

IDENTIFIKASI POLA POLIMORFISME PADA PUNGGUNG KUMBANG *COCCINELLIDAE* MENGUNAKAN METODE YOLO UNTUK MEMBEDAKAN JENIS KUMBANG PREDATOR DAN HAMA

Eva Nurmalasari¹, Agus Susanto², Agustin Zarkani³

^{1,3} Program Studi Informatika, Fakultas Teknik, Universitas Bengkulu,
Jl. WR. Supratman, Kandang Limun, Bengkulu 38371.
Telp. (627) 3621170, Faks (627) 3622105

¹evanurmalasari320@gmail.com

²agus.susanto@unib.ac.id

³agustinzarkani@unib.ac.id

Abstrak: Identifikasi pola polimorfisme pada punggung kumbang *Coccinellidae* penting untuk membedakan predator dan hama dalam pertanian. Namun, perbedaan visual sering kali sulit dikenali karena beberapa kumbang predator memiliki ciri fisik yang mirip dengan kumbang hama, seperti pola pada punggung dan warna tubuh. Penelitian ini mengusulkan metode *deep learning* menggunakan YOLOv5 untuk identifikasi otomatis. Data kumbang *Coccinellidae* dikumpulkan, melalui *preprocessing* dan augmentasi, menghasilkan 1.821 gambar. Model YOLO dilatih dengan parameter optimal hingga *epoch* 729 dan *patience* 300. Evaluasi menggunakan metrik *Mean Average Precision* (mAP) menunjukkan kinerja tinggi, dengan mAP@0,5 sebesar 0,966 dan mAP@0,75 sebesar 0,962. Selain itu, aplikasi berbasis Android dikembangkan untuk implementasi model ini dan diuji dengan hasil kepuasan pengguna sebesar 80. Hasil penelitian menunjukkan bahwa pendekatan ini efektif dalam membedakan kumbang predator dan hama secara akurat serta berpotensi membantu pengendalian hama di bidang pertanian.

Kata Kunci: Identifikasi, *Coccinellidae*, Polimorfisme, YOLOv5.

Abstract: Identification of polymorphism patterns on the backs of *Coccinellidae* beetles is important for distinguishing predators and pests in agriculture. However, visual differences are often difficult to recognize because some predatory beetles have similar physical features to pest beetles, such as patterns on the back and body color. This study proposes a deep learning method using YOLOv5 for automatic identification. *Coccinellidae* beetle data were collected, through preprocessing and augmentation, resulting in 1,821 images. The YOLO model was trained with optimal parameters up to 729 epochs and 300 patience. Evaluation using the Mean Average Precision (mAP) metric showed high performance, with mAP@0.5 of 0.966 and mAP@0.75 of 0.962. In

addition, an Android-based application was developed for the implementation of this model and tested with a user satisfaction result of 80. The results show that this approach is effective in accurately distinguishing predatory beetles and pests and has the potential to help pest control in agriculture.

Keywords: Identification, *Coccinellidae*, Polymorphism, YOLOv5.

I. PENDAHULUAN

Coccinellidae atau kumbang koxi adalah predator yang berperan sebagai agen pengendali hayati serangga ditentukan oleh berbagai faktor ekologi. *Coccinellidae* merupakan salah satu

famili ordo *Coleoptera* yang memiliki keanekaragaman spesies dan kelimpahan yang cukup tinggi. Secara umum, ada beberapa faktor ekologi yang mempengaruhi keanekaragaman dan kelimpahan predator *Coccinellidae*, antara lain jenis habitat, mangsa, penggunaan insektisida dan keanekaragaman tumbuhan. *Coccinellidae* predator berjumlah 6000 spesies dan terdapat di daerah pegunungan, kawasan pertanian, daerah pantai hingga perkotaan [1]. Indonesia memiliki lebih dari 300 jenis kumbang *Coccinellidae* yang tersebar luas [2]. Beberapa spesies *Coccinellidae* sifatnya sebagai predator untuk mengendalikan populasi serangga lain pada tanaman budidaya seperti *aphids* atau kutu daun, kutu putih, tungau, kumbang tepung, kutu sisik kapas [3].

Berdasarkan data terbaru, serangan kutu daun pada tanaman mangga di beberapa provinsi di Indonesia mencapai luas tambah serangan (LTS) sebesar 4.318 pohon, dengan luas pengendalian (LP) mencapai 13.715 pohon [4]. Selain itu, penelitian menunjukkan bahwa kutu daun (*Aphididae*) menyerang berbagai tanaman pangan, termasuk jagung, kacang panjang, dan talas, dengan karakteristik koloni yang bervariasi [5]. Kondisi ini menunjukkan bahwa hama kutu daun tetap menjadi ancaman bagi sektor pertanian di Indonesia.

Banyak jenis *Coccinellidae* membuat petani kesulitan untuk menentukan spesies mana yang termasuk ke golongan predator atau hama. *Coccinellidae* memiliki ukuran yang kecil sehingga sulit untuk dilihat dengan mata telanjang. Hal ini menyebabkan petani membasmi predator karena menduga itu adalah hama. *Coccinellidae* bisa dibedakan dari pola pada punggungnya atau yang bisa disebut dengan polimorfisme pada pola punggung kumbang koksi. Polimorfisme adalah keberadaan individu

yang berbeda dengan morfologi yang berbeda, perilaku atau karakteristik yang berbeda dalam suatu populasi [6].

