas District, Bogor Regency, using multispectral UAV imagery acquired on October 4, 2023, before weed cleaning, and October 13, 2023, after weed cleaning. The imagery consisted of green, red, red-edge, and near-infrared (NIR) bands. Pixel samples representing weed and non-weed classes, including rice, soil, and water bodies, were selected using purposive sampling. The pixel data were then divided into training and validation datasets at a 70:30 ratio and classified using RF and SVM with default parameters in the DZetsaka plugin. The results showed that weeds generally had higher reflectance values than rice plants, particularly in the red-edge and NIR bands, providing spectral separability that could be exploited for pixel-based classification. RF achieved 100% Overall Accuracy (OA), User's Accuracy (UA), and Producer's Accuracy (PA) on both observation dates. SVM achieved an OA of 100% on October 4, 2023, which decreased to 92.13% on October 13, 2023, with a PA of 81.65% for the weed class. Weed area estimates also differed between the two algorithms, with the average weed area estimated by RF decreasing from 5.75% to 2.50%, while that estimated by SVM decreased from 3.06% to 2.76% after weed cleaning. These findings indicate that multispectral UAV imagery combined with pixel-based classification can be used to identify and map weeds in lowland rice fields, with RF showing more consistent performance than SVM under the conditions of this study.

Key words: multispectral UAV, random forest, support vector machine, weeds

ABSTRAK

Gulma merupakan salah satu kendala dalam budidaya padi sawah karena dapat berkompetisi dengan tanaman padi dalam memperoleh sumber daya tumbuh dan berpotensi menurunkan produktivitas. Identifikasi dan pemetaan gulma secara cepat dan akurat diperlukan untuk mendukung pengelolaan gulma secara efektif. Penelitian ini bertujuan menganalisis pola reflektansi gulma dan tanaman padi serta mengevaluasi kinerja klasifikasi berbasis piksel menggunakan algoritma Random Forest (RF) dan Support Vector Machine (SVM) pada citra drone multispektral. Penelitian dilakukan pada lahan padi sawah seluas 1.300 m² di Desa Ciherang, Kecamatan Ciomas, Kabupaten Bogor, menggunakan citra drone multispektral yang diakuisisi pada 4 Oktober 2023 sebelum pembersihan gulma dan 13 Oktober 2023 setelah pembersihan gulma. Citra terdiri atas kanal hijau, merah, *red-edge*, dan *near-infrared* (NIR). Sampel piksel untuk kelas gulma dan non-gulma yang meliputi padi, tanah, dan badan air ditentukan secara *purposive sampling*. Data piksel selanjutnya dibagi menjadi data latih dan validasi dengan rasio 70:30 dan diklasifikasikan menggunakan RF dan SVM dengan parameter default pada plugin DZetsaka. Hasil menunjukkan bahwa gulma secara umum memiliki nilai reflektansi lebih tinggi dibandingkan tanaman padi, terutama pada kanal *red-edge* dan NIR, sehingga memberikan keterpisahan spektral yang dapat dimanfaatkan dalam klasifikasi berbasis piksel. RF menghasilkan nilai Overall Accuracy (OA), User's Accuracy (UA), dan Producer's Accuracy (PA) sebesar 100% pada kedua waktu pengamatan. SVM menghasilkan OA sebesar 100% pada 4 Oktober 2023 dan menurun menjadi 92.13% pada 13 Oktober 2023, dengan PA kelas gulma sebesar 81.65%. Estimasi luas gulma juga menunjukkan adanya perbedaan hasil antara kedua algoritma, dengan rata-rata luas gulma berdasarkan RF menurun dari 5.75% menjadi 2.50%, sedangkan SVM menurun dari 3.06% menjadi 2.76% setelah pembersihan. Hasil penelitian menunjukkan bahwa citra multispektral drone dan klasifikasi berbasis piksel mampu mengidentifikasi serta memetakan gulma pada lahan padi sawah, dengan RF menunjukkan kinerja yang lebih konsisten dibandingkan SVM pada kondisi penelitian ini.

Kata kunci: drone multispektral, gulma, *random forest*, *support vector machine*

* Penulis Korespondensi: Telp. +62811112973; Email: ardysaja@gmail.com

DOI: <http://dx.doi.org/10.29244/jitl.28.2.80-90>

PENDAHULUAN

Padi (*Oryza sativa* L.) merupakan salah satu komoditas strategis dalam sistem pangan Indonesia karena beras menjadi sumber pangan utama bagi sebagian besar penduduk. Tingginya ketergantungan masyarakat terhadap beras menjadikan peningkatan produktivitas padi sebagai salah satu aspek penting dalam menjaga ketahanan pangan nasional. Data Badan Pusat Statistik (BPS, 2024) menunjukkan bahwa rata-rata konsumsi beras per kapita per minggu di Indonesia meningkat dari 1.505 kg pada tahun 2020 menjadi 1.558 kg pada tahun 2023. Di sisi lain, produksi beras nasional pada tahun 2023 sekitar 30.9 juta ton lebih rendah dibandingkan dengan sekitar 31.5 juta ton pada tahun 2020. Kondisi tersebut menunjukkan adanya tantangan dalam memenuhi kebutuhan pangan yang terus meningkat sehingga diperlukan upaya untuk meminimalkan berbagai faktor yang dapat menurunkan produktivitas padi.

Salah satu faktor biologis yang menjadi kendala penting dalam budidaya padi adalah keberadaan gulma. Gulma dapat berkompetisi dengan tanaman padi dalam memperoleh cahaya, air, unsur hara, dan ruang tumbuh sehingga menghambat pertumbuhan dan berpotensi menurunkan hasil. Besarnya kehilangan hasil akibat gulma dipengaruhi oleh jenis gulma, kepadatan populasi, waktu kemunculan, serta lama periode kompetisi. Pada kondisi tertentu, keberadaan gulma selama periode kritis pertumbuhan tanaman dapat menyebabkan kehilangan hasil yang besar (Chauhan, 2020; Ghosh *et al.*, 2021). Selain kompetisi sumber daya, beberapa gulma juga menghasilkan senyawa alelopati yang dapat menghambat perkecambahan dan pertumbuhan tanaman budidaya (Serra Serra *et al.*, 2021). Oleh karena itu, identifikasi keberadaan dan distribusi gulma secara cepat dan akurat diperlukan sebagai dasar pengelolaan gulma yang efektif.

