

Deteksi realtime dan notifikasi hewan serangga di suatu area pertanian dengan menggunakan kamera Dan berbasis IoT

1st Muhammad Ilham Shalahuddin

Fakultas Teknik Elektro
Universitas Telkom
Bandung,Indonesia

ilhams@student.telkomuniversity.ac.id

2nd Sony Sumaryo

Fakultas Teknik Elektro
Universitas Telkom
Bandung,Indonesia

sonysumaryo@telkomuniversity.ac.id

3rd Iswahyudi Hidayat

Fakultas Teknik Elektro
Universitas Telkom
Bandung,Indonesia

iswahyudihidayat@telkomuniversity.ac.id

Abstrak - Argikultur adalah suatu upaya untuk memproduksi atau membuat makanan, pangan, serat dan hasil lainnya dalam bidang pertanian yang memerlukan tenaga manusia. Terutama di Indonesia yang merupakan negara agraris, dimana sebagian besar masyarakat Indonesia memenuhi kebutuhan hidupnya dengan bekerja di sektor pertanian. Banyak faktor – faktor yang dapat mempengaruhi hasil produksi sektor pertanian, terutama serangga – serangga hama yang memakani tanaman – tanaman yang ditanam para petani dan membuat petani untuk menggunakan pestisida berlebih yang berefek pada kesuburan tanah dan hasil produksi pertanian. Sistem deteksi serangga dan notifikasi real time ini menggunakan kamera sebagai media input berbentuk citra digital dimana hasil input ini akan diproses dengan Teknik Image processing untuk mengolah hasil visual dari kamera dan Machine learning untuk mendeteksi serangga tersebut. sistem akan memberikan keluaran berbentuk notifikasi Whatsapp apabila terdapat serangga yang terdeteksi. Hasil training dataset menghasilkan nilai mAP_0.5 sebesar 0.967 dengan nilai precision sebesar 0.926 dan recall sebesar 0.918, dan hasil pengujian alat di dunia nyata menghasilkan nilai confidence dengan rasio 0.5 – 0.7 yang dapat memberikan notifikasi dalam bentuk Whatsapp

Kata Kunci: Serangga, image processing, Machine learning, citra digital

I. PENDAHULUAN

Argikultur adalah suatu upaya untuk memproduksi atau membuat makanan, pangan, serat dan hasil lainnya dalam bidang pertanian yang memerlukan tenaga manusia[1]. Terutama di Indonesia yang merupakan negara agraris, dimana sebagian besar masyarakat Indonesia memenuhi kebutuhan hidupnya dengan bekerja di sektor pertanian. Sektor pertanian juga memiliki peranan penting sebagai penopang ekonomi Indonesia dalam bentuk komoditas ekspor yang diperlukan negara lainnya, dan juga sebagai sumber material yang dapat diolah dan dikonsumsi oleh masyarakat Indonesia

Banyak faktor – faktor yang dapat mempengaruhi hasil produksi sektor pertanian, terutama serangga – serangga hama yang memakani tanaman – tanaman yang ditanam para petani. Kehadiran serangga hama di lahan pertanian sering

kali tidak terdeteksi tepat waktu. Keterlambatan dalam identifikasi hama dapat mengakibatkan penggunaan pestisida yang tidak tepat waktu dan kurang efektif, sehingga menyebabkan kerugian yang besar yang berefek pada kesuburan tanah dan hasil produksi pertanian. Oleh karena itu, diperlukan sistem deteksi dan pengendalian hama yang efektif dan efisien untuk meningkatkan produktivitas pertanian.

Kemajuan pada teknologi Internet of Things (IoT) dan kecerdasan buatan (AI) menawarkan solusi inovatif untuk mengatasi tantangan ini. Sistem deteksi serangga waktu nyata yang berbasis IoT dan menggunakan kamera dapat memberikan pemantauan secara terus-menerus terhadap area pertanian. dan dapat memberikan notifikasi real time untuk petani mengawasi area pertaniannya diluar area pertanian. Sistem ini bekerja dengan mengolah data input dari sensor kamera yang kemudian di proses dengan Machine learning, dan hasil proses data dari Machine learning akan terkirim ke petani secara real time.

II. KAJIAN TEORI

A. Deteksi Real Time Serangga

Rusaknya atau buruknya kualitas hasil argikultur dapat disebabkan oleh berbagai faktor, Selain kondisi cuaca dan kesuburan tanah, hama yang menggerogoti tanaman di lahan pertanian merupakan salah satu faktor yang dapat mempengaruhi kesehatan dan kualitas hasil tanaman.