Polymorphism pola pada punggung kumbang koksi (*Coccinellidae*) memiliki peran ekologis yang penting, karena warna dan pola pada punggung kumbang koksi sebagai adaptasi individu dalam populasi serta sebagai warna peringatan apakah hewan tersebut merupakan predator ataupun hama, dan juga sebagai pengendalian hayati untuk petani [7].

Berdasarkan permasalahan diatas dibutuhkan suatu teknologi atau suatu metode untuk membedakan kumbang koksi yang termasuk ke golongan predator atau hama berdasarkan pola pada punggung kumbang koksi. Terdapat salah satu metode deep learning yang dapat mendeteksi secara akurat yaitu YOLO (*You Only Look Once*). YOLO merupakan metode yang cocok untuk identifikasi objek kecil terutama kumbang koksi.

YOLO (*You Only Look Once*) adalah salah satu metode deteksi objek dalam bidang pengolahan citra dan *computer vision*. YOLO memiliki kemampuan untuk mendeteksi objek secara *real-time*. YOLO memiliki beberapa karakteristik utama yaitu: (1) kemampuan deteksi secara *real-time*, (2) YOLO menghasilkan prediksi objek langsung dari satu *frame* citra, tanpa memerlukan langkah tambahan seperti *region proposal*, (3) YOLO memberikan koordinat *bounding box* yang tepat untuk setiap objek yang terdeteksi, (4) YOLO mampu mengatasi variasi skala objek dalam citra dengan baik, sehingga dapat mendeteksi objek yang berbeda ukuran secara efektif [8]. Pada penelitian ini menggunakan YOLO versi 5 yang merupakan metode terbaru. YOLO versi 5 memiliki *precision*, *recall*, dan *accuracy* yang lebih tinggi dibandingkan versi 3 dan 4. Selain akurasi yang tinggi YOLO versi 5 memiliki arsitektur yang

dapat memproses *frame* dengan sangat cepat [9].

Penelitian terkait menggunakan metode YOLO pernah dilakukan oleh Abas [10]. Pada penelitian ini dilakukan deteksi penyakit *leukimia* dengan menggunakan algoritma YOLO versi 2 dan mendapatkan akurasi 94,3 % dengan jumlah citra berjumlah 2448 citra. Penelitian selanjutnya dilakukan oleh Zhang mengenai identifikasi stomata dan juga menghitung stomata, pada penelitian ini menghasilkan akurasi 95,9 % dengan jumlah citra latihan sebanyak 2200 citra [11]. Penelitian serupa selanjutnya pernah dilakukan oleh Jun Liu & Xuewei Wang, penelitian ini menerapkan arsitektur *transfer learning MoblieNetV2* pada *backbone* YOLO versi 3 dalam mendeteksi penyakit bintik daun abu-abu pada tanaman tomat. Penelitian ini mendapati hasil bahwa untuk skor F1 dan nilai AP (*Average Precision*) adalah 94,13% dan 92,53 %, nilai rata-rata IoU pada data latihan adalah 89,92 %. Kecepatan deteksi yang didapat mencapai 246 *frame/s* di mana hampir empat kali lebih cepat dari SSD dan dua puluh kali lebih cepat dibandingkan *Faster-RCNN* [12].

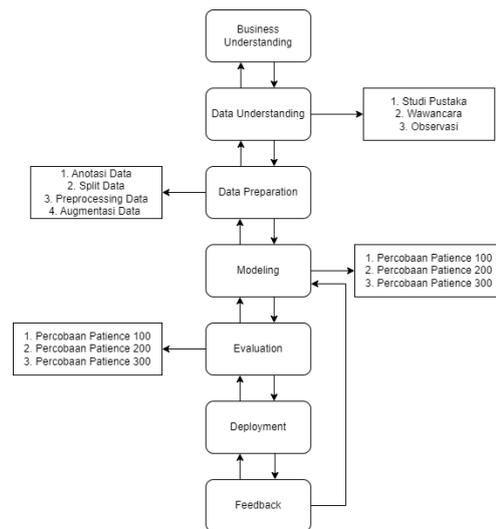
Berdasarkan penelitian sebelumnya dapat ditarik kesimpulan, bahwa akurasi dan kecepatan menjadi aspek yang penting untuk dipertimbangkan, sehingga pengguna dapat melakukan identifikasi pola polimorfisme pada punggung kumbang *coccinellidae* menggunakan perangkat android.

II. METODOLOGI PENELITIAN

A. Metode Pengembangan Sistem

Penelitian ini dilaksanakan menggunakan metode *CRISP-DM* dari IBM. *CRISP-DM* merupakan singkatan dari *Cross-Industry Standard Process for Data Mining*, dikembangkan pada 25 Desember 1996 oleh standarisasi *Daimler Chrysler*

(*Daimler-Benz*), *SPSS*, *NCR*. *CRISP-DM* yang kerap kali digunakan oleh industri global dalam mengembangkan suatu proyek untuk data *science*. Terdapat enam tahap dari metode *CRISP-DM* yaitu *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modeling*, *Evaluation*, dan *Deployment* [13]. Alur metode ini dapat dilihat pada Gambar berikut.



