

IMPLEMENTASI YOLO11 UNTUK DETEKSI PENYAKIT TANAMAN PADI BERDASARKAN CITRA DAUN

Farrel Alifandra Akbar¹, Julia Purnama Sari², Widhia KZ Oktoeberza³

^{1,3} Program Studi Informatika, Fakultas Teknik, Universitas Bengkulu,
Jl. WR. Supratman, Kandang Limun, Bengkulu, 3871A
Telp. (627) 3621170, Faks (627) 3622105

¹farrel.akbar33@gmail.com
²juliapurnamasari@unib.ac.id
³widhiakz@unib.ac.id

Abstrak: Padi (*Oryza sativa*) merupakan komoditas strategis bagi ketahanan pangan di Indonesia, namun rentan terhadap serangan penyakit seperti hawar daun bakteri (blight), blast, dan tungro, yang dapat menurunkan produktivitas secara signifikan. Deteksi dini penyakit ini secara manual oleh petani seringkali tidak akurat dan lambat. Penelitian ini bertujuan mengimplementasikan algoritma YOLOv11 berbasis *deep learning* untuk mendeteksi penyakit tanaman padi berdasarkan citra daun dengan akurasi tinggi. Metode penelitian mengikuti kerangka CRISP-DM (*Cross Industry Standard Process for Data Mining*), dimulai dari pemahaman bisnis, pengumpulan data, persiapan data, pemodelan, hingga evaluasi. Dataset terdiri dari 500 citra daun padi yang diklasifikasikan ke dalam tiga kelas penyakit. Data diproses melalui augmentasi dan *resizing* untuk menyeimbangkan distribusi kelas dan menyeragamkan ukuran gambar. Model YOLOv11 dilatih dengan parameter 100 epochs, ukuran gambar 224x224 piksel, dan batch size 32. Hasil evaluasi menunjukkan model mencapai akurasi 95% dengan precision dan recall rata-rata di atas 95%. Confusion matrix mengungkapkan kemampuan klasifikasi yang sangat baik, terutama untuk penyakit tungro (100% akurasi). Model juga efisien dalam melakukan prediksi dengan waktu inferensi 8.2 milidetik per gambar. Kesimpulan penelitian ini membuktikan bahwa YOLOv11 efektif untuk deteksi penyakit padi berbasis citra daun. Saran untuk pengembangan selanjutnya meliputi penambahan variasi data, integrasi ke aplikasi mobile, dan pengujian lapangan untuk validasi kinerja di kondisi nyata.

Kata Kunci: YOLOv11, deteksi penyakit padi, *deep learning*, citra daun, *computer vision*.

Abstract: Rice (*Oryza sativa*) is a strategic commodity for food security in Indonesia, yet it is highly vulnerable to diseases such as bacterial leaf blight (blight), blast, and tungro, which can significantly reduce productivity. Early detection of these diseases through manual observation by farmers is often inaccurate and slow. This study aims to implement the YOLOv11 algorithm, a deep learning-based approach, to detect rice plant diseases from leaf images with high accuracy. The research method follows the CRISP-DM (Cross Industry Standard Process for Data Mining) framework, encompassing business understanding, data collection, data preparation, modeling, and evaluation. The dataset consists of 500 rice leaf images classified into three disease categories. The data was processed through augmentation and resizing to balance class distribution and standardize image dimensions. The YOLOv11 model was trained with parameters set at 100 epochs, an image size of 224x224 pixels, and a batch size of 32. Evaluation results demonstrate that the model achieved 95% accuracy, with average precision and recall exceeding 95%. The confusion matrix revealed excellent classification performance, particularly for tungro disease (100% accuracy). The model also proved efficient in prediction, with an inference time of 8.2 milliseconds per image. In conclusion, this research confirms the effectiveness of YOLOv11 for rice disease detection based on leaf images. Recommendations for future development include expanding dataset diversity, integrating the model into mobile applications, and conducting field tests to validate real-world performance.

Keywords: YOLOv11, rice disease detection, deep learning, leaf image, computer vision.

I. PENDAHULUAN

Padi (*Oryza sativa*) memegang peranan vital sebagai komoditas strategis dalam ketahanan pangan global, menempati posisi ketiga sebagai penyedia karbohidrat utama setelah jagung dan gandum. Tanaman ini menjadi tulang punggung pangan bagi mayoritas populasi dunia, dengan kontribusi esensial dalam menjaga stabilitas pangan dan sosial. Di Indonesia, padi memiliki nilai strategis sebagai komoditas pertanian utama yang perlu terus dikembangkan di seluruh wilayah. Sebagai negara agraris, ketergantungan Indonesia

terhadap produksi padi sangat tinggi mengingat sekitar 80% penduduknya mengkonsumsi beras sebagai makanan pokok sehari-hari[1].

Dalam praktik budidaya padi, tanaman rentan terhadap serangan berbagai patogen seperti hawar daun bakteri (*Xanthomonas oryzae*), blast (*Pyricularia oryzae*), dan tungro (virus yang ditularkan wereng hijau) - tiga penyakit yang paling sering dilaporkan di lahan padi Indonesia. Masing-masing penyakit ini membutuhkan pendekatan penanganan spesifik, dimana petani lebih membutuhkan alat deteksi untuk penyakit yang langsung mengancam hasil panen daripada penyakit minor. Hawar daun bakteri menyebabkan daun menguning dengan garis-garis hijau pucat, blas menimbulkan bercak belah ketupat dan kerusakan pada malai, sementara tungro menghambat pertumbuhan dan menguningkan daun. Keterlambatan dalam identifikasi dan penanganan penyakit ini berpotensi menyebabkan penurunan produktivitas hingga kegagalan panen. Minimnya pengetahuan petani mengenai karakteristik penyakit dan metode pengendalian yang tepat seringkali menyebabkan tindakan yang kurang efektif.

Berdasarkan refrensi [2] data menunjukkan bahwa serangan penyakit pada tanaman padi di Indonesia menyebabkan kerugian hasil panen sekitar 200.000 hingga 300.000 ton setiap tahunnya, menggambarkan besarnya dampak negatif terhadap produktivitas pertanian nasional. Angka ini mengindikasikan tingkat ancaman yang signifikan bagi ketahanan pangan dan stabilitas ekonomi sektor pertanian di tanah air, sehingga diperlukan strategi pengendalian terpadu seperti penggunaan varietas tahan, pengelolaan air, dan pelatihan petani.