Dalam hal ini, banyak petani yang terlambat mengambil tindakan pengendalian kerusakan akibat hama karena kurangnya peringatan sehingga mengakibatkan kerusakan pada tanamannya. Oleh karena itu, petani berbuat curang dengan menggunakan pestisida secara berlebihan sehingga berdampak pada kualitas hasil panennya.

Metode deteksi serangga tradisional, seperti penggunaan perangkap lengket dan pengamatan langsung, sangat memakan waktu dan memerlukan sumber daya manusia dalam jumlah besar. Sistem deteksi serangga real-time ini tidak hanya menghilangkan ketidakakuratan namun juga bertujuan untuk lebih mempersiapkan petani dalam

menghadapi serangan serangga dan mengurangi penggunaan pestisida yang berlebihan.

B. Serangga

Insecta yang berasal dari bahasa latin *Insectium*, dapat disebut juga sebagai serangga atau heksapoda. Heksapoda berasal dari kata *heksa* yang artinya enam (7) dan kata *podos* yang berarti kaki. *Insecta* mempunyai ciri khas yaitu berkaki 6 (tiga pasang). Diperkirakan oleh para ahli zoologi, *insecta* mempunyai jumlah lebih dari 70.000 jenis. *Insecta* berhabitat hampir di seluruh bagian biosfer, kecuali di laut.



GAMBAR 2.2
Serangga

Keanekaragaman serangga baik dalam hal kelimpahan dan kepunahan maupun kekayaannya juga sangat terkait dengan tingkat tropik lainnya. Hal ini disebabkan adanya interaksi yang terjadi, baik diantara kelompok fungsional serangga maupun dengan tumbuhan yang selanjutnya akan membentuk keanekaragaman serangga itu sendiri. Penurunan keanekaragaman spesies serangga herbivora dapat menimbulkan "efek domino" terhadap keanekaragaman musuh alami serangga-serangga tersebut. Kemungkinan ini cukup beralasan karena serangga mendukung hampir setengah dari jumlah spesies predator dan parasitoid.

C. Machine Learning

Machine learning adalah salah satu bentuk aplikasi kecerdasan buatan (AI) yang dapat memberikan sistem kemampuan untuk mempelajari suatu data dan mengaplikasikan ke dalam sistem secara otomatis dari pengalaman tanpa diprogram secara eksplisit. *Machine learning* berfokus pada pengembangan program yang dapat mengakses data dan menggunakannya untuk belajar secara mandiri. Program komputer yang diimplementasikan dengan *machine learning* dapat meningkatkan performa program dikarenakan kinerja program sangat bergantung dari jumlah dan kualitas data yang diberikan. Harapannya adalah jika data yang ada cukup, *machine learning* akan mempelajari pola dan menghasilkan kecerdasan buatan untuk data baru yang dimasukkan. Nama lain dari *machine learning* adalah pembelajaran induktif, karena kode dari mesin mencoba menyimpulkan struktur dari data[8]

1. Komponen Machine Learning

Machine learning terdiri atas beberapa komponen berikut ini[8]:

a. Learning

Pada bagian ini algoritma digunakan sebagai dasar untuk proses *machine learning*. Algoritma dipilih berdasarkan jenis masalah yang ingin diselesaikan atau

dipecahkan, karena tidak ada algoritma yang dapat menyelesaikan semua jenis masalah yang ada.

b. Data collection

Data collection atau dataset merupakan kumpulan data yang belum terolah untuk menjadi sumberdaya untuk dipelajari. Data - data ini berbentuk data yang sudah diberikan label maupun yang belum diberikan label. Kuantitas dari dataset merupakan faktor penting untuk proses *self learning* agar dapat memahami struktur masalah.

c. Representation

Representation adalah proses *machine learning* memvisualisasikan atau menggambarkan data - data berdasarkan dari fitur yang dipilih, sehingga dapat digunakan untuk proses pembelajaran. Misalnya, untuk dapat mengklasifikasikan gambar jenis daun, maka gambar akan diwakilkan sebagai nilai array. Setiap sel akan berisi nilai dalam warna dalam satu piksel. Pemilihan representasi yang baik akan menentukan untuk mendapatkan hasil yang lebih baik.

d. Goal

Bagian ini memvisualisasikan atau merepresentasikan alasan mengapa program *machine learning* ini belajar dari data-data untuk menyelesaikan masalah. Tujuan ini membantu untuk menentukan bagaimana dan apa yang harus digunakan dalam proses pembelajaran dan representasi apa yang digunakan.

e. Target

Target adalah fitur dari data yang telah dipelajari serta hasil akhir yang didapatkan. Target dapat berupa klasifikasi data yang tidak memiliki label, representasi data yang sesuai dengan pola, memprediksi masa depan, dan respons terhadap stimulus atau strategi.

