



Model Deteksi Gulma dan Tanaman Jagung Berbasis YOLOv5n untuk Sistem Pertanian Presisi

YOLOv5n-Based Weed and Maize Plant Detection Model for Precision Agriculture Systems

Mi'raj Fuadi^{1*}, M. Azhar Mustafid¹, Rosyid Ridho¹, Endang Purnama Dewi¹, Eusabius Paul Pega²

¹ Program Studi Teknik Pertanian, Fakultas Teknologi Pangan dan Agroindustri, Universitas Mataram

² Program Studi Teknologi Industri Hortikultura, Politeknik Pertanian Negeri Kupang

*Corresponding Author: mirajfuadi@unram.ac.id

Abstract. *Weed infestation is one of the main challenges in maize cultivation because it can reduce crop growth and productivity through competition for nutrients, water, light, and growing space. An automatic detection system is therefore needed to support precision agriculture, particularly for selective weed control. This study aimed to develop and evaluate a YOLOv5n-based detection model for identifying maize plants and weeds in agricultural field images. The dataset used in this study was obtained from the Weed Classification dataset available on Kaggle. Image annotation was performed using bounding boxes with two object classes, namely maize and weed. The dataset was divided into training, validation, and testing subsets using an 80:10:10 ratio. Model training was conducted on Google Colab for 100 epochs using an image size of 640 × 640 pixels and the YOLOv5n architecture. Model performance was evaluated using precision, recall, F1-score, and mAP. The results showed that the YOLOv5n model achieved an average precision of 0.894, recall of 0.923, F1-score of 0.908, and mAP of 0.936. The maize class obtained a higher mAP of 0.976, while the weed class achieved an mAP of 0.897. These results indicate that YOLOv5n can effectively detect maize plants and weeds and has the potential to support precision agriculture applications, particularly selective spraying systems.*

Keywords: *Computer Vision, Maize, Precision Agriculture, Weed Detection, YOLOv5n.*

1. Pendahuluan

Jagung merupakan salah satu tanaman pangan penting yang banyak dibudidayakan karena memiliki peran strategis sebagai sumber pangan, pakan, dan bahan baku industri. Namun, produktivitas tanaman jagung di lapangan masih dapat terganggu oleh keberadaan gulma, terutama pada fase awal pertumbuhan tanaman. Gulma berkompetisi dengan tanaman utama dalam memperoleh cahaya, air, ruang tumbuh, dan unsur hara, sehingga keberadaannya perlu dikendalikan secara tepat. Pengendalian gulma yang tidak akurat dapat menurunkan efisiensi budidaya serta meningkatkan penggunaan herbisida secara berlebihan. Pada pertanian presisi, deteksi gulma secara cepat dan akurat menjadi salah satu tahapan penting untuk mendukung pengendalian gulma yang lebih selektif dan efisien (Darbyshire et al., 2023; Hu et al., 2023).

Pengamatan gulma secara manual masih memiliki keterbatasan karena membutuhkan waktu, tenaga kerja, dan bersifat subjektif. Selain itu, kondisi lahan yang kompleks, variasi ukuran tanaman, bentuk gulma, pencahayaan tidak seragam, serta tumpang tindih antar objek dapat mempersulit identifikasi visual. Kondisi ini mendorong penggunaan pengolahan citra dan kecerdasan buatan untuk mendeteksi gulma dan tanaman jagung secara otomatis (Chen et al., 2022; Picon et al., 2022).


Pendekatan deteksi objek berbasis deep learning banyak digunakan dalam pengenalan tanaman dan gulma karena mampu memberikan informasi kelas dan posisi objek secara bersamaan. Informasi bounding box yang dihasilkan model dapat dimanfaatkan sebagai dasar pengambilan keputusan pada sistem pertanian presisi, terutama untuk mendukung pengendalian gulma secara selektif dan mengurangi penggunaan herbisida yang tidak diperlukan (Allmendinger et al., 2025; Hasan et al., 2023).