Berbagai strategi pengendalian penyakit padi telah diterapkan, mulai dari penggunaan bibit unggul tahan penyakit, modifikasi lingkungan budaya, hingga pemberian bahan kimia protektif. Namun,

pendekatan tradisional tersebut masih memiliki mengklasifikasikan objek yang terhalang (occluded) kelemahan mendasar dalam hal kemampuan deteksi atau hanya terlihat sebagian dengan tingkat awal. Kondisi ini mendorong perlunya konsistensi yang lebih tinggi—khususnya untuk pengembangan solusi berbasis teknologi yang lebih canggih untuk meningkatkan akurasi dan kecepatan identifikasi gangguan patologis pada tanaman padi.

Revolusi digital di pertanian, khususnya melalui kecerdasan buatan (AI), memperkenalkan terobosan dalam identifikasi penyakit tanaman. Salah satu solusi inovatifnya adalah algoritma YOLO (*Deep learning*), sistem *deep learning* yang mendeteksi objek secara *real-time* dengan presisi tinggi. Teknologi ini memungkinkan diagnosa otomatis penyakit padi melalui pemrosesan gambar digital, membantu petani merespons cepat sebelum penyakit menyebar. Pendekatan ini mengatasi kelemahan metode tradisional, meningkatkan produktivitas, dan mengurangi kerugian panen.

YOLO adalah algoritma *deep learning* untuk deteksi objek *real-time* dalam gambar atau video. Berbeda dengan metode tradisional, YOLO menggunakan sistem *end-to-end* yang membagi gambar menjadi grid, dengan setiap sel memprediksi koordinat *bounding box* dan klasifikasi objek secara paralel. Arsitektur ini memungkinkan deteksi multi-objek yang efisien dan cepat, cocok untuk aplikasi *real-time*. Keunggulan YOLO terletak pada kecepatan dan akurasinya, membuatnya ideal untuk berbagai aplikasi canggih seperti transportasi otonom, pengawasan cerdas, dan pemrosesan konten visual [3].

YOLOv11 menunjukkan peningkatan signifikan dibandingkan dengan versi sebelumnya, yaitu YOLOv8 dan YOLOv10, terutama dalam hal ketahanan terhadap berbagai kondisi lingkungan dan ukuran objek yang beragam. Berdasarkan analisis confusion matrix dan kurva precision-recall, YOLOv11 mampu mengidentifikasi dan

menangani bentuk objek yang kompleks serta sudut pandang yang sulit. Secara keseluruhan, YOLOv11 memiliki keunggulan dalam akurasi deteksi, terutama untuk objek yang berukuran kecil dan memiliki bentuk yang rumit, serta menunjukkan peningkatan kecepatan dan ketahanan. Hal ini menjadikan YOLOv11 sebagai solusi yang lebih efektif untuk tugas deteksi secara *real-time*[4].

Jadi padi merupakan komoditas vital bagi ketahanan pangan, khususnya di Indonesia, namun rentan terhadap berbagai penyakit yang dapat mengancam produksi. Metode konvensional dalam mendeteksi dan mengendalikan penyakit padi masih memiliki keterbatasan, terutama dalam deteksi dini. Oleh karena itu, pemanfaatan teknologi seperti algoritma YOLO (*Deep learning*) berbasis *deep learning* menjadi solusi yang menjanjikan. YOLO mampu melakukan deteksi penyakit secara cepat dan akurat melalui analisis citra digital, sehingga meningkatkan efektivitas pengelolaan tanaman padi. Terlebih, versi terbaru yaitu YOLOv11 menunjukkan peningkatan signifikan dalam akurasi dan kecepatan deteksi, menjadikannya metode potensial untuk mendukung keberlanjutan produksi padi dan ketahanan pangan nasional.

II. TINJAUAN PUSTAKA

A. Tanaman Padi

Padi (*Oryza sativa*) adalah salah satu komoditas pertanian yang paling penting di dunia, menduduki peringkat ketiga sebagai sumber karbohidrat utama setelah jagung dan gandum. Kedudukannya yang krusial ini menjadikannya sumber pangan pokok

bagi sebagian besar penduduk dunia, terutama di pangan nasional. Pengembangan tanaman padi di wilayah Asia, di mana nasi merupakan makanan Indonesia juga menghadapi berbagai tantangan, sehari-hari. Sebagai sumber karbohidrat utama, padi memiliki peran yang tak tergantikan dalam menjaga ketahanan pangan global. Ketersediaan juga membuka peluang untuk inovasi dan padi yang cukup dan terjangkau sangat penting pengembangan solusi yang lebih berkelanjutan, untuk mencegah kelaparan dan kekurangan gizi, seperti penggunaan pupuk organik, pengendalian terutama di negara-negara berkembang dengan hama terpadu, dan pengembangan varietas padi yang populasi yang besar. Fluktuasi harga dan ketersediaan padi dapat memiliki dampak signifikan terhadap stabilitas sosial dan ekonomi suatu negara[2].

Menurut refensi [5] ada beberapa penyakit yang terdapat pada tanaman padi, berikut tabel penyakit padi berdasarkan dari ciri-ciri daun:

| No | Nama Penyakit | Penyebab | Gejala |
|----|---------------------------------------|-----------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------|
| 1 | bacterial leaf bright atau hawar daun | Xanthomonas oryzae | Muncul bercak basah kehijauan-abu di tepi daun yang meluas seiring waktu, diikuti penggulungan daun dan pengeringan menjadi abu-abu pucat. |
| 2 | Blast | Magnaporthe oryzae | Bercak oval/belah ketupat dengan tepi coklat dan pusat abu-abu keputihan. |
| 3 | Tungro | Virus (Rice tungro bacilliform dan spherical virus) | Daun menguning-jingga, menggulung, lalu mengering menjadi kecoklatan |

Di Indonesia, sebagai negara agraris dengan mayoritas penduduknya menjadikan nasi sebagai makanan pokok, padi memiliki signifikansi yang sangat besar. Lebih dari 80% masyarakat Indonesia mengonsumsi nasi sebagai makanan sehari-hari, sehingga produksi padi yang cukup dan stabil merupakan kunci untuk memenuhi kebutuhan

B. Deep learning

Deep learning merupakan salah satu bidang dalam machine learning yang menggunakan struktur jaringan saraf tiruan (artificial neural network/ANN) untuk melakukan klasifikasi langsung dari data seperti gambar atau audio. Salah satu algoritma utamanya adalah *Deep learning* (CNN), yang merupakan pengembangan dari Multilayer Perceptron (MLP) dan secara khusus dirancang untuk memproses data multidimensi, terutama citra dan sinyal suara. Proses komputasi dalam *deep learning* memanfaatkan sumber daya seperti CPU, RAM, dan GPU, sehingga mampu menangani dataset berskala besar dengan struktur lapisan (layer) yang kompleks [6].

