

DETEKSI PENYAKIT PADA DAUN TANAMAN PADI BERBASIS YOLOV8

Achmad Yasid¹, Ana Tsalitsatun Ni'mah², Risma Ramadhaningtias³, Rima Tri Wahyuningrum*⁴

^{1,2,3,4}Universitas Trunojoyo Madura, Kabupaten Bangkalan
Email: ¹ayasid@trunojoyo.ac.id, ²ana.tsalits@trunojoyo.ac.id, ³risma.tias04@gmail.com,
⁴rimatriwahyuningrum@trunojoyo.ac.id,
*Penulis Korespondensi

(Naskah masuk: 17 Desember 2024, diterima untuk diterbitkan: 05 Januari 2026)

Abstrak

Padi (*Oryza sativa*) merupakan sumber pangan utama di Indonesia yang rentan terhadap serangan penyakit daun seperti Brown Spot, Hispa, dan Leaf Blast. Penyakit ini menghambat fotosintesis dan berdampak pada produktivitas, sehingga deteksi dini sangat penting. Penelitian ini menerapkan metode deteksi objek berbasis YOLOv8n untuk mengidentifikasi tiga penyakit daun padi. Dataset yang digunakan terdiri dari 1.999 citra, yang mencakup 1.867 citra dari Kaggle Repository dan 132 citra hasil pengambilan data lokal di Bangkalan, Jawa Timur. Dataset dibagi menjadi 70% untuk pelatihan, 20% validasi, dan 10% pengujian. Evaluasi model menggunakan metrik mean Average Precision (mAP) dengan delapan skenario pelatihan, yakni kombinasi batch size (16, 32), epoch (100, 300), serta penggunaan augmentasi dan tanpa augmentasi. Hasil menunjukkan bahwa konfigurasi batch size 32 dengan 100 epoch, tanpa augmentasi menghasilkan performa terbaik dengan mAP sebesar 76,5%. Temuan ini menunjukkan bahwa YOLOv8n merupakan metode yang akurat, efisien, dan potensial untuk diimplementasikan pada perangkat mobile sebagai sistem peringatan dini penyakit daun padi.

Kata kunci : Deteksi objek, YOLOv8, penyakit daun padi, *deep learning*, pertanian

DISEASE DETECTION IN RICE PLANT LEAVES BASED ON YOLOv8

Abstract

Rice (Oryza sativa) is a major food source in Indonesia that is susceptible to leaf diseases such as Brown Spot, Hispa, and Leaf Blast. These diseases inhibit photosynthesis and impact productivity, so early detection is very important. This study applies the YOLOv8n-based object detection method to identify three rice leaf diseases. The dataset used consists of 1,999 images, which includes 1,867 images from the Kaggle Repository and 132 images from local data collection in Bangkalan, East Java. The dataset is divided into 70% for training, 20% validation, and 10% testing. The evaluation model uses the mean Average Precision (mAP) metric with eight training scenarios, namely a combination of batch size (16, 32), epochs (100, 300), and the use of augmentation and without augmentation. The results show that the configuration of batch size 32 with 100 epochs, without augmentation produces the best performance with an mAP of 76.5%. These findings indicate that YOLOv8n is an accurate, efficient, and potential method to be implemented on mobile devices as an early warning system for rice leaf diseases.

Keywords: Object detection, YOLOv8, rice leaf disease, *deep learning*, agriculture

1. PENDAHULUAN

Padi sebagai penghasil beras yang merupakan salah satu hasil pertanian terpenting di dunia, tidak hanya sebagai sumber karbohidrat, hasil pertanian ini memiliki banyak vitamin dan mineral untuk pertumbuhan dan perkembangan manusia. Beras termasuk Biji-bijian yang merupakan poin penting dalam masakan Asia (Trinh et al., 2024). Asia mampu menghasilkan beras dalam jumlah yang sangat besar dibandingkan dengan benua lain. Sektor pertanian memiliki peran penting di setiap negara bagi

pembangunan ekonominya, hal ini dapat dilihat ketika lebih dari seratus negara yang menanam padi untuk menghasilkan beras. Sebagian besar perekonomian negara bergantung pada produk pertanian sebagai bahan baku (Kumar et al., 2023). Negara Indonesia menjadi salah satu negara yang menggunakan padi sebagai bahan makanan pokok utama, hal ini mengharuskan Indonesia untuk mempertahankan dan meningkatkan produksi padi (Ulfah Nur Oktaviana et al., 2021). Banyaknya provinsi di Indonesia, Jawa Timur menjadi salah satu produsen utama padi dengan tingkat produksi

mencapai 9,71 juta ton pada tahun 2023, dan produksi beras mencapai 5,61 juta ton pada tahun 2023 (*Luas Panen Dan Produksi Padi Di Jawa Timur 2023*, 2024). Meskipun begitu Jawa Timur memiliki penurunan produksi padi sejak tahun 2020. Tercatat oleh Badan Pusat Statistik Jawa Timur, produksi padi tahun 2020, 2021, dan 2022 berturut-turut sebanyak 9,94 juta ton (*Luas Panen Dan Produksi Padi Di Provinsi Jawa Timur 2020, 2021*), 9,79 juta ton (*LUAS PANEN DAN PRODUKSI PADI DI PROVINSI JAWA TIMUR 2021, 2022*), dan 9,53 juta ton. Produksi padi menurun akibat beberapa faktor, antara lain perubahan iklim yang menyebabkan cuaca ekstrem, serangan hama dan penyakit, penurunan luas lahan pertanian akibat alih fungsi lahan, serta rendahnya efisiensi dalam penggunaan pupuk dan teknik pertanian (*Luas Panen Dan Produksi Padi Di Provinsi Jawa Timur 2022, 2023*). Semua faktor ini saling berkontribusi terhadap penurunan hasil panen padi.

Penyakit pada padi adalah salah satu ancaman utama bagi tanaman ini. Tanaman yang terinfeksi akan menunjukkan gejala berupa bercak dengan pola dan warna tertentu. Gejala ini dapat terlihat pada berbagai bagian tanaman padi, termasuk daun, batang, dan akar. Namun, karena daun padi memiliki ukuran yang lebih besar dibandingkan bagian lainnya, gejala penyakit yang muncul pada daun akan terlihat lebih cepat, jelas, dan perubahan warna serta bentuk bercak akan lebih mencolok (Agustiani et al., 2022). Salah satu faktor yang berpengaruh adalah serangan organisme pengganggu tanaman (OPT). OPT dapat menimbulkan kerusakan fisik serta gangguan pada fungsi fisiologis tanaman budidaya. Patogen seperti jamur, bakteri, nematoda, protozoa, dan virus berkontribusi pada munculnya penyakit pada tanaman. Serangan patogen ini mengganggu kinerja sel tanaman, sehingga menyebabkan gejala kerusakan dan penurunan hasil panen. Daun adalah bagian penting dari tanaman yang berfungsi untuk fotosintesis, yaitu proses mengubah energi cahaya menjadi energi kimia. Serangan patogen pada daun dapat mengganggu fotosintesis, menyebabkan gejala nekrosis yaitu menghitamnya warna pada tanaman yang menandakan kematian sel tanaman dan klorosis yaitu menguningnya daun karena kekurangan klorofil. Jika tidak diatasi, ini dapat mengakibatkan kerusakan jaringan atau defoliasi (pengguguran daun), yang mengurangi kemampuan fotosintesis. Infeksi patogen juga dapat mempengaruhi stomata yang merupakan pori-pori kecil yang berfungsi dalam pertukaran gas di daun, dan menghambat aliran CO₂. Selain itu, daun yang terinfeksi mengalami peningkatan laju respirasi, sehingga jaringan yang terserang menggunakan cadangan karbohidrat lebih cepat dan mengganggu proses respirasi tanaman secara keseluruhan (Walascha et al., n.d.).

