



Department of Digital Business

Journal of Artificial Intelligence and Digital Business (RIGGS)

Homepage: <https://journal.ilmudata.co.id/index.php/RIGGS>

Vol. 5 No. 2 (2026) pp: 23815-23822

P-ISSN: 2963-9298, e-ISSN: 2963-914X

Deteksi Biji-Bijian Familia Poaceae Menggunakan YOLOv8 Transfer Learning Berbasis Web

Fitra Maulana*, Tomi Tri Sujaka, Muhamad Azwar

Program Studi Ilmu Komputer, Fakultas Teknik, Universitas Bumigora

ryugen739@gmail.com, tomi.tri@universitasbumigora.ac.id, azwar@universitasbumigora.ac.id

Abstrak

Famili Poaceae mencakup berbagai komoditas pangan penting, seperti padi, jagung, gandum, oat, sorgum, barley, dan millet, yang memiliki karakteristik visual hampir serupa sehingga proses identifikasi manual rentan terhadap kesalahan. Penelitian ini bertujuan mengembangkan sistem deteksi biji-bijian Famili Poaceae berbasis web menggunakan algoritma YOLOv8 dengan pendekatan transfer learning. Penelitian menerapkan metode eksperimen yang meliputi pengumpulan dan pelabelan data, prapemrosesan, pembagian dataset, pelatihan model, evaluasi performa, serta implementasi sistem. Dataset terdiri atas 3.500 citra dari tujuh kelas, dengan masing-masing kelas berjumlah 500 citra, yang dibagi menjadi 70% data pelatihan, 15% data validasi, dan 15% data pengujian. Model dilatih menggunakan PyTorch dan Ultralytics YOLOv8 pada Google Colab Pro dengan GPU NVIDIA A100, ukuran citra 640×640 piksel, batch size 64, dan optimizer AdamW. Model terbaik kemudian diintegrasikan ke dalam aplikasi web menggunakan Streamlit agar pengguna dapat mengunggah citra atau menggunakan kamera secara langsung. Hasil pengujian menunjukkan nilai precision sebesar 71,6%, recall 73,2%, mAP50 75,7%, dan mAP50-95 46,9%. Kelas jagung memperoleh performa terbaik dengan mAP50 95,9%, sedangkan kelas padi memperoleh nilai terendah sebesar 64,5%. Sistem yang dikembangkan mampu mendeteksi tujuh jenis biji-bijian secara otomatis, cepat, dan mudah diakses, sehingga berpotensi membantu masyarakat, petani, dan penyuluh pertanian dalam proses identifikasi serta mendukung digitalisasi sektor pertanian.

Kata kunci: Famili Poaceae, Deteksi Objek, Transfer Learning, YOLOv8, Website

1. Latar Belakang

Famili poaceae merupakan kelompok tanaman pangan yang memiliki peran strategis dalam kehidupan masyarakat karena menjadi sumber utama pakan. Berbagai komoditas penting seperti padi (*Orzya sativa*), jagung (*Zea mays*), gandum (*Triticum astivum*), oat (*Avena sativa*), sorgum (*Sorgum bicolor*), barley (*Hordeum vulgere*), dan millet termasuk dalam famili ini dan banyak dimanfaatkan baik sebagai bahan pangan pokok maupun bahan industri pangan [1]. Berdasarkan observasi pada Balai Penyuluhan Pertanian (BPP) Kecamatan Plampang, komoditas famili Poaceae menjadi salah satu perhatian utama dalam kegiatan penyuluhan dan pendampingan petani, sehingga identifikasi yang akurat terhadap ragam biji-bijian ini menjadi kebutuhan penting. Namun demikian, proses identifikasi selama ini masih banyak dilakukan secara manual berdasarkan pengamatan visual dan pengalaman individu, sehingga membutuhkan waktu lama dan rentan terhadap kesalahan manusia (human error), khususnya pada jenis biji yang memiliki kemiripan bentuk, ukuran, dan warna [2]. Kondisi ini menjadi tantangan dalam kegiatan edukasi, penyuluhan pertanian, maupun proses identifikasi di sektor pangan karena hasil identifikasi yang diperoleh belum tentu konsisten.