C. YOLO

YOLO (*Deep learning*) adalah salah satu algoritma *deep learning* terkenal yang banyak digunakan karena kemampuannya dalam mendeteksi objek secara cepat dan akurat baik pada gambar maupun video. Algoritma ini menerapkan pendekatan *end-to-end* yang efektif, di mana gambar dibagi menjadi beberapa *grid*, dan setiap *grid* melakukan prediksi terhadap *bounding box* serta probabilitas kelas objek yang ada. Dengan metode ini, YOLO mampu mendeteksi berbagai objek sekaligus dengan kecepatan tinggi, bahkan dalam kondisi *real-time*. Tujuan utama penggunaan YOLO adalah untuk menjawab tantangan dalam *computer vision* yang membutuhkan teknik

deteksi objek yang cepat dan tepat, sehingga sangat berguna di berbagai bidang seperti *autonomous vehicle, surveillance system, dan video analytics*[3].

Selain dikenal unggul dalam hal kecepatan dan ketepatan, YOLO juga memiliki kelebihan dalam mendeteksi objek dengan berbagai ukuran dan tingkat pencahayaan yang berbeda-beda. Perkembangan algoritma ini terus berlanjut melalui berbagai pembaruan versi yang semakin meningkatkan kemampuan serta menambahkan berbagai fitur canggih. Inovasi tersebut meliputi penyempurnaan struktur jaringan, metode pelatihan yang lebih efektif, serta pengenalan kemampuan baru seperti identifikasi objek berukuran kecil dan *real-time instance segmentation*[7].

D. YOLOv11

YOLOv11 merupakan pengembangan terbaru dari keluarga YOLO (*Deep learning*) yang menawarkan peningkatan signifikan dibanding versi sebelumnya, terutama YOLOv8. Model ini dirancang untuk meningkatkan efisiensi komputasi dan akurasi deteksi, menjadikannya sangat sesuai untuk aplikasi real-time seperti deteksi kendaraan.

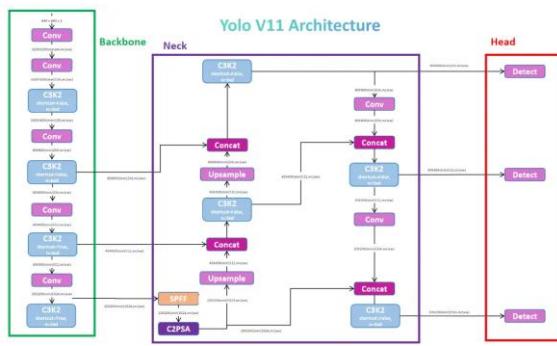
YOLOv11 mengadopsi konsep dasar yang mirip dengan pendahulunya. Sistem ini memproses gambar masukan dengan membaginya menjadi kisi-kisi berukuran $S \times S$. Apabila titik tengah suatu objek terletak dalam suatu sel kisi, maka sel tersebut akan bertugas membuat prediksi terkait objek itu. Setiap sel kisi menghasilkan sejumlah prediksi berupa kotak pembatas (*bounding box*), skor kepercayaan (*confidence score*), dan kategori objek. Seperti pada versi sebelumnya, posisi kotak pembatas (x, y, w, h) diprediksi berdasarkan proporsi gambar, sementara skor kepercayaan mencerminkan tingkat keyakinan model terhadap keberadaan objek serta ketepatan prediksi kotak tersebut.

Namun, YOLOv11 memperkenalkan berbagai penyempurnaan dalam hal ketepatan dan

kinerja, termasuk:

- Struktur *backbone* yang lebih optimal
- Kemampuan mendeteksi objek berukuran kecil dengan lebih baik
- Peningkatan efisiensi proses inferensi

Dengan inovasi-inovasi ini, YOLOv11 menawarkan kecepatan dan akurasi yang lebih unggul dibandingkan generasi sebelumnya[8].



1. Backbone

Backbone pada YOLOv11 berfungsi untuk mengekstraksi fitur dari citra masukan pada berbagai skala. Komponen ini terdiri dari sejumlah lapisan konvolusional dan blok-blok khusus yang membentuk peta fitur pada resolusi yang berbeda. Beberapa inovasi utama pada bagian ini antara lain:

a. Blok C3k2

Blok C3k2 merupakan penyempurnaan dari blok C2f pada YOLOv8, yang didasarkan pada arsitektur Cross-Stage Partial (CSP). Blok ini menggunakan dua konvolusi kecil (kernel size = 2) untuk menekan biaya komputasi tanpa mengorbankan performa.

b. SPPF (Spatial Pyramid Pooling Fast)

SPPF digunakan untuk melakukan pooling spasial pada berbagai skala, mempertahankan fitur penting dari objek dengan ukuran bervariasi.

c. Blok C2PSA (Cross-Path Spatial Attention)

Blok C2PSA menambahkan mekanisme perhatian spasial untuk membantu model fokus pada area-area penting dalam citra, seperti objek kecil atau tumpang tindih.

2. Neck

Bagian neck bertugas menggabungkan fitur dari berbagai resolusi untuk diteruskan ke bagian head. Pada YOLOv11, proses agregasi fitur dilakukan melalui:

a. Upsampling dan Concatenation

Fitur dari resolusi yang lebih tinggi di-upsample dan digabungkan dengan fitur dari resolusi yang lebih rendah.

b. Blok C3k2

Blok C3k2 kembali digunakan pada neck untuk meningkatkan efisiensi proses agregasi fitur.

c. C2PSA

C2PSA diterapkan untuk meningkatkan kemampuan model dalam mengenali objek di area yang padat atau rumit.