Penyakit *leaf blast* merupakan salah satu ancaman serius bagi tanaman padi yang dapat menyebabkan kerugian ekonomi yang signifikan bagi

petani. Penyakit ini menyerang daun tanaman padi, yang merupakan organ utama dalam proses fotosintesis, sehingga berdampak langsung pada produktivitas tanaman. Dampak penyakit *leaf blast* terhadap hasil panen padi sangatlah besar, dengan potensi penurunan hasil mencapai 61% atau setara dengan 365 ton/ha (Safitri et al., 2020). Penyakit bercak daun *Cercospora*, yang dikenal dengan sebutan *brown spot*, disebabkan oleh jamur *C. oryzae*. Penyakit ini merupakan salah satu ancaman serius bagi tanaman padi, terutama pada lahan sawah yang mengalami kekurangan kalium. Gejala yang muncul berupa bercak coklat sempit pada daun, yang dapat mengakibatkan daun padi mengering sebelum waktunya (Walascha et al., n.d.). Hujan lebat, terutama saat musim hujan, dapat menciptakan kondisi yang mendukung pertumbuhan serangga, termasuk *hispa* padi. Curah hujan yang tinggi dan kelembapan relatif yang meningkat selama periode ini sangat menguntungkan bagi populasi hama tersebut. *Hispa* padi banyak ditemukan di lahan basah, baik yang menggunakan irigasi maupun yang bergantung pada air hujan. Dengan lingkungan yang mendukung, serangga ini dapat berkembang biak dengan cepat, sehingga meningkatkan risiko kerusakan pada tanaman padi (Jo Catindig, n.d.).

Para petani biasanya mengidentifikasi penyakit daun padi dengan melihat dan memeriksa secara langsung. Identifikasi juga dapat dilakukan dengan menggunakan perangkat teknologi citra digital (Anwar & Setyowibowo, 2021). Perkembangan yang sangat pesat pada ilmu pengetahuan dan teknologi dengan banyaknya terobosan yang memudahkan pekerjaan manusia. *Deep Learning* merupakan pembelajaran mesin yang meniru pemrosesan dan mekanisme pengambilan keputusan otak manusia (Trinh et al., 2024). Klasifikasi mampu untuk mengidentifikasi objek pada sebuah citra, namun klasifikasi tidak mampu untuk menentukan lokasi keberadaan objek secara tepat. Maka dari itu visi komputer dimanfaatkan untuk pengembangan sistem otomatis dan aplikasi canggih yang mampu membedakan, dan melokalisasi citra yang disebut deteksi objek (Kurniawan et al., 2023). Penerapan jaringan saraf tiruan (CNN) sukses untuk masalah klasifikasi citra, maka dari itu para peneliti mengembangkan potensi penggunaan CNN yang lebih canggih seperti deteksi objek (Rajasekhar et al., 2024).

YOLO (*You Only Look Once*) mampu mengklasifikasi citra, bahkan melakukan deteksi untuk beberapa citra. YOLOv8 merupakan salah satu versi terbaru dari model deteksi objek YOLO, bersamaan dengan kemunculan YOLO-NAS. Sebelumnya, terdapat beberapa versi yang dihormati seperti YOLOv1, YOLO9000v2, YOLOv3, YOLOv4, YOLOv5, YOLOv6, dan YOLOv7. YOLOv8 menghadirkan beberapa variasi, yaitu YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l, dan YOLOv8x. Di antara model-model tersebut,

YOLOv8n adalah yang paling ringan, sedangkan YOLOv8x merupakan model yang paling berat. Perbedaan berat antara versi-versi ini disebabkan oleh variasi dalam kernel konvolusional dan jumlah ekstraksi fitur yang digunakan. Perlu dicatat bahwa baik YOLOv8 maupun YOLOv5 dikembangkan oleh tim yang sama, yaitu Ultralytics, sehingga terdapat kesamaan dalam arsitektur keduanya (Trinh et al., 2024).

Penelitian sebelumnya telah banyak membahas deteksi penyakit daun padi menggunakan *Deep Convolutional Neural Network* menggunakan metode YOLO. Ditinjau dari penelitian yang telah dilakukan sebelumnya, maka penelitian tersebut memiliki hubungan yang erat dengan penelitian yang dilakukan saat ini, sehingga mampu menambah dan memperkuat proses pelaksanaan penelitian ini. Beberapa penelitian diantaranya sebagai berikut:

Dalam judul "*Alpha-EIOU-YOLOv8: An Improved Algorithm for Rice Leaf Disease Detection*" yang diteliti oleh Dong Cong Trinh dkk. tahun 2024 telah mendeteksi penyakit daun padi menggunakan YOLOv8n dengan menggantikan fungsi *Box Loss* asli dengan kombinasi dari *loss* EIoU dan *loss* alpha-IoU untuk meningkatkan sistem deteksi penyakit daun. Penyakit daun padi yang telah terdeteksi digunakan untuk mengirim informasi ke para petani melalui email (Trinh et al., 2024).

Dalam judul "*DCF-Yolov8: An Improved Algorithm for Aggregating Low-Level Features to Detect Agricultural Pests and Diseases*" yang Liangyu Zhang dkk. tahun 2023 mengembangkan algoritma berbasis YOLOv8 untuk deteksi hama dan penyakit pertanian, termasuk penyakit daun padi. Mereka memperkenalkan modul DCF (*Low-level Feature Aggregation*) yang meningkatkan kemampuan model dalam mendeteksi tekstur dan fitur penyakit. Model ini mencapai peningkatan akurasi sebesar 2% dibandingkan YOLOv8 standar, dengan akurasi mencapai 60,8%(Zhang et al., 2023).

Dalam judul "*Corn Leaf Spot Disease Recognition Based on Improved YOLOv8*" yang diteliti oleh Shaoyu Yang dkk. tahun 2024 menerapkan YOLOv8 yang ditingkatkan untuk deteksi penyakit bercak daun jagung. Meskipun fokus pada jagung, metodologi mereka relevan untuk deteksi penyakit daun padi. Mereka menggunakan teknik augmentasi data dan optimasi model yang dapat diterapkan pada deteksi penyakit daun padi (Yang et al., 2024).

Dalam judul "*A Lightweight YOLOv8 Model for Apple Leaf Disease Detection*" yang diteliti oleh Wenxuan Xie dkk. tahun 2024 mengusulkan model YOLOv8 yang ringan untuk deteksi penyakit daun apel. Mereka mengganti *Conv layer* tradisional dengan *GhostConv* dan menambahkan modul *C3Ghost*, yang dapat diterapkan untuk meningkatkan efisiensi deteksi penyakit daun padi. Model ini mencapai peningkatan presisi sebesar 1,4% dan *recall*

sebesar 2,3% dibandingkan YOLOv8 standar(Gao et al., 2024).

Dalam judul "*YOLOv8-RCAA: A Lightweight and High-Performance Network for Tea Leaf Disease Detection*" yang diteliti oleh Yifan Zhang dkk. tahun 2024 mengembangkan model YOLOv8 yang dimodifikasi untuk deteksi penyakit daun teh. Mereka mengintegrasikan blok CBAM ke dalam lapisan FPN-PAN dan mengusulkan strategi sampel ATSS, yang dapat diadaptasi untuk meningkatkan akurasi deteksi penyakit daun padi (Wang et al., 2024).

Penelitian terkini menunjukkan fokus yang intens pada peningkatan akurasi dan efisiensi YOLOv8 untuk aplikasi pertanian. Sebagai contoh, sebuah studi berhasil meningkatkan performa YOLOv8n dengan merancang *detection head* yang lebih ringan dan efisien, menghasilkan G-YOLO yang mampu mencapai mAP@0.5 sebesar 72,8% untuk deteksi penyakit daun padi, bahkan dengan kecepatan inferensi yang lebih tinggi(Gan et al., 2025). Penelitian lain yang berfokus pada penyakit hawar daun padi (*leaf blast*) juga melakukan modifikasi signifikan pada arsitektur YOLOv8x, yang disebut Pyramid-YOLOv8, dan berhasil mencapai mAP sebesar 84,3%, menunjukkan potensi besar dalam mendeteksi target penyakit yang kecil dan padat (Cao et al., 2024)Di sisi lain, penerapan YOLOv8 pada dataset penyakit tanaman di Bangladesh yang lebih beragam menunjukkan hasil yang sangat tinggi dengan mAP mencapai 98%, yang menggarisbawahi kekuatan model ini ketika dilatih pada dataset yang terkurasi dengan baik(Shahriar Zaman Abid et al., 2024). Berbagai pendekatan ini menegaskan bahwa meskipun YOLOv8 merupakan fondasi yang kuat, masih terdapat ruang untuk inovasi, baik melalui modifikasi arsitektur maupun kurasi dataset, di mana penelitian ini turut berkontribusi.

