

RANCANG BANGUN APLIKASI PENGOLAHAN CITRA DETEKSI TINGKAT KESUBURAN TANAMAN PADI BEDASARKAN WARNA DAUN MENGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK

Muhammad Raehan, Rahmawati, Eko Sutono

Teknik Informatika, Universitas Pamulang

Fakultas Ilmu Komputer, Teknik Informatika, Universitas Pamulang, Tangerang Selatan, Indonesia

muhammad.raehan1264@gmail.com

ABSTRAK

Penentuan tingkat kesuburan dan penyakit tanaman padi melalui uji laboratorium umumnya memerlukan biaya tinggi dan waktu lama. Di sisi lain, deteksi visual manual di lapangan seringkali tidak konsisten akibat keterbatasan penglihatan. Untuk mengatasinya, penelitian ini mengusulkan aplikasi cerdas berbasis web untuk mendeteksi kondisi tanaman padi melalui analisis citra warna daun menggunakan algoritma *Convolutional Neural Network (CNN)* berbasis *object detection*. Dataset yang digunakan berjumlah 358 citra yang mencakup enam kelas kondisi penyakit. Data tersebut dibagi menjadi 70,4% data *training*, 20,1% data *validation*, dan 9,5% data *testing*. Seluruh data diproses secara komprehensif melalui tahapan *pre-processing* dan augmentasi. Hasil pengujian akhir model pada 25 *epoch* menunjukkan performa yang sangat optimal, mencatat nilai *Precision* sebesar 0,938, *Recall* 0,943, dan *mAP@50* mencapai 0,988. Implementasi model ke dalam antarmuka web memfasilitasi pengguna untuk melakukan deteksi secara instan melalui unggahan gambar maupun pindaian *webcam* secara *real-time*. Sistem ini diharapkan memberikan kemudahan bagi petani dalam memantau kesehatan padi secara mandiri untuk mencegah gagal panen dan menjaga ketahanan pangan.

Kata kunci : Tanaman Padi, *Convolutional Neural Network*, *Object Detection*, Deteksi Kesuburan, Aplikasi Berbasis Web.

1. PENDAHULUAN

Sebagai komoditas pangan pokok bagi lebih dari separuh populasi global, budidaya padi memiliki urgensi yang sangat tinggi dalam menopang kehidupan manusia dan ketahanan pangan, sebagaimana disoroti oleh [1]. Dalam konteks pertanian modern, pemantauan tingkat kesuburan dan kesehatan tanaman secara tepat merupakan faktor kunci yang memengaruhi optimalisasi hasil panen. Karakteristik visual daun menjadi indikator utama dalam menilai kondisi vegetatif tanaman; perubahan pigmen seperti warna pucat mengindikasikan defisiensi nutrisi makro seperti nitrogen, sedangkan kemunculan bercak spesifik menandakan adanya infeksi patogen atau komplikasi penyakit. Oleh karena itu, pengenalan dini terhadap perubahan fisik daun padi sangat krusial agar petani dapat mengambil tindakan penanganan yang cepat dan tepat sasaran.

Namun, praktik pengujian kondisi tanaman di lapangan saat ini masih menghadapi keterbatasan teknis dan operasional. Pendekatan konvensional melalui survei lapangan dan analisis laboratorium seperti yang dilakukan oleh [2] untuk mengukur unsur hara, maupun penelitian [3] dalam mengidentifikasi jenis virus membutuhkan waktu pemrosesan sampel yang lama, berbiaya tinggi, serta memiliki aksesibilitas yang sangat terbatas bagi petani. Di sisi lain, metode identifikasi manual secara kasatmata sangat rentan terhadap subjektivitas dan kekeliruan, terlebih dengan adanya fakta penurunan kemampuan visual pada mayoritas petani yang telah berusia lanjut. Upaya digitalisasi terdahulu yang memanfaatkan sensor fisik

maupun algoritma *Machine Learning* konvensional seperti *Support Vector Machine (SVM)* juga masih memiliki kelemahan. Kinerja model *SVM* sangat bergantung pada tahapan ekstraksi fitur manual (seperti deskriptor warna dan tekstur) yang terpisah dari proses klasifikasi, sehingga sistem menjadi kurang luwes dan mengalami penurunan akurasi ketika domain citra di lapangan semakin beragam, sebagaimana temuan dari [4].