3. Head

Head pada YOLOv11 bertugas menghasilkan prediksi akhir berupa koordinat bounding box, label kelas, dan skor kepercayaan. Sistem deteksi dilakukan pada tiga skala berbeda:

a. P3 (small), P4 (medium), dan P5 (large)

Masing-masing bertugas mendeteksi objek dengan ukuran yang berbeda. Pendekatan multi-skala ini memungkinkan YOLOv11 mendeteksi objek kecil hingga besar secara lebih efektif[4].

YOLO merupakan algoritma deteksi objek populer di computer vision berkat keunggulannya, dengan penggunaan yang terus berkembang seiring kemajuan *deep learning* dan kebutuhan akan sistem deteksi yang lebih cepat dan akurat.

Fase Ekstraksi Fitur (*Backbone*) Gambar input pertama kali diproses melalui *backbone* yang telah mengalami penyempurnaan dibanding versi sebelumnya. Pada YOLOv11, komponen ini dirancang untuk melakukan ekstraksi fitur secara lebih optimal, dengan beban komputasi yang lebih ringan namun tetap mempertahankan ketepatan deteksi. Penggabungan Fitur Multi-Level (*Neck*)

Fitur yang telah diekstrak kemudian diolah melalui *neck* (biasanya menggunakan arsitektur seperti PANet atau FPN). Tahap ini berfungsi untuk memadukan informasi dari berbagai level abstraksi fitur, sehingga model mampu mengenali objek dalam berbagai skala ukuran dengan hasil yang lebih akurat. Fase Prediksi (*Head*) Hasil pemrosesan kemudian dikirim ke *head*, yang bertanggung jawab untuk menghasilkan prediksi akhir berupa lokasi (*bounding box*), tingkat kepercayaan, dan klasifikasi objek yang terdeteksi dalam gambar[8].

III. METODE PENELITIAN

A. Jenis Penelitian

Penelitian ini termasuk dalam kategori penelitian terapan yang bertujuan untuk menghasilkan solusi praktis dalam menyelesaikan permasalahan nyata. Berbeda dengan penelitian dasar, studi ini berfokus pada penerapan teori-teori ilmiah untuk kemudian diuji dan dievaluasi efektivitasnya dalam mengatasi tantangan praktis di lapangan. Hasil penelitian dirancang untuk dapat segera diimplementasikan guna menjawab kebutuhan spesifik yang dihadapi.[9].

B. Metode Pengumpulan Data

Studi pustaka dilakukan dengan cara menelaah beberapa literatur, di antaranya:

a. Buku referensi

Buku yang digunakan sebagai referensi ialah buku-buku yang membahas tentang Tanaman Padi (*Oryza sativa*) dan penyakit yang ada pada tanaman padi.

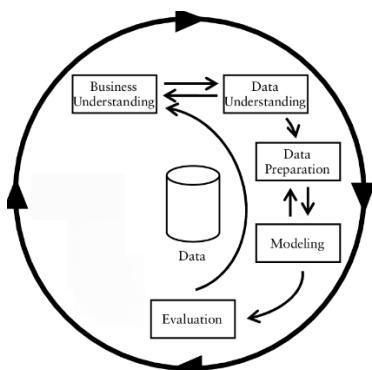
b. Jurnal ilmiah

Literatur yang digunakan dalam penelitian ini diperoleh melalui pencarian dan pengunduhan dari berbagai platform akademik online. Referensi tersebut mencakup kajian-kajian terkait tanaman padi (*Oryza sativa*) dan

algoritma deteksi objek YOLO (*Deep learning*) untuk kebutuhan analisis, penelitian ini menggunakan dataset penyakit tanaman padi yang bersumber dari platform Kaggle. Dataset tersebut dapat diakses pada tautan berikut: <https://www.kaggle.com/datasets/rahmi21/rice-datasets/data>.

C. Disain Penelitian

Penelitian ini mengikuti pendekatan CRISP-DM (Cross Industry Standard Process for Data Mining), yang terdiri dari enam tahap utama[10]. Namun, dalam penelitian ini hanya lima tahap pertama yang diterapkan, tanpa mencakup tahap deployment, karena fokus utama adalah pada pengembangan dan evaluasi model deteksi penyakit tanaman berbasis YOLOv11.



Gambar 3.1 Diagram proses CRISP-DM

1. *Business Understanding*

Tahap ini bertujuan untuk memahami tujuan dari penelitian. Permasalahan yang diangkat adalah kesulitan dalam mendeteksi penyakit tanaman padi berdasarkan citra daun secara cepat dan akurat. Oleh karena itu, sistem ini dikembangkan untuk membantu mendeteksi penyakit melalui citra daun padi menggunakan teknologi deteksi objek berbasis YOLOv11.

2. *Data Understanding*

Pada tahap ini dilakukan pengumpulan dan pemahaman terhadap data yang digunakan, yaitu gambar daun padi yang terinfeksi berbagai jenis penyakit. Data dikumpulkan dari

sumber terpercaya dan diklasifikasikan berdasarkan jenis penyakit yang terlihat pada daun.

3. *Data Preparation*

Gambar-gambar yang telah dikumpulkan diproses agar siap digunakan dalam pelatihan model. Proses ini mencakup pengubahan ukuran gambar, pelabelan bagian daun yang terkena penyakit, serta pembagian data menjadi data latih dan data uji.

4. *Modeling*

Tahap ini merupakan proses pelatihan model YOLOv11 untuk mengenali dan mengklasifikasikan jenis penyakit pada gambar daun padi. Model dilatih untuk mendeteksi lokasi penyakit serta menentukan jenis penyakit berdasarkan pola visual pada daun.

5. *Evaluation*

Model yang telah dibuat akan diuji untuk melihat seberapa akurat dan baik kemampuannya dalam mendeteksi penyakit pada gambar baru menggunakan *confusion matrix* dan *classification report*. Hasil evaluasi digunakan untuk mengetahui apakah model sudah layak digunakan.

