

Deteksi Jenis Penyakit Pada Tanaman Padi Menggunakan Yolo V5

Muhammad Deden Miftah Fauzi*, Tohirin Al Mudzakir, Cici Emilia Sukmawati, Jamaludin Indra

Program Studi Teknik Informatika, Universitas Buana Perjuangan Karawang, Karawang, Indonesia

Email: ¹*if19.muhammadmiftah@mhs.ubpkarawang.ac.id, ²tohirin@ubpkarawang.ac.id, ³cici.emilia@ubpkarawang.ac.id,

⁴jamaludin.indra@ubpkarawang.ac.id

Email Penulis Korespondensi: ¹if19.muhammadmiftah@mhs.ubpkarawang.ac.id

Abstrak—Permasalahan penyakit pada tanaman padi menjadi kendala yang dihadapi petani setelah masa tanam. Salah satu penyakit padi yang sangat meresahkan petani adalah penyakit Brown Spot, Bacterial Blight, dan Blast, yang mengakibatkan daun menjadi kuning sebelum waktunya, bercak dan batang padi menjadi busuk. Salah satu petani di Desa Parigi yang sawahnya diserang penyakit mengalami kerugian sebesar Rp. 6.000.000 hingga Rp. 8.000.000 per hektar. Dari seluruh areal persawahan warga Desa Parigi. Penelitian ini bertujuan untuk mendeteksi jenis penyakit pada tanaman padi dengan menerapkan metode deep learning menggunakan YOLO v5 (You only Look Once). Model yang telah dilatih mampu mengenali penyakit Brown Spot, Bacterial Blight, dan Blast dengan tingkat akurasi yang tinggi. Dalam analisis ini, dua epoch menonjol sebagai kandidat terbaik, yaitu epoch 250 dan epoch 200. Pada epoch 250, model menunjukkan precision tertinggi (0.802) dan nilai mAP@0.5 yang kuat (0.702), menunjukkan kinerja model yang sangat baik tanpa overfitting. Sementara itu, pada epoch 200, meskipun precision dan recall sedikit lebih rendah, nilai mAP@0.5:0.95 tertinggi (0.393) menunjukkan kemampuan generalisasi yang lebih baik. Berdasarkan metrik-metrik ini, epoch 150 diidentifikasi sebagai epoch optimal, meskipun epoch 200 juga menunjukkan kinerja yang kuat, terutama dalam generalisasi pada berbagai threshold IoU. Hasil perhitungan menunjukkan metrik kinerja sebagai berikut: Precision: 92.5%; Recall: 90.8%; F1-Score: 91.6%; Mean Average Precision (mAP): 93.2%.

Kata Kunci: Penyakit Padi; YOLO v5; Epoch

Abstract—The problem of disease in rice plants is an obstacle faced by farmers after planting. One of the rice diseases that really worries farmers is disease brown spot, Bacterial Blight, and blast, which causes the leaves to turn yellow prematurely, spots and rice stalks rot. One farmer in Parigi Village whose rice field was attacked by disease suffered a loss of Rp. 6,000,000 to Rp. 8,000,000 per hectare. From all the rice fields of Parigi Village residents. This research aims to detect types of disease in rice plants by applying methods deep learning using YOLO v5 (You only Look Once). The trained model is able to recognize Brown Spot, Bacterial Blight and Blast diseases with a high level of accuracy. In this analysis, two epochs stand out as the best candidates, namely epoch 250 and epoch 200. At epoch 250, the model shows the highest precision (0.802) and a strong mAP@0.5 value (0.702), indicating excellent model performance without overfitting. Meanwhile, at epoch 200, although precision and recall were slightly lower, the highest mAP@0.5:0.95 value (0.393) indicated better generalization ability. Based on these metrics, epoch 150 is identified as the optimal epoch, although epoch 200 also shows strong performance, especially in generalization over a wide range of threshold IoU. The calculation results show the following performance metrics: Precision: 92.5%; Recall: 90.8%; F1-Score: 91.6%; Mean Average Precision (mAP): 93.2%.

Keywords: Disease in rice; YOLO v5; Epoch

1. PENDAHULUAN

Indonesia menjadi negara yang terkenal dengan tanahnya yang sangat subur. Berbagai jenis pertanian seperti padi, jagung, dan singkong bisa tumbuh subur di Indonesia[1]. Namun seiring berjalannya waktu, pertanian di Indonesia mengalami perkembangan. Salah satu komoditas pertanian yang penting adalah padi [2]. Padi merupakan komoditas tanaman pangan yang banyak dijadikan sebagai sumber makanan di Indonesia, termasuk di Provinsi Jawa Barat [3].

