

# Analisis Dan Klasifikasi Penyakit Pada Daun Padi Dengan Menggunakan Metode Yolov8

1<sup>st</sup> Yoshi Prayudi  
Fakultas Teknik Elektro  
Universitas Telkom  
Bandung, Indonesia

yoship@student.telkomuniversity.ac.id

2<sup>nd</sup> Sofia Saidah  
Fakultas Teknik Elektro  
Universitas Telkom  
Bandung, Indonesia

sofiasaidahsfi@telkomuniversity.ac.id

3<sup>rd</sup> Rita Magdalena  
Fakultas Teknik Elektro  
Universitas Telkom  
Bandung, Indonesia

ritamagdalen@telkomuniversity.ac.id

**Abstrak** — Penyakit pada daun padi merupakan tantangan utama dalam pertanian padi yang dapat secara signifikan mengurangi hasil panen. Penyakit ini disebabkan oleh berbagai patogen, termasuk jamur, bakteri, dan virus, yang menyerang daun padi dan mempengaruhi pertumbuhan serta kualitas tanaman. Gejala umum yang muncul meliputi bercak-bercak pada daun, perubahan warna, deformasi, dan penurunan luas daun yang sehat. Pengendalian penyakit ini melibatkan pemilihan varietas yang tahan, pengaturan tanaman yang baik, penerapan teknik sanitasi, serta penggunaan agen pengendali penyakit yang tepat. Memahami penyakit pada daun padi dengan baik sangat penting untuk menjaga produktivitas pertanian dan keberlanjutan sistem pertanian padi di masa depan.

Pada penelitian ini dilakukan klasifikasi penyakit pada daun padi menggunakan metode YOLOv8. Metode ini digunakan karena akurasi yang dihasilkan dalam melakukan klasifikasi objek cukup tinggi. Selain itu dengan YOLOv8 proses klasifikasi objek dapat dilakukan secara real time.

Dari total dataset yang digunakan 3.773 gambar dengan pembagian data testing sebanyak 418 gambar, data training 2.684 gambar, dan data validasi 671 gambar. Dengan total data training sebesar 70%, validasi sebesar 20%, dan testing sebesar 10%. Hasil dari pengujian yang dilakukan didapatkan nilai terbaik yaitu pada saat pengujian menggunakan size 224, learning rate 0.01, batch size 16, dan optimizer SGD yaitu presisi sebesar 0.982, recall 0.989, mAP50 0.986, dan mAP50-95 0.929 dan dari hasil perhitungan F1-Score sebesar 96,2%.

**Kata Kunci** : Penyakit Daun Padi, YOLOv8, Python, Google Collab

## I. PENDAHULUAN

Beras adalah komponen penting dalam kebutuhan pangan pokok di Indonesia, sehingga kehadirannya sangat vital untuk memenuhi kebutuhan gizi masyarakat Asia, terutama di Indonesia. Menurut data dari Badan Pusat Statistik (BPS) pada tahun 2022, luas panen padi diperkirakan mencapai 10,45 juta hektar, meningkat sebesar 40,87 ribu hektar (0,39 persen) dibandingkan tahun

2021 [1]. Produksi padi pada tahun 2022 mencapai 54,75 juta ton GKG, yang jika dikonversikan menjadi beras, menghasilkan sekitar 31,54 juta ton, meningkat sebesar 184,50 ribu ton (0,59 persen) dibandingkan dengan produksi beras tahun 2021. Peningkatan ini tentu saja disebabkan oleh pertumbuhan populasi yang terus meningkat dan kebutuhan pangan pokok yang bertambah seiring dengan pertumbuhan penduduk di Indonesia. Namun, para petani padi di Indonesia masih menghadapi berbagai tantangan, termasuk masalah cuaca, hama, dan penyakit padi. Penyakit padi menjadi salah satu masalah yang sulit ditangani, terutama karena terbatasnya pengetahuan petani Indonesia dalam mengatasi penyakit ini.

Dalam penelitian sebelumnya yang berjudul "Nutrients Deficiency Diagnosis of Rice Crop by Weighted Average Ensemble Learning," diukur identifikasi hama, pengenalan defisiensi nutrisi, dan penyakit lainnya. Analisis kinerja keseluruhan model menunjukkan bahwa InceptionResNetV2 mencapai akurasi sebesar 91,6%, recall 93%, dan macro average precision 91% [2].

Tujuan dari penelitian ini adalah merancang sistem klasifikasi untuk daun padi. Salah satu metode yang telah menunjukkan hasil baik dalam pengenalan pola pada citra adalah YOLOv8 (You Only Look Once v8). Oleh karena itu, peneliti akan menggunakan algoritma YOLOv8 untuk Tugas Akhir ini. Diharapkan hasil penelitian ini dapat mempermudah petani dalam memeriksa penyakit pada daun padi di masa mendatang dengan mengotomatiskan proses klasifikasi. Proses ini akan dilakukan menggunakan kamera untuk memperoleh citra daun padi, yang kemudian akan diproses oleh aplikasi YOLOv8 untuk deteksi dan klasifikasi penyakit secara otomatis, sehingga kualitas dan keamanan panen padi dapat ditingkatkan.