Dalam judul "*YOLOv8-G: An Improved YOLOv8 Model for Major Disease Detection in Dragon Fruit Stems*" yang diteliti oleh Luobin Huang dkk. tahun 2024 mengembangkan model YOLOv8 yang dimodifikasi, yaitu YOLOv8-G, untuk deteksi penyakit utama pada batang buah naga. Mereka memperkenalkan modul C2f-Faster yang mengurangi redundansi komputasi dan meningkatkan efisiensi model. Selain itu, mereka menerapkan teknik CARAFE untuk meningkatkan ekstraksi fitur dari gambar resolusi rendah, yang memungkinkan deteksi penyakit kecil dengan akurasi lebih tinggi. Model ini menunjukkan kinerja yang lebih baik dibandingkan dengan model lain dalam hal ukuran dan akurasi deteksi penyakit(Huang et al., 2024).

YOLOv8 *n (nano)* memiliki keunggulan utama dalam hal kecepatan dan efisiensi dibandingkan dengan varian YOLOv8 lainnya, seperti *s (small)*, *m (medium)*, *l (large)*, dan *x (extra large)*. Ukurannya yang lebih kecil membuat YOLOv8n sangat ringan dan memproses gambar dengan waktu inferensi yang jauh lebih cepat dibandingkan varian yang lebih

besar. Meskipun memiliki jumlah parameter yang lebih sedikit dibandingkan varian lain, YOLOv8n tetap mampu memberikan hasil yang baik dalam hal akurasi untuk tugas-tugas deteksi objek.

2. KAJIAN PUSTAKA

2.1 Deteksi Objek

Deteksi objek adalah proses klasifikasi dan menentukan posisi objek-objek yang ada dalam sebuah citra digital. Teknologi ini memanfaatkan algoritma *machine learning* atau *deep Learning* untuk meniru kemampuan penglihatan manusia dalam mengenali objek (PARDEDE & HARDIANSAH, 2022). Deteksi objek tidak hanya bertujuan untuk klasifikasi objek, tetapi juga untuk menunjukkan lokasi spesifik objek dalam bentuk kotak pembatas. Deteksi objek sering digunakan dalam berbagai bidang seperti keamanan, transportasi, dan pengolahan citra medis. Sistem deteksi memanfaatkan jaringan saraf tiruan (*neural networks*) yang dilatih dengan data besar agar mampu mengenali pola secara akurat. Proses ini melibatkan *deep learning* yang memungkinkan komputer memproses citra dalam waktu singkat dan membuat prediksi dengan cepat.

2.2 YOLOV8

Salah satu metode yang banyak digunakan dalam deteksi objek secara *real time* adalah YOLO (*You Only Look Once*). Seiring perkembangan teknologi, berbagai varian terbaru dari YOLO terus dirilis. Setiap varian menawarkan peningkatan kualitas dan performa dalam hal akurasi deteksi, efisiensi komputasi, dan kecepatan inferensi, sehingga memungkinkan penggunaan YOLO dalam melakukan deteksi cepat dan akurat (Syarif Hidayat et al., 2024). YOLOv8 dikenal karena kecepatan dan akurasinya. Dikembangkan oleh Ultralytics, YOLOv8 terdiri dari lima varian: YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l, dan YOLOv8x. Arsitektur YOLOv8 terbagi menjadi tiga komponen utama: backbone, neck, dan head. Bagian *backbone* berfungsi untuk menerima gambar *input* dan mengekstraksi fitur-fitur penting melalui serangkaian operasi konvolusi dan *pooling*, yang kemudian diteruskan ke *neck* untuk dilakukan fusi fitur dan transformasi skala. Proses ini membantu mendeteksi objek dengan ukuran dan kondisi yang beragam. Setelah itu, bagian head bertugas untuk menghasilkan hasil akhir deteksi berupa lokasi objek dan label kelas.

Selain itu, YOLOv8 menggunakan beberapa modul penting yang mendukung kinerja deteksinya, seperti *Spatial Pyramid Pooling* (SPPF), yang menggabungkan lapisan konvolusi dan *pooling* untuk menangkap informasi dari berbagai skala gambar, serta *Cross-Stage Partial Network* (C2f), yang menggabungkan fitur dari berbagai tahap jaringan.

Lapisan konvolusi (Conv), normalisasi batch (BN), dan fungsi aktivasi *Sigmoid Linear Unit* (SiLU) juga berperan penting dalam memastikan efisiensi proses pelatihan. Dengan kombinasi modul-modul ini, YOLOv8 mampu mempertahankan keseimbangan antara efisiensi komputasi dan akurasi deteksi, menjadikannya cocok untuk aplikasi *real-time* dengan performa tinggi (Gao et al., 2024). Pada penelitian ini, deteksi penyakit daun tanaman padi menggunakan YOLOv8n (*nano*) yang memiliki keunggulan utama dalam hal kecepatan dan efisiensi dibandingkan dengan varian YOLOv8 lainnya.

2.3 Deep Learning

Deep Learning merupakan sekumpulan algoritma *machine learning* yang dirancang untuk belajar dari data melalui berbagai tingkat lapisan, dimana jaringan syaraf tiruan (*neural network*) umum digunakan. Setiap lapisan pada *neural network* memproses informasi sesuai fitur atau pola tertentu dalam data. Informasi yang dipelajari dari tingkat rendah yang berfokus pada fitur sederhana seperti tepi atau sudut citra membantu pemahaman pada tingkat tinggi yang mempelajari konsep seperti bentuk atau objek utuh, sehingga model mampu mengenali pola dan membuat keputusan yang lebih baik pada data yang lebih kompleks (Rahma et al., 2021).

2.4 Evaluasi Kinerja Sistem

Mean Average Precision (mAP), adalah metrik yang digunakan untuk mengevaluasi kinerja model deteksi objek dengan menghitung rata-rata nilai *Average Precision* (AP) untuk setiap kelas objek yang berhasil dideteksi. AP adalah nilai rata-rata dari *precision* pada berbagai tingkat *recall*. *Precision* menunjukkan seberapa akurat model dalam mendeteksi objek, *recall* mengukur seberapa banyak total objek yang berhasil dideteksi oleh model. Proses perhitungan mAP bisa dilihat di persamaan 1 sampai 5 (Chen et al., 2022).

1. Hitung IoU (*Intersection over Union*)

IoU adalah ukuran yang digunakan untuk mengevaluasi seberapa baik prediksi bounding box dari model deteksi objek berinteraksi dengan *bounding box ground truth*.