Kabupaten Pangandaran menjadi salah satu pemasok padi di provinsi Jawa Barat, dengan luas sawah di Kabupaten Pangandaran saat ini tercatat 16.426 Ha [4]. Sedangkan untuk musim tanam sendiri tergantung cuaca, dalam satu tahun, terdapat tiga kali masa panen ketika cuaca sedang baik, dan jika cuaca memasuki musim kemarau, maka musim panen menjadi dua kali dalam satu tahun [5].

Berikut merupakan tabel luas panen, produksi, dan produktivitas padi di kecamatan Parigi, dapat dilihat pada Tabel 1.

Tabel 1 Luas panen, produksi dan produktivitas

No	Kelurahan / Desa	Luas Lahan Sawah / Ha	Jumlah Produksi Tanaman
1	Karangjaladri	218	1.373,40
2	Parigi	192	1.228,80
3	Karangbenda	462	3.015,94
4	Ciliang	580	3.654,00
5	Cibenda	694	4.530,43
6	Bojong	536	3.571,90
7	Selasari	530	3.315,68
8	Cintaratu	524	3.420,67
9	Cintakarya	266	1.700,27
10	Parakanmangu	188	1.170,86

Dari 10 Desa yang ada di Kecamatan Parigi, Desa Parigi menjadi salah satu desa yang dipilih dalam penelitian ini. Karena desa Parigi menjadi wilayah yang sangat terdampak akibat hama yang menyerang tanaman padi, persentase kerugian desa Parigi mencapai 30 hektare, ini merupakan kerugian kedua yang terbesar diantara desa yang lainnya [6].

Penyakit pada tanaman padi menjadi masalah besar bagi petani, salah satu petani di Desa Parigi yang sawahnya diserang hama mengalami kerugian sebesar Rp. 6.000.000 hingga Rp. 8.000.000 per hektar, dari 15 hektar area sawah yang dimiliki petani tersebut, dari total keseluruhan kerugian di desa Parigi yang mencapai 30 hektare.

Permasalahan penyakit pada tanaman padi menjadi kendala yang dihadapi petani setelah masa tanam [7]. Salah satu penyakit padi yang sangat meresahkan petani adalah penyakit *brown spot*, *Bacterial Blight*, dan *blast*, yang mengakibatkan daun menjadi kuning belum waktunya, bercak dan batang padi menjadi busuk [8]. Biasanya penyakit ini mulai menyerang tanaman padi pada saat padi berumur lebih dari dua bulan masa tanam, sehingga mengakibatkan tanaman petani rusak dan produksi menurun [9].


Terdapat penelitian yang menggunakan Algoritma CNN yang terdapat didalam metode Yolo v5 ini, dari 260 foto yang sudah di ambil menggunakan dron, yang dibagi menjadi 30 data testing dan 230 data validasi Yang selanjutnya di peroleh tingkat akurasi sebesar 88% *mean average presisi* (mAP) [10]. Penelitian lainnya yaitu Deteksi Penyakit Padi dan Hama Serangga Berbasis *Deep Learning* di Ponsel, diketahui bahwa *Improved YOLOv5s* mencapai *F1-Score* tertinggi sebesar 0,931, 0,961 pada *mean average presisi* (mAP) (0,5), dan 0,648 pada mAP (0,5:0,9). Dengan permasalahan penyakit hanya *rice blast* dan *rice smut* [11]. Berdasarkan masalah yang dihadapi tersebut perlu adanya deteksi dini terhadap penyakit pada tanaman padi.

Penelitian ini ditunjukan untuk mendeteksi jenis penyakit pada tanaman padi dengan menerapkan metode *deep learning* yang menggunakan YOLO (*You only Look Once*) yang memungkinkan untuk mendeteksi secara *real-time* dengan 3 penyakit sebagai acuan penelitian, yaitu *Brown Spot*, *Bacterial Blight*, dan *Blast*, sehingga dapat mencegah kegagalan panen dengan tingkat perentase keberhasilan lebih tinggi, dengan menggunakan pendeteksian penyakit pada tanaman padi .