2. Tipe Machine Learning

Machine learning terbagi menjadi 3 tipe berdasarkan cara pembelajarannya[8]

a. Supervised learning

Supervised learning adalah proses pembelajaran *machine learning* yang bersumber dari contoh-contoh data yang telah diberikan label sebelumnya. *Supervised learning* membutuhkan data berlabel yang diberikan dari operator untuk dapat melakukan pelatihan data, Dimana algoritma nya akan menemukan metode untuk mendapatkan masukan atau keluaran yang diinginkan. Salah satu bentuk pengaplikasian metode *supervised learning* yaitu ketika operator memerlukan *model* untuk mengidentifikasi jenis jenis pohon, maka operator memerlukan dataset berupa video atau foto pohon yang telah diberi label jenis jenis pohon yang operator ingin identifikasi.

b. Unsupervised learning

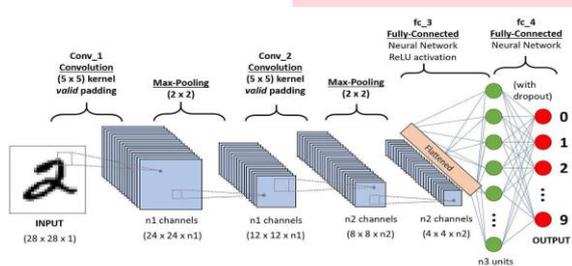
Unsupervised learning merupakan antitesis dari metode *Supervised learning*. dimana algoritma sistem mempelajari data dan menyimpulkan sendiri tanpa masukkan dari operator dalam bentuk label. Dengan data yang tersedia memungkinkan algoritma untuk menemukan pola dan struktur dari data. Dua tahap yang banyak digunakan operator *machine learning* untuk belajar dari data tanpa label data adalah pengelompokan (*clustering*) dan pengurangan dimensi.

c. Reinforcement learning

Reinforcement learning adalah salah satu metode *machine learning* yang bereaksi terhadap Tindakan untuk memaksimalkan akumulasi nilai imbalan. Cara kerja metode *reinforcement learning* mencapai tujuannya melalui banyak proses *trial and error* berdasarkan lingkungan yang tidak tentu dan mendapatkan *feedback* dari proses *trial and error* nya.

D. CNN

Convolutional Neural Network (CNN) adalah pengembangan dari *Multilayer Perceptron* (MLP) yang didesain untuk mengolah data dua dimensi. CNN termasuk dalam jenis *Deep Neural Network* karena kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra. Pada kasus klasifikasi citra, MLP kurang sesuai untuk digunakan karena tidak menyimpan informasi spasial dari data citra dan menganggap setiap piksel adalah fitur yang independen sehingga menghasilkan hasil yang kurang baik



GAMBAR 2.2
CNN

Dalam *Convolutional Neural Network*, konvolusi adalah operasi linier yang melibatkan penggandaan sekumpulan bobot dengan masukan, seperti jaringan saraf tradisional. Dengan asumsi bahwa teknik ini dirancang untuk masukan dua dimensi, perkalian dilakukan antara larik data masukan dan larik bobot dua dimensi (disebut filter atau kernel). Filter lebih kecil dari data masukan, dan jenis perkalian yang diterapkan antara filter dan patch warna masukan dari ukuran filter adalah perkalian titik. Produk titik adalah perkalian input dan patch berukuran filter dan elemen di antara filter, lalu jumlahnya selalu berupa nilai.[9]

CNN terdiri dari beberapa lapisan utama:

E. Convolutional Layer:

Convolutional Layer merupakan lapisan pertama yang digunakan untuk mengekstrak berbagai fitur dari gambar masukan. Pada lapisan ini, operasi matematika konvolusi dilakukan antara gambar input dan filter dengan ukuran $M \times M$ tertentu. Dengan menggeser filter di atas gambar input, produk titik diambil antara filter dan bagian-bagian dari gambar input sehubungan dengan ukuran filter ($M \times M$).