Gambar 1 Alur Metode CRISP-DM

1. *Business Understanding*

Coccinellidae dikenal sebagai predator alami bagi petani karena beberapa anggotanya memangsa serangga hama seperti spesies *aphids*. Meskipun memiliki peran yang penting dalam pengendalian hama, petani sering menghadapi kesulitan dalam mengidentifikasi spesies *Coccinellidae* yang merupakan predator, terutama karena banyaknya variasi spesies dan ukuran tubuhnya yang kecil, sulit untuk dilihat dengan mata telanjang. Akibatnya, terkadang petani secara keliru membasmi predator ini karena menganggapnya sebagai hama. Oleh karena itu, diperlukan suatu program atau aplikasi untuk mengidentifikasi kumbang *Coccinellidae* dengan tepat dan cepat.

YOLO versi 5 adalah model yang dinilai tepat untuk menyelesaikan permasalahan diatas.

Karena YOLO memiliki kecepatan komputasi yang sangat tinggi dan dapat melakukan klasifikasi. Aplikasi berbasis android akan dikembangkan berdasarkan model yang dihasilkan. Pemilihan aplikasi berbasis android dirasa cocok untuk pengguna, karena di masa kini hampir semua orang memiliki *smartphone* walaupun terkadang tidak dengan spesifikasi *high-end*.

2. Data Understanding

a) Analisis Kebutuhan Data

Kebutuhan terkait data yang akan digunakan dapat dilihat pada Tabel 1 dan Tabel 2. Tabel 1 berisi Data Kumbang dan Tabel 2 menunjukkan pembagian data yang akan digunakan termasuk yang sudah dilakukan *preprocessing* dan augmentasi.

Data gambar yang digunakan adalah gambar kumbang *Coccinellidae* yang terdiri dari 5 kelas sesuai dengan jenis kumbang yang sudah divalidasi oleh ahli yaitu *Henosepilachna Sparsa*, *Hippodamia Variegata*, *Menochilus sexmaculatus*, *Verania lineata*, dan *Coccinella transversalis*.

Tabel 1 Data Kumbang

No	Nama	Gambar	Jenis
1.	<i>Henosepilachna Sparsa</i>		Hama
2.	<i>Hippodamia Variegata</i>		Predator
3.	<i>Menochilus sexmaculatus</i>		Predator

4.	<i>Verania lineata</i>		Predator
5.	<i>Coccinella transversalis</i>		Predator

Tabel 2 Jumlah Dataset

No	Nama Data	Jumlah
1	Latih	70 % dari total = 750
2	Validasi	20 % dari total = 214
3	Uji	10 % dari total = 107
Total		1.071

b) Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan kumbang *Coccinellidae* yang diambil langsung dari pekebunan dan persawahan di Provinsi Bengkulu. Pengambilan gambar atau citra kumbang *Coccinellidae* dilakukan menggunakan kamera *smartphone* dengan spesifikasi 16 MP (*Megapixel*) pada jarak 5-15 cm. Waktu pengambilan data dilakukan dipagi hari dimulai jam 7.00 – 9.00 WIB. Hal ini dilakukan karena pada waktu tersebut, kumbang mulai muncul atau terlihat aktif. Jika pengambilan data dilakukan di siang atau sore hari kumbang cenderung berkurang aktivitasnya sehingga sulit ditemukan. Data yang diambil tidak memiliki kriteria khusus asalkan objek kelihatan itu sudah cukup, karena hal ini akan diatur pada tahapan augmentasi, dengan teknik augmentasi *rotation*, *brightness* dan *blur*.

3. Data Preparation

Tahapan data *preparation* meliputi anotasi, *split* data, *preprocessing*, dan augmentasi. Pada tahap anotasi, objek dalam

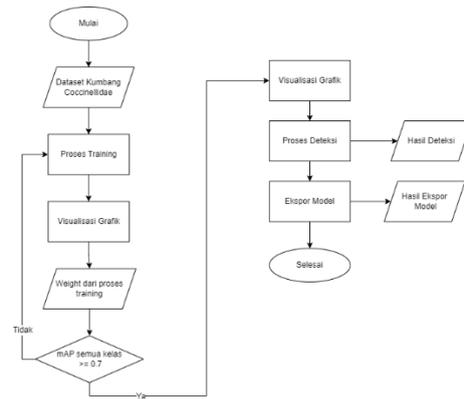
gambar diberi label atau *bouding box* untuk mendapatkan data yang teranotasi dengan baik. Proses anotasi yang dilakukan pada penelitian ini dibuat menggunakan website Roboflow. Selanjutnya, data dibagi menjadi tiga bagian yaitu data latih, data validasi, dan data uji. Pembagian dataset yang direkomendasikan adalah 70% data latih, 20% data validasi, dan 10% data uji [8]. Data latih digunakan untuk melatih model, data validasi digunakan untuk mengukur kinerja model selama proses pelatihan, dan data uji digunakan untuk menguji kinerja akhir model.