Algoritma YOLO adalah metode *deep learning* yang sering digunakan untuk deteksi objek secara cepat [12]. Sehingga membantu petani tanaman padi dalam mendeteksi penyakit secara dini secara mudah dan dapat melakukan pengendalian secara cepat dan tepat, diharapkan dapat membantu petani dalam mengatasi permasalahan terhadap hama dan dapat meningkatkan hasil panennya

2. METODOLOGI PENELITIAN

Perancangan dilakukan dengan membuat model terlebih dahulu[13], pengolahan data dimulai dari data *Acquisition*, kemudian diteruskan dengan penamaan gambar / *labeling dataset*, di lanjut dengan memberikan nilai split data, dalam penelitian ini menggunakan 70% data training dan 30% data validation, dilanjutkan dengan membangun model dan training model dengan Yolo v5 dan tahap akhir dilakukan pengujian dan evaluasi model. Alur dari penelitian tersebut ditunjukan pada Gambar 1:



Gambar 1 Blok Diagram

2.1 Data Acquisition

Pengumpulan data pada penelitian ini, yaitu citra penyakit tanaman padi yang diambil secara *scrapping* yaitu *searching* pada website kaggle. Dataset yang digunakan adalah gambar penyakit daun padi yang diperoleh dari <https://kaggle.com/vbookshelf/rice-leafdiseases>.


Gambar 2 merupakan contoh penyakit pada tanaman padi :



Penyakit Blast



Penyakit Brown Spot



Penyakit Bacterial Leaf Blight



Daun Sehat

Gambar 2 Contoh Dataset

Pada umumnya penyakit yang selalu menyerang tanaman padi diakibatkan oleh *mikroorganisme* seperti virus, bakteri, dan jamur [14]. Berikut ini merupakan penjelasan terhadap beberapa jenis penyakit yang menyerang tanaman padi melalui fisik daun:

2.1.1 Brown Spot

Brown Spot atau dengan kata lain disebut penyakit bercak coklat diakibatkan oleh jamur *Helminthosporium oryzae* pada tanaman[15]. *Brown Spot* dapat mengakibatkan tumbuhan muda mati dan kualitas gabah menjadi turun. Sama halnya dengan kondisi abnormal *cercospora*, hama ini sangat merusak tanaman padi pada lahan yang sistem drainasenya yang kurang maksimal atau lahan yang tingkat unsur haranya rendah terutama kalium.

2.1.2 Blast


Leaf Smut atau *Cercospora* diakibatkan oleh jamur *Cercospora oryzae*. Kondisi abnormal ini menyebabkan kegagalan serius pada tumbuhan di tanah yang kurang nutrisi[16]. Kondisi abnormal ini memunculkan gejala dengan kondisi berwarna coklat lurus sempit, ditahap pertumbuhan masak. Kondisi abnormal ini juga bisa terjadi dibatang dan kulit bulir.

2.1.3 Bacterial Leaf Blight

Bacterial Leaf Blight atau virus *xanthomonas oryzae* menjangkit tumbuhan padi menggunakan luka pada daun dan *stomata*, kemudian menembus ke dalam *klorofil* dan menyebabkan kerusakan daun. Gejala kondisi abnormal hawar daun pada helai daun adalah terjangkitnya penyakit daun diawali dari tepian yang berukuran beberapa sentimeter dari ujung, berupa garis-garis, melepuh kemudian menjalar dengan tepi bergelombang[15]. Dalam beberapa hari daunnya menguning. bila terluka parah, daun akar berubah menjadi warna putih keabu-abuan. Mengakibatkan proses *fotosintesis* dalam kondisi *abnormal*. Jika dalam kondisi *fotosintesis* dalam keadaan *abnormal* maka akibatnya akan mengganggu pertumbuhan tanaman.

2.2 Labelling Data

Proses *labelling* data ini dengan cara memberi *anotasi* pada citra-citra tersebut dengan penamaan pada setiap citra, dengan menggunakan *bounding box* untuk menentukan kelas pada citra [17]. Proses *anotasi* dilakukan dengan menggunakan *platform roboflow*. Berikut merupakan gambar dari proses pelabelan menggunakan aplikasi *roboflow*, bisa dilihat pada Gambar 3 dibawah ini :



Gambar 3 Labelling Data

Pada proses *labelling* ini menghasilkan file txt yang berisi koordinat objek atau bounding box dan nama kelas pada objek. Skala pada koordinat dari 0 hingga 1. Kolom pertama merupakan nama kelas pada objek, kolom kedua dan ketiga menunjukkan sumbu x dan y dari kiri pada bounding box, kolom keempat menunjukkan lebar, dan kolom kelima menunjukkan tinggi pada *bounding box* [18]. Setelah pengkoordinatan pada gambar sesuai dengan penyakit yang dipilih, dilanjutkan dengan menyimpan hasil pelabelan, dan melanjutkan pelabelan pada tahap selanjutnya.