Guna mengatasi keterbatasan tersebut, para peneliti terdahulu telah mengeksplorasi pemanfaatan *Artificial Intelligence* (AI) untuk melakukan identifikasi objek secara otomatis melalui citra digital. Salah satu algoritma yang banyak digunakan pada bidang deteksi objek adalah *You Only Look Once* (YOLO), yaitu algoritma berbasis *deep learning* yang mampu mendeteksi lokasi objek sekaligus mengklasifikasikan jenisnya dalam satu inferensi [3]. Perkembangan metode *deep learning* telah banyak dimanfaatkan untuk meningkatkan akurasi identifikasi objek berbasis citra. Beberapa penelitian menunjukkan bahwa algoritma YOLO mampu memberikan performa yang tinggi pada berbagai permasalahan deteksi objek. Abdillah menerapkan YOLO untuk klasifikasi biji jagung dan memperoleh tingkat akurasi yang tinggi [4], Prasetya menggunakan YOLOv8 pada klasifikasi kualitas buah jeruk dengan hasil yang sangat baik [5], sedangkan Suwela dan Hedriyadi berhasil menerapkan YOLOv8 untuk mendeteksi jenis sampah secara real-time [6]. Selain itu, Hidayah dan Kristian


menunjukkan bahwa penerapan transfer learning mampu meningkatkan performa model ketika jumlah dataset pelatihan terbatas [7]. Hasil penelitian tersebut menunjukkan bahwa kombinasi YOLO dan transfer learning memiliki potensi yang besar untuk diterapkan pada berbagai objek dengan karakteristik visual yang kompleks.

Meskipun demikian, penelitian-penelitian sebelumnya masih memiliki beberapa keterbatasan. Sebagian besar penelitian hanya berfokus pada satu jenis komoditas atau satu domain objek sehingga belum mampu melakukan deteksi multi-kelas pada berbagai jenis biji-bijian dalam satu model [8]. Selain itu, implementasi yang dilakukan umumnya masih terbatas pada pengembangan model deteksi tanpa menyediakan aplikasi berbasis web yang dapat dimanfaatkan secara langsung oleh masyarakat maupun penyuluh pertanian. Hingga penelitian ini dilakukan, belum ditemukan penelitian yang mengembangkan sistem deteksi tujuh jenis biji-bijian famili poaceae secara bersamaan menggunakan YOLOv8 dengan pendekatan *transfer learning* serta mengimplementasikannya ke dalam aplikasi berbasis web.

Berdasarkan kesenjangan tersebut, penelitian ini mengembangkan sistem deteksi multi-kelas biji-bijian Famili Poaceae menggunakan algoritma YOLOv8 dengan pendekatan *transfer learning*. Model dikembangkan menggunakan dataset sebanyak 3.500 citra yang terdiri atas tujuh kelas, yaitu padi, jagung, gandum, oat, sorgum, barley, dan millet, kemudian diimplementasikan pada aplikasi berbasis web menggunakan Streamlit. Kontribusi utama penelitian ini meliputi pengembangan model deteksi multi-kelas untuk tujuh jenis biji-bijian Famili Poaceae, penerapan *transfer learning* untuk meningkatkan performa model pada dataset yang terbatas, serta implementasi sistem berbasis web yang dapat digunakan sebagai media identifikasi secara praktis [9]. Penelitian ini bertujuan mengevaluasi kinerja model menggunakan metrik *precision*, *recall*, *mean Average Precision* (mAP50), dan *mean Average Precision* (mAP50-95) sebagai dasar penilaian kemampuan model dalam mendeteksi berbagai jenis biji-bijian Famili Poaceae secara otomatis.