Tabel 3 Teknik Augmentasi

No	Teknik	Nilai
1.	<i>Rotation</i>	<i>Between -10° & +10°</i>
3.	<i>Brightness</i>	<i>Between -15% & +15%</i>
5.	<i>Blur</i>	3px

Pada penelitian ini digunakan 3 teknik augmentasi yaitu *rotation*, *brightness*, dan *blur*. Penggunaan teknik *rotation* digunakan untuk meningkatkan variasi dataset pelatihan. Dengan memutar gambar dalam berbagai sudut. Hal ini berguna untuk memperkaya *dataset* dan mencegah model menjadi terlalu terbiasa dengan orientasi tertentu. Teknik *brightness* mengubah tingkat kecerahan gambar agar mendapatkan data saat kondisi lapangan gelap dan terang. Hal ini membantu model melihat dan belajar dari berbagai kondisi pencahayaan yang berbeda. Teknik *blur* untuk mengatasi data yang tidak sempurna akibat *blur* karena resolusi maupun kompresi gambar.

4. Modeling



Gambar 2 Diagram Alir *Modeling*

Gambar 2 merupakan diagram alir tahap *modeling*. Tahap pemodelan diawali dengan pengumpulan data kumbang *Coccinellidae*, yang terdiri atas data latih, validasi, dan uji. Sebelum pelatihan, dilakukan pengaturan parameter, seperti *img*, *batch*, *epoch*, *patience*, *save period*, *data*, dan *cfg*.

Evaluasi pelatihan dilakukan melalui visualisasi grafik *precision*, *recall*, *box loss*, *class loss*, dan *object loss*. Hasil pelatihan juga menghasilkan *weight* yang digunakan dalam proses deteksi objek. Kinerja model dievaluasi menggunakan *Mean Average Precision (MAP)*, dengan standar MAP lebih dari 0,7 untuk memastikan keandalan model. Jika MAP yang diperoleh kurang dari atau sama dengan 0,7, maka dilakukan penyesuaian parameter atau penambahan data sebelum pelatihan ulang.

Setelah model memenuhi kriteria yang ditetapkan, dilakukan evaluasi lebih lanjut dengan *confusion matrix* dan pengujian menggunakan data uji. Model akhir kemudian diekspor dalam format *PyTorch Lite* untuk tahap deployment.

5. Evaluation

Tahap evaluasi akan dilakukan dengan proses validasi pada model dengan menggunakan dataset validasi terhadap bobot (*weight*) yang sebelumnya diperoleh dari proses *training* sebelumnya. Hasil evaluasi ini akan

menghasilkan nilai *Mean Average Precision* (MAP) dan juga *confusion matrix*.

6. Deployment

Pada tahap ini akan dilakukan proses *deployment* dengan merancang aplikasi yang dimulai dengan membuat *wireframe* dan *interface*, kemudian mengembangkan aplikasi berdasarkan rancangan yang telah dibuat.

7. Feedback

Pada penelitian ini dilakukan 2 jenis pengujian aplikasi. Pengujian pertama dilakukan menggunakan metode *black box* untuk menguji fungsionalitas aplikasi yang telah dibuat. Pengujian kedua dilakukan menggunakan metode SUS (*System Usability Scale*) untuk menguji aplikasi berdasarkan kepuasan pengguna terhadap aplikasi.

B. Kumbang Koksi (*Coccinellidae*)

Kumbang Koksi adalah salah satu hewan anggota *ordo Coleoptera*, *family Coccinellidae*. Mereka mudah dikenali karena memiliki bundar kecil dan punggungnya yang berwarna-warni serta ada beberapa jenis berbintik-bintik. Serangga ini dikenal sebagai sahabat petani, karena beberapa anggotanya memangsa serangga-serangga hama seperti spesies *aphis* [14]. Menurut buku “the pests of crops in indonesia” (1981) di indonesia ada terdapat 5 jenis kumbang koksi yaitu di antaranya: (1) *Henosepilachna sparsa*, (2) *Hippodamia variegata*, (3) *Menochilus sexmaculatus*, (4) *Verania lineata*, (5) *Coccinella transversalis* [15].

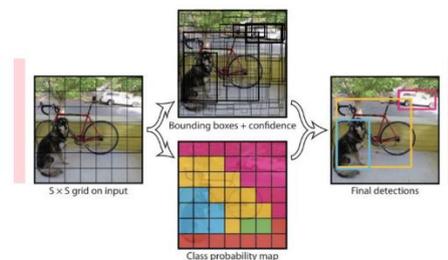
C. Polymorphism

Polimorphism dalam biologi merupakan variasi genetik terputus-putus yang mengakibatkan terjadinya beberapa bentuk atau tipe individu yang berbeda di antara anggota spesies tunggal. Variasi genetik terputus-putus membagi individu-individu dari populasi menjadi dua atau lebih bentuk yang sangat berbeda. Jika frekuensi dua atau lebih bentuk terputus-putus dalam suatu spesies terlalu

tinggi untuk dijelaskan mutasi, variasi serta populasi yang menampilkannya dikatakan polimorfik [16].

D. YOLO

YOLO (*You Only Look Once*) merupakan salah satu algoritma deteksi objek satu tahap. YOLO memiliki kecepatan komputasi yang sangat tinggi dan dapat memproses gambar secara *realtime*. Pada YOLO, komponen *object detection* yang terpisah disatukan ke dalam satu jaringan saraf tiruan. Sehingga YOLO memungkinkan pelatihan secara *end-to-end* dan memperoleh kecepatan yang tinggi dengan tetap mempertahankan presisi yang cukup tinggi[8].