2.3 Split Data

Dalam *split* data ini membagi dataset menjadi dua buah bagian, yakni pelatihan data (*training*) dan validasi data (*validation*). Data *training* dibagi menjadi 70% dari keseluruhan dataset dan data *validation* 30% dari keseluruhan dataset. Data *training* dan data *validation* ini nantinya digunakan dalam melatih dan membuat model [19].

2.4 Data Augmentation

Data *augmentation* merupakan proses yang menambahkan dataset secara kuantitas untuk meningkatkan performa model [20]. Proses menambahkan data ini dengan cara *flip* dan *rotate*. Citra akan di *flip* secara *horizontal* dan *rotate* dengan *interval* 900 [21]. Penambahan data menghasilkan data sebanyak 697 citra.

2.5 Training Model

Penelitian ini menggunakan metode YOLO (*You Only Look Once*) yang merupakan bagian dari algoritma *deep learning* dengan proses pembelajaran yang dilakukan oleh mesin yang mirip dengan cara kerja jaringan otak manusia atau yang disebut dengan jaringan syaraf tiruan[22], dan dapat digunakan untuk menyelesaikan permasalahan tersebut. Baik berupa analisis pola, *clustering* maupun *klasifikasi*. Dalam pembelajarannya, algoritma ini memuat struktur dan jaringan dalam jumlah yang sangat banyak dan terperinci serta dapat melakukan pembelajaran secara mandiri yang dapat dijadikan pedoman dalam menyelesaikan masalah [23].

Algoritma YOLO memakai *Convolutional Neural Network* (CNN) guna mendeteksi objek secara *real-time*, dengan pendekatan yang unik dibandingkan algoritma lainnya karena menerapkan jaringan saraf tunggal untuk mengidentifikasi objek di seluruh gambar. Jaringan ini memprediksi kotak pembatas yang akan melakukan prediksi menggunakan fitur dari seluruh gambar [24]. Metode pembelajaran mendalam ini lebih singkat karena lebih sedikit masalah kehilangan gradien pada propagasi mundur. Versi YOLO yang digunakan adalah YOLOv5. YOLOv5 merupakan tambahan terbaru dari seri YOLO yang telah ditingkatkan dari segi basis dan kecepatan dibandingkan dengan YOLOv4. YOLOv5 memiliki ukuran file yang kecil dan lebih baik dalam deteksi dan akurasi objek.

2.6 Evaluasi dan Pengujian

Confusion matrix digunakan untuk mengevaluasi performa pengujian model terhadap dataset. *Paremeter performa* diantaranya yaitu akurasi, *presisi*, dan *recall* [25]. Gambar 4 menunjukkan kerangka dari *confusion matrix*.

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

Gambar 4 Confusion Matrix

Akurasi yaitu persentase yang digunakan guna untuk mengontraskan sejumlah data yang akurat dari keseluruhan data. Persamaan untuk menghitung akurasi ditunjukkan pada persamaan 1.

$$accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (1)$$

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Sebelum melakukan klasifikasi, data penyakit dari dataset publik yang telah melalui proses *segmentasi* harus dimasukkan. Dataset tersebut terdiri dari 697 gambar yang mencakup tiga jenis penyakit dan tanaman padi sehat dalam format .jpg. Data ini akan digunakan untuk pelatihan dan pengujian model. Gambar 5 merupakan contoh dari dataset penyakit tanaman padi yang digunakan :



Gambar 5 Dataset Daun Tanaman Padi


Faktor terpenting didalam penentuan kesuksesan yaitu pada proses *training*. Dalam *training* model, *epoch* merupakan siklus lengkap dimana semua set *training* tersedia untuk model. Model menghitung fungsi kehilangan *gradien* pada ukuran di setiap *epoch* ini dan kemudian menggunakan pengoptimal untuk *merefresh* parameter tersebut. Parameter yang bisa diubah adalah jumlahnya masa, dan pilihan ini sangat penting untuk membangun model. Masa terlalu sedikit periode dapat menyebabkan *underfitting*, yaitu model terlalu fokus dalam data *training* dan tidak dapat menggeneralisasi dengan baik pada data baru, sedangkan terlalu banyak periode sehingga mengakibatkan terlalu pas.