2. Metode Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen, yaitu metode penelitian yang digunakan untuk mencari pengaruh suatu perlakuan (treatment) tertentu terhadap variabel yang diukur dalam kondisi terkendali [10]. Desain eksperimen yang diterapkan yaitu Pre-Experiment Design dengan tipe One-Shot Case Study, yaitu suatu data diberikan suatu perlakuan berupa pelatihan model YOLOv8 dengan *transfer learning* dengan hasil diukur berupa metrik *precision*, *recall*, mAP50, dan mAP50-95 tanpa dibandingkan dengan kelompok atau kontrol atau konfigurasi model lain [11]. Tahapan penelitian secara keseluruhan meliputi analisis kebutuhan, pengumpulan dataset, pra-pemrosesan data, desain sistem, konfigurasi eksperimen, pengujian dan evaluasi, analisis hasil dan implementasi Web, hingga implementasi sistem ke dalam aplikasi berbasis web. Setiap tahapan dilakukan secara berurutan agar hasil pelatihan dapat dievaluasi secara objektif sebelum diintegrasikan ke antarmuka pengguna.



Gambar 2. 1 Diagram Alur Metode Penelitian Eksperimen

2.1. Analisis Kebutuhan

Tahap analisis kebutuhan bertujuan untuk mengidentifikasi masalah utama serta menentukan kebutuhan sistem yang akan dikembangkan. Pada tahap ini dilakukan analisis terhadap proses identifikasi biji-bijian famili poaceae yang selama ini dilakukan secara manual melalui pengamatan visual, sehingga menimbulkan subjektivitas dan hasil yang tidak konsisten. Berdasarkan analisis tersebut, dipilih arsitektur YOLOv8 dengan pendekatan *transfer learning* karena mampu melakukan deteksi multi-kelas secara efisien tanpa memerlukan rekayasa fitur manual [12]. Tahap ini juga mencakup identitas perangkat keras berupa komputer dengan spesifikasi yang memadai, serta perangkat lunak seperti Python, PyTorch, Ultralytics YOLOv8, Google Colab, dan framework Streamlit untuk implementasi sistem berbasis web.

2.2. Pengumpulan Dataset dan Preprocessing Data

Dataset yang digunakan merupakan kombinasi data primer dan sekunder. Sebagian sampel diperoleh langsung dari petani setempat, sedangkan sebagian lainnya diperoleh melalui pembelian di toko bahan pangan dan platform e-commerce, dengan pertimbangan bahwa beberapa jenis biji-bijian (seperti gandum, oat, dan barley) tidak dibudidayakan secara luas di wilayah penelitian sehingga sulit diperoleh langsung dari lahan. Tujuh jenis biji-bijian yang menjadi objek penelitian adalah padi, jagung, gandum, barley, sorgum, oat, dan millet. Pengambilan citra menggunakan kamera smartphone beresolusi 40 MP dengan variasi latar belakang berupa kertas HVS, lantai, dan piring berwarna, serta variasi pencahayaan alami maupun dalam ruangan, untuk memperluas variasi visual dataset. Setiap kelas biji-bijian terdiri dari 500 citra, sehingga total dataset yang terkumpul berjumlah 3.500 citra.

Tahap preprocessing bertujuan untuk memastikan data yang digunakan memiliki kualitas dan format yang sesuai dengan kebutuhan model YOLOv8. Pelabelan dilakukan dengan memberikan anotasi bounding box pada setiap objek biji-bijian menggunakan aplikasi LabelImg, dengan format anotasi awal yaitu XML yang berisi nama kelas, ukuran gambar, serta koordinat xmin, ymin, xmax, dan ymax. Anotasi tersebut kemudian dikonversi ke format YOLO (.txt) menggunakan skrip Python dengan memanfaatkan pustaka xml.etree.ElementTree, os, dan shutil, sehingga menghasilkan nilai kelas serta koordinat titik tengah dan ukuran bounding box (x_center, y_center, width, height) yang dinormalisasi dalam rentang 0 hingga 1. Dataset selanjutnya dibagi menjadi data training (70%), data validasi (15%), dan data testing (15%), yang dipisahkan sejak awal dan tidak dilibatkan dalam proses pelatihan maupun pemilihan checkpoint terbaik.