## II. KAJIAN TEORI

### A. Tanaman Padi

Padi adalah salah satu tanaman pangan yang paling penting di Indonesia. Struktur tanaman padi terdiri dari daun, batang, dan akar. Tanaman ini merupakan komoditas budidaya, dan hasil olahannya dapat diubah menjadi beras yang dikonsumsi. Beras menjadi makanan pokok bagi sebagian besar masyarakat Indonesia. Namun, petani sering menghadapi berbagai masalah dalam budidaya padi, salah satunya adalah penyakit padi. Penyakit ini biasanya disebabkan oleh dua faktor, yaitu faktor abiotik dan biotik. Faktor abiotik berkaitan dengan kondisi lingkungan, sementara faktor biotik sering kali disebabkan oleh virus, bakteri, jamur, dan nematoda [3].

Ada berbagai jenis penyakit yang menyerang padi, yang dapat mengurangi kuantitas dan kualitas tanaman, sehingga secara tidak langsung berdampak pada produksi padi untuk memenuhi kebutuhan pangan di Indonesia. Beberapa penyakit yang umum terjadi antara lain bercak coklat, blast daun, dan kumbang hijau. Penyakit-penyakit inilah yang sering kali menyerang daun padi.



GAMBAR 2.1  
Tanaman Padi [4]

#### 1. Bercak Coklat (Brown Spot)

Penyakit ini disebabkan oleh jamur *Cochliobolus miyabeanus*, dengan gejala awal berupa bercak-bercak kecil berwarna coklat keabu-abuan pada daun padi. Bercak ini biasanya muncul dari bagian bawah daun dan dapat menyebar ke atas. Bercak-bercak tersebut memiliki tepi gelap di sekelilingnya, sering kali dengan pusat bercak yang lebih terang. Daun yang terinfeksi dapat mengalami kekeringan dan akhirnya mengering, yang dapat mengurangi kemampuan fotosintesis tanaman.



GAMBAR 2.2  
Brown Spot [5]

#### 2. Blast Daun (Leaf Blast)

Penyakit Leaf Blast pada padi adalah salah satu penyakit yang sangat merugikan dan dapat mengurangi hasil panen secara signifikan. Penyakit ini disebabkan oleh jamur *Magnaporthe oryzae* dan gejala awalnya biasanya berupa bercak kecil yang memanjang dengan tepi tidak teratur. Bercak tersebut sering kali berwarna abu-abu hingga putih, dengan tepi berwarna coklat atau gelap. Dalam kondisi infeksi yang parah, daun padi dapat mengalami pembusukan dan mengering.



GAMBAR 2.3  
Leaf Blast [6]

#### 3. Kumbang Hijau (Hispa)

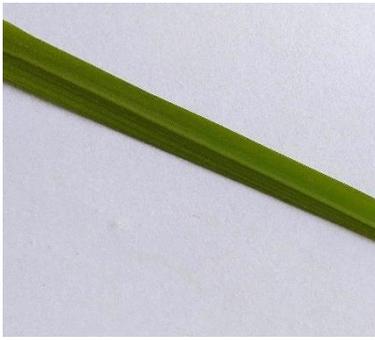
Penyakit Hispa disebabkan oleh serangga kumbang dari keluarga Chrysomelidae, terutama dari genus *Dicladispa*. Di Indonesia, hama yang umum ditemui adalah *Dicladispa armigera* dan *Dicladispa viridicyanea*. Gejala awal serangan hispa ditandai dengan munculnya bercak-bercak kecil pada permukaan daun. Bercak ini disebabkan oleh aktivitas makan larva kumbang yang merusak epidermis daun. Daun yang terinfeksi akan menunjukkan kerusakan berupa kerat-kerat kering dan tidak berfungsi dengan baik. Hal ini terjadi karena hilangnya lapisan pelindung daun dan berkurangnya area untuk fotosintesis.



GAMBAR 2.4  
Hispa [7]

#### 4. Sehat (Healthy)

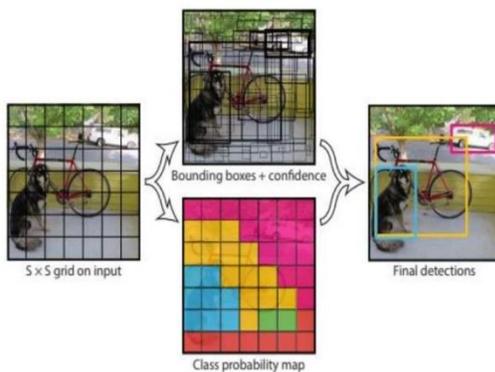
Daun yang sehat memiliki permukaan halus tanpa bercak, bintik, atau kerusakan. Tidak ada tanda-tanda kerusakan fisik atau mekanis seperti sobekan atau lubang. Daun padi yang sehat memiliki ukuran yang sesuai dengan varietasnya, tidak terlalu kecil atau terlalu besar dibandingkan dengan ukuran daun padi yang seharusnya.