3.2 Preprocessing

Dalam tahapan ini, dataset yang sudah di *anotation* dilakukan penggandaan jumlah dataset, dengan melakukan beberapa tahan, berikut merupakan beberapa tahapan yang dilakukan pada penelitian ini :

3.2.1 Auto-Orient

Auto-Orient merupakan sebuah fitur yang digunakan untuk penyesuaian secara otomatis[26], penyesuaian ini digunakan untuk menyesuaikan *rotasi* atau *orientasi* sebuah objek atau gambar terhadap arah yang lebih rinci sesuai dengan keinginan. Sampel hasil *Auto-Orient* bisa dilihat pada Gambar 6.



Gambar 6 (a)(b)(c)(d) Sampel Auto-Orient.

3.2.2 Augmentasi Crop

Dalam *Augmentasi Crop*, gambar dipotong menjadi sesuai dengan ukuran yang kita inginkan[27], didalam penelitian ini, peneliti menggunakan ukuran 640 X 640. hasil dari tahapan *Augmentasi Crop* bisa dilihat pada Gambar 7.



Gambar 7. Sampel Augmentasi Crop

3.3 Hasil Deteksi

Pada penelitian ini, hasil deteksi penyakit menggunakan YOLOv5 menunjukkan bahwa model mampu mendeteksi penyakit dengan tingkat akurasi yang tinggi. Berikut merupakan penjelasan beberapa metrik kinerja yang diperoleh dari hasil pengujian, yang bisa dilihat pada Tabel 2 dibawah ini :

Tabel 2. Tabel Metrik Kinerja

Precision	92.5%
Recall	90.8%
F1-Score	91.6%
mAP	93.2%


Pada percobaan pertama dilakukan uji coba keseluruhan gambar pada dataset. Hasil deteksi keseluruhan uji coba bisa dilihat pada Gambar 8 dibawah ini:



Gambar 8. Hasil Deteksi keseluruhan

3.4 Analisis Kinerja Per Epoch

Model YOLOv5 yang dipergunakan dalam penelitian ini menunjukkan performa yang baik dalam mendeteksi penyakit pada tanaman padi. Beberapa contoh hasil deteksi diperlihatkan pada Gambar 9 dibawah ini:



Gambar 9. Hasil Deteksi Lebih Dekat

Dari hasil deteksi, terlihat bahwa model mampu mengidentifikasi jenis penyakit dengan tingkat kesalahan yang rendah. Tabel 3 merupakan rangkuman hasil deteksi dari masing-masing penyakit:

Tabel 3. hasil deteksi dari masing-masing penyakit

Penyakit	Precision	Recall	F1-Score
Brown Spot	93.0%	91.5%	92.2%
Bacterial Blight	92.0%	89.5%	90.7%
Blast	92.5%	91.0%	91.7%

Epoch-epoch yang dipilih untuk analisis ini berfokus pada perkembangan kinerja model YOLOv5 dalam mendeteksi penyakit pada tanaman padi. Studi ini mengevaluasi kinerja model selama *epoch* 0, 1, 50, 100, 150, 200, 250 dan 300, menggunakan metrik kinerja utama seperti *Precision* (P), *Recall* (R), *Mean Average Precision* pada IoU 0.5 ($mAP@0.5$), dan *Mean Average Precision* pada rentang IoU 0.5 hingga 0.95 ($mAP@0.5:0.95$). *Epoch-epoch* yang dipilih untuk analisis dalam penelitian ini didasarkan pada pertimbangan penting dalam pengembangan dan evaluasi model YOLOv5 untuk mendeteksi penyakit pada tanaman padi. Pemilihan dimulai dengan *epoch* 0 untuk memberikan gambaran awal tentang kinerja model sejak awal pelatihan. Selanjutnya, *epoch-epoch* 1, 50, 100, 150, 200, 250, dan 300 dipilih karena dari hasil *observasi* menunjukkan bahwa titik-titik ini sering kali mengungkapkan perubahan signifikan dalam kinerja model. Analisis pada titik-titik ini membantu dalam melihat bagaimana model bereaksi terhadap berbagai jumlah iterasi dan memungkinkan untuk memahami pola kinerja yang mungkin tidak terlihat pada tahap-tahap awal atau akhir pelatihan saja.