Salah satu algoritma deteksi objek yang banyak digunakan adalah You Only Look Once (YOLO), karena memiliki kemampuan deteksi satu tahap dengan kecepatan pemrosesan tinggi. Chen et al. (2022) melaporkan bahwa model YOLO untuk deteksi gulma pada lahan wijen mampu mencapai mAP 96,16% dan kecepatan 36,8 frame per second. Fan et al. (2024) juga mengembangkan model YOLOv5 ringan dan akurat untuk deteksi gulma pada lahan kapas guna meningkatkan efisiensi komputasi dan implementasi lapangan.

Penelitian ini menggunakan YOLOv5n atau YOLOv5 nano karena memiliki ukuran model kecil dan kebutuhan komputasi rendah. Karakteristik tersebut sesuai untuk sistem pertanian presisi berbasis perangkat komputasi ringan yang membutuhkan inferensi cepat di kondisi lahan nyata (Fan et al., 2024; Li et al., 2022). Berdasarkan uraian tersebut, penelitian ini bertujuan mengembangkan dan mengevaluasi model deteksi gulma dan tanaman jagung berbasis YOLOv5n. Evaluasi dilakukan menggunakan precision, recall, F1-score, dan mAP. Hasil penelitian diharapkan menjadi dasar pengembangan sistem pertanian presisi, khususnya untuk aplikasi pengendalian gulma secara selektif.

2. Metode Penelitian

Tahapan penelitian diawali dengan identifikasi masalah mengenai kebutuhan deteksi otomatis tanaman jagung dan gulma. Selanjutnya dilakukan studi literatur terkait deteksi objek, YOLOv5n, dan penerapannya pada pertanian presisi. Dataset yang digunakan merupakan dataset sekunder dari Kaggle. Dataset kemudian dibagi menjadi data *training*, *validation*, dan *testing*. Setelah itu, citra dianotasi menggunakan *bounding box*. Model yang telah dilatih kemudian divalidasi dan diuji. Evaluasi performa dilakukan menggunakan precision, recall, F1-score, dan mAP, kemudian hasilnya digunakan untuk menarik kesimpulan mengenai kemampuan model dalam mendeteksi tanaman jagung dan gulma. Diagram alir penelitian dapat dilihat pada Gambar 1.



Gambar 1. Diagram alir penelitian

2.1 Dataset Penelitian

Dataset yang digunakan dalam penelitian ini merupakan dataset sekunder dari platform Kaggle dengan nama *Weed Classification*. Dataset ini berisi citra tanaman jagung dan gulma yang dapat digunakan untuk pengembangan model deteksi objek berbasis *deep learning*. Dataset Kaggle dipilih karena menyediakan citra lapangan dengan variasi objek, latar belakang tanah, pencahayaan, dan ukuran tanaman yang beragam, sehingga relevan untuk pengembangan model deteksi gulma pada lahan jagung. Penggunaan dataset publik juga dapat mempercepat pengembangan model awal sebelum dilakukan validasi lebih lanjut pada kondisi lapangan spesifik (Olsen et al., 2019). Dataset ini dapat diakses melalui laman Kaggle *Weed Classification* (<https://www.kaggle.com/datasets/aminelaatam/weed-classification>).

Dataset yang digunakan dalam penelitian ini terdiri atas 2.085 citra dengan dua kelas objek, yaitu Jagung dan Gulma. Kelas Jagung memiliki jumlah data sebanyak 1.200 citra, sedangkan kelas Gulma memiliki jumlah data sebanyak 885 citra. Contoh citra gulma dan tanaman jagung dapat dilihat pada Gambar 2 dan 3.



Gambar 2. Citra tanaman jagung



Gambar 3. Citra gulma

2.2 Anotasi Data

Proses anotasi citra dilakukan menggunakan Label Studio dengan metode *bounding box*, yaitu memberi kotak pembatas pada objek kelas Jagung dan Gulma. Metode ini dipilih karena sesuai untuk pelatihan model deteksi objek, di mana model tidak hanya mengenali kelas objek, tetapi juga

menentukan lokasinya pada citra. Label Studio mendukung anotasi citra menggunakan *rectangular bounding boxes*, sehingga sesuai untuk menyiapkan dataset deteksi objek.