2.3. Desain Sistem

Tahap desain sistem dilakukan untuk merancang struktur sistem klasifikasi yang akan dibangun, baik dari sisi arsitektur perangkat lunak maupun alur pemrosesan data [13]. Alur kerja sistem dirancang dimulai dari proses pengguna mengunggah citra biji-bijian, tahapan preprocessing citra, proses inferensi menggunakan model YOLOv8 yang telah dilatih, hingga keluaran berupa hasil deteksi kepada pengguna [14]. Selain merancang alur kerja sistem, antarmuka pengguna juga dirancang agar praktis dan mudah digunakan. Antarmuka ini berbasis web sehingga dapat diakses dari berbagai perangkat tanpa memerlukan instalasi tambahan.



Gambar 2. 2 Desain Alur Sistem Deteksi Biji-Bijian Famili Poaceae

Sebagaimana ditunjukkan pada Gambar 2.2, pengguna dapat mengunggah gambar biji-bijian atau menggunakan kamera secara langsung kemudian sistem memvalidasi format citra, memprosesnya melalui model YOLOv8, dan menampilkan hasil deteksi berupa bounding box, nama kelas, serta tingkat kepercayaan (confidence score) pada antarmuka web. Model yang telah dilatih diintegrasikan ke dalam aplikasi berbasis web menggunakan framework streamlit karena kemudahan pengembangan antarmuka interaktif berbasis python tanpa memerlukan penulisan kode front-end secara terpisah.

2.4 Konfigurasi Eksperimen

Proses pelatihan dilakukan menggunakan pustaka Ultralytics YOLOv8 berbasis PyTorch melalui fungsi `model.train()`, dengan dataset dimuat melalui berkas konfigurasi `data.yaml` pelatihan dijalankan pada lingkungan google colab pro dengan GPU NVIDIA A100 menggunakan parameter yang dirangkum pada tabel 2.1.

Tabel 2. 1 Konfigurasi Parameter

Parameter	Nilai
Batch Size	64
Jumlah Epoch	140
Train/Validation split	70% / 15% / 15%
Optimizer	AdamW
Learning Rate Awal	0,01
Training Sample	2450
Validation Sample	525
Testing Sample	525
Learning Rate	0,01
GPU	NVIDIA A100
VRAM	40GB
Versi Cuda	12

Optimizer Adam dipilih karena kemampuannya menggabungkan momentum dengan estimasi adaptif dari gradien, sehingga menghasilkan proses konvergensi yang lebih cepat dan stabil dibandingkan optimizer konvensional seperti SGD. Nilai learning rate awal sebesar 0,01 dipilih agar cukup kecil untuk menghindari overshooting pada proses optimasi, namun tetap cukup besar untuk menjaga kecepatan pembelajaran model tetap efisien

2.5. Pengujian dan Evaluasi

Evaluasi performa model dilakukan menggunakan confusion matrix, yaitu representatif yang menggambarkan perbandingan antara label prediksi model dengan label sebenarnya (ground truth). Komponen utama confusion matrix meliputi True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN).

TP adalah jumlah prediksi yang benar, FP adalah jumlah prediksi yang salah pada suatu kelas, dan FN adalah jumlah objek yang gagal terdeteksi oleh model. Selain precision dan recall, penelitian ini juga menggunakan mAP50 (mean Average Precision pada ambang IoU 0,5) dan mAP50-95 (rata-rata mAP pada rentang IoU 0,5 hingga 0,95) sebagai ukuran menyeluruh terhadap kemampuan model dalam mendeteksi seluruh kelas biji-bijian secara bersamaan, serta dievaluasi pada data testing yang belum pernah dilihat model sebelumnya [15].