F. Pooling Layer:

Pooling layer menggantikan keluaran jaringan pada lokasi tertentu dengan mendapatkan ringkasan statistik dari keluaran terdekat. Hal ini membantu mengurangi ukuran spasial representasi, yang mengurangi jumlah komputasi dan bobot yang diperlukan. *Pooling operation* diproses pada setiap irisan representasi secara individual.

G. Fully Connected Layer (FC Layer):

Fully Connected Layer (FC Layer) merupakan lapisan neuron pada aktifitas sebelumnya dapat bergabung ke neuron pada lapisan selanjutnya. Lapisan ini terdiri dari bobot dan bias. Lapisan ini biasanya ditempatkan sebelum lapisan output dan membentuk beberapa lapisan terakhir dari Arsitektur CNN.

H. Dropout

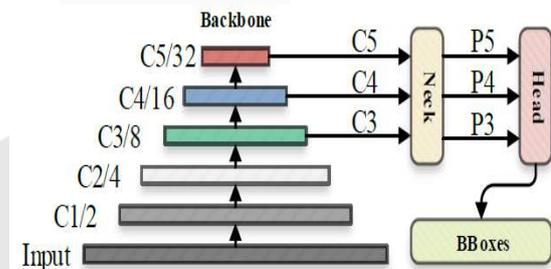
Dropout merupakan bentuk regularisasi jaringan syaraf dimana neuron akan dipilih secara acak untuk tidak digunakan pada proses *training*. ini bertujuan untuk membantu mencegah overfitting dengan meningkatkan akurasi pengujian, dengan mengorbankan akurasi pelatihan. Untuk setiap mini-batch dalam set pelatihan kami, lapisan dropout, dengan probabilitas p , secara acak memutuskan input dari lapisan sebelumnya ke lapisan berikutnya dalam arsitektur jaringan.

I. Output Layer

Lapisan terakhir yang biasanya menggunakan fungsi aktivasi *softmax* (untuk klasifikasi multi-kelas) atau *sigmoid* (untuk klasifikasi biner), untuk menghasilkan probabilitas atau prediksi akhir.

J. YOLOv5

YOLO (You Only Look Once) adalah algoritma pendeteksi objek real-time yang dikembangkan pada tahun 2015 oleh Joseph Redmon dan Ali Farhadi. YOLO adalah detektor objek satu tahap yang menggunakan jaringan saraf konvolusional (CNN) untuk memprediksi kotak pembatas dan probabilitas kelas objek dalam gambar masukan. YOLO pertama kali diimplementasikan menggunakan kerangka Darknet



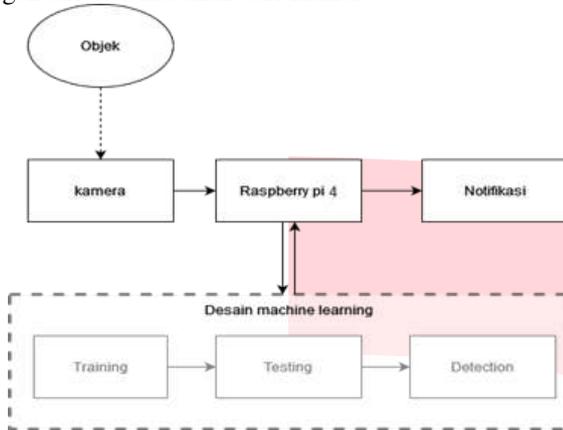
GAMBAR 2.3
Flowchart inference YOLOv5[10]

Algoritma YOLO membagi gambar masukan menjadi kisi-kisi sel, dimana pada setiap sel ini, algoritma akan memprediksi probabilitas keberadaan objek dan koordinat kotak pembatas objek. Algoritma ini juga memprediksi kelas objek. Tidak seperti pendeteksi objek dua tahap seperti R-CNN dan variannya, YOLO memproses seluruh gambar secara *one pass*, sehingga lebih cepat dan efisien

III. METODE

A. Diagram Blok Sistem

Pada penelitian tugas akhir ini akan merancang Desain Deteksi realtime dan notifikasi hewan serangga di suatu area pertanian dengan menggunakan kamera dan berbasis IoT, Sistem yang dibangun mempunyai fungsi membaca, memproses citra yang didapatkan, kemudian akan disampaikan dalam bentuk notifikasi. sehingga dapat dilihat oleh pengguna, agar sistem dapat memvalidasi dan menampilkan data mesin kendaraan. Perancangan ini berbasis mikrokontroler Raspberry Pi 4 sebagai otak pengendali data masukan dari Kamera.