Gambar 4. Proses anotasi citra

Setiap citra diperiksa dan diberi label berdasarkan objek yang terlihat. Tanaman jagung diberi label Jagung, sedangkan tanaman pengganggu diberi label Gulma (Gambar 4). Setelah anotasi selesai, data diekspor ke format YOLO karena kompatibel dengan pelatihan YOLOv5n. Setiap file anotasi memuat informasi kelas objek dan koordinat *bounding box* yang telah dinormalisasi terhadap ukuran citra.

2.3 Pembagian Dataset

Dataset terlebih dahulu diacak menggunakan kode Python sebelum dibagi menjadi data training, validation, dan testing. Pembagian dataset dilakukan dengan metode stratified random split dengan rasio 80:10:10. Metode ini memungkinkan pembagian data secara acak, namun tetap mempertahankan proporsi kelas Jagung dan Gulma pada setiap subset. Dengan demikian, distribusi data pada subset training, validation, dan testing tetap merepresentasikan komposisi dataset awal, sehingga evaluasi performa model dapat dilakukan secara lebih objektif.

Berdasarkan hasil pembacaan dataset saat proses *training*, jumlah data yang digunakan terdiri atas 1.668 citra latih, 208 citra validasi, dan 208 citra uji. Pembagian ini bertujuan menyediakan data latih yang memadai sekaligus menjaga data validasi dan uji tetap terpisah untuk mengukur kemampuan generalisasi model.

2.4 Pelatihan Model YOLOv5n

Model yang digunakan dalam penelitian ini adalah YOLOv5n atau YOLOv5 nano, yaitu varian ringan dari keluarga YOLOv5 yang memiliki ukuran model kecil dan kebutuhan komputasi rendah. Karakteristik tersebut sesuai untuk pengembangan sistem pertanian presisi berbasis perangkat komputasi ringan, karena aplikasi lapangan membutuhkan model yang efisien, cepat, dan dapat dijalankan pada perangkat dengan sumber daya terbatas. YOLOv5 juga banyak digunakan karena mendukung deteksi objek berbasis PyTorch dengan keunggulan pada kemudahan penggunaan, kecepatan inferensi, dan akurasi deteksi (Wang et al., 2025).

Pelatihan model dilakukan menggunakan Google Colab dengan akselerasi GPU selama 100 *epoch* dan ukuran citra masukan 640×640 piksel. Optimizer yang digunakan dalam pelatihan model adalah AdamW, yaitu optimizer adaptif yang bertujuan untuk meningkatkan stabilitas pelatihan dan membantu mengurangi risiko *overfitting* pada model (Loshchilov and Hutter, 2017). Berdasarkan log *training*, model terbaik yang dihasilkan dari proses pelatihan memiliki ukuran file sekitar 5,3 MB, sehingga tergolong ringan untuk pengembangan sistem deteksi berbasis *edge device*. Spesifikasi pelatihan model ditunjukkan pada Tabel 1.

Tabel 1. Spesifikasi pelatihan model YOLOv5n

Komponen	Spesifikasi
Platform	Google Colab
Framework	Ultralytics
Python	3.12.13
GPU	NVIDIA A100-SXM4-40GB
Model	YOLOv5n
Nama kelas	Jagung dan Gulma
Jumlah epoch	100
Optimizer	AdamW

2.5 Evaluasi Model

Evaluasi model dilakukan menggunakan *precision*, *recall*, *F1-score*, dan *mAP*. *Precision* menunjukkan ketepatan model dalam mendeteksi objek, yaitu seberapa besar prediksi yang dihasilkan benar sesuai kelasnya. *Recall* menunjukkan kemampuan model dalam menemukan seluruh objek aktual yang terdapat pada citra. Nilai *precision* dan *recall* yang tinggi menunjukkan bahwa model mampu menghasilkan prediksi yang tepat sekaligus mendeteksi sebagian besar objek yang ada. *Precision* dihitung menggunakan persamaan berikut:

$$Precision = \frac{TP}{TP+FP} \quad (1)$$

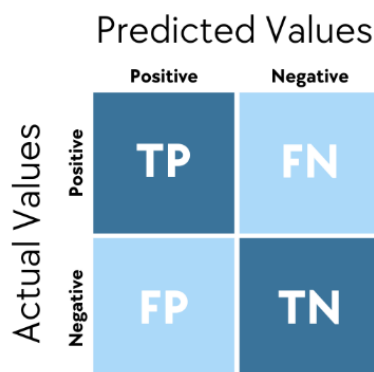
Recall dihitung menggunakan persamaan berikut:

$$Recall = \frac{TP}{TP+FN} \quad (2)$$

F1-score digunakan untuk menunjukkan keseimbangan antara *precision* dan *recall*. Nilai *F1-score* dihitung menggunakan persamaan berikut:

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (3)$$

dimana *TP* (*True Positive*) adalah objek yang benar terdeteksi sesuai kelasnya, *FP* (*False Positive*) adalah objek yang salah terdeteksi sebagai kelas tertentu, *FN* (*False Negative*) adalah objek yang seharusnya terdeteksi tetapi tidak terdeteksi oleh model.



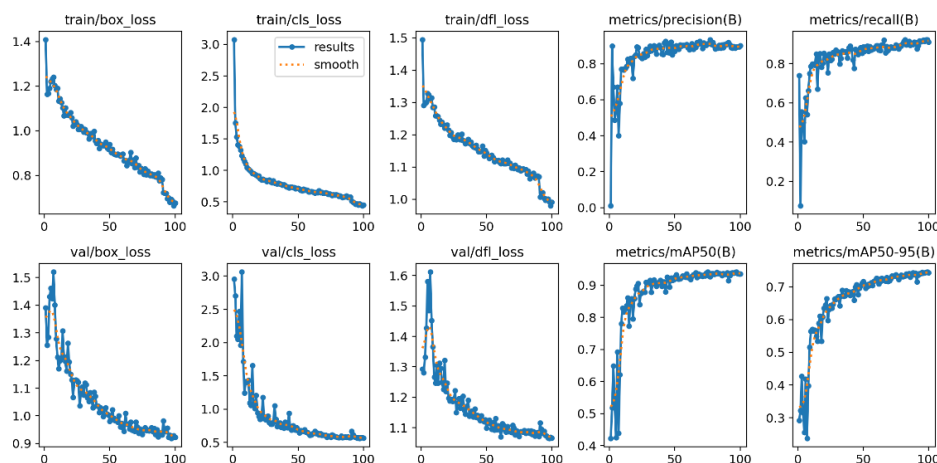
Gambar 5. Confusion matrix

Evaluasi juga dilengkapi dengan *confusion matrix*, *precision-recall curve*, *F1-confidence curve*, dan visualisasi hasil prediksi pada citra validasi. *Confusion matrix* digunakan untuk melihat klasifikasi benar dan salah, sedangkan kurva *precision-recall* dan *F1-confidence* digunakan untuk menilai kestabilan performa model pada berbagai ambang deteksi. Pendekatan ini penting agar performa model tidak hanya dinilai dari satu metrik, tetapi juga dari kemampuannya mengenali objek pada berbagai kondisi visual lahan pertanian.

3. Hasil dan Pembahasan

3.1 Hasil Pelatihan Model YOLOv5n

Pelatihan model YOLOv5n dilakukan hingga 100 *epoch* menggunakan dataset citra tanaman jagung dan gulma yang telah dianotasi dengan metode *bounding box*. Selama proses pelatihan, nilai *loss* model mengalami penurunan secara bertahap pada komponen *bounding box regression loss* (*box_loss*), *classification loss* (*cls_loss*), dan *distribution focal loss* (*dfl_loss*). Penurunan ini menunjukkan bahwa model semakin baik dalam mempelajari lokasi objek, membedakan kelas objek, serta mengestimasi posisi kotak pembatas secara lebih akurat.