- *Area Intersection*: Luas daerah yang tumpang tindih antara *bounding box* prediksi dan *bounding box ground truth*. Ini dapat dihitung dengan cara mencari area yang dibentuk oleh koordinat tumpang tindih dari kedua *bounding box*.
- *Area Union*: Luas total dari kedua *bounding box*, yang dihitung sebagai:

$$\text{Area Union} = \text{Area prediksi} + \text{Area Ground Truth} - \text{Area Intersection}$$

Rumus IoU:

$$\text{IoU} = \frac{\text{Area Intersection}}{\text{Area Union}} \quad (1)$$

2. Menentukan *True Positives* (TP), *False Positives* (FP), dan *False Negatives* (FN)

Setelah menghitung IoU, tentukan prediksi:

- *True Positive* (TP): Model berhasil mendeteksi penyakit pada gambar yang benar-benar memiliki penyakit. Prediksi dianggap benar jika IoU antara *bounding box* prediksi dan *ground truth* \geq *threshold* (biasanya 0.5).
- *False Positive* (FP): Model salah mendeteksi penyakit pada gambar yang sebenarnya tidak ada penyakit. Prediksi dianggap salah jika IoU $<$ *threshold* (artinya prediksi tidak sesuai dengan *ground truth*).
- *False Negative* (FN): Model gagal mendeteksi penyakit pada gambar yang sebenarnya memiliki penyakit. *Ground truth* yang tidak terdeteksi oleh model (tidak ada prediksi yang sesuai untuk *ground truth* tersebut).

3. Hitung *Precision* dan *Recall*

Setelah mendapatkan TP, FP, dan FN, Anda dapat menghitung *Precision* dan *Recall*:

- *Precision* mengukur akurasi dari prediksi positif:

$$P = \frac{TP}{TP+FP} \quad (2)$$

- *Recall* mengukur seberapa banyak dari total *ground truth* yang berhasil terdeteksi:

$$R = \frac{TP}{TP+FN} \quad (3)$$

4. Hitung *Average Precision* (AP) untuk setiap kelas

Average Precision (AP) dihitung berdasarkan nilai *Precision* dan *Recall*

$$AP = \sum_{n=1}^N (R_n - R_{n-1}) P_n \quad (4)$$

Dimana:

AP = Ini menunjukkan *Average Precision*,

R_n = Nilai *recall* pada titik ke- n ,

P_n = Nilai *Precision* pada titik ke- n ,

N = Jumlah titik yang digunakan dalam kurva.

5. Hitung *mAP*

Jika Anda memiliki beberapa kelas yang berbeda dalam *dataset*, Anda dapat menghitung *mAP* dengan cara berikut:

$$mAP = \frac{1}{N} \sum_{k=1}^N AP_k \quad (5)$$

Dimana:

N = Jumlah kelas yang ada di dalam *dataset*,

k = Indeks untuk setiap kelas dalam *dataset*,

AP_k = *Average precision* (AP) untuk kelas ke- k , mengukur performa model dalam mendeteksi objek dari kelas tersebut. AP dihitung berdasarkan *precision* dan *recall* pada berbagai tingkat *threshold* untuk kelas tertentu.

2.5 Hyperparameter

Hyperparameter optimization merupakan proses pemilihan set *hyperparameter* yang paling

baik untuk algoritma pembelajaran mesin. Parameter ini tidak dipelajari oleh model secara langsung dari data, namun ditentukan terlebih dahulu sebelum atau selama proses *training* dimulai (Putri et al., 2023). *Hyperparameter* mengontrol cara model belajar dari data sehingga memiliki pengaruh besar terhadap performa model. Pemilihan *hyperparameter* yang tepat sangat penting untuk menghasilkan akurasi yang baik, atau *loss* yang lebih rendah. Pemilihan ini juga menentukan apakah model yang telah dibuat memiliki *overfitting* akibat model terlalu kompleks dan belajar terlalu banyak dari data pelatihan, *underfitting* akibat model terlalu sederhana untuk menangkap pola yang ada dalam data, atau telah mencapai kinerja yang optimal. *Hyperparameter* yang sering dioptimalkan seperti *learning rate*, *batch size*, Jumlah *epoch*, Jumlah lapisan dan *neuron*, *optimizer*.

2.6 Roboflow


RoboFlow digunakan sebagai media untuk merancang sistem deteksi objek. RoboFlow menyediakan berbagai tugas mulai dari pembuatan *dataset*, pelabelan, hingga pelatihan model deteksi objek. Dengan menggunakan RoboFlow, yang mampu melakukan anotasi gambar secara efisien, yang sangat penting untuk meningkatkan kualitas *dataset*. Setelah proses anotasi, RoboFlow juga menyediakan opsi untuk melakukan *pre-processing* pada *dataset*. Selain itu, RoboFlow memungkinkan untuk melakukan augmentasi data, yang bertujuan untuk memperkaya variasi dalam *dataset* dan meningkatkan akurasi model (Tungady & Purnomo, 2023).

3. METODE PENELITIAN

3.1 Dataset

Data citra daun padi yang digunakan dalam penelitian ini diambil dari dua sumber. Pertama dari situs Kaggle dengan judul "Rice Leafs" yang dapat diakses melalui link <https://www.kaggle.com/datasets/shayanriyaz/ricelaf>, yang bersumber dari *UCI-Rice Disease*. Kedua, *dataset* diambil dari penelitian sebelumnya di Kabupaten Bangkalan yang diambil pada link Google Drive yang dapat diakses melalui link <https://www.kaggle.com/datasets/thariqrifkitajjala/ri-ce-leaf-dataset-bangkalan>. *Dataset* ini memiliki 3 kelas yang meliputi nama penyakit daun padi, yaitu *leaf blast*, *brown spot*, dan *hispa*. *Brown Spot* disebabkan oleh jamur *Cercospora oryzae* yang menimbulkan bercak coklat tua dengan tepi lebih muda pada satu helai daun. *Leaf Blast* disebabkan oleh *Magnaporthe grisea* dengan gejala bercak kelabu atau putih dikelilingi coklat yang terus membesar dan diikuti warna kuning pucat. Sementara itu, *Hispa* disebabkan oleh serangga yang mengikis

permukaan daun hingga tersisa garis putih sejajar urat daun. ciri-ciri penyakit dapat dilihat pada Gambar 1.



Gambar 1. Contoh Jenis Penyakit Daun Padi

Dataset citra daun padi yang digunakan dalam penelitian ini memiliki total 1999 citra daun dengan pembagian yang dapat dilihat di Tabel 1.

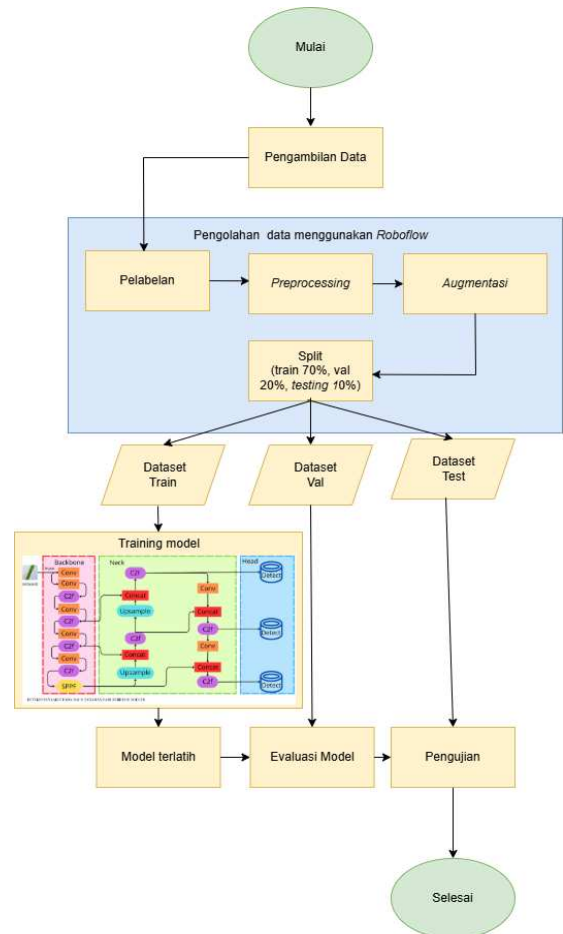
Tabel 1 Rincian jumlah citra daun padi yang digunakan dalam penelitian, dipisahkan berdasarkan kelas penyakit dan sumber data.

Kelas	Citra Daun dari Kaggle	Citra Daun dari dinas Pertanian Bangkalan	Total Citra
Brown Spot	523	48	571
Leaf Blast	779	48	827
Hispa	565	36	601
Total	1867	132	1999

3.2 Arsitektur Sistem


Gambar 2 menunjukkan arsitektur sistem dari penelitian ini. Berikut ini penjelasan dari Gambar 3.