IV. HASIL DAN PEMBAHASAN

A. *Bussiness Understanding*

Tanaman padi (*Oryza sativa*) merupakan komoditas pertanian strategis di Indonesia yang sering mengalami penurunan produktivitas akibat serangan penyakit yang terlambat terdeteksi. Saat ini, petani masih mengandalkan metode identifikasi manual melalui pengamatan visual terhadap gejala penyakit seperti blast, hawar daun, atau virus tungro pada tanaman. Namun, pendekatan konvensional ini memiliki berbagai keterbatasan, termasuk ketergantungan pada subjektivitas pengamat, proses identifikasi yang lambat, kesulitan penerapan di lahan

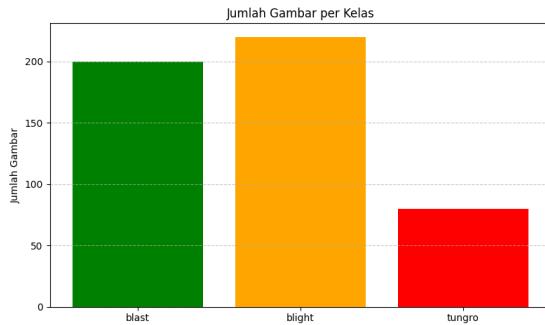
luas, serta risiko keterlambatan penanganan yang dapat memperluas kerusakan tanaman.

Berdasarkan permasalahan tersebut, penelitian ini mengembangkan model berbasis algoritma YOLOv11 untuk mendeteksi penyakit tanaman padi melalui analisis citra daun. Pemilihan daun sebagai objek analisis didasarkan pada fakta bahwa gejala awal sebagian besar penyakit padi umumnya muncul pertama kali pada bagian daun, berupa perubahan warna, pembentukan bercak khas, atau kerusakan jaringan. Model ini dirancang untuk memberikan solusi deteksi penyakit yang bekerja secara real-time dengan tingkat akurasi tinggi, efisiensi komputasi yang baik, serta kemampuan beradaptasi dengan berbagai kondisi lingkungan di lapangan. Melalui pengembangan ini, diharapkan dapat tercipta sistem pendekripsi dini yang lebih efektif dalam mengidentifikasi penyakit tanaman padi dibandingkan metode konvensional yang selama ini digunakan.

B. Data Understanding

Dataset yang digunakan dalam penelitian ini telah di klasifikasikan menjadi tiga penyakit yang ada pada tanaman padi, sehingga bisa menjadi referensi untuk akurasi dari model yang akan dibuat. Dataset ini di unggah ke situs Kaggle dan telah dibagi menjadi tiga folder yang berbeda sesuai dengan penyakit pada tanaman padi.

Terdapat tiga kelas dataset yang berisi gambar dari setiap penyakit



Gambar 4.1 Diagram jumlah gambar pada dataset Dari tiga folder yang berada di datset tersebut

terdapat total 500 gambar yang telah di klasifikasikan penyakitnya, gambar berupa daun tanaman padi yang telah terkena penyakit blast, blight dan tungro. Pada diagram juga bisa dilihat proporsi setiap kelas tidak sama rata, maka perlu dilakukan persiapan data atau preprcessing data agar distribusi kelas merata.

C. Data Preparation

Persiapan data (*data preparation*) merupakan tahapan krusial dalam proses pelatihan model deteksi penyakit tanaman, karena kualitas dan keseimbangan data sangat mempengaruhi performa akhir model. Pada tahap ini, dilakukan berbagai proses untuk memastikan bahwa data yang digunakan memiliki distribusi yang seimbang dan representatif, serta memiliki format dan kualitas yang sesuai dengan kebutuhan algoritma YOLOv11.

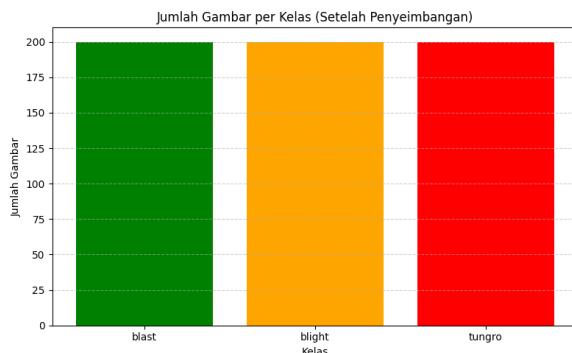
Dalam dataset yang digunakan, ditemukan adanya ketimpangan distribusi antar kelas, di mana jumlah data pada kategori penyakit blast jauh lebih banyak dibandingkan kelas lainnya, seperti tungro atau blight. Ketidakseimbangan ini berpotensi menyebabkan model menjadi bias terhadap kelas dengan jumlah data terbanyak.

Untuk mengatasi hal tersebut, dilakukan dua pendekatan utama:

- Augmentasi pada kelas minoritas: Kelas dengan jumlah data yang relatif sedikit, seperti tungro, dilakukan augmentasi menggunakan teknik seperti rotasi, flipping, zooming, brightness adjustment, dan cropping. Tujuannya adalah menambah jumlah sampel tanpa mengubah makna visual dari citra, sehingga kelas tersebut memiliki jumlah data yang sebanding dengan kelas blast.
- Under-sampling* pada kelas mayoritas: Sementara itu, pada kelas blight yang jumlahnya lebih besar dibanding kelas blast, dilakukan under-sampling. Ini berarti sebagian data dari kelas blight dikurangi secara acak agar

distribusinya tidak terlalu dominan, dan menjadi seimbang dengan kelas lainnya.

Dengan kombinasi antara augmentasi data dan *under-sampling*, diharapkan distribusi antar kelas menjadi lebih proporsional. Hal ini sangat penting agar model tidak hanya fokus atau lebih “terlatih” pada satu jenis penyakit saja, melainkan dapat mendeteksi seluruh kategori penyakit secara adil dan akurat. Langkah-langkah ini juga meningkatkan kemampuan generalisasi model terhadap data baru di dunia nyata.



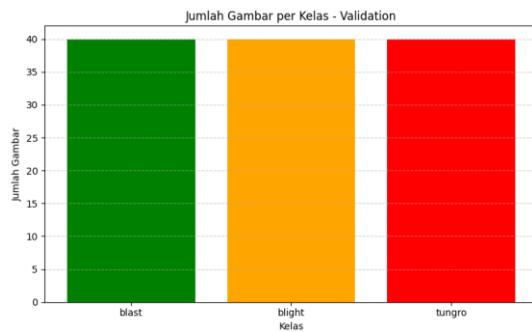
Gambar 4.2 Grafik jumlah gambar pada dataset setelah penyeimbangan

Pada grafik diatas telah di dapatkan penyeimbangan data dimana setiap kelas telah memiliki jumlah yang sama disetiap kelas yaitu terdapat 200 gambar disetiap kelas.