Gambar 6. Hasil pengujian model YOLOv5n dalam deteksi objek gulma dan jagung

Pada data validasi, nilai *val/box_loss*, *val/cls_loss*, dan *val/dfl_loss* juga menunjukkan kecenderungan menurun. Kondisi ini mengindikasikan bahwa model tidak hanya belajar dari data latih, tetapi juga mampu mempertahankan performa pada data validasi. Hal tersebut penting karena model deteksi objek yang baik harus mampu mengenali objek pada citra baru yang tidak digunakan langsung dalam proses pelatihan. Selain itu, metrik *precision*, *recall*, dan *mAP* menunjukkan peningkatan selama proses pelatihan. Peningkatan ini menandakan bahwa kemampuan model dalam mendeteksi dan mengklasifikasikan objek semakin baik seiring bertambahnya *epoch*.

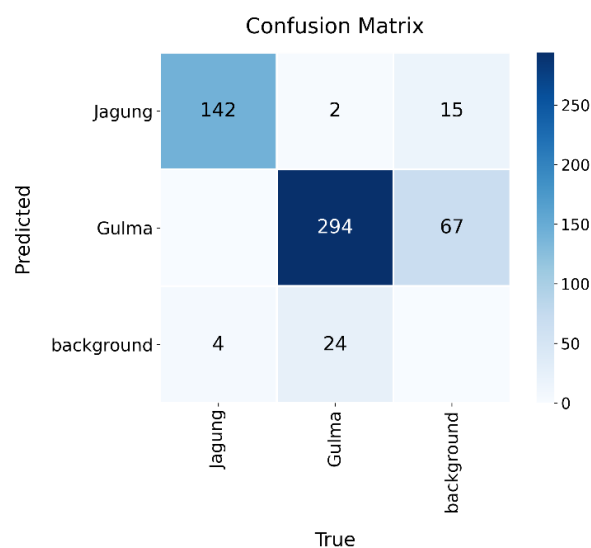
3.2 Hasil Evaluasi Model

Hasil evaluasi model YOLOv5n menunjukkan bahwa model mampu mendeteksi dua kelas objek, yaitu Jagung dan Gulma, dengan performa yang baik. Evaluasi dilakukan menggunakan *precision*, *recall*, *F1-score*, *mAP*, *confusion matrix*, dan visualisasi hasil prediksi. Ringkasan hasil evaluasi model ditunjukkan pada Tabel 2.

Tabel 2. Hasil evaluasi model YOLOv5n pada kelas Jagung dan Gulma

Kelas	Precision	Recall	F1-score	mAP
Jagung	0,893	0,973	0,931	0,976
Gulma	0,814	0,919	0,863	0,897
Rata-rata	0,854	0,946	0,897	0,936

Berdasarkan Tabel 2, model memperoleh nilai rata-rata precision sebesar 0,854, recall sebesar 0,946, F1-score sebesar 0,897, dan mAP sebesar 0,936. Nilai tersebut menunjukkan bahwa YOLOv5n memiliki kemampuan yang baik dalam mendeteksi tanaman jagung dan gulma pada citra lahan pertanian. Nilai recall yang tinggi menunjukkan bahwa sebagian besar objek aktual berhasil terdeteksi, sedangkan nilai precision menunjukkan bahwa sebagian besar prediksi model sudah sesuai dengan kelas objek yang benar.