1. Pengambilan Data: Tahap awal adalah pengumpulan data citra daun padi yang terinfeksi penyakit. Untuk memastikan variasi dan ketangguhan model, dataset diambil dari dua sumber berbeda: repositori publik Kaggle dan data lokal dari Dinas Pertanian Kabupaten Bangkalan. Penggabungan dua sumber ini bertujuan untuk melatih model agar dapat mengenali penyakit dalam berbagai kondisi pencahayaan dan latar belakang yang berbeda.
2. Pengolahan Data Menggunakan Roboflow: Seluruh data citra kemudian diolah menggunakan platform Roboflow. Proses ini dimulai dengan pelabelan (anotasi), di mana setiap area yang terinfeksi penyakit pada citra ditandai secara manual menggunakan bounding box. Selanjutnya, dilakukan tahap preprocessing, yaitu proses standarisasi ukuran semua citra menjadi 640x640 piksel untuk menjaga kestabilan selama pelatihan. Beberapa skenario pelatihan juga melibatkan augmentasi data, seperti rotasi, shear, dan flip, untuk memperkaya variasi dataset dan mengurangi potensi overfitting.



Gambar 2 Diagram alur arsitektur sistem penelitian, mulai dari tahap pengambilan data, pengolahan data menggunakan Roboflow, pelatihan model YOLOv8n, hingga evaluasi.

3. Pembagian Dataset: Setelah diolah, dataset dibagi menjadi tiga set dengan rasio 70:20:10, yang masing-masing digunakan untuk pelatihan (training), validasi (validation), dan pengujian (testing) model.
4. Training Model: Dataset latih digunakan untuk melatih model deteksi objek YOLOv8n. Selama proses ini, model belajar mengenali pola dan fitur dari ketiga kelas penyakit daun padi berdasarkan anotasi yang telah diberikan.
5. Evaluasi Model: Setelah proses pelatihan selesai, performa model dievaluasi menggunakan dataset validasi. Model yang telah terlatih kemudian diuji kinerjanya menggunakan dataset uji yang belum pernah dilihat sebelumnya. Metrik utama yang digunakan untuk evaluasi adalah mean Average Precision (mAP). Hasil dari tahap ini menentukan model dengan konfigurasi terbaik yang akan menjadi hasil akhir penelitian.
6. Selesai: Setelah evaluasi selesai, proses dianggap selesai, dan model siap untuk digunakan.



Gambar 3. Arsitektur YOLOv8 secara rinci menggambarkan alur pemrosesan mulai dari input gambar, kemudian melalui Backbone sebagai ekstraktor fitur, dilanjutkan ke Neck untuk penggabungan fitur, hingga akhirnya mencapai Head yang menghasilkan prediksi deteksi objek (Shahriar Zaman Abid et al., 2024).

Arsitektur YOLOv8, sebagaimana ditunjukkan pada Gambar 3, terdiri atas tiga komponen utama: Backbone yang berfungsi untuk mengekstraksi fitur, Neck yang menggabungkan fitur dari berbagai tingkat, serta Head yang menghasilkan prediksi akhir.

1. Backbone: Backbone berperan sebagai tahap awal untuk mengekstraksi fitur dari citra masukan berukuran 640×640 piksel.

- Proses dimulai dengan lapisan Convolution (Conv) yang berfungsi mereduksi dimensi sekaligus mempertajam pola visual penting dari input.
- Modul C2f digunakan secara berulang pada beberapa tingkat kedalaman untuk menghasilkan representasi fitur yang lebih kaya. Keunggulan C2f dibanding modul sebelumnya adalah kemampuannya memanfaatkan koneksi shortcut secara lebih efisien, sehingga distribusi informasi antar layer tetap optimal dengan kompleksitas komputasi yang lebih rendah.
- Pada bagian akhir Backbone, terdapat SPPF (Spatial Pyramid Pooling Fast). Modul ini melakukan pooling dengan ukuran kernel berbeda sehingga mampu menangkap konteks global dan memperluas receptive field, tanpa menambah biaya komputasi yang besar. Secara keseluruhan, Backbone bertugas menghasilkan peta fitur beragam resolusi yang kemudian diteruskan ke tahap Neck untuk dilakukan penggabungan.

2. Neck: Neck bertugas melakukan fusi fitur dari berbagai tingkat resolusi yang dihasilkan oleh Backbone.

- Proses ini dilakukan dengan kombinasi Concat (penggabungan fitur), Upsample (peningkatan resolusi), serta tambahan modul C2f untuk memperhalus hasil penggabungan.
- Mekanisme ini memungkinkan informasi dari fitur resolusi tinggi (detail spasial) dan fitur resolusi rendah (informasi semantik) dapat dipadukan dengan baik.

- Dengan adanya fusi multi-skala ini, YOLOv8 lebih adaptif dalam mengenali objek dengan ukuran yang bervariasi, termasuk pola penyakit pada daun padi yang dapat muncul dalam bentuk bercak kecil maupun area yang lebih luas. Neck berperan penting dalam menjaga keseimbangan antara keakuratan deteksi dan efisiensi pemrosesan, sehingga model tetap ringan untuk kebutuhan real-time.

3. Head: Head merupakan tahap akhir yang menghasilkan output deteksi.

- Pada YOLOv8, prediksi dilakukan pada tiga skala berbeda: $80 \times 80 \times 64$, $40 \times 40 \times 128$, dan $20 \times 20 \times 256$.
- Masing-masing skala bertanggung jawab mendeteksi objek berukuran kecil, sedang, dan besar. Dengan cara ini, model dapat melakukan deteksi multi-skala secara simultan.
- Head menghasilkan tiga informasi utama untuk setiap kotak prediksi, yaitu: lokasi bounding box, kelas objek, dan nilai confidence score. Keluaran dari Head inilah yang kemudian digunakan dalam tahap evaluasi maupun inferensi pada aplikasi deteksi.

3.3 Skenario Uji Coba

Penelitian ini menguji efektivitas dan efisiensi varian YOLOv8 dengan versi YOLOv8n dalam mendeteksi penyakit daun pada tanaman padi, dimana deteksi penyakit menjadi tiga jenis yaitu *brown spot*, *hispa*, dan *leaf blast*. Hasil dari implementasi model akan diuji melalui nilai mAP dan waktu deteksi model. Pada skenario ini, *dataset* akan dibagi menjadi data *training*, dan *testing* dalam proporsi 70:20:10. Semua model dilatih selama 100 dan 300 *epoch*, variasi *batch size* 16 dan 32, serta penggunaan *augmentasi* dan tanpa *augmentasi*. Berikut detail rencana uji coba dapat dilihat pada Tabel 2 (Li et al., 2024), (Gao et al., 2024).

Tabel 2 Skenario uji coba yang dilakukan dengan variasi hyperparameter meliputi batch size, jumlah epoch, dan penggunaan augmentasi data.

No	Penggunaan Augmentasi	Batch Size	Epoch
1	YOLOV8n menggunakan Augmentasi	16	100
			300
		32	100
2	YOLOV8n tanpa menggunakan Augmentasi	16	100
			300
		32	100
			300

4. HASIL DAN PEMBAHASAN

4.1 Uji Coba penggunaan augmentasi, Batch size 16 dengan epoch 100

Pada percobaan ini menggunakan 100 epoch, Batch size = 16. Tabel 3 merupakan hasil dari percobaan ini.

Tabel 3 Hasil evaluasi model pada skenario pelatihan dengan penggunaan augmentasi, batch size 16, dan 100 epoch.

Class	Images	Instances	P	R	mAP50
All	308	863	0.775	0.552	0.619
Brown	52	133	0.88	0.353	0.521
Spot					
Hispa	249	639	0.747	0.534	0.618
Leafblast	56	91	0.699	0.769	0.717

4.2 Uji Coba penggunaan augmentasi, batch size 16 dengan epoch 300

Pada percobaan ini menggunakan 300 epoch, Batch size = 16. Tabel 4 merupakan hasil dari percobaan ini.