2.6. Analisis Hasil dan Implementasi

Analisis hasil dilakukan melalui beberapa pendekatan. Pertama, kurva train/validation loss dan mAP dipantau pada setiap epoch untuk mendeteksi indikasi overfitting atau underfitting, sehingga checkpoint model terbaik dipilih berdasarkan nilai mAP validasi tertinggi [15], bukan semata-mata pada epoch terakhir pelatihan. Kedua, hasil confusion matrix dianalisis per kelas untuk menelusuri pasangan kelas yang paling sering tertukar, sebagai dasar untuk mengidentifikasi kemungkinan penyebabnya, misalnya kemiripan bentuk, ukuran, atau tekstur antarjenis biji-bijian. Ketiga, dilakukan analisis kesalahan (error analysis) untuk membedakan apakah kesalahan model didominasi oleh false negative, yaitu objek yang gagal terdeteksi, atau oleh kesalahan klasifikasi antarkelas, karena kedua jenis kesalahan tersebut mengindikasikan akar masalah yang berbeda. Keempat, hasil evaluasi model juga dibandingkan secara kualitatif dengan penelitian terdahulu yang menerapkan YOLO pada domain serupa, untuk menilai posisi capaian penelitian ini relatif terhadap studi sejenis yang umumnya masih berfokus pada satu jenis komoditas.

Setelah proses analisis, model yang telah dilatih diimplementasikan ke dalam aplikasi berbasis web menggunakan framework Streamlit dan disebarkan (deploy) melalui platform hugging face agar dapat diakses secara publik tanpa memerlukan instalasi maupun perangkat keras berkapasitas tinggi di sisi pengguna. Model disimpan dalam format .pt dan dimuat saat aplikasi dijalankan, sehingga proses inferensi dilakukan langsung di sisi server ketika pengguna mengunggah citra biji-bijian melalui antarmuka web, mulai dari validasi format citra, pra-pemrosesan (resize ke 640×640 piksel), inferensi model, hingga penampilan hasil deteksi berupa bounding box, nama kelas, dan confidence score kepada pengguna.

3. Hasil dan Diskusi


Hasil penelitian ini menghasilkan sistem deteksi biji-bijian famili poaceae berbasis web menggunakan YOLOv8 dengan pendekatan *transfer learning*. Proses pelatihan model ini dilakukan menggunakan dataset sebanyak 3500 citra yang terbagi menjadi tujuh kelas dari famili poaceae dengan pembagian dataset menjadi 70% data training, 15% data testing, dan 15% data validasi. Evaluasi model menggunakan empat metrik yaitu precision, recall, mAP50, dan mAP50-95, yang umum digunakan untuk deteksi citra dengan beberapa matrik tambahan untuk hasil evaluasi dari training dan validasinya seperti class loss, box loss, dan dfl loss.

3.1. Hasil Pelatihan Model

Model YOLOv8 dilatih menggunakan optimizer AdamW dengan menerapkan teknik augmentasi data untuk meningkatkan variasi citra selama pelatihan. Kurva train/box_loss menunjukkan penurunan nilai kesalahan bounding box dari sekitar 1,52 menjadi 0,72, sedangkan train/cls_loss menurun dari sekitar 2,5 menjadi 0,38, dan train/dfl_loss menurun dari sekitar 1,27 menjadi 0,91. Penurunan yang konsisten pada seluruh kurva pelatihan ini menunjukkan bahwa model semakin mampu menentukan posisi bounding box serta membedakan ketujuh kelas biji-bijian secara akurat.