Proses selanjutnya melibatkan segmentasi dataset menjadi dua kelompok utama: data training untuk pembentukan model dan data validasi untuk pengujian performa. Data training berperan dalam proses pembelajaran model, sementara data validasi digunakan sebagai bahan evaluasi terhadap data baru yang belum diproses sebelumnya. Pembagian ini bertujuan untuk menguji sejauh mana model mampu melakukan generalisasi dalam mengenali penyakit padi secara tepat pada kasus-kasus baru di luar sampel pembelajaran.



Gambar 4.3 Grafik dataset *train*



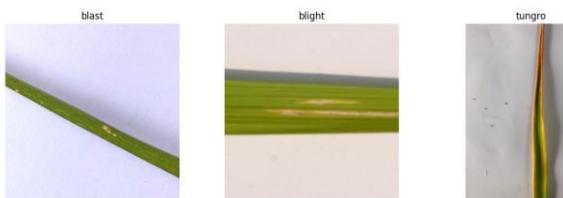
Gambar 4.4 Grafik dataset *validation*

Dua grafik di atas merepresentasikan distribusi data yang digunakan dalam proses pelatihan (*training*) dan evaluasi model. Gambar 4.3 menunjukkan jumlah data pada masing-masing kelas dalam dataset pelatihan, yang digunakan untuk melatih model agar dapat mengenali pola visual dari setiap jenis penyakit yang dimana pada data pelatihan ini setiap kelas memiliki 160 gambar dan berjumlah total 480 gambar dari seluruh kelas. Sementara itu, gambar 4.4 menampilkan distribusi data pada dataset validasi, pada dataset yang digunakan untuk evaluasi ini memiliki 40 gambar di setiap kelas dan total berjumlah 120 gambar dari seluruh kelas, yang digunakan untuk menguji dan mengevaluasi performa model terhadap data yang belum pernah dilihat sebelumnya. Visualisasi ini penting untuk memastikan bahwa distribusi data pada kedua subset tersebut seimbang dan representatif, sehingga proses pelatihan dan evaluasi dapat berjalan secara adil dan akurat.

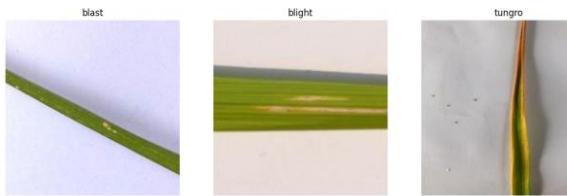
Proses *resizing* atau penyesuaian ukuran gambar dilakukan untuk menyamakan dimensi

seluruh citra dalam dataset sebelum digunakan dalam pelatihan model. Hal ini penting karena ukuran gambar pada masing-masing kelas penyakit tanaman padi tidak seragam, yang dapat mengganggu proses pemrosesan oleh model deteksi seperti YOLOv11, yang mensyaratkan ukuran input gambar yang konsisten.

Dengan melakukan *resizing*, setiap citra diubah ke ukuran tetap yang telah ditentukan agar dapat diproses secara efisien oleh jaringan neural tanpa menyebabkan kesalahan atau ketidaksesuaian dimensi. Penyeragaman ini juga bertujuan untuk menjaga stabilitas pelatihan serta memastikan bahwa fitur visual dari citra dapat dianalisis secara konsisten oleh model, tanpa dipengaruhi oleh perbedaan resolusi asli antar gambar.



Gambar 4.5 contoh gambar dari setiap kelas sebelum di *resizing*



Gambar 4.6 contoh gambar dari setiap kelas yang telah dilakukan *resizing*

Gambar di atas merupakan representasi dari masing-masing kelas dalam dataset setelah melalui proses *resizing*. Setiap citra telah disesuaikan ukurannya agar memiliki dimensi yang seragam, sesuai dengan standar input yang dibutuhkan oleh model YOLOv11. Visualisasi ini bertujuan untuk menunjukkan hasil akhir dari proses penyeragaman ukuran gambar, sekaligus memastikan bahwa karakteristik visual penting dari setiap kelas penyakit tetap terjaga meskipun ukurannya telah diubah.

D. Modeling

Penelitian ini mengimplementasikan arsitektur YOLOv11 dari framework Ultralytics untuk membangun model klasifikasi. Sebagai varian terbaru dalam seri YOLO, YOLOv11 tidak hanya unggul dalam deteksi objek tetapi juga memiliki kemampuan tambahan untuk menyelesaikan berbagai tugas visi komputer, termasuk klasifikasi gambar. Secara spesifik, model ini dikembangkan untuk mengidentifikasi tiga jenis penyakit utama pada daun padi: blast, blight, dan tungro melalui analisis citra digital.

Pemilihan YOLOv11 dilakukan karena model ini memiliki keunggulan dalam hal kecepatan inferensi, efisiensi komputasi, serta akurasi yang kompetitif, terutama pada dataset citra yang kompleks namun terbatas. Selain itu, dukungan pretrained weights dan pipeline pelatihan yang telah terintegrasi dalam Ultralytics menjadikan model ini fleksibel dan mudah untuk dikustomisasi.

Adapun proses pelatihan model dikonfigurasi dengan beberapa parameter utama sebagai berikut:

- Epochs = 100

Model dilatih selama 100 epoch, yang berarti seluruh dataset pelatihan diproses sebanyak 100 kali. Jumlah ini dipilih untuk memberikan waktu yang cukup bagi model dalam mempelajari pola-pola penting pada citra tanpa kehilangan generalisasi. Proses pelatihan ini dilakukan secara otomatis, dimulai dari epoch ke-0 dan akan berhenti lebih awal jika kriteria *early stopping* terpenuhi, yaitu saat tidak terjadi peningkatan signifikan pada performa validasi dalam beberapa epoch berturut-turut. Selama proses ini, metrik performa dievaluasi secara bertahap melalui validasi antar-epoch.

- Image Size (imgsz) = 224 score, dan overall accuracy. Kedua alat evaluasi ini diaplikasikan pada model final yang telah melalui proses pelatihan untuk mengenali pola visual spesifik model klasifikasi modern. Ukuran ini penyakit pada citra daun padi, memungkinkan merupakan kompromi antara efisiensi peneliti untuk mengukur kemampuan generalisasi komputasi dan kedalaman informasi visual. Proses *resizing* dilakukan saat pra-pemrosesan agar semua gambar memiliki dimensi yang seragam(He et al., 2016).