Pengendalian gulma secara konvensional umumnya dilakukan melalui penyiangan manual, mekanis, atau aplikasi herbisida secara seragam pada seluruh petak lahan. Pendekatan tersebut belum sepenuhnya mempertimbangkan distribusi gulma yang bersifat heterogen secara spasial. Aplikasi herbisida secara menyeluruh dapat meningkatkan penggunaan input dan biaya produksi apabila infestasi gulma hanya terdapat pada bagian tertentu dari lahan. Kondisi tersebut mendorong penerapan *precision weed management*, yaitu pengelolaan gulma berdasarkan informasi mengenai lokasi dan tingkat infestasi secara spasial sehingga tindakan pengendalian dapat diarahkan pada bagian lahan yang membutuhkan perlakuan (Ashraf dan Khan, 2020; Rai *et al.*, 2023). Pemetaan distribusi gulma dengan resolusi spasial tinggi menjadi salah satu komponen penting dalam mendukung pendekatan tersebut.

Perkembangan teknologi penginderaan jauh berbasis *Unmanned Aerial Vehicle* (UAV) atau drone memberikan peluang untuk memperoleh informasi spasial gulma secara cepat dan rinci. UAV mampu menghasilkan citra beresolusi spasial tinggi, fleksibel dalam waktu akuisisi, dan dapat digunakan pada skala petak hingga individu tanaman. Karakteristik tersebut memungkinkan perbedaan kondisi tanaman padi, gulma, tanah, air, dan objek lainnya direkam secara lebih detail dibandingkan citra resolusi menengah. Pemanfaatan UAV untuk pertanian presisi telah berkembang pada berbagai aplikasi, termasuk

pemantauan tanaman, klasifikasi vegetasi, deteksi gulma, dan penyusunan informasi untuk pengelolaan tanaman secara spesifik lokasi (Shahi *et al.*, 2023; Juwono *et al.*, 2023). Pada lahan padi, penelitian berbasis UAV juga telah menunjukkan bahwa informasi citra dapat digunakan untuk mengidentifikasi dan memetakan distribusi gulma secara spasial (Wang *et al.*, 2022).

Salah satu pendekatan yang dapat digunakan untuk mengolah citra UAV dalam identifikasi gulma adalah klasifikasi berbasis piksel (*pixel-based classification*). Pada pendekatan ini, piksel citra digunakan sebagai unit analisis dan setiap piksel diklasifikasikan ke dalam kelas tertentu berdasarkan karakteristik spektralnya. Nilai pantulan pada kanal spektral maupun variabel turunannya, seperti indeks vegetasi, dapat digunakan untuk membedakan tanaman padi, gulma, tanah, air, dan kelas lainnya. Resolusi spasial UAV yang tinggi memberikan keuntungan karena variasi kondisi vegetasi dapat direpresentasikan secara lebih rinci pada tingkat piksel. Dengan demikian, klasifikasi berbasis piksel dapat menghasilkan peta distribusi gulma secara langsung berdasarkan pola nilai spektral setiap piksel. Pendekatan ini juga telah digunakan dalam penelitian pemetaan gulma menggunakan citra UAV dengan algoritma pembelajaran mesin, termasuk SVM dan RF.

Klasifikasi berbasis piksel menghadapi tantangan ketika kelas yang akan dibedakan memiliki karakteristik spektral yang serupa. Tanaman padi dan gulma sama-sama merupakan vegetasi sehingga dapat memiliki respons spektral yang berdekatan, terutama pada fase pertumbuhan tertentu. Selain itu, citra UAV beresolusi sangat tinggi menghasilkan variasi nilai piksel yang dapat dipengaruhi oleh umur tanaman, kondisi kesehatan tanaman, pencahayaan, bayangan tajuk, kelembapan, serta keberadaan tanah dan air di antara tanaman. Kondisi tersebut menyebabkan hubungan antara karakteristik spektral dan kelas objek menjadi kompleks sehingga diperlukan algoritma yang mampu menangani hubungan nonlinier dan variasi data yang tinggi.

Dalam penelitian ini, klasifikasi berbasis piksel digunakan sebagai pendekatan, sedangkan *Random Forest* (RF) dan *Support Vector Machine* (SVM) digunakan sebagai algoritma klasifikasi. RF merupakan algoritma *ensemble learning* yang membangun sejumlah pohon keputusan menggunakan subset data dan variabel secara acak. RF mampu menangani hubungan nonlinier, sejumlah variabel prediktor, dan karakteristik data penginderaan jauh yang kompleks (Shahi *et al.*, 2022; Juwono *et al.*, 2023). Selain itu, RF dapat memberikan informasi peubah penting yang berguna untuk mengetahui kontribusi relatif setiap variabel terhadap proses klasifikasi. Sementara itu, SVM menentukan *hyperplane optimal* yang memaksimalkan margin antarkelas dan, melalui penggunaan fungsi kernel, mampu menangani pola pemisahan yang bersifat nonlinier. SVM juga efektif digunakan ketika jumlah sampel pelatihan relatif terbatas (Shahi *et al.*, 2022). Kedua algoritma tersebut memiliki mekanisme pembelajaran yang berbeda sehingga dapat menghasilkan keputusan klasifikasi yang berbeda pada karakteristik data yang sama. Perbedaan tersebut menjadikan RF dan SVM relevan untuk dibandingkan dalam mengevaluasi kemampuan klasifikasi berbasis piksel pada citra multispektral UAV untuk identifikasi gulma pada lahan padi sawah (Juwono *et al.*, 2023).

Sejumlah penelitian menunjukkan bahwa RF dan SVM memiliki potensi dalam identifikasi gulma berbasis citra UAV, tetapi algoritma terbaik dapat berbeda bergantung pada jenis tanaman, karakteristik gulma, sensor, fitur, dan kondisi lingkungan. Islam *et al.* (2021), misalnya, menunjukkan bahwa RF dan SVM masing-masing menghasilkan akurasi 96% dan 94% dalam deteksi gulma menggunakan citra UAV pada tanaman cabai. Pada lahan padi, penelitian berbasis UAV juga telah menggunakan beberapa algoritma pembelajaran mesin untuk menghasilkan peta distribusi gulma. Penelitian lain menggunakan citra UAV hiperspektral dan membandingkan RF, SVM, serta ANN untuk identifikasi gulma jajagoan pada lahan padi, dengan hasil yang menunjukkan bahwa penggunaan data multitemporal dapat meningkatkan kinerja klasifikasi (Zhang *et al.*, 2024). Sementara itu, Xu *et al.* (2023) menunjukkan bahwa SVM dapat memberikan hasil lebih baik dibandingkan RF ketika informasi spektral, tekstur, struktur, dan termal digabungkan dalam pemetaan gulma. Temuan tersebut menunjukkan bahwa kinerja algoritma tidak dapat digeneralisasi dan perlu dievaluasi berdasarkan karakteristik data dan lingkungan penelitian.