Pada kurva validasi, nilai loss menurun pada awal pelatihan namun menunjukkan sedikit peningkatan setelah sekitar epoch ke-30 hingga ke-40. Pola ini, bersama dengan penurunan nilai mAP50 dan mAP50-95 setelah mencapai puncaknya di sekitar epoch ke-40 hingga ke-50, mengindikasikan terjadinya overfitting ringan, yaitu kondisi ketika model mulai lebih menyesuaikan diri terhadap data training dibandingkan data validasi. Hal ini menunjukkan bahwa model terbaik kemungkinan bukan berada pada epoch terakhir, melainkan pada epoch ketika mAP50 dan mAP50-95 mencapai nilai maksimum.

Pada data testing, model memperoleh nilai precision sebesar 71,6%, recall sebesar 73,2%, mAP50 sebesar 75,7%, dan mAP50-95 sebesar 46,9%. Nilai precision menunjukkan bahwa sekitar tujuh dari sepuluh prediksi yang dihasilkan model merupakan prediksi yang benar, sementara nilai recall menunjukkan bahwa model berhasil mendeteksi sekitar 73,2% objek yang terdapat pada data pengujian.



Gambar 3. 1 Hasil Pelatihan Model

3.2. Hasil Evaluasi per kelas

Evaluasi lebih lanjut dilakukan berdasarkan confusion matrix untuk melihat performa model pada masing-masing kelas biji-bijian, sebagaimana dirangkum pada Tabel 3.1 dan divisualisasikan pada Gambar 3.2.

Tabel 3. 1 Ringkasan Hasil Evaluasi Model per Kelas Pada Data Testing

Kelas	Precision	Recall	mAP50	mAP50-95
Sorgum	68,9%	81,6%	77,5%	47,0%
Paddy (Padi)	55,2%	66,8%	64,5%	38,2%
Oat	62,6%	70,3%	66,5%	36,6%
Millet	76,5%	74,2%	84,0%	60,5%
Jelai (Barley)	85,2%	91,1%	92,7%	50,2%
Gandum	64,7%	66,5%	69,6%	38,8%
Corn (Jagung)	81,7%	95,8%	95,9%	74,1%



Gambar 3. 2 Confusion Matrix Hasil Pengujian Model pada Tujuh Kelas Biji-Bijian

Kelas corn (jagung) menunjukkan performa terbaik dengan precision 81,7%, recall 95,8%, mAP50 95,9%, dan mAP50-95 74,1%, yang menunjukkan bahwa model memiliki kemampuan sangat baik dalam mengenali objek jagung secara konsisten bahkan pada ambang IoU yang ketat. Kelas jelai (barley) juga menunjukkan performa sangat baik dengan mAP50 sebesar 92,7%, diikuti oleh millet dengan mAP50 sebesar 84,0%. Kelas sorgum memperoleh recall (81,6%) yang lebih tinggi dibandingkan precision (68,9%), yang menunjukkan model mampu menemukan sebagian besar objek sorgum meskipun masih terdapat beberapa false positive. Pada kelas gandum dan oat, nilai mAP50-95 yang masih di bawah 40% menunjukkan bahwa ketepatan posisi bounding box pada ambang IoU yang lebih ketat masih perlu ditingkatkan.

Performa terendah diperoleh pada kelas paddy (padi), dengan precision 55,2%, recall 66,8%, mAP50 64,5%, dan mAP50-95 38,2%. Berdasarkan confusion matrix pada Gambar 3, sebagian besar kesalahan model terjadi berupa objek yang tidak terdeteksi (dikategorikan sebagai latar belakang) dibandingkan kesalahan klasifikasi antarkelas, yang mengindikasikan bahwa tantangan utama model bukan pada kemiripan antarkelas melainkan pada sensitivitas deteksi terhadap objek berukuran kecil dan padat. Secara keseluruhan, nilai mAP50 pada seluruh kelas berada pada rentang 64,5% hingga 95,9%, dengan kesalahan deteksi paling banyak terjadi pada kelas paddy dan gandum, sedangkan kelas corn dan jelai memiliki tingkat klasifikasi paling tinggi.