Gambar 7. Confusion matrix model YOLOv5n

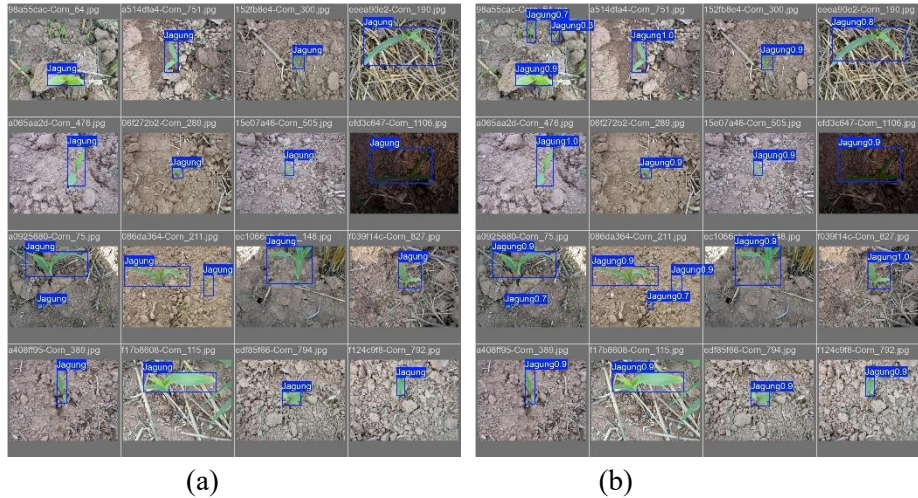
Pada kelas Jagung, model memperoleh precision 0,893, recall 0,973, dan F1-score 0,931. Berdasarkan *confusion matrix*, sebanyak 142 objek Jagung berhasil terdeteksi dengan benar, 4 objek Jagung tidak terdeteksi dan masuk ke kategori *background*, serta 2 objek Gulma salah terdeteksi sebagai Jagung. Nilai recall yang sangat tinggi menunjukkan bahwa model sangat baik dalam menemukan objek Jagung pada citra.

Pada kelas Gulma, model memperoleh precision 0,814, recall 0,919, dan F1-score 0,863. Sebanyak 294 objek Gulma berhasil terdeteksi dengan benar, sedangkan 24 objek Gulma tidak terdeteksi dan masuk sebagai *background*. Selain itu, terdapat 67 objek *background* yang terdeteksi sebagai Gulma. Hasil ini menunjukkan bahwa deteksi Gulma lebih sulit dibandingkan Jagung, kemungkinan karena variasi bentuk, ukuran, kerapatan, serta kemiripan warna gulma dengan latar belakang atau tanaman utama.

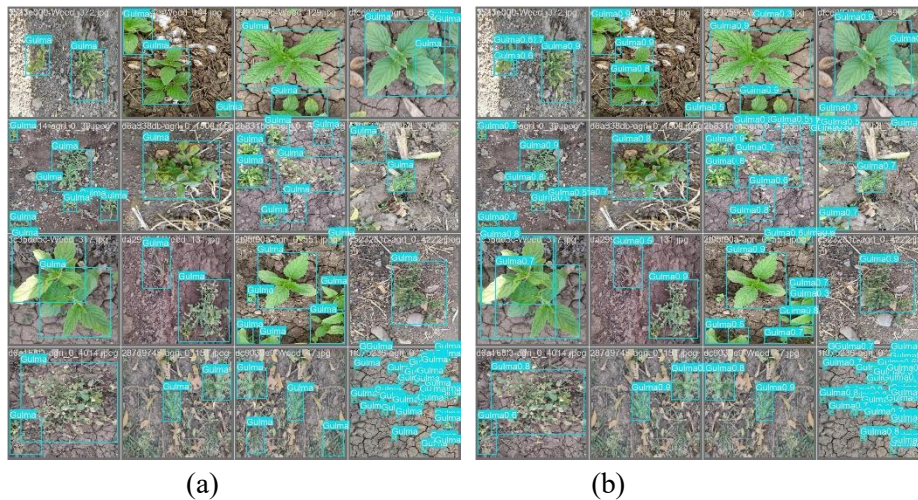
Nilai mAP sebesar 0,936 menunjukkan bahwa model memiliki performa deteksi yang tinggi pada ambang IoU 0,50. Hal ini mengindikasikan bahwa model tidak hanya mampu mengenali kelas objek, tetapi juga mampu menentukan lokasi objek melalui *bounding box* dengan baik. Dengan demikian, YOLOv5n dinilai layak sebagai model awal untuk pengembangan sistem deteksi gulma dan tanaman jagung dalam mendukung aplikasi pertanian presisi, khususnya penyemprotan selektif.