Perkembangan penelitian terbaru juga memperlihatkan semakin luasnya penggunaan *deep learning*, *object detection*, dan *semantic segmentation* untuk identifikasi gulma. Pendekatan tersebut mampu memanfaatkan informasi spasial dan konteks objek secara lebih kompleks, tetapi umumnya membutuhkan dataset berlabel yang lebih besar dan proses pemodelan yang lebih kompleks. Kajian terbaru menunjukkan bahwa masih terdapat tantangan terkait generalisasi model, ketersediaan dataset UAV, dan penerapan model pada kondisi lapangan yang beragam (Rai *et al.*, 2023). Oleh karena itu, klasifikasi berbasis piksel menggunakan algoritma pembelajaran mesin tetap relevan sebagai pendekatan yang relatif sederhana dan dapat dievaluasi secara langsung berdasarkan karakteristik spektral citra.


Berdasarkan uraian tersebut, kesenjangan penelitian terletak pada masih terbatasnya kajian yang secara khusus membandingkan kinerja RF dan SVM dalam klasifikasi berbasis piksel citra drone multispektral untuk identifikasi dan pemetaan gulma pada lahan padi sawah, khususnya pada kondisi agroekosistem tropis Indonesia. Penelitian terdahulu telah menunjukkan potensi UAV dan pembelajaran mesin untuk deteksi gulma, tetapi hasil kinerja algoritma masih bervariasi dan sebagian penelitian telah beralih pada pendekatan *deep learning* atau *object-based*. Oleh karena itu, diperlukan evaluasi komparatif RF dan SVM dalam pendekatan klasifikasi berbasis piksel untuk mengetahui algoritma yang lebih sesuai dalam membedakan padi, gulma, dan kelas penutup lahan lainnya.

Penelitian ini bertujuan untuk menganalisis pola reflektansi gulma dan tanaman padi serta mengevaluasi kinerja klasifikasi berbasis piksel menggunakan algoritma RF dan SVM pada citra drone multispektral. Hasil penelitian diharapkan dapat memberikan informasi mengenai algoritma yang efektif untuk pemetaan gulma berbasis citra UAV dan menjadi dasar pengembangan pengelolaan gulma secara lebih tepat sasaran dalam mendukung penerapan pertanian presisi.

BAHAN DAN METODE

Waktu dan Lokasi Penelitian

Penelitian dilaksanakan pada Agustus 2023 – Juni 2024, meliputi persiapan, pengumpulan data lapangan, akuisisi citra UAV, pengolahan citra, klasifikasi, dan analisis data. Penelitian dilakukan pada lahan padi sawah seluas $\pm 1,300 \text{ m}^2$ di Desa Ciherang, Kecamatan Ciomas, Kabupaten Bogor, Jawa Barat (Gambar 1). Akuisisi citra multispektral dilakukan pada 4 Oktober 2023, sebelum pembersihan gulma, dan 13 Oktober 2023, setelah pembersihan gulma.



Gambar 1. Lokasi penelitian

Kondisi dan Perlakuan Pertanaman

Lahan penelitian ditanami dua varietas padi, yaitu IR64 dan Ciherang, dengan tiga perlakuan pengelolaan air, yaitu penggenangan, pengeringan, dan praktik pengelolaan air yang umum diterapkan dalam budidaya padi setempat sebagai kontrol. Kombinasi varietas dan perlakuan tersebut menghasilkan enam petak, yaitu Ciherang Basah (CB), Ciherang Kering (CK), Ciherang Kontrol (CT), IR64 Basah (IB), IR64 Kering (IK), dan IR64 Kontrol (IT). Pembersihan gulma dilakukan dua kali selama periode pertanaman pada 17 September 2023 (35 HST) dan tanggal 7 Oktober 2023 (55 HST). Pemupukan menggunakan urea berdasarkan rekomendasi petani setempat dan diaplikasikan pada 12 dan 31 hari setelah tanam (HST).

Alat dan Bahan

Alat yang digunakan meliputi kamera multispektral *Parrot Sequoia* yang dipasang pada UAV DJI Inspire, telepon pintar yang dilengkapi GPS untuk pengambilan koordinat lapangan, serta komputer untuk pengolahan dan analisis data. Perangkat lunak yang digunakan adalah Pix4Dmapper untuk pemrosesan citra UAV dan QGIS versi 3.28 dengan plugin DZetsaka untuk pengolahan dan klasifikasi citra. Bahan penelitian berupa citra multispektral hasil akuisisi UAV pada 4 dan 13 Oktober 2023 dengan *ground sampling distance* 6.2 cm/px, data koordinat dan informasi kelas penutupan lahan hasil pengamatan lapangan.

Akuisisi dan Prapemrosesan Citra UAV

Akuisisi citra multispektral dilakukan menggunakan UAV DJI Inspire yang dilengkapi kamera multispektral *Parrot Sequoia* pada 4 Oktober 2023 (sebelum pembersihan gulma) dan 13 Oktober 2023 (setelah pembersihan gulma), pada pukul 10.00–13.00 WIB (Gambar 2). Kamera *Parrot Sequoia* memiliki empat kanal multispektral, yaitu hijau (530–570 nm), merah (640–680 nm), *red-edge* (730–740 nm), dan *near-infrared* (770–810 nm), serta kamera RGB dan sensor cahaya matahari untuk mendukung kalibrasi radiometrik.