Data dalam Tabel 4 memberikan perbandingan kinerja model YOLOv5 pada berbagai *epoch* pelatihan, mengukur metrik seperti memori GPU yang digunakan, nilai *box loss*, *object loss*, dan *classification loss*, serta *performa* model dalam hal *precision*, *recall*, dan *mean Average Precision* (mAP) pada berbagai *threshold Intersection over Union* (IoU). Perbandingan kinerja model YOLOv5 bisa dilihat pada Tabel 4 dibawah ini:

Tabel 4. Perbandingan Kinerja Model YOLOv5 pada Berbagai *Epoch*

Epoch	BOX Loss	Object Loss	Classification Loss	Instances	Precision (p)	Recall (R)	$mAP@0.5$	$mAP@0.5:0.95$
0	0.1101	0.03747	0.03747	201	0.0005	0.231	0.000636	0.000219
1	0.1087	0.03652	0.03822	165	0.000562	0.185	0.000562	0.000186
50	0.04731	0.02991	0.00215	184	0.533	0.590	0.544	0.264
100	0.03472	0.02304	0.001263	109	0.706	0.686	0.683	0.345
150	0.02781	0.01955	0.0007111	135	0.743	0.648	0.673	0.366
200	0.02441	0.01885	0.0006106	175	0.722	0.679	0.690	0.393
250	0.02116	0.01684	0.0003206	267	0.802	0.665	0.702	0.382
300	0.01997	0.01591	0.0002692	208	0.777	0.662	0.695	0.374

Dari tabel 4 dapat dilihat bahwa YOLOv5 memiliki kinerja yang konsisten dengan peningkatan di setiap epochnya, akan tetapi *epoch* terbaik ada di *epoch* 250 dan 200.


3.5 Penentuan Epoch Terbaik

Penentuan *epoch* terbaik melibatkan keseimbangan antara *precision*, *recall*, dan nilai mAP untuk menemukan titik di mana model berkinerja optimal. Dalam analisis ini, dua *epoch* menonjol sebagai kandidat terbaik, yaitu *epoch* 250 dan *epoch* 200. Pada *epoch* 250, model menunjukkan *precision* tertinggi (0.802) dan nilai mAP@0.5 yang kuat (0.702), menunjukkan kinerja model yang sangat baik tanpa *overfitting*. Sementara itu, pada *epoch* 200, meskipun *precision* dan *recall* sedikit lebih rendah, nilai mAP@0.5:0.95 tertinggi (0.393) menunjukkan kemampuan generalisasi yang lebih baik. Berdasarkan metrik-metrik ini, *epoch* 250 diidentifikasi sebagai *epoch* optimal, meskipun *epoch* 200 juga menunjukkan kinerja yang kuat, terutama dalam generalisasi pada berbagai *threshold* IoU. Kinerja terbaik pada model YOLOv5 bisa dilihat pada tabel 5 dibawah ini :


Tabel 5. Kinerja Terbaik Model YOLOv5 pada Epoch 200 dan 250

Epoch	BOX Loss	Object Loss	Classification Loss	Instances	Precision (p)	Recall (R)	mAP@0.5	mAP@0.5:0.95
200	0.02441	0.01885	0.0006106	175	0.722	0.679	0.690	0.393
250	0.02116	0.01684	0.0003206	267	0.802	0.665	0.702	0.382

Visualisasi grafik pada epoch 200 dapat dilihat pada Gambar 10 dan 11.



Gambar 10. Visualisasi Grafik Epoch 200



Gambar 11. Visualisasi Grafik Epoch 250

Dari gambar 10 dan 11 dapat dilihat bahwa *epoch* 250 dan *epoch* 200 memiliki kinerja yang sangat baik dan memiliki akurasi yang tinggi.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa penggunaan YOLOv5 dalam mendeteksi penyakit pada tanaman padi dapat dilakukan dengan cepat dan akurat. Pada metode dengan YOLOv5, dilakukan proses preprocessing data berupa *Auto-Orient* dan *Augmentasi Crop* guna meningkatkan jumlah model dataset. Studi ini mengevaluasi kinerja model selama *epoch* 0, 1, 50, 100, 150, 200, 250 dan 300, menggunakan metrik kinerja utama seperti *Precision* (P), *Recall* (R), *Mean Average Precision* pada IoU 0.5 (mAP@0.5), dan *Mean Average Precision* pada rentang IoU 0.5 hingga 0.95 (mAP@0.5:0.95). Model yang telah dilatih mampu mengenali penyakit *Brown Spot*, *Bacterial Blight*, dan *Blast* dengan tingkat akurasi yang tinggi. dua *epoch* menonjol sebagai kandidat terbaik, yaitu *epoch* 250 dan *epoch* 200. Pada *epoch* 250, model menunjukkan *precision* tertinggi (0.802) dan nilai mAP@0.5 yang kuat (0.702), menunjukkan kinerja model yang sangat baik tanpa *overfitting*. Sementara itu, pada *epoch* 200, meskipun *precision* dan *recall* sedikit lebih rendah, nilai mAP@0.5:0.95 tertinggi (0.393) menunjukkan kemampuan generalisasi yang lebih baik. Hasil perhitungan menunjukkan metrik kinerja sebagai berikut: *Precision*: 92.5%; *Recall*: 90.8%; *F1-Score*: 91.6%; *Mean Average Precision* (mAP): 93.2%. Model ini memberikan harapan baru bagi petani dalam melakukan deteksi dini dan pengendalian penyakit secara efektif, sehingga dapat meningkatkan produktivitas dan mengurangi kerugian ekonomi. Untuk penelitian selanjutnya, disarankan untuk mengembangkan model dengan dataset yang lebih beragam dan melibatkan lebih banyak jenis penyakit tanaman. Selain itu, implementasi pada aplikasi mobile juga dapat menjadi langkah lanjutan untuk memudahkan petani dalam mengakses teknologi ini.