3.3 Visualisasi Hasil Deteksi

Visualisasi hasil deteksi pada data validasi menunjukkan bahwa model YOLOv5n mampu mendeteksi sebagian besar objek tanaman jagung dan gulma dengan baik. *Bounding box* yang dihasilkan model umumnya mampu mengikuti posisi objek pada citra. Pada objek tanaman jagung, hasil prediksi terlihat lebih konsisten karena bentuk tanaman relatif lebih mudah dibedakan dari latar belakang. Pada objek gulma, hasil prediksi juga cukup baik, meskipun terdapat beberapa objek kecil atau saling berdekatan yang lebih sulit dideteksi secara sempurna.



Gambar 8. Contoh hasil anotasi tanaman jagung (a), dan hasil validasi menggunakan model YOLOv5n (b)



Gambar 9. Contoh hasil anotasi gulma (a), dan hasil validasi menggunakan model YOLOv5n (b)

Perbandingan antara citra label dan citra prediksi menunjukkan bahwa model mampu mengenali pola visual utama dari kedua kelas. Namun, beberapa kesalahan masih dapat ditemukan, terutama pada area dengan kepadatan gulma tinggi atau objek yang berukuran kecil. Hal ini menunjukkan bahwa peningkatan jumlah dan variasi data, perbaikan kualitas anotasi, serta pengaturan parameter training dapat menjadi strategi untuk meningkatkan performa model pada penelitian selanjutnya.

3.4 Potensi Penerapan untuk Sistem Pertanian Presisi

Hasil penelitian menunjukkan bahwa YOLOv5n berpotensi digunakan sebagai model dasar dalam sistem pertanian presisi, khususnya untuk deteksi gulma dan tanaman jagung. Nilai mAP sebesar 0,936 menunjukkan bahwa model mampu mendeteksi objek dengan baik, sedangkan ukuran file model terbaik sekitar 5,3 MB menunjukkan peluang implementasi pada perangkat komputasi ringan.

Dalam pertanian presisi, model deteksi gulma dapat digunakan untuk mengidentifikasi lokasi gulma pada lahan. Informasi ini dapat menjadi dasar pengembangan sistem penyemprotan selektif, sehingga herbisida hanya diarahkan pada area yang terdeteksi sebagai gulma. Pendekatan tersebut berpotensi meningkatkan efisiensi penggunaan herbisida dan mengurangi penyemprotan yang tidak diperlukan. Li et al. ⁽²⁰²²⁾ menjelaskan bahwa deteksi objek dapat mendukung penyemprotan target secara real-time, sedangkan Darbyshire et al. ⁽²⁰²³⁾ menekankan pentingnya sistem deteksi yang praktis untuk aplikasi penyemprotan gulma presisi di lapangan.

Meskipun demikian, penelitian ini masih terbatas pada penggunaan dataset sekunder, sehingga belum sepenuhnya merepresentasikan kondisi lahan jagung lokal. Oleh karena itu, pengujian lanjutan menggunakan citra lapangan langsung serta implementasi pada perangkat edge seperti Raspberry Pi, Jetson Nano, atau perangkat ringan lainnya perlu dilakukan untuk mengevaluasi kecepatan inferensi dan kelayakan penerapan model secara *real-time*.

4. Kesimpulan dan Saran

4.1 Kesimpulan

Penelitian ini berhasil mengembangkan model deteksi gulma dan tanaman jagung berbasis YOLOv5n untuk mendukung sistem pertanian presisi. Dataset diperoleh dari Kaggle, dianotasi menggunakan Label Studio dengan metode *bounding box*, dan dibagi menjadi dua kelas, yaitu Jagung dan Gulma.

Hasil evaluasi menunjukkan bahwa model memiliki performa baik dengan nilai rata-rata precision 0,894, recall 0,923, F1-score 0,908, dan mAP 0,936. Kelas Jagung memperoleh mAP lebih tinggi, yaitu 0,976, sedangkan kelas Gulma memperoleh mAP sebesar 0,897. Performa gulma yang lebih rendah disebabkan oleh variasi bentuk, ukuran, dan kondisi visual yang lebih kompleks.

Secara keseluruhan, YOLOv5n mampu mendeteksi gulma dan tanaman jagung dengan baik. Ukuran model yang ringan, sekitar 5,3 MB, menunjukkan potensinya untuk diterapkan pada perangkat komputasi terbatas sebagai dasar sistem deteksi gulma dan penyemprotan selektif.