Tabel 4 Hasil evaluasi model pada skenario pelatihan dengan penggunaan augmentasi, batch size 16, dan 300 epoch.

Class	Images	Instances	P	R	mAP50
All	308	863	0.691	0.539	0.602
Brown	52	133	0.788	0.346	0.469
Spot					
Hispa	249	639	0.741	0.546	0.642
Leafblast	56	91	0.545	0.725	0.695

4.3 Uji Coba penggunaan augmentasi, batch size 32 dengan epoch 100

Pada percobaan ini menggunakan 100 epoch, Batch size = 32. Tabel 5 merupakan hasil dari percobaan ini.

4.4 Uji Coba penggunaan augmentasi, batch size 32 dengan epoch 300

Pada percobaan ini menggunakan 300 epoch, Batch size = 32. Tabel 6 merupakan hasil dari percobaan ini.

4.5 Uji Coba tanpa augmentasi, batch size 16 dengan epoch 100

Pada percobaan ini menggunakan 100 epoch, Batch size = 16. Tabel 7 merupakan hasil dari percobaan ini.

Tabel 5 Hasil evaluasi model pada skenario pelatihan dengan penggunaan augmentasi, batch size 32, dan 100 epoch.

Class	Images	Instances	P	R	mAP50
All	308	863	0.732	0.571	0.634
Brown	52	133	0.764	0.439	0.512
Spot					
Hispa	249	639	0.752	0.56	0.654
Leafblast	56	91	0.678	0.714	0.73

Tabel 6 Hasil evaluasi model pada skenario pelatihan dengan penggunaan augmentasi, batch size 32, dan 300 epoch.

Class	Images	Instances	P	R	mAP50
All	308	863	0.696	0.531	0.579
Brown	52	133	0.747	0.346	0.443
Spot					
Hispa	249	639	0.728	0.532	0.623
Leafblast	56	91	0.613	0.714	0.67

Tabel 7 Hasil evaluasi model pada skenario pelatihan tanpa penggunaan augmentasi, batch size 16, dan 100 epoch.

Class	Images	Instances	P	R	mAP50
All	200	595	0.797	0.669	0.722
Brown	20	47	0.881	0.66	0.684
Spot					
Hispa	168	490	0.797	0.59	0.719
Leafblast	33	58	0.714	0.759	0.763

4.6 Uji Coba tanpa augmentasi, batch size 16 dengan epoch 300

Pada percobaan ini menggunakan 300 epoch, Batch size = 16. Tabel 8 merupakan hasil dari percobaan ini.

Tabel 8 Hasil evaluasi model pada skenario pelatihan tanpa penggunaan augmentasi, batch size 16, dan 300 epoch.

Class	Images	Instances	P	R	mAP50
All	200	595	0.757	0.708	0.744
Brown	20	47	0.843	0.683	0.69
Spot					
Hispa	168	490	0.773	0.596	0.705
Leafblast	33	58	0.656	0.845	0.837

4.7 Uji Coba tanpa augmentasi, batch size 32 dengan epoch 100

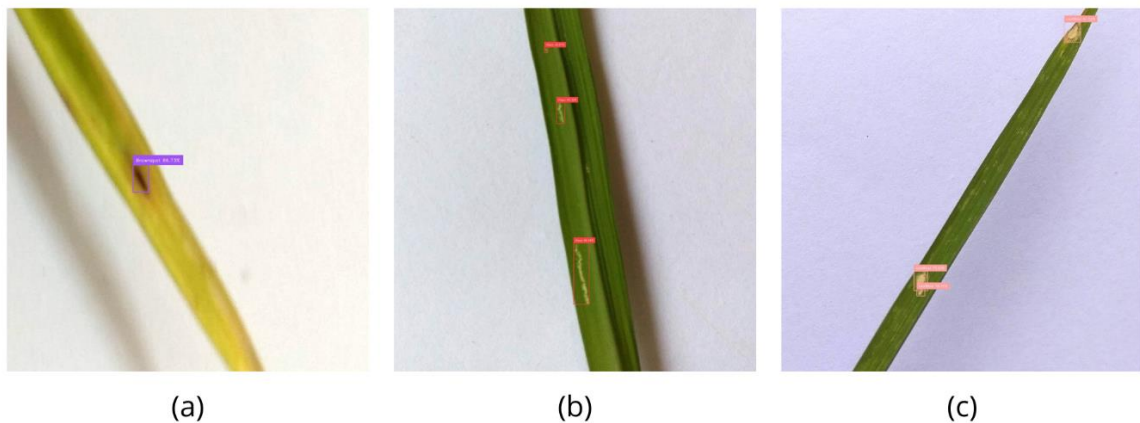
Pada percobaan ini menggunakan 100 epoch, Batch size = 32. Gambar 7 merupakan hasil dari percobaan ini.

Tabel 9. Hasil evaluasi model pada skenario pelatihan tanpa penggunaan augmentasi, batch size 32, dan 100 epoch.

Class	Images	Instances	P	R	mAP50
All	200	595	0.785	0.725	0.765
Brown	20	47	0.89	0.688	0.73
Spot					
Hispa	168	490	0.784	0.608	0.715
Leafblast	33	58	0.682	0.879	0.85

4.8 Uji Coba tanpa augmentasi, batch size 32 dengan epoch 300

Pada percobaan ini menggunakan 300 epoch, Batch size = 32. Gambar 7 merupakan hasil dari percobaan ini.



Gambar 4. Hasil deteksi sampel dari model terbaik, yang menunjukkan kemampuan dalam melakukan deteksi. Sub-gambar (a-c) menunjukkan deteksi yang berhasil dan akurat untuk setiap kelas penyakit.

Tabel 10. Hasil evaluasi model pada skenario pelatihan tanpa penggunaan augmentasi, batch size 32, dan 300 epoch.

Class	Images	Instances	P	R	mAP50
All	200	595	0.757	0.68	0.724
Brown	20	47	0.809	0.638	0.675
Spot					
Hispa	168	490	0.78	0.585	0.705
Leafblast	33	58	0.683	0.817	0.792

Hasil menunjukkan bahwa performa terbaik diperoleh pada Skenario 7, yaitu pelatihan tanpa augmentasi dengan *batch size* 32 dan 100 *epoch*, yang mencapai $mAP@0.5$ sebesar 76,5%. Sebaliknya, performa terendah terdapat pada Skenario 4 dengan augmentasi, *batch size* 32, dan 300 *epoch*, yang hanya mencapai $mAP@0.5$ sebesar 57,9%. Kemampuan deteksi model terbaik (Skenario 7) untuk setiap kelas penyakit divisualisasikan pada Gambar 4.

4.9 Analisis Komparatif dan Kontribusi Penelitian

Untuk mengukur kontribusi dan efektivitas model yang diusulkan, dilakukan analisis komparatif dengan penelitian sebelumnya serta peninjauan terhadap keunikan dataset yang digunakan. Hasil penelitian menunjukkan bahwa model YOLOv8n berhasil mencapai nilai *mean Average Precision* (mAP) sebesar 76,5%. Performa ini tidak hanya menunjukkan akurasi yang tinggi, tetapi juga menawarkan keunggulan signifikan jika dibandingkan dengan arsitektur lain yang lebih kompleks, seperti yang disarankan untuk dianalisis oleh reviewer.

Salah satu perbandingan yang relevan adalah dengan arsitektur two-stage detector seperti Faster R-CNN. Dalam penelitian sebelumnya terkait deteksi penyakit daun tanaman, metode berbasis Faster R-CNN dilaporkan hanya mencapai Average Precision (AP) sekitar 63,1% (Gong & Zhang, 2023). Model YOLOv8n yang diusulkan dalam penelitian ini terbukti lebih unggul sekitar 13,4% dari segi akurasi. Keunggulan ini menjadi lebih signifikan mengingat arsitektur YOLOv8 merupakan one-stage detector,

yang secara inheren memiliki kecepatan inferensi yang jauh lebih tinggi dan kebutuhan komputasi yang lebih rendah. Kombinasi antara akurasi yang superior dan efisiensi tinggi ini menegaskan bahwa YOLOv8n merupakan solusi yang sangat potensial untuk implementasi deteksi penyakit secara real-time di lapangan.