Gambar 3 Ilustrasi YOLO

YOLO sekarang telah memasuki era YOLOv5 versi ke 6 berdasarkan *repository* asli YOLOv5 yaitu *ultralytic*. Berdasarkan dari *repository ultralytic* rilis versi 6 ini terdapat beberapa pembaruan penting, diantaranya yaitu [17]:

1. Terintegrasi langsung dengan roboflow.
2. Terdapat model baru yaitu YOLOv5n (1.9 juta parameter) yang lebih kecil dibandingkan YOLOv5s (7,5 juta params), yang ideal untuk solusi perangkat *mobile*.
3. Sepenuhnya sudah terintegrasi untuk mengekspor model ke *TensorFlow*, *Keras*, *TFLite* dan *TF.js*.
4. YOLOv5 sekarang sudah kompatibel dengan *OpenCV* dan *ONNX*. *Backbone* diperbarui sedikit lebih kecil, lebih cepat dan lebih akurat dengan cara:

- a. Mengganti *layer Focus()* dengan *layer Conv()*.
- b. Mengganti *layer SPP()* dengan *SPPF()*.
- c. Pengurangan lapisan *backbone P3 C3()* berulang dari 9 menjadi 6 untuk meningkatkan kecepatan.
- d. Menyusun ulang tempat pada ujung *backbone SPPF()*.
- e. Pengenalan kembali pintasan di lapisan *backbone C3()* terakhir
- f. Memperbarui *hyperparameter*.

E. *Mean Average Precision (MAP)*

Mean average precision (MAP) adalah perhitungan rata-rata dari *Average Precision*. *Average Precision* adalah jumlah nilai *precision* berdasarkan objek terpilih dari yang bernilai *true/relevant* dibagi dengan jumlah semua item terpilih *true/relevant* [18]. MAP merupakan rata-rata dari hasil *precision* yang telah didapat. MAP dapat dirumuskan sebagai berikut. [19].

$$mAP = \frac{1}{(n)} \sum_{k=1}^{k=n} AP_k$$

Keterangan:

n = Jumlah kelas

AP_k = Nilai presisi untuk kelas k

F. *Confusion Matrix*

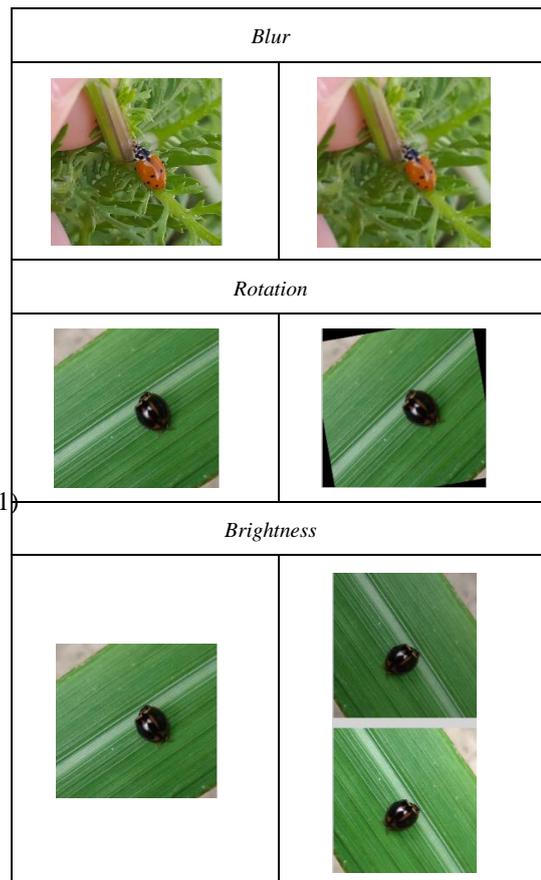
Confusion matrix adalah paramater yang dapat mengukur kinerja model klasifikasi. Pada dasarnya *confusion matrix* mengandung informasi yang membandingkan hasil klasifikasi yang dilakukan oleh sistem dengan hasil klasifikasi yang seharusnya. Pada pengukuran kinerja menggunakan *confusion matrix*, terdapat 4 (empat) istilah sebagai representasi hasil proses klasifikasi. Keempat istilah tersebut adalah *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)* dan *False Negative (FN)* [20].

III. *HASIL DAN PEMBAHASAN*

A. *Data Preparation*

Augmentasi diperlukan untuk menyesuaikan data dengan kondisi lingkungan dan membuat data menjadi lebih bervariasi, sehingga model dapat mempelajari data dengan baik. Hasil proses augmentasi data yang dilakukan di *website Roboflow* terlihat pada tabel 4.