GAMBAR 2.5  
Healthy [8]

## B. YOLOv8

YOLOv8 (You Only Look Once versi 8) adalah versi terbaru dari algoritma deteksi objek YOLO yang sangat terkenal dalam bidang visi komputer. YOLO merupakan algoritma yang dirancang untuk mendeteksi objek dalam gambar atau video secara real-time dengan efisiensi tinggi dan akurasi yang baik. YOLOv8 adalah pengembangan dari YOLOv7 yang menghadirkan berbagai perbaikan dalam arsitektur dan kinerja.



GAMBAR 2.6  
Model Sistem Deteksi YOLO [9]

### 1. Backbone

Backbone di YOLOv8 dirancang untuk mencapai keseimbangan antara kecepatan, akurasi, dan efisiensi. Fungsi backbone pada YOLOv8 adalah untuk meningkatkan efisiensi model dengan mengurangi jumlah parameter dan kompleksitas komputasi, sambil tetap mempertahankan atau meningkatkan akurasi. Ini dilakukan melalui teknik seperti pruning (pemangkasan) dan quantization (kuantisasi). Backbone dilatih menggunakan dataset besar yang mencakup berbagai jenis gambar dan objek. Proses pelatihan melibatkan teknik augmentasi data dan regularisasi untuk mencegah overfitting serta meningkatkan kemampuan generalisasi. Selama inferensi, backbone menghasilkan representasi fitur yang digunakan oleh bagian lain dari model (neck dan head) untuk memprediksi lokasi dan kelas objek dalam gambar [10].

Implementasi backbone di YOLOv8 sering kali melibatkan optimasi untuk perangkat keras tertentu, seperti GPU, TPU, atau perangkat edge computing, guna memastikan kinerja yang optimal dalam aplikasi real-time.

### 2. Neck

Neck dalam arsitektur YOLOv8 adalah komponen penting yang terletak di antara backbone (bagian ekstraksi fitur) dan head (bagian deteksi akhir). Fungsinya adalah untuk memproses dan mengintegrasikan fitur yang dihasilkan oleh backbone sebelum diteruskan ke head untuk prediksi akhir. Neck bertanggung jawab untuk menggabungkan fitur dari berbagai skala dan menyiapkan data untuk deteksi objek yang lebih akurat. Dengan mengintegrasikan fitur dari berbagai lapisan backbone yang mewakili resolusi dan tingkat detail yang berbeda [10], neck memungkinkan YOLOv8 untuk mendeteksi objek dengan ukuran yang bervariasi, mulai dari yang kecil hingga yang besar.

Teknik fusi fitur digunakan untuk mengkombinasikan informasi dari berbagai skala fitur, yang mendukung deteksi objek dengan akurasi yang lebih tinggi. Teknik normalisasi seperti Batch Normalization atau Layer Normalization sering diterapkan untuk memastikan bahwa fitur yang dihasilkan memiliki skala dan distribusi yang konsisten, yang membantu selama pelatihan dan inferensi. Neck sering menggunakan teknik upsampling (meningkatkan resolusi) dan downsampling (mengurangi resolusi) untuk menyesuaikan fitur sesuai kebutuhan deteksi. Upsampling memungkinkan penggabungan informasi dari fitur beresolusi rendah dengan fitur beresolusi tinggi, sehingga meningkatkan akurasi deteksi.

### 3. Head

Head dalam arsitektur YOLOv8 adalah komponen terakhir dari model deteksi objek yang bertanggung jawab untuk menghasilkan prediksi akhir dari gambar yang telah diproses oleh backbone dan neck. Head YOLOv8 memberikan informasi penting seperti lokasi bounding box, kelas objek, dan skor kepercayaan. Dirancang untuk efisiensi tinggi, head ini memungkinkan deteksi objek dilakukan secara real-time, yang sangat penting untuk aplikasi seperti pengawasan video atau kendaraan otonom yang memerlukan deteksi cepat. Dengan menghasilkan prediksi dari berbagai skala, YOLOv8 mampu mendeteksi objek dalam berbagai ukuran dan kondisi.

Head pada YOLOv8 adalah komponen penting dalam sistem deteksi objek yang bertugas untuk menghasilkan prediksi akhir, termasuk lokasi bounding box, kelas objek, dan skor kepercayaan [10]. Dengan memanfaatkan teknik canggih seperti anchor boxes, deteksi multi-skala, dan berbagai fungsi aktivasi, head YOLOv8 mampu memberikan deteksi objek yang cepat dan akurat. Desain dan fungsi head ini berkontribusi pada performa keseluruhan YOLOv8 dalam berbagai aplikasi dunia nyata, mulai dari pengawasan hingga hinggta sistem kendaraan otonom.