3.3. Implementasi Sistem Berbasis Web

Model YOLOv8 yang telah dilatih berhasil diimplementasikan ke dalam aplikasi berbasis web menggunakan framework Streamlit. Sistem menyediakan fitur unggah gambar maupun pengambilan gambar secara langsung melalui kamera, kemudian menampilkan hasil deteksi berupa bounding box pada objek biji-bijian, nama kelas, serta tingkat kepercayaan (confidence score). Waktu pemrosesan citra pada sistem tergolong cepat karena arsitektur YOLOv8 dirancang untuk melakukan deteksi dalam satu kali proses inferensi (single-stage detector), sehingga sesuai untuk diterapkan pada aplikasi web yang membutuhkan respons cepat terhadap masukan pengguna.



Gambar 3. 3 Tampilan Halaman Pada Framework Streamlit

3.4. Diskusi

Hasil penelitian menunjukkan bahwa penggunaan arsitektur YOLOv8 dengan pendekatan *transfer learning* mampu menghasilkan performa yang cukup baik dalam proses deteksi biji-bijian famili Poaceae. Model mampu mengenali karakteristik visual objek seperti bentuk, tekstur, dan warna biji sehingga memberikan hasil evaluasi yang optimal pada sebagian besar kelas. Keberhasilan model ini dipengaruhi oleh proses pra-pemrosesan data, kualitas pelabelan (anotasi), serta pemanfaatan *transfer learning* yang membantu model mempelajari fitur objek secara lebih efektif dan efisien meskipun dengan keterbatasan jumlah data pelatihan.

Dibandingkan dengan penelitian terdahulu yang umumnya berfokus pada deteksi atau klasifikasi satu jenis komoditas, penelitian ini menunjukkan bahwa pendekatan deteksi multi-kelas menggunakan YOLOv8 mampu memberikan performa yang kompetitif dalam mengenali beberapa jenis biji-bijian famili Poaceae secara bersamaan. Temuan ini sejalan dengan penelitian sebelumnya yang menyatakan bahwa *transfer learning* efektif dalam meningkatkan kemampuan model pada dataset dengan jumlah data yang terbatas. Meskipun masih terdapat peluang untuk meningkatkan performa melalui penambahan variasi dataset dan pengujian pada kondisi lapangan yang lebih beragam, hasil penelitian ini menunjukkan bahwa model yang dikembangkan telah memiliki potensi untuk diterapkan sebagai pendukung proses identifikasi biji-bijian secara otomatis, cepat, dan objektif serta mendukung pengembangan digitalisasi di bidang pertanian.

4. Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penerapan algoritma YOLOv8 dengan metode *transfer learning* mampu digunakan untuk melakukan deteksi biji-bijian famili Poaceae secara otomatis. Model berhasil mengenali tujuh kelas biji-bijian, yaitu padi, jagung, gandum, sorgum, barley, oat, dan millet, dengan nilai precision 71,6%, recall 73,2%, mAP50 75,7%, dan mAP50-95 46,9% pada data testing. Kelas corn (jagung) dan jelai (barley) menunjukkan performa terbaik, sedangkan kelas paddy (padi) menunjukkan performa terendah akibat kemiripan visual dengan kelas lain. Penelitian ini juga berhasil membangun sebuah sistem deteksi berbasis web menggunakan framework Streamlit yang memungkinkan pengguna melakukan deteksi hanya dengan mengunggah gambar atau menggunakan kamera secara langsung. Dengan adanya sistem ini, diharapkan dapat memberikan kontribusi dalam mendukung digitalisasi sektor pertanian, khususnya pada proses identifikasi komoditas biji-bijian yang sering sulit dibedakan secara visual. Penelitian selanjutnya disarankan untuk memperluas dataset, menguji arsitektur YOLO versi lain, serta menambahkan fitur pendukung seperti riwayat deteksi dan informasi deskriptif setiap jenis biji-bijian pada sistem berbasis web.