GAMBAR 3.1
Diagram Blok Sistem

B. Desain Perangkat Keras



GAMBAR 3.2
Desain perangkat keras

C. Alat

1. Raspberry pi 4

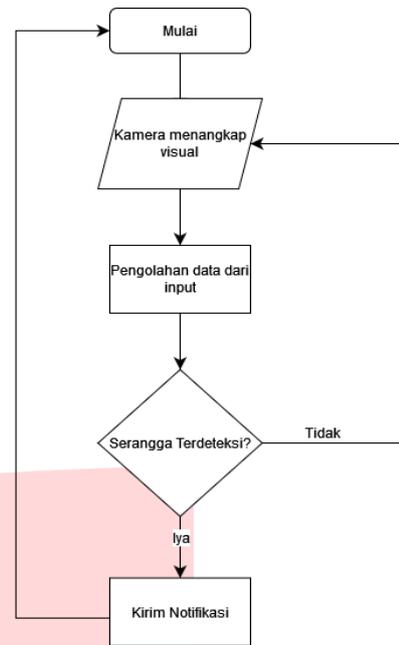
Raspberry Pi adalah serangkaian komputer papan tunggal (SBC), seukuran kartu kredit, yang dapat digunakan untuk menjalankan program perkantoran, permainan komputer, dan bertindak sebagai pemutar media untuk video definisi tinggi.

Raspberry Pi dikembangkan oleh sebuah yayasan nirlaba bernama Raspberry Pi Foundation. Tujuan utama dari sistem Raspberry Pi adalah untuk mempromosikan dan mendidik siswa dalam komputasi dasar.

2. Kamera

Webcam adalah kamera video umum yang memungkinkan pengguna merekam video dan foto setelah terhubung ke komputer pribadi.

D. Diagram Alir Sistem



GAMBAR 3.5
Diagram Alir Sistem

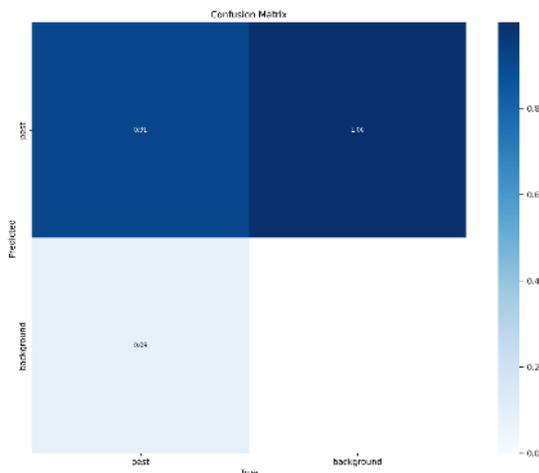
Diagram alir sistem "Deteksi dan pemberitahuan serangga secara real-time di area pertanian menggunakan kamera dan basis IoT" Proses inisialisasi sistem awal dimana Raspberry Pi dan modul kamera diaktifkan dan siap digunakan. Setelah sistem disiapkan, kami melanjutkan ke fase pengambilan gambar. Gambar yang diambil dianalisis dalam fase deteksi serangga menggunakan model pembelajaran mesin yang telah dilatih sebelumnya. Jika ditemukan serangga, proses dilanjutkan ke langkah berikutnya. Jika tidak ada serangga yang terdeteksi, sistem kembali ke proses akuisisi citra. Jika serangga terdeteksi, data diproses dan informasi dikirim dalam bentuk pemberitahuan yang diterima pengguna yang terkena dampak.

IV. HASIL DAN PEMBAHASAN

A. Hasil training

1. Confusion Matrix

Confusion Matrix adalah tabel yang digunakan untuk mendefinisikan kinerja algoritme klasifikasi. Confusion Matrix memvisualisasikan dan memberikan pemahaman secara detail apakah model training bekerja dengan baik atau tidak.