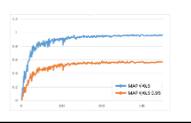
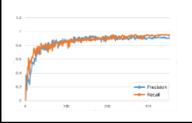
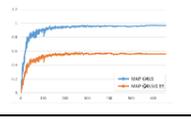
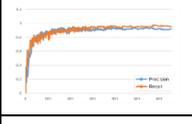
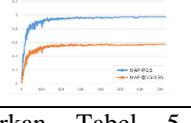
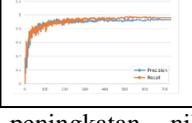
Tabel 4 Hasil Augmentasi



B. *Modeling*

Pada tahap ini gambar yang telah diambil dan dilakukan *preprocessing* serta augmentasi akan di implementasikan menggunakan model YOLO dengan melakukan tiga percobaan dalam penelitian ini dengan nilai *patience* sebesar 100, 200 dan 300.

Tabel 5 Hasil *Training*

<i>Patience</i>	<i>MAP</i>	<i>Precision/Recall</i>
100		
200		
300		

Berdasarkan Tabel 5, peningkatan nilai *patience* dari 100 ke 300 meningkatkan kinerja model dalam mengenali objek dan menghindari kesalahan deteksi. Pada *patience* 300, model mencapai konvergensi dengan jarak *precision* dan *recall* yang lebih kecil serta stabilitas pada komparasi *loss*. Model ini tidak mengalami *overfitting* maupun *underfitting*, dengan rata-rata *precision* dan *recall* di atas 0,7. Dengan demikian, *patience* 300 menghasilkan performa paling optimal dan stabil.

C. Evaluation

1. Mean Average Precision (MAP)

Penggunaan MAP ini didasarkan pada penelitian yang dilakukan oleh Aidouni , yang menjelaskan bahwa $mAP@.5$ dan $mAP@.5:.95$ sering digunakan dalam kompetisi seperti *MS COCO* dan *Pascal VOC Challenge* untuk mengevaluasi kinerja model [21]. Berikut hasil pengujian mAP dengan menggunakan IOU 0,5.

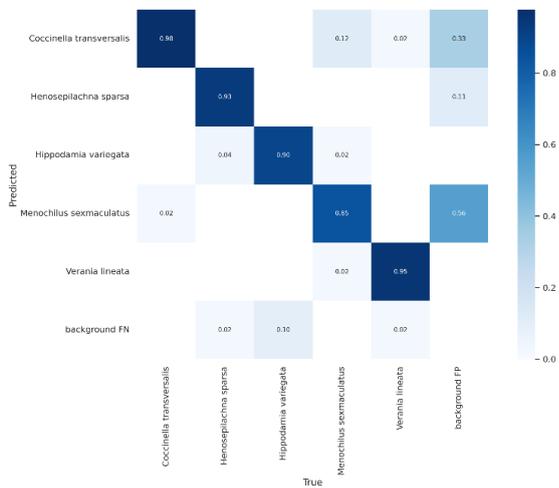
Tabel 6 Hasil Pengujian MAP dengan IOU 0,5

Class	Images	Labels	P	R	mAP@.5	mAP@.5:.95
<i>patience 100 (default)</i>						
All	214	222	0,884	0,931	0,957	0,578
<i>Coccinella transversalis</i>	214	44	0,798	0,955	0,976	0,649
<i>Henosepilachna sparsa</i>	214	45	0,933	0,911	0,943	0,492
<i>Hippodamia variegata</i>	214	40	0,847	0,925	0,915	0,57
<i>Menochilus sexmaculatus</i>	214	52	0,942	0,936	0,97	0,633
<i>Verania lineata</i>	214	41	0,9	0,927	0,983	0,548
<i>patience 200</i>						
All	214	222	0,884	0,931	0,957	0,578
<i>Coccinella transversalis</i>	214	44	0,798	0,955	0,976	0,649
<i>Henosepilachna sparsa</i>	214	45	0,933	0,911	0,943	0,492
<i>Hippodamia variegata</i>	214	40	0,847	0,925	0,915	0,57
<i>Menochilus sexmaculatus</i>	214	52	0,942	0,936	0,97	0,633
<i>Verania lineata</i>	214	41	0,9	0,927	0,983	0,548
<i>patience 300</i>						
All	214	222	0,924	0,945	0,966	0,58
<i>Coccinella transversalis</i>	214	44	0,824	1	0,973	0,628
<i>Henosepilachna sparsa</i>	214	45	0,961	0,933	0,95	0,457
<i>Hippodamia variegata</i>	214	40	0,903	0,9	0,952	0,612
<i>Menochilus sexmaculatus</i>	214	52	0,955	0,923	0,975	0,641
<i>Verania lineata</i>	214	41	0,975	0,967	0,982	0,561

Tabel 6 menunjukkan bahwa rata-rata MAP tertinggi untuk seluruh kelas berada pada nilai *patience* sebesar 300 dengan $mAP@.5$ sebesar 0,966. MAP terbesar diperoleh pada kelas *Verania lineata* yaitu berturut-turut 0,983, 0,983, 0,982. MAP terkecil diperoleh pada kelas *Hippodamia variegata* yaitu berturut-turut 0,915, 0,915, 0,952.

2. Confusion Matrix

Pada saat melakukan validasi, sistem akan menyimpan *confusion matrix* yang membandingkan hasil klasifikasi yang dilakukan oleh sistem dengan hasil klasifikasi yang seharusnya, seperti pada gambar 4 dan gambar 5. IoU sendiri merupakan pembatas untuk memilih *bounding box* yang benar dari sebuah objek di sel *grid*. Jika $\text{IoU} \geq 0.5$ maka bernilai *True Positive* sedangkan jika nilai $\text{IoU} < 0.5$ maka bernilai *False Positive*.