C. Pengumpulan Dataset

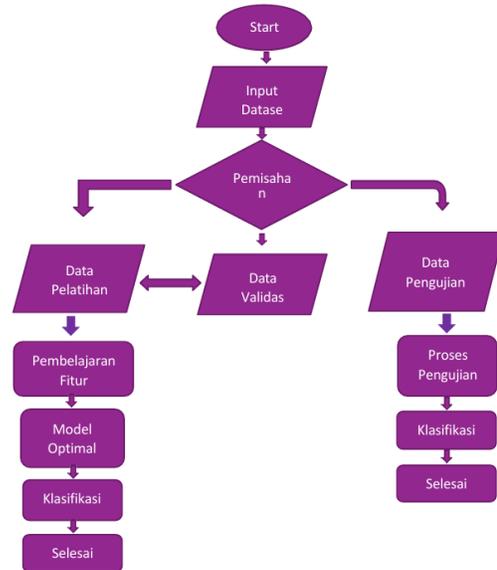
Pada tahap ini, total jumlah dataset yang digunakan adalah 3.773 berformat JPG, terdiri dari 418 gambar untuk testing, 2.684 gambar untuk training, dan 671 gambar untuk validasi. Dataset ini berfungsi sebagai input untuk sistem yang telah dikembangkan dan diambil dari situs www.kaggle.com, mencakup empat kelas: bercak coklat, blast daun, kumbang hijau, dan sehat. Dataset kemudian dibagi menjadi data training, validasi, dan testing, dengan proporsi 70% untuk training, 20% untuk validasi, dan 10% untuk testing. Semua citra dalam dataset berformat JPG dengan ukuran 64 x 64 piksel.

D. Preprocessing

Preprocessing pada YOLOv8 adalah langkah penting yang dilakukan sebelum gambar dimasukkan ke dalam model untuk deteksi objek. Proses ini bertujuan untuk mempersiapkan data agar sesuai dengan format dan skala yang diharapkan oleh model. Anotasi dan pelabelan adalah langkah dalam preprocessing dataset yang bertujuan untuk menandai data dengan titik-titik koordinat yang juga menyertakan informasi mengenai kelas yang sesuai dengan nama objek, serta mencakup lebar dan tinggi objek tersebut. Resize yang digunakan pada preprocessing ini adalah 224 x 224.

Augmentasi data adalah proses yang dilakukan untuk memperkaya jumlah dataset, sehingga meningkatkan volume dan variasi data. Teknik augmentasi yang digunakan mencakup flip horizontal dan rotasi 90°.

adalah pembagian data (data splitting), di mana penulis membagi proses penelitian menjadi tiga bagian: training, validasi, dan testing. Setelah data dibagi, tahap selanjutnya adalah training dan validasi, yang dilakukan secara bersamaan selama proses pelatihan. Pada setiap tahap ini, dilakukan pembelajaran fitur, pengoptimalan model, dan klasifikasi. Kemudian, proses testing dilakukan menggunakan data yang telah dibagi sebelumnya, di mana model diklasifikasikan. Setiap pengujian melalui serangkaian langkah tertentu, seperti yang ditunjukkan dalam diagram alir.

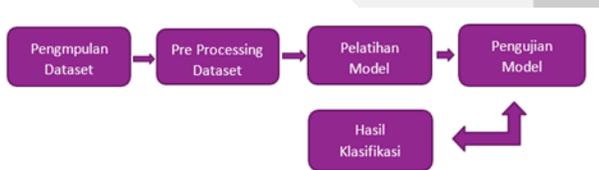


GAMBAR 3.2 Diagram Alir

III. PRANCANGAN SISTEM

A. Desain Sistem

Perancangan sistem deteksi penyakit pada tanaman dilakukan melalui tiga tahap: data training, data validation, dan data test. Data training adalah kumpulan sampel citra yang digunakan oleh sistem untuk mempelajari objek yang terdapat dalam citra, disesuaikan dengan parameter training yang telah ditentukan.