GAMBAR 4.6
Grafik Confusion Matrix

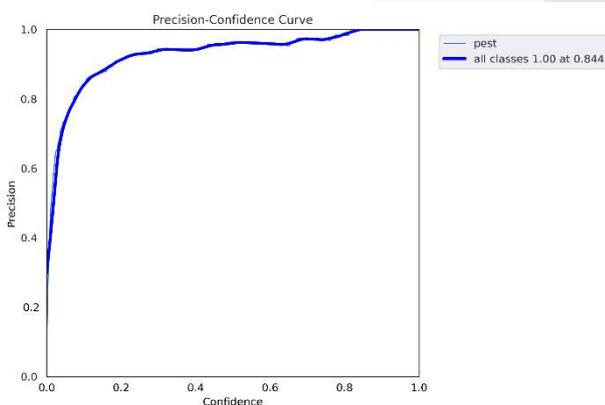
Confusion matrix digambarkan dengan tabel 2x2 yang terdiri dari empat karakteristik dasar (angka) yang digunakan untuk mendefinisikan metrik pengukuran pengklasifikasi. Keempat angka tersebut adalah:

- a. TP (True Positive):
(kiri atas). Model memprediksi hasil positif (hasil aktualnya positif).
- b. TN (True Negative):
(kanan bawah). Model memprediksi hasil negatif (hasil aktualnya negatif).
- c. FP (False Positive):
(kiri bawah). Model memprediksi hasil positif (hasil aktualnya negatif). Juga dikenal sebagai kesalahan Tipe I
- d. FN (False Negative):
(kanan atas). Model memprediksi hasil negatif (hasil aktualnya positif). Juga dikenal sebagai kesalahan Tipe II

2. Precision

Precision mengukur seberapa akurat prediksi Anda, yaitu persentase prediksi Anda benar Precision sendiri dapat dikalkulasikan dengan rumus

$$Precision = \frac{TP}{TP + FP}$$



GAMBAR 4.7
Grafik Precision

X-axis = Confidence Threshold
Y-axis = Precision

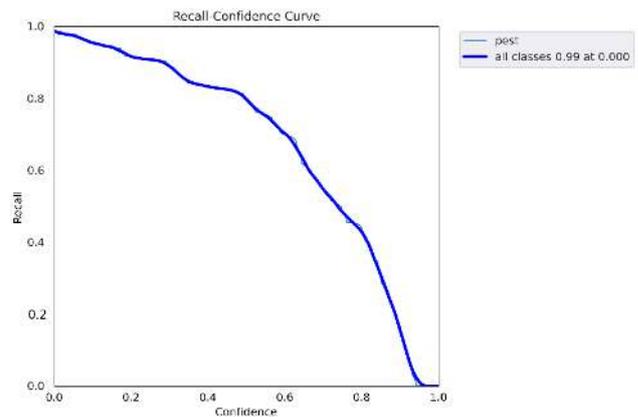
Grafik ini menunjukkan bagaimana Precision berubah pada tiap confidence threshold. Semakin tinggi tingkat Threshold, semakin tinggi confidence dari model untuk mendeteksi objek.

3. Recall

Recall adalah rasio observasi positif yang diprediksi dengan benar terhadap semua observasi positif yang sebenarnya.

Recall sendiri dapat dikalkulasikan dengan rumus

$$Recall = \frac{TP}{TP + FN}$$



GAMBAR 4.8
Grafik Recall

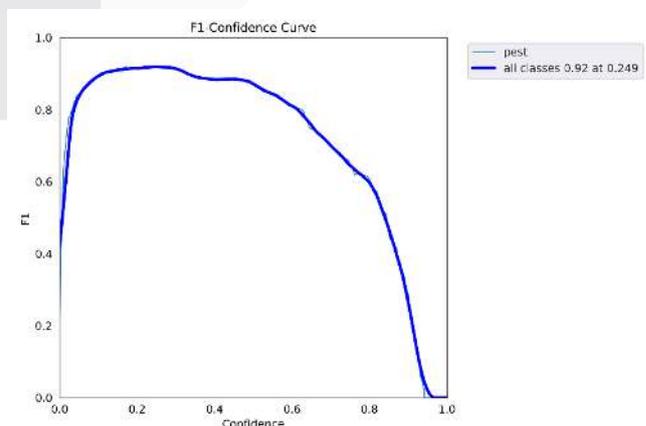
X-axis = Confidence Threshold
Y-axis = Recall

Grafik ini menunjukkan bagaimana recall berubah pada tiap confidence threshold. Semakin tinggi tingkat Threshold, semakin rendah recall dari model ini untuk menangkap true positive dari semua positive yang tertangkap