Jika dibandingkan dengan penelitian-penelitian termutakhir lainnya yang juga berfokus pada deteksi penyakit daun padi menggunakan varian YOLOv8, hasil mAP sebesar 76,5% yang dicapai dalam penelitian ini menunjukkan performa yang sangat kompetitif. Sebagai contoh, penelitian yang mengembangkan G-YOLO, sebuah modifikasi dari YOLOv8n, melaporkan pencapaian $mAP@0.5$ sebesar 72,8% (Gan et al., 2025), yang kemungkinan disebabkan oleh efektivitas dataset kombinasi (Kaggle dan data lokal) dalam melatih model untuk mengenali variasi penyakit yang lebih luas. Sementara itu, penelitian lain yang secara spesifik menargetkan penyakit leaf blast dengan model Pyramid-YOLOv8x mencapai mAP yang lebih tinggi sebesar 84,3% (Cao et al., 2024), yang menyoroti pentingnya spesialisasi model untuk target penyakit tertentu. Perbandingan ini memposisikan hasil kami sebagai sebuah pencapaian yang solid dan relevan dalam upaya pengembangan deteksi penyakit daun padi yang akurat dan efisien.

Selanjutnya, kontribusi penelitian ini juga terletak pada penggunaan dataset yang beragam. Dengan mengintegrasikan dataset standar dari repositori Kaggle dengan data yang diambil secara lokal di Kabupaten Bangkalan, model dilatih untuk mengenali penyakit pada daun padi dalam berbagai kondisi pencahayaan dan latar belakang yang berbeda. Penggunaan data lokal ini sangat penting untuk meningkatkan ketangguhan (*robustness*) model dan memastikan relevansinya untuk diterapkan pada kondisi pertanian di Indonesia, yang mungkin memiliki karakteristik berbeda dari data yang tersedia secara umum. Dengan demikian, penelitian ini tidak hanya sekadar mengaplikasikan sebuah metode,

tetapi juga membangun sebuah model yang lebih adaptif terhadap variasi kondisi di dunia nyata.

Secara praktis, performa model YOLOv8n yang akurat dan efisien membuka peluang implementasi yang luas di lapangan. Mengingat ukurannya yang ringan dan kecepatan inferensinya yang tinggi, model ini sangat ideal untuk diintegrasikan ke dalam aplikasi berbasis perangkat bergerak (*mobile*). Petani dapat menggunakan kamera ponsel pintar untuk memindai daun padi, dan aplikasi akan memberikan hasil deteksi penyakit secara instan. Sistem seperti ini berfungsi sebagai alat bantu pengambilan keputusan yang cepat dan objektif, mengurangi ketergantungan pada identifikasi visual manual yang terkadang subjektif. Dengan adanya deteksi dini, tindakan penanggulangan seperti pemberian pestisida yang tepat sasaran dapat dilakukan lebih awal, sehingga mampu menekan penyebaran penyakit dan meminimalkan potensi gagal panen. Lebih jauh lagi, data yang terkumpul dari berbagai pengguna dapat dianalisis untuk pemetaan sebaran penyakit secara geografis, berfungsi sebagai sistem peringatan dini (*early warning system*) bagi dinas pertanian dan komunitas petani yang lebih luas.

5. KESIMPULAN

Penelitian ini menggunakan model YOLOv8n untuk mendeteksi penyakit pada daun tanaman padi. Dataset awal terdiri dari 1.999 citra yang kemudian dibagi menjadi 70% untuk pelatihan, 20% untuk validasi, dan 10% untuk pengujian. Seluruh citra diberi label menggunakan platform Roboflow. Proses augmentasi diterapkan untuk meningkatkan jumlah data, sehingga menghasilkan total 3.077 citra yang lebih bervariasi. Hasil eksperimen menunjukkan bahwa kombinasi parameter pelatihan *batch size*, jumlah epoch, serta penggunaan augmentasi memengaruhi akurasi dan efisiensi waktu pelatihan model YOLOv8n dalam mendeteksi penyakit daun padi. Konfigurasi *batch size* 32 dengan 100 *epoch* yang dilakukan tanpa augmentasi menghasilkan akurasi tertinggi sebesar 76,5%, namun membutuhkan waktu pelatihan yang lebih lama yaitu 6,2 ms, sehingga cocok untuk kondisi dengan sumber daya komputasi yang memadai. Oleh karena itu, pemilihan parameter pelatihan perlu disesuaikan dengan kebutuhan spesifik, baik untuk memprioritaskan akurasi maupun efisiensi waktu pelatihan. Pelabelan juga perlu ditingkatkan sebagai kesesuaian dengan penyakit daun tanaman padi.

6. UCAPAN TERIMA KASIH

Ucapan terima kasih disampaikan kepada Dinas Pertanian Kabupaten Bangkalan yang telah memvalidasi hasil deteksi penyakit daun padi menggunakan YOLOv8 variasi *n* dan LPPM Universitas Trunojoyo Madura yang memberikan dana penelitian Grup Riset dengan nomer kontrak: 407/UN46.4.1/PT.01.03/RISMAN/2024.

DAFTAR PUSTAKA

- AGUSTIANI, S., TAJUL ARIFIN, Y., JUNAI, A., KHOTIMATUL WILDAH, S., & MUSTOPA, A. 2022. *Klasifikasi Penyakit Daun Padi menggunakan Random Forest dan Color Histogram 1,** (Vol. 10, Issue 1). <https://www.kaggle.com/vbookshelf/rice-leaf->
- ANWAR, K., & SETYOWIBOWO, S. 2021. JEPIN Jurnal Edukasi dan Penelitian Informatika. *Jurnal Edukasi Dan Penelitian Informatika*.
- CAO, Q., ZHAO, D., LI, J., LI, J. X., LI, G., FENG, S., & XU, T. (2024). Pyramid-YOLOv8: a detection algorithm for precise detection of rice leaf blast. *Plant Methods*, 20(1). <https://doi.org/10.1186/s13007-024-01275-3>
- CHEN, Z., WU, R., LIN, Y., LI, C., CHEN, S., YUAN, Z., CHEN, S., & ZOU, X. 2022. Plant Disease Recognition Model Based on Improved YOLOv5. *Agronomy*, 12(2). <https://doi.org/10.3390/agronomy12020365>
- LUAS PANEN DAN PRODUKSI PADI DI PROVINSI JAWA TIMUR 2021. 2022, March 1. Badan Pusat Statistik Provinsi Jawa Timur. <https://jatim.bps.go.id/id/pressrelease/2022/03/01/1312/produksi-padi-jawa-timur-selama-tahun-2021-sebesar-9-789-juta-ton-gabah-kering-giling.html>
- GAN, B., PU, G., XING, W., WANG, L., & LIANG, S. 2025. Enhanced YOLOv8 with lightweight and efficient detection head for detecting rice leaf diseases. *Scientific Reports*, 15(1). <https://doi.org/10.1038/s41598-025-06843-8>
- GAO, L., ZHAO, X., YUE, X., YUE, Y., WANG, X., WU, H., & ZHANG, X. 2024. A Lightweight YOLOv8 Model for Apple Leaf Disease Detection. *Applied Sciences (Switzerland)*, 14(15). <https://doi.org/10.3390/app14156710>
- GONG, X., & ZHANG, S. 2023. A High-Precision Detection Method of Apple Leaf Diseases Using Improved Faster R-CNN. *Agriculture (Switzerland)*, 13(2). <https://doi.org/10.3390/agriculture13020240>
- HUANG, L., CHEN, M., & PENG, Z. 2024. YOLOv8-G: An Improved YOLOv8 Model for Major Disease Detection in Dragon Fruit Stems. *Sensors*, 24(15). <https://doi.org/10.3390/s24155034>
- JO CATINDIG. (n.d.). *Rice Knowledge Bank Your Information Source for Rice Farming Rice Hispa*. International Rice Research Institute. Retrieved October 18, 2025, from <http://www.knowledgebank.irri.org/training/fact-sheets/pest-management/insects/item/rice-hispa>
- KUMAR, V. S., JAGANATHAN, M., VISWANATHAN, A., UMAMAHESWARI, M., & VIGNESH, J. 2023. Rice leaf disease detection based on bidirectional feature attention pyramid network with YOLO v5 model. *Environmental Research*