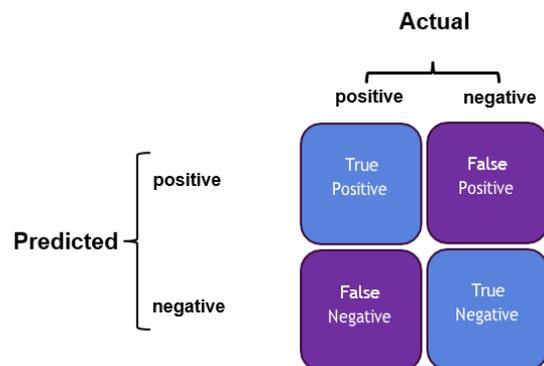
GAMBAR 3.1 Blok Diagram Sistem

B. Diagram Alir

Dalam penelitian ini, langkah pertama yang diambil oleh penulis adalah mengumpulkan dataset yang relevan dengan topik penelitian. Dataset tersebut diperoleh dari situs web kaggle.com dengan judul "Rice leaf" yang diunggah oleh Shayan Riyaz [8]. Langkah berikutnya

C. Performansi Sistem

Performansi sistem bertujuan untuk mengukur kinerja model dalam klasifikasi, yang dapat dilihat pada gambar 3.3 Confusion Matrix. Kinerja sistem YOLOv8 dapat dievaluasi melalui parameter seperti presisi, recall, dan mAP.



GAMBAR 3.3 Confusion Matrix

Istilah dalam confusion matrix mencakup beberapa komponen sebagai berikut: True Positive (TP) adalah ketika prediksi yang benar memang terbukti benar. True Negative (TN) adalah ketika prediksi yang salah juga terbukti salah. False Positive (FP) adalah ketika prediksi yang benar ternyata salah. False Negative (FN) adalah ketika prediksi yang salah sebenarnya benar.

1. Akurasi

Akurasi adalah rasio antara total true positif (TP) dan true negatif (TN) dengan total data yang ada. Rumus akurasi dapat dilihat pada persamaan (3.1) [11].

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \tag{3.1}$$

Dari rumus tersebut, dapat disimpulkan bahwa semakin tinggi nilai akurasi, semakin baik model dalam memprediksi objek yang diinginkan.

2. Presisi

Parameter presisi mengukur perbandingan jumlah objek atau data yang diklasifikasikan sebagai benar dalam pendeteksian terhadap total data yang diprediksi sebagai positif. Nilai presisi dapat dihitung menggunakan rumus (3.2) [11].

$$Presisi = \frac{TP}{TP + FP} \times 100\% \tag{3.2}$$

3. Recall

Parameter recall mengukur rasio antara True Positive (TP) dan jumlah data yang sebenarnya positif. Semakin tinggi nilai recall, semakin baik sistem dalam mengklasifikasikan objek dalam data yang diuji. Recall dapat dihitung menggunakan rumus (3.3) [11].

$$Recall = \frac{TP}{TP + FN} \times 100\% \tag{3.3}$$

4. mean Average Precision (mAP)

Nilai mAP adalah parameter yang digunakan untuk mengevaluasi performa model deteksi objek. Mean Average Precision (mAP) merupakan rata-rata dari nilai Average Precision (AP), yang menggambarkan tingkat presisi model deteksi objek pada data uji. mAP dihitung dengan mencari rata-rata dari semua nilai AP untuk setiap kelas [12]. Mean Average Precision dapat dihitung menggunakan rumus (3.4).

$$mAP = \frac{1}{K} \sum_{k=-1}^K AP_k \tag{3.4}$$

5. F1-Score

F1-score adalah metrik evaluasi yang mengkombinasikan precision dan recall, memberikan gambaran lebih komprehensif tentang kinerja model klasifikasi. Metrik ini bertujuan untuk mencapai keseimbangan antara precision dan recall, terutama dalam situasi di mana terdapat ketidakseimbangan antara kelas positif dan negatif. F1-Score dapat dihitung menggunakan rumus (3.5).

$$F1 - Score = \frac{2 \times precision \times recall}{precision + recall} \tag{3.5}$$

D. Sarana Penunjang Simulasi

Dalam proyek ini, fasilitas pendukung untuk simulasi antara lain:

- Laptop : HP 14-cm0xxx
- Prosesor: intel CORE i7 7th gen
- Memory: 12 GB
- Simulator: Google Collab.

IV. ANALISIS SIMULASI

A. Skenario Pengujian

Pengujian dalam penelitian ini dilakukan dalam empat tahap, yaitu: pengujian terhadap Optimizer, Learning Rate, Epoch, dan Resize.

1. Pengujian Optimizer

Pengujian terhadap Optimizer dilakukan untuk menentukan mana yang paling sesuai untuk klasifikasi daun padi, karena setiap Optimizer memiliki kinerja yang berbeda tergantung pada dataset dan masalah tertentu. Dalam penelitian ini, dua Optimizer yang diuji adalah SGD dan Adam, dengan parameter lain yang juga diuji yaitu :

- Size :224
- Learning Rate: 0.01
- Epoch :10
- Batch Size:16

Hasil Pengujian *Optimizer* dapat dilihat pada tabel dibawah.