4. F1 Score

F1 Score adalah rata-rata harmonis dari precision dan recall, memberikan penilaian yang seimbang terhadap kinerja model dan mempertimbangkan positif asli dan positif palsu. F1 Score sendiri dapat dikalkulasikan dengan rumus

$$F1\ Score = \frac{2 * Precision * Recall}{Precision + Recall}$$



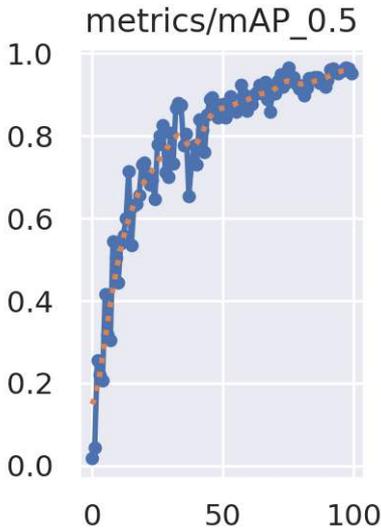
GAMBAR 4.9
Grafik F1 Score

X-axis = Confidence Threshold
 Y-axis = F1 score

Grafik ini menunjukkan hubungan antara *F1 score* dan *confidence threshold*. Ini memberikan komprehensif penilaian kemampuan model untuk mengidentifikasi secara akurat *true positive* dan menghindari *false positive*

5. *mAP*

mAP (Mean Average Precision) adalah metrik yang digunakan untuk mengukur kinerja model yang berfokus pada tugas pendeteksian objek dan pengambilan informasi pada gambar.



GAMBAR 4.10
 Grafik mAP

X-axis = *mAP@0.5*
 Y-axis = jumlah iterasi training dataset (*epoch*)

Grafik ini menunjukkan adanya tren peningkatan nilai rata – rata *precision* tiap iterasi *training dataset*. Semakin banyak iterasi *training dataset* yang dilakukan, semakin akurat prediksi dari model untuk mendeteksi objek.

TABEL 1
 Hasil Training

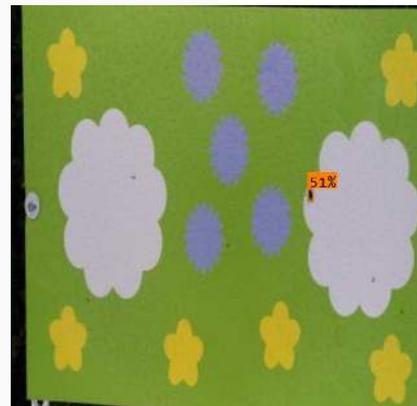
| Load Model | | YOLOv5n |
|------------|----|---------|
| Pest | AP | 100% |
| | TP | 123 |
| | FP | 0 |
| Precision | | 0.926 |
| Recall | | 0.918 |
| F1 Score | | 0.6254 |
| mAP 0.5 | | 0.967 |

B. *Pengujian Alat*

Pengujian alat Deteksi realtime dan notifikasi hewan serangga di suatu area pertanian dengan menggunakan kamera dan berbasis IOT dilakukan di halaman rumah penulis. Dimana halaman rumah terdapat tanaman kelengkeng, jeruk nipis, dan berbagai jenis tanaman lainnya. Dan diperlukannya sumber listrik yang mudah diraih



GAMBAR 4.11
 Alat deteksi



GAMBAR 13
 Citra dari alat



GAMBAR 14
 Citra dari alat



GAMBAR 15
Citra dari alat

Citra yang didapat memiliki nilai confidence dengan rasio 0.5 – 0.7. nilai ini akan tersimpan didalam Raspberry Pi dan akan dibuatkan oleh sistem suatu *detection log* dimana *log* ini terdapat riwayat objek serangga yang terdeteksi sebelumnya, disertai dengan nilai *confidence* yang tertera

Sistem Notifikasi menggunakan basis dari Twilio. Dan bentuk notifikasi berupa pesan melalui aplikasi *Whatsapp*. Notifikasi mempunyai *delay* 100 detik dan hanya memberikan notifikasi apabila objek serangga yang terdeteksi memiliki nilai *confidence* ≥ 0.5 untuk menghindari notifikasi dengan informasi yang sama menumpuk.