Referensi

- [1] A. Agustin *et al.*, “Keanekaragaman Famili Poaceae Di Wilayah Kampus I UIN Sunan Gunung Djati Bandung,” vol. 2, no. 4, 2024.
- [2] J. Barat, “Inventarisasi dan Identifikasi Jenis Tumbuhan Famili Poaceae di Sekitar,” vol. 1, no. 2, 2023.
- [3] X. Cong, S. Li, F. Chen, C. Liu, and Y. Meng, “A Review of YOLO Object Detection Algorithms based on Deep Learning,” vol. 4, no. 2, pp. 2–5, 2023.
- [4] I. Abdillah, “Klasifikasi Jenis Jagung Berdasarkan Bentuk Biji Menggunakan Metode You Only Look Once (YOLO),” vol. 5, no. 2, pp. 215–226, 2023, doi: 10.33650/jeecon.v4i2.
- [5] D. Arsitektur and V. Yolo, “Klasifikasi kualitas buah jeruk menggunakan computer vision dengan arsitektur yolo v8,” vol. 13, no. 2, pp. 187–201, 2024, doi: 10.31571/saintek.v13i2.8346.
- [6] N. Suwela and M. Z. Hedriyadi, “Deteksi Jenis Sampah Menggunakan Metode Transfer Learning YOLO-V8,” vol. 7, no. 1, pp. 61–74, 2025.
- [7] F. Hidayah and Y. Kristian, “Identifikasi Kerusakan Badan Kontainer Pada Waktu Pengiriman Berdasarkan Citra CCTV Memanfaatkan YOLO dan Deep Transfer Learning Identification of Container Body Damage During Delivery Based on CCTV Images Using YOLO and Deep Transfer Learning,” vol. 13, no. 1, pp. 10–17, 2024, doi: 10.34148/teknika.v13i1.718.
- [8] S. Cheng, L. Chen, and K. Yang, “DGSS-YOLOv8s: A Real-Time Model for Small and Complex Object Detection in Autonomous Vehicles,” pp. 1–20, 2025.
- [9] D. Kurniadi, A. A. Latif, A. Mulyani, and H. Aulawi, “Benchmarking YOLOv8 Variants with Transfer Learning for Real-Time Detection and Classification of Road Cracks and Potholes,” vol. 9, no. 4, pp. 771–780, 2025.
- [10] M. Waruwu, S. Natijatul, P. R. Utami, and E. Yanti, “Metode Penelitian Kuantitatif: Konsep, Jenis, Tahapan dan Kelebihan,” vol. 10, pp. 917–932, 2025.
- [11] H. Dermawan and A. Hasibuan, “Metode Penelitian Eksperimen: Prinsip, Prosedur, dan Aplikasi dalam Penelitian Ilmiah,” pp. 4–7, 2025.
- [12] M. Talib, “YOLOv8-CAB: Improved YOLOv8 for Real-time object detection YOLOv8-CAB: Improved YOLOv8 for Real-time object detection,” vol. 10, no. 1, 2024.
- [13] S. Purwanti *et al.*, “DESAIN SISTEM INFORMASI MENGGUNAKAN UNIFIED MODELING LANGUAGE (UML) Pendahuluan Kajian Teori Metode Hasil dan Pembahasan,” vol. 11, no. 1, pp. 32–38, 2024.
- [14] J. M. Polgan *et al.*, “Evaluasi Performa YOLOv8 Dalam Deteksi Objek Di Depan Kendaraan Dengan Variasi Kondisi Lingkungan,” vol. 13, pp. 1755–1773, 2024.
- [15] A. Rismayanti *et al.*, “DETEKSI DAN KLASIFIKASI TINGKAT KEMATANGAN BUAH MANGGA HARUM MANIS MENGGUNAKAN YOU ONLY LOOK ONCE (YOLO) V8,” vol. 9, no. 3, pp. 3645–3654, 2025.