- Batch Size = 32

Selama pelatihan, model memproses 32 citra dalam satu iterasi (*mini-batch*). Ukuran batch ini dianggap optimal untuk menjaga stabilitas pembelajaran dan memaksimalkan penggunaan sumber daya perangkat keras (RAM/GPU) yang tersedia(Masters & Luschi, 2018).

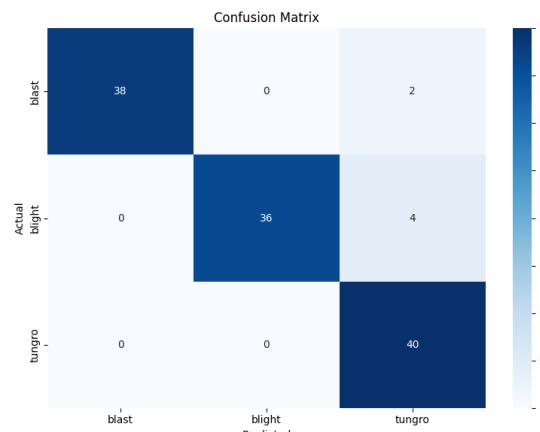
Model dijalankan dalam mode klasifikasi (YOLOv11 *classification mode*) dengan memanfaatkan pretrained weights dari pelatihan sebelumnya pada dataset ImageNet, yang memungkinkan model memiliki pemahaman awal terhadap fitur visual umum. Setelah pelatihan, model terbaik disimpan berdasarkan metrik evaluasi pada data validasi. Model tersebut kemudian digunakan untuk melakukan inferensi terhadap citra baru guna menguji kemampuan klasifikasinya secara nyata.

Dengan konfigurasi tersebut, diharapkan model dapat mengenali jenis penyakit daun padi secara akurat, cepat, dan dapat diandalkan dalam kondisi dunia nyata.

E. Evaluation

Evaluasi kinerja model dilakukan dengan memanfaatkan Confusion Matrix dan Classification Report sebagai alat analisis utama. Confusion Matrix memvisualisasikan akurasi prediksi per kelas melalui perbandingan hasil klasifikasi yang benar dan salah, sementara Classification Report memberikan pengukuran kuantitatif menggunakan metrik-metrik penting seperti precision, recall, F1-

score, dan overall accuracy. Kedua alat evaluasi ini model terhadap data baru, mengidentifikasi kelemahan klasifikasi per kelas, serta mengevaluasi konsistensi prediksi secara menyeluruh guna menentukan kebutuhan optimasi lebih lanjut.



Gambar 4.8 Confusion Matrix

Confusion matrix di atas digunakan untuk mengevaluasi kinerja model klasifikasi dimana model bekerja sangat baik dalam mengklasifikasikan ketiga jenis penyakit, kesalahan klasifikasi hanya terjadi pada kelas blast dan blight, dan pada tungro diklasifikasikan dengan akurasi 100%

| | precision | recall | f1-score | support |
|--------------|-----------|--------|----------|---------|
| blast | 1.00 | 0.95 | 0.97 | 40 |
| blight | 1.00 | 0.90 | 0.95 | 40 |
| tungro | 0.87 | 1.00 | 0.93 | 40 |
| accuracy | | | 0.95 | 120 |
| macro avg | 0.96 | 0.95 | 0.95 | 120 |
| weighted avg | 0.96 | 0.95 | 0.95 | 120 |

Gambar 4.9 Classification report

Gambar 4.9. *Classification Report* Hasilnya akurasi sebesar 95%. Rata-rata precision (macro): 95.7%. Rata-rata recall (macro): 95.0%. Model ini memiliki performa yang baik, namun tetap ada indikasi overfitting. Karena hal tersebut tidak mungkin diperoleh dari model klasifikasi yang baik dan robust.

F. *Prediction Model*

Setelah proses pelatihan selesai dan model terbaik berhasil diperoleh, langkah selanjutnya adalah melakukan prediksi menggunakan model YOLOv11. Model yang telah dilatih digunakan untuk mengklasifikasikan citra daun padi yang belum pernah dilihat sebelumnya. Proses prediksi ini bertujuan untuk menguji seberapa baik model mampu mengenali jenis penyakit berdasarkan fitur visual yang terdapat pada gambar. Model akan memberikan hasil berupa kelas yang diprediksi beserta nilai kepercayaan (*confidence score*) untuk setiap citra yang diuji. Prediksi dilakukan dengan memanfaatkan perintah bawaan dari *Ultralytics*, di mana model akan membaca citra dari folder input, memprosesnya, dan menghasilkan output dalam bentuk label kelas. Hasil prediksi ini kemudian dianalisis lebih lanjut untuk melihat apakah model sudah bekerja secara optimal dalam mengidentifikasi penyakit tanaman padi. Selain itu, visualisasi hasil prediksi juga ditampilkan agar memudahkan interpretasi kinerja model secara langsung.



Gambar 4.10 hasil dari prediksi model terlatih

Hasil prediksi model klasifikasi YOLOv11 ditunjukkan pada Gambar di atas. Pada gambar tersebut, model melakukan klasifikasi terhadap citra daun padi dengan ukuran 224x224 piksel. Model menghasilkan tiga kemungkinan kelas penyakit, yaitu blight, tungro, dan blast, masing-masing dengan tingkat probabilitas (*confidence score*) sebesar 0.65, 0.34, dan 0.01. Berdasarkan skor

tertinggi, model memprediksi bahwa citra tersebut tergolong dalam kelas blight, yang berarti terdapat indikasi bahwa daun padi yang diuji mengalami gejala penyakit blight.

Proses prediksi berlangsung dengan cukup efisien, di mana waktu preprocessing tercatat selama 2.3 milidetik, proses inferensi selama 8.2 milidetik, dan postprocessing hanya membutuhkan 0.1 milidetik. Output hasil prediksi secara otomatis disimpan dalam folder runs/classify/predict29, termasuk label prediksi dan visualisasi hasil klasifikasi.

Prediksi ini menunjukkan bahwa model mampu mengenali ciri-ciri visual pada citra daun dengan baik, dan memberikan hasil berupa label prediksi yang disertai dengan nilai confidence. Nilai confidence ini menjadi indikator seberapa yakin model terhadap hasil prediksi yang diberikan. Dengan nilai prediksi tertinggi pada kelas blight, maka dapat disimpulkan bahwa model bekerja sesuai harapan dalam mengidentifikasi penyakit tanaman padi berdasarkan citra daun.