Tabel 4.1 Hasil Pengujian Optimizer

Pengjian Optimizer	Presisi	Recall	mAP50	mAP50-95
SGD	0.953	0.976	0.942	0.885
Adam	0.914	0.935	0.910	0.837

Hasil pelatihan model tersebut kemudian di validasi sehingga didapat *precision* 0.933, *recall* 0.955, *mAP50* sebesar 0.926, dan *mAP50-95* sebesar 0.861. Setelah itu, dilakukan perhitungan *F1-Score* sehingga didapat nilai sebesar 94,3%.

$$F1 - Score = \frac{2 \times precision \times recall}{precision + recall} = \frac{2 \times 0.933 \times 0.955}{0.933 + 0.955} = 94.3 \tag{4.1}$$

2. Pengujian Terhadap Learning Rate

Pengujian terhadap Learning Rate bertujuan untuk menemukan nilai optimal yang mengatur ukuran langkah dalam proses optimasi saat melatih model. Learning Rate yang terlalu tinggi dapat membuat model melewati solusi optimal, sedangkan yang terlalu rendah dapat membuat proses pelatihan menjadi lambat. Pengujian Learning Rate dimulai dari 0.1, 0.01, dan 0.001 dengan menggunakan parameter berikut:

- *Size* :224
- *Epoch* :10
- *Batch Size*:16
- *Optimizer* : SGD

Hasil Pengujian *Learning Rate* dapat dilihat pada tabel dibawah.

TABEL 4.2  
Hasil Pengujian *Learning Rate*

Pengujian Learning Rate	Presisi	Recall	mAP50	mAP50-95
0.1	0.935	0.950	0.921	0.844
0.01	0.953	0.976	0.942	0.885
0.001	0.971	0.987	0.966	0.897

Hasil pelatihan model tersebut kemudian di validasi sehingga didapat *precision* 0.953, *recall* 0.971, *mAP50* sebesar 0.943, dan *mAP50-95* sebesar 0.875. Setelah itu, dilakukan perhitungan *F1-Score* sehingga didapat nilai sebesar 96,1%.

$$F1 - Score = \frac{2 \times precision \times recall}{precision + recall} = \frac{2 \times 0.953 \times 0.971}{0.953 + 0.971} = 96.1 \tag{4.2}$$

3. Pengujian Terhadap Epoch

Epoch diperlukan untuk menentukan jumlah iterasi pelatihan yang optimal bagi model. Dengan menguji berbagai jumlah iterasi, dapat ditentukan jumlah Epoch terbaik untuk masalah dan dataset yang ada, sehingga model tidak mengalami overfitting atau underfitting. Dalam penelitian ini, pengujian Epoch dimulai dari 20, 40, 60, 80, dan 100. Pengujian ini dilakukan dengan parameter lainnya, yaitu:

- *Size* :224

- *Learning Rate* :0.01
- *Batch Size*:16
- *Optimizer* : SGD

Hasil Pengujian *Epoch* dapat dilihat pada tabel dibawah.

Pengujian Epoch	Presisi	Recall	mAP50	mAP50-95
20	0.936	0.940	0.933	0.875
40	0.948	0.961	0.944	0.886
60	0.956	0.965	0.952	0.893
80	0.970	0.981	0.974	0.905
100	0.982	0.989	0.986	0.929

Hasil pelatihan model tersebut kemudian di validasi sehingga didapat *precision* 0.958, *recall* 0.967, *mAP50* sebesar 0.957, dan *mAP50-95* sebesar 0.897. Setelah itu, dilakukan perhitungan *F1-Score* sehingga didapat nilai sebesar 96,2%.

$$F1 - Score = \frac{2 \times precision \times recall}{precision + recall} = \frac{2 \times 0.958 \times 0.967}{0.958 + 0.967} = 96.2 \tag{4.3}$$

4. Pengujian Terhadap Resize

Tujuan dari pengujian ini adalah untuk menentukan ukuran yang tepat dalam pengklasifikasian citra daun padi serta untuk membantu mengidentifikasi potensi masalah pada pengklasifikasi, seperti kinerja yang buruk pada gambar yang lebih kecil atau gambar dengan rasio tinggi dan lebar tertentu. Terdapat tiga pengujian ukuran yang dilakukan, yaitu dengan ukuran 64x64, 128x128, dan 224x224. Dalam pengujian *Resize*, penulis menggunakan parameter lain dalam sistem, yaitu:

- *Optimizer* : SGD
- *Learning Rate*: 0.01
- *Epoch* :10
- *Batch Size*:16

Hasil Pengujian *Resize* dapat dilihat pada tabel dibawah.