- Communications, 5(6).
<https://doi.org/10.1088/2515-7620/acdece>
- KURNIAWAN, F., ASTAWA, I. N. G. A., SENTANA, I. W. B., ATMAJA, I. M. A. D. S., & WIBAWA, A. P. 2023. Facemask Detection using the YOLO-v5 Algorithm: Assessing Dataset Variation and Resolutions. *Register: Jurnal Ilmiah Teknologi Sistem Informasi*, 9(2), 95–102.
<https://doi.org/10.26594/register.v9i2.3249>
- LI, Y., CHEN, X., YIN, L., & HU, Y. 2024. Deep Learning-Based Methods for Multi-Class Rice Disease Detection Using Plant Images. *Agronomy*, 14(9), 1879.
<https://doi.org/10.3390/agronomy14091879>
- LUAS PANEN DAN PRODUKSI PADI DI JAWA TIMUR 2023. 2024, March 1. Badan Pusat Statistik Provinsi Jawa Timur. <https://jatim.bps.go.id/id/pressrelease/2024/03/01/1454/pada-2023--luas-panen-padi-mencapai-sekitar-1-698-juta-hektare-dengan-produksi-padi-sebesar-9-71-juta-ton-gabah-kering-giling--gkg-.html>
- LUAS PANEN DAN PRODUKSI PADI DI PROVINSI JAWA TIMUR 2020. 2021, March 1. Badan Pusat Statistik Propinsi Jawa Timur. <https://jatim.bps.go.id/id/pressrelease/2021/03/01/1231/pada-2020--luas-panen-padi-sebesar-1-75-juta-hektar-dengan-produksi-sebesar-9-94-juta-ton-gkg--jika-dikonversikan-menjadi-beras--produksi-beras-pada-2020-mencapai-5-71-juta-ton-.html>
- LUAS PANEN DAN PRODUKSI PADI DI PROVINSI JAWA TIMUR 2022. 2023, March 1. Badan Pusat Statistik Provinsi Jawa Timur. <https://jatim.bps.go.id/id/pressrelease/2023/03/01/1384/pada-2022--luas-panen-padi-mencapai-sekitar-1-69-juta-hektare-dengan-produksi-sebesar-9-53-juta-ton-gkg--jika-dikonversikan-menjadi-beras--maka-produksi-beras-pada-2022-mencapai-5-50-juta-ton-.html>
- WALASCHA, A., FEBRIANA, A., SAPUTRI, D., SRI NUR HARYANTI, D., TSANIA, R., SANJAYA, Y., & PRIYANTI. (n.d.). *Prosiding SEMNAS BIO 2021 Review Artikel: Inventarisasi Jenis Penyakit yang Menyerang Daun Tanaman Padi (Oryza sativa L.)*.
- PARDEDE, J., & HARDIANSAH, H. 2022. Deteksi Objek Kereta Api menggunakan Metode Faster R-CNN dengan Arsitektur VGG 16. *MIND Journal*, 7(1), 21–36.
<https://doi.org/10.26760/mindjournal.v7i1.21-36>
- PUTRI, T. A. E., WIDIHARIH, T., & SANTOSO, R. 2023. Penerapan Tuning Hyperparameter Randomsearchcv Pada Adaptive Boosting Untuk Prediksi Kelangsungan Hidup Pasien Gagal Jantung. *Jurnal Gaussian*, 11(3), 397–406. <https://doi.org/10.14710/j.gauss.11.3.397-406>
- RAHMA, L., SYAPUTRA, H., MIRZA, A. H., & PURNAMASARI, S. D. 2021. Objek Deteksi Makanan Khas Palembang Menggunakan Algoritma YOLO (You Only Look Once). In *Jurnal Nasional Ilmu Komputer* (Vol. 2, Issue 3).
- RAJASEKHAR, V., ARULSELVI, G., & SURESH BABU, K. 2024. Detection of diseases in rice leaf using convolutional neural network with transfer learning based on ResNeXt. *International Journal of Electrical and Computer Engineering*, 14(2), 1739–1749. <https://doi.org/10.11591/ijece.v14i2.pp1739-1749>
- SAFITRI, N., DJAYA, L., MARTUA SUHUNAN SIANIPAR, DAN, & RAYA BANDUNG SUMEDANG KM, J. 2020. Kemampuan *Bacillus subtilis* dan *Trichoderma harzianum* dalam Campuran Serat Karbon dan Silika Nano untuk Meningkatkan Ketahanan Tanaman Padi terhadap Penyakit Blas (*Pyricularia oryzae*). *Jurnal Agrikultura*, 2020(3), 182–192.
- SHAHRIAR ZAMAN ABID, M., JAHAN, B., MAMUN, A. AL, JAKIR HOSSEN, M., & HOSSAIN MAZUMDER, S. 2024. Bangladeshi crops leaf disease detection using YOLOv8. *Heliyon*, 10(18). <https://doi.org/10.1016/j.heliyon.2024.e36694>
- SYARIF HIDAYAT, Z., WIJAYA, Y. A., & KURNIAWAN, R. 2024. *Optimizing YOLOv8 For Autonomous Driving: Batch Size For Best Mean Average Precision (MAP)*. 5(4), 1147–1153.
<https://doi.org/10.52436/1.jutif.2024.5.4.1626>
- TRINH, D. C., MAC, A. T., DANG, K. G., NGUYEN, H. T., NGUYEN, H. T., & BUI, T. D. 2024. Alpha-EIOU-YOLOv8: An Improved Algorithm for Rice Leaf Disease Detection. *AgriEngineering*, 6(1), 302–317. <https://doi.org/10.3390/agriengineering6010018>
- TUNGADY, C. A. P., & PURNOMO, H. D. 2023. Perancangan Sistem Pendukung Objek Deteksi untuk Permainan Kartu Cardfight! Vanguard Menggunakan Aplikasi Roboflow dan Flask. *Jurnal Teknologi Sistem Informasi Dan Aplikasi*, 6(3), 283–290. <https://doi.org/10.32493/jtsi.v6i3.30303>
- ULFAH NUR OKTAVIANA, RICKY HENDRAWAN, ALFIAN DWI KHOIRUL ANNAS, & GALIH WASIS WICAKSONO. 2021. Klasifikasi Penyakit Padi berdasarkan Citra Daun Menggunakan Model Terlatih Resnet101. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(6), 1216–1222. <https://doi.org/10.29207/resti.v5i6.3607>
- WANG, J., LI, M., HAN, C., & GUO, X. 2024. YOLOv8-RCAA: A Lightweight and High-Performance Network for Tea Leaf Disease

- Detection. *Agriculture (Switzerland)*, 14(8).
<https://doi.org/10.3390/agriculture14081240>
- YANG, S., YAO, J., & TENG, G. 2024. Corn Leaf Spot Disease Recognition Based on Improved YOLOv8. *Agriculture (Switzerland)*, 14(5).
<https://doi.org/10.3390/agriculture14050666>
- ZHANG, L., DING, G., LI, C., & LI, D. 2023. DCF-Yolov8: An Improved Algorithm for Aggregating Low-Level Features to Detect Agricultural Pests and Diseases. *Agronomy*, 13(8).
<https://doi.org/10.3390/agronomy13082012>