Rute penerbangan direncanakan menggunakan *Mission Planner* (ArduPilot, RSSA) dengan endlap dan


sidelap masing-masing minimal 80%, kecepatan terbang 3 m per detik, dan ketinggian 30 m di atas permukaan tanah. Eksekusi penerbangan dilakukan menggunakan aplikasi *Flylitchi* (VC Technology Ltd., Hong Kong) mengikuti metode Okamoto *et al.* (2017). Sebelum penerbangan, dipasang *Ground Control Point* (GCP) pada lokasi penelitian menggunakan GPS Garmin 62s (Garmin, USA), serta dilakukan pengambilan citra panel kalibrasi reflektan. GCP digunakan untuk mendukung koreksi geometrik, sedangkan panel kalibrasi dan sensor cahaya matahari digunakan untuk mendukung koreksi radiometrik citra.

Akuisisi citra berlangsung sekitar 15 menit untuk mencakup area penelitian seluas $\pm 1,300 \text{ m}^2$ dan menghasilkan sekitar 350 citra untuk setiap sensor. Citra hasil akuisisi diproses menggunakan Pix4Dmapper versi 4.9.0 (Pix4D, Prilly, Switzerland) melalui proses *mosaicking* untuk menggabungkan citra yang saling bertampalan menjadi ortomosaik. Selanjutnya, ortomosaik direferensikan secara geometrik menggunakan QGIS versi 3.28 dengan memanfaatkan koordinat GCP sebagai titik pengikat.

Pengambilan Sampel Piksel dan Penyusunan Data Latih/Validasi

Identifikasi awal gulma dan non-gulma dilakukan menggunakan citra *False Color Composite* (FCC) dengan kombinasi kanal *near-infrared* (R), merah (G), dan hijau (B). Komposit tersebut digunakan untuk memperjelas perbedaan karakteristik vegetasi pada lahan sawah dan membantu penentuan sampel piksel yang selanjutnya digunakan sebagai input dalam klasifikasi berbasis piksel menggunakan algoritma RF dan SVM.

Pengambilan sampel piksel dilakukan menggunakan *purposive sampling* berdasarkan interpretasi visual citra dan kondisi objek di lapangan. Kelas klasifikasi terdiri atas gulma dan non-gulma, yaitu padi, tanah, dan badan air. Sampel ditentukan dalam bentuk poligon berukuran sekitar 3×3 , 4×4 , atau 5×5 piksel, disesuaikan dengan luasan dan kondisi masing-masing kelas pada citra. Secara keseluruhan, sebanyak 21 poligon sampel digunakan sebagai sumber pengambilan piksel dari citra multispektral yang diperoleh pada 4 Oktober 2023 dan 13 Oktober 2023 (Tabel 1 dan Tabel 2).



Gambar 2. Citra lokasi penelitian akuisisi 4 Oktober 2023 (kiri) dan 13 Oktober 2023 (kanan)

Tabel 1. Jumlah poligon dan piksel pada citra 04 Oktober 2023

No.	Kelas	Keterangan	Total Poligon Sampel	Jumlah Poligon 3x3	Jumlah Poligon 4x4	Jumlah Poligon 5x5	Jumlah Piksel Keseluruhan
1	Gulma	Gulma di petak IB	21	7	4	2	177
		Gulma di petak CC		1	1	6	175
2	Non Gulma	Tanah	21	0	0	6	150
		Badan Air		0	0	7	175
		Padi		0	0	8	200

Tabel 2. Jumlah poligon dan piksel pada citra 13 Oktober 2023

No.	Kelas	Keterangan	Total Poligon Sampel	Jumlah Poligon 3x3	Jumlah Poligon 4x4	Jumlah Poligon 5x5	Jumlah Piksel Keseluruhan
1	Gulma	Gulma di petak IB	21	10	6	5	311
2	Non Gulma	Tanah	21	0	0	5	125
		Badan Air		0	0	9	225
		Padi		0	0	6	150

Piksel yang diperoleh dari seluruh poligon sampel selanjutnya dibagi secara acak menjadi data latih dan data validasi dengan proporsi 70:30. Data latih digunakan untuk membangun model klasifikasi RF dan SVM, sedangkan data validasi digunakan untuk mengevaluasi hasil klasifikasi. Pembagian data dilakukan pada tingkat piksel sehingga setiap piksel menjadi unit pengamatan dalam proses pelatihan dan validasi model.

Analisis Pola Nilai Reflektansi

Analisis pola nilai reflektansi dilakukan untuk mengetahui karakteristik spektral padi dan gulma pada citra multispektral. Nilai reflektansi diekstraksi dari sampel piksel non-gulma dan gulma menggunakan fitur *Sample Raster Value* pada QGIS. Poligon sampel dikonversi menjadi titik sampel, kemudian nilai reflektansi pada masing-masing kanal multispektral diekstraksi berdasarkan lokasi titik tersebut. Nilai reflektansi yang diperoleh selanjutnya disimpan dalam format *.xls* dan dianalisis menggunakan *Microsoft Excel* untuk membandingkan pola respons spektral padi dan gulma pada setiap kanal.

Klasifikasi Berbasis Piksel dan Uji Akurasi

Klasifikasi citra dilakukan menggunakan pendekatan klasifikasi berbasis piksel dengan algoritma RF dan SVM yang tersedia pada plugin Dzetsaka. Data latih hasil penyusunan sampel piksel digunakan untuk membangun model RF dan SVM, kemudian model yang terbentuk diterapkan pada citra multispektral menggunakan fitur *Predict Model* untuk menghasilkan peta klasifikasi berbasis piksel. Kedua algoritma menggunakan data latih dan data validasi yang sama sehingga kinerja klasifikasi dapat dibandingkan pada kondisi data yang setara.

Klasifikasi RF menggunakan parameter *default* yang tersedia pada plugin Dzetsaka, meliputi *n_estimators* sebanyak 100, *criterion gini*, *max_depth* tidak terbatas, *min_samples_split* 2, *min_samples_leaf* 1, *max_features* *auto*, *bootstrap* aktif, *oob_score* tidak diaktifkan, dan *random_state* tidak ditentukan (Tabel 3). SVM menggunakan kernel *Radial Basis Function* (RBF) dengan *gamma* *auto*, nilai *C* sebesar 1, *tolerance* 0.001, dan jumlah iterasi maksimum tidak terbatas (Tabel 4).