Gambar 4 Hasil *Confusion Matrix* dengan IoU 0,5 dan *Patience* 300



Gambar 5 Hasil *Confusion Matrix* dengan IoU 0,75 dan *Patience* 300

3. Hasil Deteksi Gambar

Tabel 7 Hasil Deteksi Gambar

No	Jenis <i>Coccinellidae</i>	Gambar
1	<i>Coccinella transversalis</i>	
2	<i>Henosepilachna sparsa</i>	
3	<i>Hippodamia variegata</i>	
4	<i>Menochilus sexmaculatus</i>	
5	<i>Verania lineata</i>	

Berikut adalah hasil deteksi dari tiap percobaan evaluasi dengan menggunakan data uji sebanyak 107.

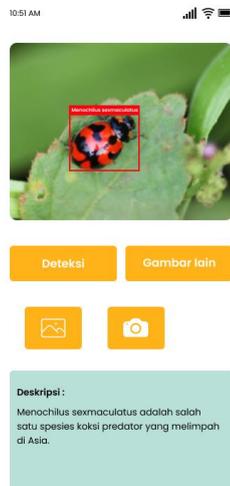
Tabel 8 Hasil Percobaan

Percobaan	<i>Patience</i>	IoU	Berhasil Deteksi	Gagal Deteksi
Percobaan 1	100	0,5	96 gambar (89,71 %)	11 gambar (10,29%)
Percobaan 2	100	0,75	58 gambar	49 gambar

			(54,20%)	(45,80%)
Percobaan 3	200	0,5	95 gambar (88,79%)	12 gambar (11,21%)
Percobaan 4	200	0,75	62 gambar (57,94%)	45 gambar (42,06%)
Percobaan 5	300	0,5	99 gambar (92,52%)	8 gambar (7,48 %)
Percobaan 6	300	0,75	74 gambar (69,16 %)	33 gambar (30,84%)

Tabel 7 Terdapat hasil percobaan deteksi gambar kumbang *coccinellidae*. Berdasarkan hasil percobaan, ditemukan bahwa percobaan 5 dengan *patience* 300 dan IoU 0,5 memiliki tingkat keberhasilan yang lebih tinggi dibandingkan percobaan lainnya yaitu 92,52%.

D. Deployment



Gambar 6 Menu Deteksi

Gambar tersebut menunjukkan hasil *deployment* aplikasi deteksi objek berbasis deep learning yang berhasil mengenali serangga *Menochilus sexmaculatus*. Aplikasi ini memiliki antarmuka intuitif dengan tombol "Deteksi" dan

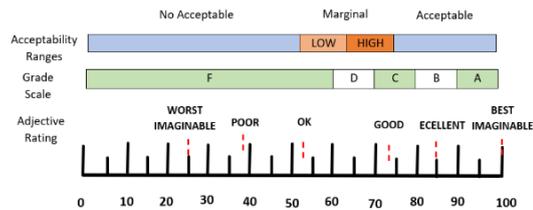
"Gambar Lain," serta menampilkan deskripsi spesies secara *real-time*.

E. Feedback

Tabel 9 Hasil Pengujian SUS

Responden	Hasil Pengujian	Skor
1	30 x 2,5	75
2	31 x 2,5	77,5
3	32 x 2,5	80
4	35 x 2,5	87,5
5	32 x 2,5	80
6	31 x 2,5	77,5
7	30 x 2,5	75
8	30 x 2,5	75
9	30 x 2,5	75
10	30 x 2,5	75
11	31 x 2,5	77,5
12	30 x 2,5	75
13	30 x 2,5	75
14	33 x 2,5	82,5
15	30 x 2,5	75
16	30 x 2,5	75
17	30 x 2,5	75
18	30 x 2,5	75
19	33 x 2,5	82,5
20	30 x 2,5	75
Hasil Pengujian SUS		1.545 / 20 = 77,25

Hasil pengujian menunjukkan skor yang didapat sebesar 77,25. Berdasarkan gambar 5.23, aplikasi yang diujikan dapat diterima (*acceptable*) oleh pengguna, dan berada di grade C dengan *GOOD* [22].



Gambar 7 Penentuan Hasil Pengujian

IV. KESIMPULAN

Penelitian ini menghasilkan dataset sebanyak 1.821 gambar dengan resolusi 1216 x 1216 piksel, diambil menggunakan kamera smartphone. Model YOLO dengan konfigurasi *patience* 300 dan 729 *epoch* menunjukkan kinerja optimal, menghasilkan mAP@0.5 sebesar 0,966 dan mAP@0.75 sebesar 0,962. *Confusion matrix* menunjukkan nilai background yang kecil, mencerminkan kemampuan

deteksi objek yang tinggi. Model berhasil mendeteksi 99 dari 107 gambar uji dengan akurasi dan presisi tinggi. Pengujian aplikasi menggunakan metode SUS menghasilkan skor 77,25, menunjukkan aplikasi dapat diterima pengguna.