GAMBAR 4.18
Notifikasi *Whatsapp*

V. KESIMPULAN

Berdasarkan pengujian yang dilakukan, dapat disimpulkan bahwa sistem telah terbukti mampu mendeteksi

serangga menggunakan model yang dilatih pada YOLOv5n. Hasil pelatihan tiap kelas menunjukkan jumlah true positif lebih besar dibandingkan jumlah false positif, dan nilai mAP_0.5 sebesar 96.7% untuk iterasi terbaik. Hal ini membuktikan bahwa sistem dapat mengidentifikasi objek secara optimal, Selain itu, sistem juga dapat mengeluarkan peringatan berupa notifikasi *Whatsapp* ketika serangga terdeteksi.

REFERENSI

- [1] (2020, December 14). Pengertian Agrikultur: Sektor, Jenis dan Produk Agrikultur di Indonesia. Accurate Online. <https://accurate.id/bisnis-ukm/pengertian-agrikultur/>
- [2] Nanni, L., Maguolo, G., & Pancino, F. (2020). Insect pest image detection and recognition based on bio-inspired methods. *Ecological Informatics*, 57, 101089. <https://doi.org/10.1016/j.ecoinf.2020.101089>.
- [3] Kasinathan, T., Singaraju, D., & Uyyala, S. R. (2021). Insect classification and detection in field crops using modern machine learning techniques. *Information Processing in Agriculture*, 8(3), 446–457. <https://doi.org/10.1016/j.inpa.2020.09.006>.
- [4] Miranda, J. L., Gerardo, B. D., & Tanguilig III, B. T. (2014). Pest Detection and Extraction Using Image Processing Techniques. *International Journal of Computer and Communication Engineering*, 3(3), 189–192. <https://doi.org/10.7763/ijcce.2014.v3.317>.
- [5] Gondal, Danish & Khan, Yasir Niaz. (2015). Early Pest Detection from Crop using Image Processing and Computational Intelligence. *FAST-NU Research Journal* ISSN: 2313-7045. 1..
- [6] Bjerge, Kim & Alison, Jamie & Dyrmann, Mads & Frigaard, Carsten & Mann, Hjalte & Høye, Toke. (2022). Accurate detection and identification of insects from camera trap images with deep learning. 10.1101/2022.10.25.513484.
- [7] Perhimpunan Entomologi Indonesia - Menghimpun, Mengembangkan, Dan Mengamalkan. (n.d.). <https://Pei-Pusat.Org/Berita/11/Pengertian-Klasifikasi-Serta-Ciri-Ciri-Insecta-Serangga.Html>.
- [8] Shukla, N. (2018). *Machine learning with TensorFlow*. Shelter Island, NY: Manning Publications.
- [9] L. Alzubaidi et al., “Review of Deep Learning: Concepts, CNN Architectures, challenges, applications, future directions - *Journal of Big Data*,” SpringerOpen, <https://journalofbigdata.springeropen.com/articles/10.1186/s40537-021-00444-8> (accessed Jul. 19, 2024).
- [10] Liu, H.; Sun, F.; Gu, J.; Deng, L. SF-YOLOv5: A Lightweight Small Object Detection Algorithm Based on Improved Feature Fusion Mode. *Sensors* **2022**, 22, 5817. <https://doi.org/10.3390/s22155817>
- [11] M. Faizan, “Roboflow,” Medium, <https://medium.com/red-buffer/roboflow-d4e8c4b52515> (accessed Jun. 20, 2024).

- [12] A. Moltzau, "Pytorch governance and history," Medium, <https://alexmoltzau.medium.com/pytorch-governance-and-history-2e5889b79dc1> (accessed Apr. 29, 2024).
- [13] O. Store, "What is twilio? how does it work," Medium, <https://medium.com/@outright-store/what-is-twilio-how-does-it-work-b28c50c06797> (accessed Jul. 19, 2024).
- [14] Raspberry pi 4 model B specifications – raspberry pi, <https://www.raspberrypi.com/products/raspberry-pi-4-model-b/specifications/> (accessed April. 24, 2024).
- [15] "Xiaovv USB camera webcam vlogging XIAOVV full HD 1080p web cam - basic webcam," UKPBJ ITS, https://ekatalog.its.ac.id/shop/product/xiaovv-usb-camera-webcam-vlogging-xiaovv-full-hd-1080p-webcam-basic-webcam-1332?category=7&order=list_price%2Basc (accessed Aug. 26, 2024).
- [16] N. Farid, 'pest detection Dataset', *Roboflow Universe*. Roboflow, Aug-2023.