REFERENCES

- [1] N. Hikmah and A. Khumaidi, "RANCANG BANGUN PROTOTIPE PENGUSIR HAMA BURUNG MENGGUNAKAN SENSOR GERAK RCWL MICROWAVE BERBASIS INTERNET OF THINGS," *Jurnal SIMETRIS*, vol. 11, no. 2, 2020.
- [2] ADEN BAYU RESPATI, MUHAMAD NURDIN YUSUF, and DANI LUKMAN HAKIM, "ANALISIS SALURAN PEMASARAN KOMODITAS PADI (Studi Kasus di Desa Selasari Kecamatan Parigi Kabupaten Pangandaran)," 2020.
- [3] J. Juswadi, P. Sumarna, and N. S. Mulyati, "Keragaan Produktivitas Padi Sawah Jawa Barat Dan Faktor Yang Mempengaruhinya," *Paspalum: Jurnal Ilmiah Pertanian*, vol. 8, no. 2, p. 122, Sep. 2020, doi: 10.35138/paspalum.v8i2.199.
- [4] S. M. Sudarjat, I. Vijaya Isnaniawardhani, and Muhammad Abdillah Hasan Qonit, "Sosialisasi Pengendalian Hama Terpadu di Desa Cintaratu Kecamatan Parigi Kabupaten Pangandaran," 2020.
- [5] A. F. Isma, M. JT Siagian, and M. A. Muthalib, "Prototipe Teknologi Tepat Guna Bertenaga Cahaya Matahari Pengusir Hama Burung Berbasis Smartphone dan Arduino Uno," *Jurnal Teknik Elektro dan Komputasi (ELKOM)*, vol. 5, no. 1, pp. 38–44, Mar. 2023, doi: 10.32528/elkom.v5i1.9192.
- [6] "BADAN PUSAT STATISTIK KABUPATEN CIAMIS BPS-STATISTICS OF CIAMIS REGENCY."
- [7] J. Juswadi, P. Sumarna, and N. S. Mulyati, "Keragaan Produktivitas Padi Sawah Jawa Barat Dan Faktor Yang Mempengaruhinya," *Paspalum: Jurnal Ilmiah Pertanian*, vol. 8, no. 2, p. 122, Sep. 2020, doi: 10.35138/paspalum.v8i2.199.
- [8] J. Lintang Balle et al., "Implementasi alat pengusir hama sawah dengan cara tradisional dan modern bertenaga surya menggunakan sensor PIR berbasis Android Implementation of rice field pest repellents in a way traditional and modern solar powered using an Android-based PIR sensor," 2021.
- [9] ersandy, Novi Lestari, and Lukman Sunardi, "INTERNET OF THING PENGUSIR HAMA BURUNG PEMAKAN PADI PADA KOMUNITAS PERSAWAHAN SRI REJEKI," 2022.
- [10] K. A. Baihaqi and C. Zonyfar, "Deteksi Lahan Pertanian Yang Terdampak Hama Tikus Menggunakan Yolo v5," 2022.
- [11] J. Deng et al., "Deep-Learning-Based Rice Disease and Insect Pest Detection on a Mobile Phone," *Agronomy*, vol. 13, no. 8, pp. 1–20, 2023, doi: 10.3390/agronomy13082139.
- [12] L. Suroiyah, Y. Rahmawati, and R. Dijaya, "FACEMASK DETECTION USING YOLO V5," *Jurnal Teknik Informatika (Jutif)*, vol. 4, no. 6, pp. 1277–1286, Dec. 2023, doi: 10.52436/1.jutif.2023.4.6.1043.
- [13] Hasbi Dawami, Mahmud Dwi Sulistiyo, and Ema Rachmawati, "Deteksi Penggunaan Masker Wajah Menggunakan YOLOv5," 2023.
- [14] S. Yuliany, Aradea, and Andi Nur Rachman, "Implementasi Deep Learning pada Sistem Klasifikasi Hama Tanaman Padi Menggunakan Metode Convolutional Neural Network (CNN)," *Jurnal Buana Informatika*, vol. 13, no. 1, pp. 54–65, 2022, doi: 10.24002/jbi.v13i1.5022.
- [15] S. R. D. Amiril, "Implementasi Algoritma Convolutional Neural Network Pada Klasifikasi Penyakit Padi Melalui Citra Daun," *Dspace.Uii.Ac.Id*, p. 23, 2020, [Online]. Available: https://dspace.uui.ac.id/handle/123456789/30189%0Ahttps://dspace.uui.ac.id/bitstream/handle/123456789/30189/16611043_SitiRahmahDanurAmiril.pdf?sequence=1
- [16] ADEN BAYU RESPATI, MUHAMAD NURDIN YUSUF, and DANI LUKMAN HAKIM, "ANALISIS SALURAN PEMASARAN KOMODITAS PADI (Studi Kasus di Desa Selasari Kecamatan Parigi Kabupaten Pangandaran)," 2020.
- [17] Adi Rizky Pratama, Ayu Ratna Juwita, and Tohirin Al Mudzakir, "Klasifikasi Daging Sapi Berdasarkan Ciri Warna Dengan Metode Otsu dan K-Nearest Neighbor," 2021.
- [18] N. M. Yasen et al., "Pemanfaatan Yolo Untuk Deteksi Hama Dan Penyakit Pada Daun Cabai Menggunakan Metode Deep Learning," vol. 15, pp. 63–71, 2023.
- [19] S. Indra Maiyanti et al., "Perbandingan Klasifikasi Penyakit Kanker Paru-paru menggunakan Support Vector Machine dan K-Nearest Neighbor," vol. 18, no. 1, 2023, doi: 10.33998/processor.2023.18.1.700.
- [20] S. Suhendar, A. Purnama, and E. Fauzi, "Deteksi Penyakit Pada Daun Tanaman Ubi Jalar Menggunakan Metode Convolutional Neural Network," *Jurnal Ilmiah Informatika Global*, vol. 14, no. 3, pp. 62–67, 2023, doi: 10.36982/jiig.v14i3.3478.
- [21] I. Nugraha Pratama, T. Rohana, T. Al Mudzakir, and P. Karawang, "PENGENALAN SAMPAH PLASTIK DENGAN MODEL CONVOLUTIONAL NEURAL NETWORK," 2020.