REFERENSI

- [1] Vanderberg. (2009). The new world genus cycloneda (Coleoptera: Coccinellidae: Coccinellini): Historical review, new diagnosis, new generic and specific synonyms, and an improved key to North American species. *Entomological Society of Washington*, 221–236. <http://www.bushpea.com/in/pg/all/s/stripped%28micraspis%0Afrenata%29%2005.html>
- [2] Syahrawati, M., & Hasmindy, H. (2010). *Diversitas Coccinellidae predator pada pertanian sayuran di kota Padang. May 2014*, 1–17.
- [3] Joento. (2009). *Ladybird Beetles of Malaysia*.
- [4] Direktorat Perlindungan Hortikultura. Statistik Iklim, OPT, dan DPI Tahun 2023
- [5] M. Solakhudin Ar Rouf. Keanekaragaman dan Karakteristik Koloni Kutu Daun (Aphididae) pada Tanaman Pangan di Kabupaten Bantul dan Kabupaten Sleman. Skripsi, Fakultas Sains dan Teknologi, UIN Sunan Kalijaga Yogyakarta, 2021
- [6] Singh, V., Goyal, V., Devi, S., Hooda, S., & Malik, V. (2016). *Polymorphism of Cheilomenes sexmaculata (Fabricius) (Coleoptera: Coccinellidae) in Haryana, India*. 4(5), 548–551.
- [7] Alves, J. M., Lima, A. C., Pais, I. A., Amir, N., Celestino, R., Piras, G., Monne, M., Comas, D., Heutink, P., Chikhi, L., Amorim, A., & Lopes, A. M. (2015). Reassessing the evolutionary history of the 17q21 inversion polymorphism. *Genome Biology and Evolution*, 7(12), 3239–3248. <https://doi.org/10.1093/gbe/evv214>
- [8] Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). *You Only Look Once: Unified, Real-Time Object Detection*.
- [9] Thuan, D. (2021). *Evolution of Yolo Algorithm and Yolov5: the State-of-the-Art Object Detection Algorithm*. 61.
- [10] Abas, S. M., Abdulazeez, A. M., & Zeebaree, D. Q. (2022). A YOLO and convolutional neural network for the detection and classification of leukocytes in leukemia. *Indonesian Journal of Electrical Engineering and Computer Science*, 25(1), 200–213. <https://doi.org/10.11591/ijeecs.v25.i1.pp200-213>
- [11] Zhang, K., Wu, Q., & Chen, Y. (2021). Detecting soybean leaf disease from synthetic image using multi-feature fusion faster R-CNN. *Computers and Electronics in Agriculture*, 183(February), 106064. <https://doi.org/10.1016/j.compag.2021.106064>
- [12] Liu, J., & Wang, X. (2021). Early recognition of tomato gray leaf spot disease based on MobileNetv2-YOLOv3 model. *Plant Methods*, 16(1), 1–16. <https://doi.org/10.1186/s13007-020-00624-2>
- [13] IBM. (2021). *Pengantar CRISP-DM*. <https://www.ibm.com/docs/en/spss-modeler/SaaS?topic=guide-introduction-crispdm>.
- [14] Ardyla. (2016). *Kepik atau Kumbang Koksi*. Biodiversity Warriors. <https://biodiversitywarriors.kehati.or.id/artikel/kepik-atau-kumbang-koksi/>
- [15] Kalshoven. (1981). *The Pests of Crops in Indonesia* (I. Baru (ed.)). Van Hoeve
- [16] Augustyn. (2022). *Polimorfisme*. Britannica. <https://www.britannica.com/science/polymorphism-biology>
- [17] Jocher. (2021). *YoloV5*. <https://github.com/ultralytics/yolov5>
- [18] Ridho, A., Rahman, F., Moch, I., Bijaksana, A., & Romadhony, A. (2017). *Perankingan Jawaban yang Terklasifikasi pada Komunitas Tanya-Jawab dengan Term Frequency dan Similarity Measure Features Ranking the Classified Answer from Questioning Answering Community Using Term Frequency and Similarity Measure Features Abstrak*. 4(1), 1093–1107.
- [19] Sandy, W. K., Widodo, A. W., & Sari, Y. A. (2018). Penentuan Keaslian Tanda Tangan Menggunakan Shape Feature Extraction Techniques Dengan Metode Klasifikasi K Nearest Neighbor dan Mean Average Precision. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 2(3), 1083–1091.
- [20] Karsito, & Susanti, S. (2019). Klasifikasi Kelayakan Peserta Pengajuan Kredit Rumah Dengan Algoritma Naïve Bayes Di Perumahan Azzura Residencia. *Jurnal Teknologi Pelita Bangsa*, 9, 43–48.
- [21] Aidouni, M. (2019). *Evaluating Object Detection Models: Guide to Performance Metrics*. <https://doi.org/10.11591/ijeecs.v25.i1.pp200-213%0D>
- [22] Ayu Gede Rishma Wiwin Astari, I., & Tri Anindia Putra, I. N. (2021). Analisis Sistem Informasi Kemdikbud Studi Kasus Pada Sd Negeri 2 Dawan Klod Menggunakan Metode Sus. *JIKO (Jurnal Informatika Dan Komputer)*, 4(1), 23–30. <https://doi.org/10.33387/jiko.v4i1.2378>