Tabel 3. Parameter RF

Parameter	Nilai
<i>n_estimators</i>	100
<i>criterion</i>	Gini
<i>max_depth</i>	None (tidak terbatas)
<i>min_samples_split</i>	2
<i>min_samples_leaf</i>	1
<i>max_features</i>	Auto
<i>bootstrap</i>	TRUE
<i>oob_score</i>	FALSE
<i>random_state</i>	None

Tabel 4. Parameter SVM

Parameter	Nilai
<i>Kernel type</i>	RBF
<i>Gamma</i>	Auto
<i>C (Cost)</i>	1
<i>Tolerance</i>	0.001
<i>Max iterations</i>	-1 (tidak terbatas)
<i>Kernel type</i>	RBF

Evaluasi akurasi dilakukan dengan membandingkan kelas hasil prediksi terhadap kelas referensi pada data validasi menggunakan *confusion matrix*. Kinerja klasifikasi dievaluasi berdasarkan *Overall Accuracy* (OA), *Producer's Accuracy* (PA), *User's Accuracy* (UA), dan koefisien Kappa. Nilai akurasi tersebut digunakan untuk membandingkan kemampuan RF dan SVM dalam mengidentifikasi dan memetakan kelas gulma dan non-gulma.

Analisis Luas Sebaran Gulma per Petak Perlakuan

Luas sebaran gulma dihitung berdasarkan hasil klasifikasi citra multispektral yang telah melalui uji akurasi. Perhitungan luas setiap kelas dilakukan menggunakan fitur *Classification Report* pada *Postprocessing* plugin SCP. Fitur tersebut digunakan untuk menghitung luas area berdasarkan kelas hasil klasifikasi. Analisis difokuskan pada kelas gulma untuk memperoleh luas dan persentase sebarannya pada masing-masing petak perlakuan. Hasil perhitungan dibandingkan antara klasifikasi RF dan SVM untuk mengetahui perbedaan estimasi luas sebaran gulma. Selanjutnya, luas sebaran gulma dianalisis berdasarkan kondisi pengelolaan air, yaitu petak dengan kondisi basah, kering, dan praktek umum pengelolaan air.

HASIL DAN PEMBAHASAN

Pola Reflektansi Gulma dan Non-Gulma

Setiap objek vegetasi memiliki respons spektral yang berbeda terhadap panjang gelombang elektromagnetik akibat perbedaan kandungan pigmen, struktur internal daun, kandungan air, dan karakteristik tajuk. Pada vegetasi hijau, kanal merah terutama dipengaruhi oleh absorpsi klorofil, sedangkan peningkatan reflektansi pada wilayah red-edge dan near-infrared (NIR) berkaitan dengan perubahan absorpsi klorofil dan struktur internal jaringan daun. Penelitian berbasis citra UAV menunjukkan bahwa informasi red-edge, hijau, dan NIR dapat memberikan informasi penting mengenai kondisi vegetasi dan karakteristik klorofil. Zhu *et al.* (2020), misalnya, menunjukkan bahwa kanal red-edge dan hijau merupakan variabel spektral penting dalam estimasi kandungan klorofil tanaman menggunakan data UAV.


Gambar 3 menunjukkan pola nilai reflektansi gulma dan tanaman padi varietas Ciherang dan IR64 pada kondisi basah, kering, dan kontrol pada kanal hijau, merah, red-edge, dan NIR pada 4 dan 13 Oktober 2023. Secara umum, gulma menunjukkan nilai reflektansi yang lebih tinggi dibandingkan tanaman padi pada sebagian besar kanal dan perlakuan. Selain itu, reflektansi tanaman pada 13 Oktober cenderung lebih rendah dibandingkan 4 Oktober, yang diduga dipengaruhi oleh kondisi lahan yang lebih basah serta adanya kegiatan penyiangan gulma. Perbedaan tersebut menunjukkan bahwa karakteristik spektral dapat dimanfaatkan sebagai dasar untuk membedakan gulma dan padi dalam klasifikasi berbasis piksel.

Pada kanal hijau, reflektansi gulma di sawah dan galengan berada sekitar 0.10–0.12, sedangkan tanaman padi berada sekitar 0.06–0.08. Perbedaan tersebut dapat berkaitan dengan variasi kandungan pigmen dan struktur tajuk antarobjek. Pada kanal merah, sebagian besar objek menunjukkan reflektansi relatif rendah akibat absorpsi radiasi oleh klorofil. Namun, gulma sawah pada kondisi tertentu menunjukkan reflektansi hingga sekitar 0.48, lebih tinggi dibandingkan objek lainnya yang berada sekitar 0.33–0.43. Nilai tersebut menunjukkan adanya perbedaan respons spektral antara gulma dan padi, tetapi tidak secara langsung dapat diinterpretasikan sebagai indikator fotosintesis karena reflektansi juga dipengaruhi oleh kerapatan tajuk, struktur daun, kondisi pencahayaan, dan komposisi piksel.


Pada kanal *red-edge* dan NIR, seluruh objek menunjukkan peningkatan reflektansi dibandingkan kanal tampak. Gulma sawah memiliki reflektansi sekitar 0.41–0.45, sedangkan gulma pada galengan mencapai sekitar 0.38 dan 0.51. Peningkatan reflektansi NIR merupakan karakteristik umum vegetasi yang berkaitan dengan interaksi radiasi dengan struktur internal daun. Hasil ini memperlihatkan bahwa perbedaan struktur dan kondisi tajuk gulma dapat menghasilkan respons spektral yang berbeda dari tanaman padi. Wang (2021) juga menunjukkan bahwa kanal *red-edge* pada kamera multispektral UAV memberikan informasi yang berguna untuk membedakan dan mengevaluasi kondisi vegetasi, sekaligus menekankan pentingnya koreksi radiometrik dalam memperoleh informasi reflektansi yang konsisten.

Hasil penelitian ini sejalan dengan Yu *et al.* (2022) yang menggunakan citra multispektral UAV untuk identifikasi gulma pada lahan padi. Penelitian tersebut menunjukkan bahwa kombinasi informasi spektral, terutama kanal *red-edge*, hijau, dan NIR, mampu membedakan gulma dari padi, air, dan tanah dengan akurasi identifikasi 93.47% dan Kappa 0.859. Su *et al.* (2022) juga menunjukkan bahwa citra multispektral UAV efektif untuk menganalisis karakteristik spektral dan memetakan *blackgrass*, dengan RF menghasilkan akurasi pemetaan sekitar 93%. Penelitian tersebut menegaskan bahwa informasi spektral dari citra UAV dapat menjadi dasar yang kuat untuk pemetaan gulma secara spasial.