4.2 Saran

Penelitian selanjutnya disarankan menggunakan citra lapangan lokal serta menguji model pada perangkat *edge* seperti Raspberry Pi atau Jetson Nano untuk menilai kecepatan inferensi dan kelayakan implementasi secara *real-time*.

5. Acknowledgements

Penelitian ini dapat terlaksana berkat dukungan pendanaan dari Universitas Mataram melalui skema Penelitian Dosen Pemula. Pendanaan ini berasal dari sumber dana DIPA BLU (PNBP) Universitas Mataram Tahun Anggaran 2025, dengan nomor kontrak 2374/UN18.L1/PP/2025.

Daftar Pustaka

- Allmendinger, A., Saltik, A.O., Peteinatos, G.G., Stein, A., Gerhards, R. 2025. Assessing the capability of YOLO- and transformer-based object detectors for real-time weed detection. *Precis. Agric.* 26. <https://doi.org/10.1007/s11119-025-10246-0>
- Chen, J., Wang, H., Zhang, H., Luo, T., Wei, D., Long, T., Wang, Z. 2022. Weed detection in sesame fields using a YOLO model with an enhanced attention mechanism and feature fusion. *Comput. Electron. Agric.* 202, 107412. <https://doi.org/10.1016/j.compag.2022.107412>

- Darbyshire, M., Salazar-Gomez, A., Gao, J., Sklar, E.I., Parsons, S. 2023. Towards practical object detection for weed spraying in precision agriculture. *Front. Plant Sci.* 14. <https://doi.org/10.3389/fpls.2023.1183277>
- Fan, X., Sun, T., Chai, X., Zhou, J. 2024. YOLO-WDNet: A lightweight and accurate model for weeds detection in cotton field. *Comput. Electron. Agric.* 225, 109317. <https://doi.org/10.1016/j.compag.2024.109317>
- Hasan, A.S.M.M., Diepeveen, D., Laga, H., Jones, M.G.K., Soheli, F. 2023. Object-Level Benchmark for Deep Learning-Based Detection and Classification of Weed Species. <https://doi.org/10.2139/ssrn.4511105>
- Hu, K., Wang, Z., Coleman, G., Bender, A., Yao, T., Zeng, S., Song, D., Schumann, A., Walsh, M. 2023. Deep learning techniques for in-crop weed recognition in large-scale grain production systems: a review. *Precis. Agric.* 25, 1–29. <https://doi.org/10.1007/s11119-023-10073-1>
- Li, H., Guo, C., Yang, Z., Chai, J., Shi, Y., Liu, J., Zhang, K., Liu, D., Xu, Y. 2022. Design of field real-time target spraying system based on improved YOLOv5. *Front. Plant Sci.* 13. <https://doi.org/10.3389/fpls.2022.1072631>
- Loshchilov, I., Hutter, F. 2017. Fixing Weight Decay Regularization in Adam. *CoRR* abs/1711.05101.
- Olsen, A., Konovalov, D.A., Philippa, B., Ridd, P., Wood, J.C., Johns, J., Banks, W., Girgenti, B., Kenny, O., Whinney, J., Calvert, B., Azghadi, M.R., White, R.D. 2019. DeepWeeds: A Multiclass Weed Species Image Dataset for Deep Learning. *Sci. Rep.* 9. <https://doi.org/10.1038/s41598-018-38343-3>
- Picon, A., San-Emeterio, M.G., Bereciartua-Perez, A., Klukas, C., Eggers, T., Navarra-Mestre, R. 2022. Deep learning-based segmentation of multiple species of weeds and corn crop using synthetic and real image datasets. *Comput. Electron. Agric.* 194, 106719. <https://doi.org/10.1016/j.compag.2022.106719>
- Wang, J., Qi, Z., Wang, Y., Liu, Y. 2025. A lightweight weed detection model for cotton fields based on an improved YOLOv8n. *Sci. Rep.* 15. <https://doi.org/10.1038/s41598-024-84748-8>