- [22] J. H. Kim, N. Kim, Y. W. Park, and C. S. Won, "Object Detection and Classification Based on YOLO-V5 with Improved Maritime Dataset," *J Mar Sci Eng*, vol. 10, no. 3, Mar. 2022, doi: 10.3390/jmse10030377.
- [23] D. I. Mulyana and M. A. Rofik, "Implementasi Deteksi Real Time Klasifikasi Jenis Kendaraan Di Indonesia Menggunakan Metode YOLOV5," 2022.
- [24] S. R. D. Amiril, "Implementasi Algoritma Convolutional Neural Network Pada Klasifikasi Penyakit Padi Melalui Citra Daun," *Dspace.Uii.Ac.Id*, p. 23, 2020.
- [25] D. Ruwandara, M. Jajuli, and A. Rizal, "Analisis Algoritma K-Means Clustering Untuk Daerah Penyebaran Sampah di Kota Bekasi," *JOINS (Journal of Information System)*, vol. 6, no. 1, pp. 56–63, May 2021, doi: 10.33633/joins.v6i1.4085.
- [26] N. Saefulloh, J. Indra, and A. Ratna Juwita, "Implementasi Algoritma Convolutional Neural Network (CNN) Untuk Klasifikasi Kecacatan Pada Proses Welding di Perusahaan Manufacturing," *Technology and Science (BITS)*, vol. 6, no. 1, pp. 387–394, 2024, doi: 10.47065/bits.v6i1.5321.
- [27] D. Darmadi, P. Pratikso, and M. Rachmat, "Survei Volume Lalulintas Dengan Internet Of Thing Yolo-V5," *J Teknol*, vol. 11, no. 1, pp. 25–35, Nov. 2023, doi: 10.31479/jtek.v11i1.276.