Karakteristik distribusi nilai reflektansi pada Gambar 4 memperlihatkan bahwa variasi pada kanal hijau dan merah relatif lebih sempit, sedangkan kanal red-edge dan NIR memiliki rentang nilai yang lebih lebar. Variasi tersebut dapat mencerminkan perbedaan kondisi fisiologis, struktur tajuk, kerapatan vegetasi, dan posisi daun terhadap sensor. Dengan demikian, kanal red-edge dan NIR memberikan informasi spektral yang potensial untuk membedakan gulma dan padi. Pola serupa juga terlihat pada data akuisisi UAV tanggal 13 Oktober 2023, meskipun secara umum nilai reflektansinya lebih rendah dibandingkan pengamatan pada 4 Oktober 2023. Temuan ini juga didukung oleh Zhu *et al.* (2020), yang menunjukkan bahwa informasi spektral pada skala UAV dapat menangkap variasi karakteristik vegetasi dan bahwa kinerja model dipengaruhi oleh jenis tanaman serta fase pertumbuhannya.



Gambar 3. Pola reflektansi gulma dan padi pada citra 04 Oktober 2023 (kiri) dan 13 Oktober 2023 (kanan)



Gambar 4. Sebaran nilai reflektan gulma dan non-gulma pada citra 04 Oktober 2023

Hasil Klasifikasi dan Akurasi Gulma dan Non-Gulma

Algoritma RF dan SVM diterapkan untuk memetakan gulma dan non-gulma pada citra 4 Oktober 2023 sebelum pembersihan dan 13 Oktober 2023 setelah pembersihan. Hasil klasifikasi pada Gambar 5 menunjukkan pola spasial gulma yang relatif serupa pada beberapa lokasi, tetapi terdapat perbedaan pada tingkat piksel. SVM cenderung menghasilkan kluster gulma yang lebih terfragmentasi, sedangkan RF menghasilkan pola yang relatif lebih teragregasi. Perbedaan tersebut dapat berkaitan dengan mekanisme pembentukan batas keputusan kedua algoritma. RF membentuk prediksi melalui ensemble pohon keputusan, sedangkan SVM menentukan batas pemisah optimal antarkelas melalui fungsi kernel.

Pada 4 Oktober 2023, gulma terutama teridentifikasi pada tepi petakan dan beberapa bagian sawah (Gambar 6). Setelah pembersihan pada 13 Oktober 2023, distribusi gulma pada bagian interior cenderung berkurang (Gambar 7), sementara beberapa gulma masih teridentifikasi di tepi petakan dan galengan. Resolusi spasial tinggi citra UAV memungkinkan variasi gulma pada skala petak diamati secara lebih rinci. Yu *et al.* (2022) menunjukkan bahwa citra UAV multispektral dapat digunakan untuk menghasilkan informasi spasial gulma pada lahan padi, sedangkan Zhang


et al. (2024) menunjukkan bahwa penggunaan data UAV multitemporal dapat meningkatkan kemampuan model dalam mengidentifikasi gulma dan memperbaiki kemampuan generalisasi dibandingkan penggunaan data satu waktu.

Berdasarkan Tabel 5, RF menghasilkan UA, PA, dan OA sebesar 100% pada kedua tanggal pengamatan. Hasil tersebut menunjukkan bahwa seluruh piksel pada data validasi berhasil diklasifikasikan sesuai kelas referensinya. Pada 4 Oktober 2023, confusion matrix menunjukkan 106 piksel gulma dan 150 piksel non-gulma seluruhnya diklasifikasikan dengan benar. Pada 13 Oktober 2023, sebanyak 91 piksel gulma dan 158 piksel non-gulma juga diklasifikasikan dengan benar.


SVM juga menghasilkan akurasi 100% pada 4 Oktober 2023. Namun, pada 13 Oktober 2023 OA menurun menjadi 92.13%. Kelas gulma memperoleh UA sebesar 98.89% dan PA sebesar 81.65%, sedangkan kelas non-gulma memperoleh UA sebesar 88.70% dan PA sebesar 99.37%. Nilai PA gulma yang lebih rendah menunjukkan bahwa sebagian piksel referensi gulma masih diklasifikasikan sebagai non-gulma. Sebaliknya, PA non-gulma yang tinggi menunjukkan bahwa sebagian besar piksel referensi non-gulma berhasil dikenali oleh SVM.

Tabel 5. Nilai akurasi klasifikasi gulma dan non-gulma


Kelas	RF							SVM						
	04 Oktober 2023			13 Oktober 2023				04 Oktober 2023				13 Oktober 2023		
	UA (%)	PA (%)	OA (%)	UA (%)	PA (%)	OA (%)	OA (%)	UA (%)	PA (%)	OA (%)	OA (%)	UA (%)	PA (%)	OA (%)
Gulma	100	100		100	100			100	100	100		98.89	81.65	
Non Gulma	100	100	100	100	100	100	100	100	100	100	100	88.70	99.37	92.13



Gambar 5. Hasil klasifikasi gulma dan non gulma



Gambar 6. Gulma pada petak sawah percobaan tanggal 03 Oktober 2023



Gambar 7. Gulma pada petak sawah percobaan tanggal 13 Oktober 2023

Penurunan akurasi SVM pada pengamatan kedua kemungkinan berkaitan dengan perubahan kondisi objek setelah pembersihan gulma. Ketika jumlah dan tutupan gulma berkurang, karakteristik spektral piksel gulma yang tersisa dapat menjadi lebih beragam dan memiliki kemiripan dengan padi atau objek permukaan lainnya. Zhang *et al.* (2024) menunjukkan bahwa perubahan waktu pengamatan merupakan faktor penting dalam identifikasi gulma pada sawah dan bahwa penambahan data multitemporal dapat meningkatkan OA, Kappa, serta kemampuan generalisasi model.

Akurasi RF sebesar 100% pada data validasi tidak secara langsung membuktikan terjadinya *overfitting*. Piksel yang berdekatan secara spasial dapat memiliki karakteristik spektral yang sangat mirip sehingga tingkat independensi antara *training* dan *validation* set dapat terbatas. Oleh karena itu, akurasi 100% lebih tepat disebut sebagai akurasi validasi yang sangat tinggi pada dataset penelitian. Selain itu, hasil penelitian ini menunjukkan pentingnya kualitas dan karakteristik data pelatihan dalam menentukan kinerja algoritma.. Dengan demikian, perbedaan kinerja RF dan SVM dalam penelitian ini tidak hanya berkaitan dengan algoritma, tetapi juga dengan tingkat keterpisahan spektral

kelas dan karakteristik sampel yang digunakan.