Gambar 4.11 Hasil prediksi model terlatih 1



Gambar 4.12 Hasil prediksi model terlatih 2



Gambar 4.13 Hasil prediksi model terlatih 3

Dari gambar di atas, yang diambil secara acak sebagai sampel uji, dilakukan proses pengujian untuk mengevaluasi kemampuan prediksi model yang telah dilatih sebelumnya. Gambar tersebut diproses menggunakan model klasifikasi citra berbasis *deep learning* guna mengidentifikasi jenis penyakit yang terdapat pada daun padi. Berdasarkan hasil deteksi yang ditampilkan, model mampu mengklasifikasikan gejala penyakit dengan tingkat probabilitas yang jelas dan meyakinkan. Hal ini menunjukkan bahwa model dapat mengenali pola visual pada daun secara efektif. Dengan hasil prediksi yang konsisten dan akurat terhadap jenis penyakit tertentu, pengujian ini membuktikan bahwa performa model cukup memuaskan dan layak untuk dilakukannya deteksi penyakit tanaman berbasis citra secara otomatis.

V. KESIMPULAN SARAN

A. Kesimpulan

Implementasi YOLOv11 dalam sistem deteksi penyakit padi melalui analisis citra daun berhasil mengidentifikasi tiga patologi utama tanaman padi (blast, blight, dan tungro) dengan performa yang mengesankan. Hasil evaluasi menunjukkan akurasi sistem mencapai 95%, didukung oleh nilai precision dan recall yang konsisten di atas 95%. Analisis confusion matrix mengungkapkan kemampuan klasifikasi yang sangat akurat dengan minimal kesalahan, bahkan mencapai presisi sempurna (100%) dalam mendeteksi kasus tungro.

Proses pelatihan model selama 30 epoch dengan parameter input gambar 224×224 piksel dan batch size 32 membuktikan kemampuan adaptasi model dalam mempelajari karakteristik visual dari data pelatihan. Konfigurasi ini menghasilkan model yang tidak hanya akurat tetapi juga efisien dalam memproses pola visual penyakit pada daun padi.

B. Saran

Untuk pengembangan lebih lanjut, disarankan agar jumlah dan variasi data diperbanyak guna meningkatkan kemampuan generalisasi model. Pengujian di lapangan secara real-time juga perlu dilakukan untuk mengevaluasi kinerja model dalam kondisi nyata. Selain itu, penambahan kategori penyakit padi akan membuat sistem lebih komprehensif. Integrasi model ke dalam aplikasi mobile atau web dapat mempermudah penggunaannya di lapangan. Terakhir, penggunaan pendekatan *ensemble* atau kombinasi dengan model lain seperti ResNet dapat dipertimbangkan untuk meningkatkan akurasi.

REFERENSI

- [1] K. K. Rekayasa, M. Khoiruddin, A. Junaidi, and W. A. Saputra, “Terbit online pada laman web jurnal: <http://journal.ittelkom-pwt.ac.id/index.php/dinda> Journal of Dinda Klasifikasi Penyakit Daun Padi Menggunakan Deep learning,” *Data Inst. Teknol. Telkom Purwokerto*, vol. 2, no. 1, pp. 37–45, 2022, [Online]. Available: <https://www.kaggle.com/tedisetiady/leaf-rice-disease>
- [2] Ulfah Nur Oktaviana, Ricky Hendrawan, Alfian Dwi Khoirul Annas, and Galih Wasis Wicaksono, “Klasifikasi Penyakit Padi berdasarkan Citra Daun Menggunakan Model Terlatih Resnet101,” *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 6, pp. 1216–1222, 2021, doi: 10.29207/resti.v5i6.3607.
- [3] A. Pangestu, M. Pajar, K. Putra, C. Science, and U. T. Indonesia, “YOLOv9 – BASED TRAFFIC SIGN DETECTION UNDER VARYING LIGHTING,” vol. 6, no. 1, pp. 291–300, 2025.
- [4] M. A. R. Alif, “YOLOv11 for Vehicle Detection: Advancements, Performance, and Applications in Intelligent Transportation Systems,” 2024, [Online]. Available: <http://arxiv.org/abs/2410.22898>

- [5] S. Sheila, I. Permata Sari, A. Bagas Saputra, M. Kharil Anwar, and F. Restu Pujiyanto, “Deteksi Penyakit Pada Daun Padi Berbasis Pengolahan Citra Menggunakan Metode *Deep learning* (*CNN*),” *Multinetica*, vol. 9, no. 1, pp. 27–34, 2023, doi: 10.32722/multinetica.v9i1.5255.
- [6] N. M. Yasen, S. Rifka, R. Vitria, and Y. Yulindon, “Pemanfaatan Yolo Untuk Deteksi Hama Dan Penyakit Pada Daun Cabai Menggunakan Metode *Deep learning*,” *Elektron J. Ilm.*, vol. 15, pp. 63–71, 2023, doi: 10.30630/eji.0.0.397.
- [7] A. Putra Pranjaya, F. Rizki, R. Kurniawan, and N. K. Daulay, “KLIK: Kajian Ilmiah Informatika dan Komputer Klasifikasi Penyakit Pada Daun Tanaman Padi Berbasis YoloV5 (*Deep learning*),” *Media Online*, vol. 4, no. 6, pp. 3127–3136, 2024, doi: 10.30865/kliek.v4i6.1916.
- [8] J. Huang, K. Wang, Y. Hou, and J. Wang, “LW-YOLO11: A Lightweight Arbitrary-Oriented Ship Detection Method Based on Improved YOLO11,” *Sensors*, vol. 25, no. 1, 2025, doi: 10.3390/s25010065.
- [9] M. Arsyam and M. Yusuf Tahir, “Ragam Jenis Penelitian dan Perspektif,” *Al-Ubudiyah J. Pendidik. dan Stud. Islam*, vol. 2, no. 1, pp. 37–47, 2021, doi: 10.55623/au.v2i1.17.
- [10] J. Brzozowska, J. Pizoń, G. Baytikenova, A. Gola, A. Zakimova, and K. Piotrowska, “Data Engineering in Crisp-Dm Process Production Data – Case Study,” *Appl. Comput. Sci.*, vol. 19, no. 3, pp. 83–95, 2023, doi: 10.35784/acs-2023-26.