TABEL 4.4  
Hasil Pengujian *Resize*

Pengujian Resize	Presisi	Recall	mAP50	mAP50-95
64 x 64	0.946	0.941	0.945	0.865
128 x 128	0.949	0.933	0.948	0.868
224 x 224	0.953	0.976	0.942	0.885

Hasil pelatihan model tersebut kemudian di validasi sehingga didapat *precision* 0.949, *recall* 0.950, *mAP50* sebesar 0.945, dan *mAP50-95* sebesar 0.872. Setelah itu, dilakukan perhitungan *F1-Score* sehingga didapat nilai sebesar 94,9%.

$$F1 - Score = \frac{2 \times precision \times recall}{precision + recall} = \frac{2 \times 0.949 \times 0.950}{0.949 + 0.950} = 94.9 \quad (4.4)$$

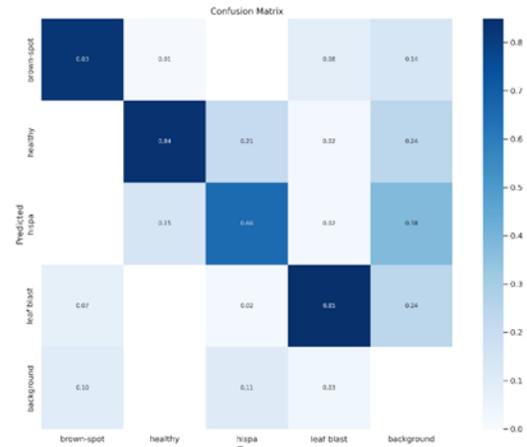
**B. Analisis Hasil Pengujian**

Dalam pengujian Optimizer, SGD memperoleh nilai presisi terbaik dan tertinggi dibandingkan dengan Optimizer lainnya. Pengujian Learning Rate menunjukkan bahwa 0.001 adalah Learning Rate yang paling sesuai untuk klasifikasi ini dibandingkan dengan nilai lainnya; selain itu, Learning Rate yang lebih kecil dapat mengurangi risiko overshooting dan membuat proses pelatihan lebih stabil. Pada pengujian Epoch, semakin besar nilai Epoch yang digunakan, semakin baik *performa* sistem. Sementara itu, dalam pengujian Resize, ukuran 224 terbukti menjadi yang terbaik di antara tiga pengujian yang dilakukan, karena semakin besar ukuran citra, semakin banyak detail informasi yang dapat diambil.

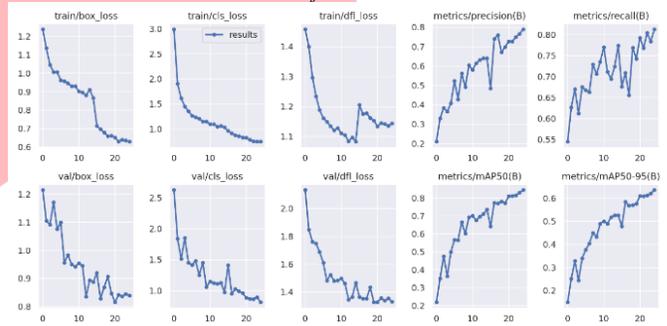
Setelah melakukan pengujian terhadap Optimizer, Learning Rate, Epoch, dan Resize, diperoleh parameter terbaik yang dapat digunakan untuk klasifikasi penyakit daun tomat pada YOLOv8, yaitu:

TABEL 4.5 Hasil Pengujian Terbaik

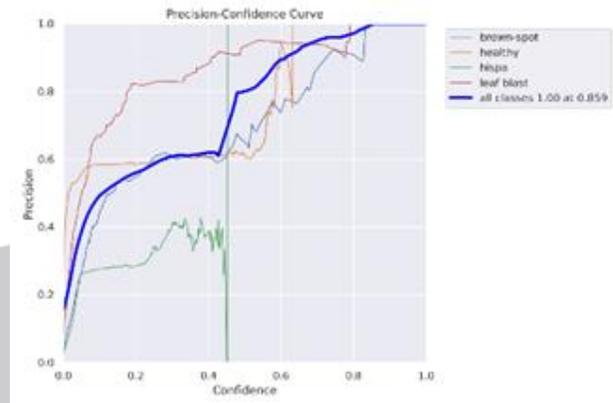
Pengujian Terbaik	
<b>Optimizer</b>	<b>SGD</b>
<b>Learning Rate</b>	<b>0.001</b>
<b>Epoch</b>	<b>100</b>
<b>Resize</b>	<b>224</b>



GAMBAR 4.1 Hasil Confusion Matrix



GAMBAR 4.2 Result Grafik



GAMBAR 4.3 Precision Confidence Curve

## V. KESIMPULAN

Pada penelitian Tugas Akhir ini, penulis merancang sistem untuk klasifikasi citra pada daun padi dengan menggunakan YOLOv8 didapatkan kesimpulan sebagai berikut:

1. Untuk melakukan klasifikasi ini, dalam merancang model YOLOv8 pada klasifikasi penyakit daun padi perlu persiapan data yang dapat digunakan untuk klasifikasi, melakukan *preprocessing* data seperti *resizing* dan pembagian data, melakukan pengujian model serta melakukan pengujian dengan mengacu pada metrik yang digunakan yaitu *presisi*, *recall*, *mAP50*, dan *mAP50-95*.
2. Metode yang digunakan untuk mencari parameter yang optimal dengan mencoba berbagai kombinasi parameter dan mengevaluasi performansi model seperti *optimizer*, *learning rate*, *epoch*, dan *resize*. Parameter terbaik yang digunakan dalam klasifikasi penyakit daun padi yaitu *optimizer SGD*, *learning rate* 0.001, *epoch* 80, dan *resize* 224.
3. Total dataset yang digunakan 3.773 gambar dengan pembagian data testing sebanyak 418 gambar, data training 2.684 gambar, dan data validasi 671 gambar. Dengan pembagian data training sebesar 70%, validasi sebesar 20%, dan testing sebesar 10%. Hasil dari pengujian yang dilakukan didapatkan nilai terbaik yaitu pada saat pengujian menggunakan size 224, learning rate 0.01, batch size 16, dan optimizer SGD yaitu presisi sebesar 0.982, recall 0.989, mAP50 0.986, dan mAP50-95 0.929 dan dari hasil perhitungan F1-Score sebesar 96,2%.

## REFERENSI

- [1] Badan Pusat Statistik, "Luas Panen dan Produksi Padi di Indonesia 2022," Statistic, 3 Agustus 2023. [Online]. Available: <https://www.bps.go.id/id/publication/2023/08/03/a78164ccd3ad09bdc88e70a2/luas-panen-dan-produksi-padi-di-indonesia-2022.html>. [Accessed 11 Januari 2024].
- [2] A. K. S. Md. Simul Hasan Talukder, "Smart Agricultural Technology," *Nutrients deficiency diagnosis of rice crop by weighted average*, vol. Table 12, no. 3.5, p. 5, 2022.
- [3] Dr. Ir. Zainal Arifin, M. S., "TEKNOLOGI PERLINDUNGAN TANAMAN," [Online]. Available: <https://faperta.untidar.ac.id/wp-content/uploads/2019/05/PETUNJUK-PRAKTIKUM-TPT-2019.pdf>. [Accessed 15 Januari 2024].
- [4] Dinas Ketahanan Pangan Kota Semarang, "Padi (Oryza Sativa)," Dinas Ketahanan Pangan, 16 Maret 2023. [Online]. Available: <https://ketahananpangan.semarangkota.go.id/v3/portal/page/artikel/Padi-Oryza-Sativa>. [Accessed 5 Januari 2024].
- [5] Rice Knowledge Bank, "Brown Spot," Plant, [Online]. Available: <http://www.knowledgebank.irri.org/training/factsheets/pest-management/diseases/item/brown-spot>. [Accessed 3 April 2024].
- [6] Rice Knowledge Bank, "Blast (leaf and collar)," Plant, [Online]. Available: <http://www.knowledgebank.irri.org/training/factsheets/pest-management/diseases/item/blast-leaf-collar>. [Accessed 3 April 2024].
- [7] Plantix, "Hispa Padi," Plantix, 2024. [Online]. Available: <https://plantix.net/id/library/plant-diseases/600098/rice-hispa/>. [Accessed 8 June 2024].
- [8] S. Riyaz, "Rice Leafs," [Online]. Available: <https://www.kaggle.com/datasets/shayanriyaz/rice-leafs?resource=download>. [Accessed 6 Maret 2024].
- [9] M. A. M. A. O. S. M. Omar Ibrahim Obaid, "Comparing the Performance of Pre-trained Deep Learning Models in Object Detection and Recognition," Juli 2022. [Online]. Available: [https://www.researchgate.net/publication/361983701\\_Comparing\\_the\\_Performance\\_of\\_Pre-trained\\_Deep\\_Learning\\_Models\\_in\\_Object\\_Detection\\_and\\_Recognition](https://www.researchgate.net/publication/361983701_Comparing_the_Performance_of_Pre-trained_Deep_Learning_Models_in_Object_Detection_and_Recognition). [Accessed 14 Mei 2024].
- [10] J. Pedro, "Detailed Explanation of YOLOv8 Architecture — Part 1," 4 Desember 2023. [Online]. Available: <https://medium.com/@juanpedro.bc22/detailed-explanation-of-yolov8-architecture-part-1-6da9296b954e>. [Accessed 14 Mei 2024].
- [11] F. A. B. Ajay Kulkarni, "Foundations of data imbalance and solutions for a data democracy," 2020. [Online]. Available: <https://www.sciencedirect.com/topics/engineering/confusion-matrix#:~:text=A%20confusion%20matrix%20is%20a,malignant%20tissue%20is%20considered%20cancerous..> [Accessed 6 Mei 2024].
- [12] R. Arthana, "Mengenal Accuracy, Precision, Recall dan Specificity serta yang diprioritaskan dalam Machine Learning," 5 April 2019. [Online]. Available: <https://rey1024.medium.com/mengenal-accuracy-precision-recall-dan-specificity-septa-yang-diprioritaskan-b79ff4d77de8>. [Accessed 6 Mei 2024].