Luas Persebaran Gulma pada Lahan Sawah

Estimasi luas sebaran gulma berdasarkan hasil klasifikasi menunjukkan adanya perbedaan respons RF dan SVM terhadap perubahan kondisi lahan. Berdasarkan Tabel 6, rata-rata persentase luas gulma hasil SVM menurun dari 3.06% pada 4 Oktober menjadi 2.76% pada 13 Oktober, sedangkan RF menunjukkan penurunan yang lebih besar, yaitu dari 5.75% menjadi 2.50%. Secara umum, penurunan tersebut sesuai dengan perubahan kondisi lapangan setelah dilakukan pembersihan gulma.

Pada SVM, beberapa petak menunjukkan peningkatan luas gulma setelah pembersihan, antara lain CB dari 0.40% menjadi 0.98% dan IK dari 3.73% menjadi 10.11%. Sebaliknya, IB mengalami penurunan dari 2.89% menjadi 0.39%, sedangkan CC menurun dari 5.29% menjadi 0%. Pada RF, sebagian besar petak menunjukkan penurunan luas gulma, termasuk IK dari 14.74% menjadi 6.32% dan CC dari 6.82% menjadi 0%.

Tabel 6. Luas sebaran gulma pada setiap perlakuan berdasarkan hasil klasifikasi

Perlakuan	Persentase Luas Persebaran Gulma							
	SVM				RF			
	04-Okt-23		13-Okt-23		04-Okt-23		13-Okt-23	
	Luas (m ²)	Persentase (%)	Luas (m ²)	Persentase (%)	Luas (m ²)	Persentase (%)	Luas (m ²)	Persentase (%)
CB	0.44	0.40	1.24	0.98	0.79	0.72	1.51	1.2
IB	5.14	2.89	0.77	0.39	7.97	4.47	2.79	1.43
CK	12.77	5.17	12.56	4.83	15.08	6.10	14.32	5.5
IK	7.94	3.73	22.58	10.11	31.39	14.74	14.11	6.32
CC	3.56	5.29	0	0.00	4.59	6.82	0	0.00
IC	0.9	0.85	0.25	0.23	1.72	1.63	0.63	0.57
Rata-rata	5.12	3.06	6.23	2.76	10.26	5.75	5.56	2.50

Perbedaan estimasi luas tersebut menunjukkan bahwa pemilihan algoritma dapat memengaruhi hasil pemetaan spasial gulma. Pada petak IK, misalnya, RF menghasilkan penurunan luas gulma dari 14.74% menjadi 6.32%, sedangkan SVM menghasilkan peningkatan dari 3.73% menjadi 10.11%. Perbedaan tersebut dipahami sebagai konsekuensi dari perbedaan mekanisme pembentukan batas keputusan RF dan SVM terhadap distribusi nilai spektral.

Faktor lain yang perlu dipertimbangkan adalah resolusi spasial citra. Ubben *et al.* (2024) menunjukkan bahwa resolusi spasial merupakan faktor penting dalam pemetaan gulma berbasis UAV karena perubahan resolusi dapat memengaruhi kemampuan mendeteksi objek gulma berukuran kecil dan memengaruhi hasil estimasi spasial. Oleh karena itu, perbedaan luas gulma antar algoritma pada penelitian ini kemungkinan berkaitan dengan kemampuan masing-masing algoritma dalam mengklasifikasikan piksel gulma berukuran kecil dan piksel pada area peralihan antara gulma dan non-gulma.

Secara keseluruhan, citra multispektral UAV mampu memberikan informasi spasial gulma pada tingkat petak melalui klasifikasi berbasis piksel. RF menghasilkan akurasi validasi yang sangat tinggi pada kedua tanggal pengamatan dan menunjukkan kecenderungan perubahan luas gulma yang lebih konsisten dengan kondisi setelah pembersihan. SVM juga memberikan hasil yang baik, tetapi lebih sensitif terhadap perubahan karakteristik spektral pada pengamatan kedua. Hasil ini memperkuat potensi kombinasi citra multispektral UAV dan pembelajaran mesin untuk mendukung pemetaan gulma secara rinci dan pengelolaan gulma berbasis lokasi.

SIMPULAN DAN SARAN

Simpulan

Gulma dan tanaman padi (Ciherang dan IR64) menunjukkan perbedaan respons spektral pada kanal hijau, merah, *red-edge*, dan NIR. Gulma secara umum memiliki nilai reflektansi lebih tinggi dibandingkan tanaman padi, terutama pada kanal *red-edge* dan NIR, sehingga karakteristik spektral tersebut dapat digunakan sebagai dasar untuk membedakan gulma dan non-gulma pada citra multispektral UAV.

Klasifikasi berbasis piksel menggunakan RF dan SVM mampu memetakan gulma dan non-gulma pada lahan padi sawah. RF menghasilkan performa validasi tertinggi dengan OA, UA, dan PA sebesar 100% pada kedua waktu pengamatan, sedangkan SVM menghasilkan akurasi 100% pada 4 Oktober 2023 dan 92.13% pada 13 Oktober 2023. Hasil tersebut menunjukkan bahwa RF lebih konsisten dalam klasifikasi berbasis piksel pada kondisi penelitian ini, sementara SVM menunjukkan penurunan kemampuan klasifikasi setelah pembersihan gulma.

Saran

Penelitian selanjutnya disarankan mengembangkan klasifikasi gulma menggunakan pendekatan berbasis objek (*Object-Based Image Analysis/OBIA*) dengan memanfaatkan informasi spektral, bentuk, tekstur, dan

konteks spasial objek. Pendekatan tersebut diharapkan dapat mengurangi fragmentasi hasil klasifikasi berbasis piksel dan meningkatkan kemampuan membedakan gulma dari tanaman padi yang memiliki karakteristik spektral serupa. Perbandingan pendekatan berbasis piksel dan berbasis objek menggunakan algoritma RF dan SVM juga perlu dilakukan untuk menentukan pendekatan yang paling efektif dalam pemetaan gulma pada lahan padi sawah.

UCAPAN TERIMA KASIH

Penulis berterima kasih atas dukungan dari pendanaan skema riset fundamental BIMA 2023 serta Divisi Penginderaan Jauh dan Informasi Spasial, Departemen Ilmu Tanah dan Sumber Daya Lahan, Fakultas Pertanian, Institut Pertanian Bogor yang telah memfasilitasi penelitian.

DAFTAR PUSTAKA

- Ashraf, T., and Khan, Y. N. (2020). Weed density classification in rice crop using computer vision. *Computers and Electronics in Agriculture*, 175, 105590. <https://doi.org/10.1016/j.compag.2020.105590>.
- [BPS] Badan Pusat Statistik. (2024). *Statistik Indonesia: Statistical Yearbook of Indonesia Vol. 52*. Jakarta (ID): BPS-Statistics Indonesia.
- Chauhan, B. S. (2020). Grand challenges in weed management. *Frontiers in Agronomy*, 1, 3. <https://doi.org/10.3389/fagro.2019.00003>.
- Ghosh, A., Ankit, R. K. Singh, and O. N. Singh. 2021. Crop-weed competition in aerobic rice (*Oryza sativa*) – serious concern in nitrogen fertilizer management. *The Indian Journal of Agricultural Sciences*, 91(7): 985–989. <https://doi.org/10.56093/ijas.v91i7.115107>.
- Islam, N., Rashid, M. M., Wibowo, S., Xu, C.-Y., Morshed, A., Wasimi, S. A., Moore, S., and Rahman, S. M.. (2021). Early weed detection using image processing and machine learning techniques in an Australian chilli farm. *Agriculture*, 11(5), 387. <https://doi.org/10.3390/agriculture11050387>.
- Juwono, F. H., Wong, W. K., Verma, S., Shekhawat, N., Lease, B. A., and Apriono, C. (2023). Machine learning for weed-plant discrimination in agriculture 5.0: An in-depth review. *Artificial Intelligence in Agriculture*, 10, 13–25. <https://doi.org/10.1016/j.aiia.2023.09.002>.
- Okamoto, Y., McCarthy, C., Mahinda, A., Iskandar, W., Mishra, A. K., and Funakawa, S. (2017). Applicability of the Multicopter (Unmanned Aerial Vehicle) and Aerial Photograph in the Experiential Station, Kyoto Japan in International Symposium on Global Environmental Studies Education and Research in Asia and the 11th Inter-University Workshop on Education and Research Collaboration in the Indochina Region, Bangkok, Thailand, November 13-15, 2016.

- Rahaman, F., Juraimi, A. S., Rafii, M. Y., Uddin, K., Hassan, L., Chowdhury, A. K., Karim, S. M. R., Rini, B. Y., Yusuff, O., Bashar, H. M. K., and Hossain, A. (2022). Allelopathic potential in rice – a biochemical tool for plant defence against weeds. *Frontiers in Plant Science*, 13, 1072723. <https://doi.org/10.3389/fpls.2022.1072723>.
- Rai, N., Zhang, Y., Ram, B. G., Schumacher, L., Yellavajjala, R. K., Bajwa, S., and Sun, X. (2023). Applications of deep learning in precision weed management: A review. *Computers and Electronics in Agriculture*, 206, 107698. <https://doi.org/10.1016/j.compag.2023.107698>.
- Serra Serra, N., Shanmuganathan, R., and Becker, C. (2021). Allelopathy in rice: A story of momilactones, kin recognition, and weed management. *Journal of Experimental Botany*, 72(11), 4022–4037. <https://doi.org/10.1093/jxb/erab084>.
- Shahi, T. B., Xu, C. Y., Neupane, A., and Guo, W. (2022). Machine learning methods for precision agriculture with UAV imagery: A review. *Electronic Research Archive*, 30(12), 4277–4317. <https://doi.org/10.3934/era.2022218>.
- Shekhawat, K., Rathore, S. S., and Chauhan, B. S. (2020). Weed management in dry direct-seeded rice: A review on challenges and opportunities for sustainable rice production. *Agronomy*, 10(9), 1264. <https://doi.org/10.3390/agronomy10091264>.
- Su, J., Yi, D., Coombes, M., Liu, C., Zhai, X., McDonald-Maier, K., and Chen, W. H. (2022). Spectral analysis and mapping of blackgrass weed by leveraging machine learning and UAV multispectral imagery. *Computers and Electronics in Agriculture*, 192, 106621. <https://doi.org/10.1016/j.compag.2021.106621>.
- Ubben, N., Pukrop, M., and Jarmer, T. (2024). Spatial resolution as a factor for efficient UAV-based weed mapping—A soybean field case study. *Remote Sensing*, 16(10), 1778. <https://doi.org/10.3390/rs16101778>.
- Wang, C. (2021). At-sensor radiometric correction of a multispectral camera (RedEdge) for UAS vegetation mapping. *Sensors*, 21(24), 8224. <https://doi.org/10.3390/s21248224>.
- Xu, B., Meng, R., Chen, G., Liang, L., Lv, Z., Zhou, L., Sun, R., Zhaom F., and Yang, W. (2023). Improved weed mapping in corn fields by combining UAV-based spectral, textural, structural, and thermal measurements. *Pest Management Science*, 79(7), 2591–2602. <https://doi.org/10.1002/ps.7443>.
- Yu, F., Jin, Z., Guo, S., Guo, Z., Zhang, H., Xu, T., and Chen, C. (2022). Research on weed identification method in rice fields based on UAV remote sensing. *Frontiers in Plant Science*, 13, 1037760. <https://doi.org/10.3389/fpls.2022.1037760>.
- Zhang, Y., Yan, Z., Gao, J., Shen, Y., Zhou, H., W. Tang, Y. Lu, and Y. Yang. 2024. UAV imaging hyperspectral for barnyard identification and spatial distribution in paddy fields. *Expert Systems with Applications*, 255, 124771. <https://doi.org/10.1016/j.eswa.2024.124771>.
- Zhu, W., Sun, Z., Yang, T., Li, J., Peng, J., Zhu, K., Li, S., Gong, H., Lyu, Y., Li, B., and Liao, X. (2020). Estimating leaf chlorophyll content of crops via optimal unmanned aerial vehicle hyperspectral data at multi-scales. *Computers and Electronics in Agriculture*, 178, 105786. <https://doi.org/10.1016/j.compag.2020.105786>.