Untuk mengatasi berbagai keterbatasan tersebut, penelitian ini mengusulkan penerapan algoritma *Convolutional Neural Network (CNN)* guna mengotomatisasi ekstraksi fitur visual daun padi. Pemilihan *CNN* dibandingkan metode *deep learning* lainnya didasarkan pada keunggulannya memproses data spasial. Berbeda dengan *Recurrent Neural Network (RNN)* yang didesain untuk data sekuensial, atau *Vision Transformer (ViT)* yang membutuhkan komputasi masif, *CNN* jauh lebih efisien menangkap pola lokal (tekstur, warna, dan bercak daun) berkat mekanisme *weight sharing* dan operasi konvolusi. Efisiensi ini menjadikannya sangat ideal sebagai model *object detection* yang akurat namun tetap ringan. Model ini dilatih menggunakan dataset citra daun padi pada kondisi normal hingga terinfeksi penyakit (*Bacterial Leaf Blight*, *Blast*, *Brown Spot*, dan *Tungro*). Agar solusi ini aplikatif bagi masyarakat luas, sistem diintegrasikan ke dalam platform web. Pendekatan ini memberikan fleksibilitas bagi petani untuk mengevaluasi kesuburan dan mendiagnosis penyakit secara mandiri, praktis, dan *real-time* melalui

smartphone, tanpa terkendala jarak maupun keterbatasan visual.

2. TINJAUAN PUSTAKA

2.1. Penelitian Terkait

Berbagai penelitian sebelumnya telah membuktikan keandalan algoritma *Convolutional Neural Network (CNN)* dalam mendeteksi penyakit tanaman guna mengatasi keterbatasan literasi visual petani. [5] mengimplementasikan *CNN* untuk diagnosis penyakit komoditas perkebunan secara otomatis dan berhasil mencapai akurasi validasi 95%. Keberhasilan serupa juga dibuktikan oleh [6] yang memanfaatkan arsitektur *CNN* untuk mengidentifikasi penyakit pada daun jagung menggunakan citra beresolusi 150x150 piksel. Melalui proses iterasi sebanyak 100 *epoch*, pemodelan tersebut sukses mencatatkan tingkat akurasi pelatihan sebesar 97,5% dan akurasi validasi sempurna mencapai 100%. Temuan ini menegaskan bahwa pendekatan *Deep Learning* sangat mumpuni dalam mengekstraksi fitur citra daun secara akurat.


Pada komoditas padi secara spesifik, sejumlah pendekatan arsitektur *Deep Learning* tingkat lanjut juga telah dieksplorasi. [7] merancang pemodelan *CNN* untuk klasifikasi hama padi dengan fokus pada penyesuaian parameter guna meredam risiko *overfitting*, menghasilkan akurasi validasi 83,02%. Sementara itu, [8] menerapkan arsitektur DenseNet-201 untuk deteksi dini penyakit padi yang sukses mencatatkan akurasi pengujian sebesar 82,99% dan metrik *F1-Score* 0,83%. Di sisi lain, [9] menggunakan metode *Transfer Learning* untuk membandingkan ekstraksi fitur, di mana model EfficientNet-B3 terbukti sangat optimal dengan akurasi pelatihan menyentuh 99% dan *loss* yang sangat minim, jauh mengungguli performa MobileNet-V3.

Meskipun berbagai studi terdahulu telah menorehkan tingkat akurasi yang memuaskan, mayoritas pemodelan tersebut hanya berfokus pada tahapan evaluasi komputasi dan belum terintegrasi ke dalam platform yang siap pakai. Oleh karena itu, penelitian ini hadir untuk melengkapi celah tersebut dengan merancang sistem *object detection* berbasis *CNN* yang tidak hanya divalidasi tingkat akurasinya, tetapi juga langsung diimplementasikan ke dalam antarmuka aplikasi berbasis web. Langkah ini diambil agar diagnosis kesuburan dan penyakit padi dapat dilakukan secara *real-time* dan mudah diakses oleh petani di lapangan.

2.2. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan salah satu algoritma *Deep Learning* jenis *feed-forward* yang terbukti sangat efektif dalam mengekstraksi dan mengklasifikasikan fitur objek pada data citra. Arsitektur jaringan *CNN* secara umum dibangun atas beberapa lapisan utama, meliputi *Input Layer*, *Convolutional Layer*, *Activation Layer*,

Pooling Layer, *Fully Connected Layer*, dan *Output Layer*.



Gambar 1. Tahapan pada *convolutional neural network (cnn)*

Mengingat klasifikasi citra penyakit daun padi ini beroperasi pada jumlah dataset yang terbatas, arsitektur *CNN* yang diterapkan dirancang menggunakan lapisan yang efisien guna mempercepat waktu komputasi pelatihan. Skala dataset yang kecil sering kali memicu fenomena *overfitting*, yaitu kondisi di mana model menghafal data latih secara presisi namun mengalami penurunan kinerja saat mengidentifikasi data baru. Untuk meredam risiko tersebut, implementasi model ini disertai dengan optimasi dan penyesuaian parameter jaringan, sebuah pendekatan yang terbukti krusial dan efektif dalam memitigasi anomali *overfitting* pada pengolahan citra agrikultur [7].

2.3. Klasifikasi Penyakit Daun Padi

Daun merupakan organ vegetatif utama pada tanaman padi yang merepresentasikan kondisi kesehatan dan tingkat kesuburan secara keseluruhan. Perubahan pigmen warna maupun kemunculan anomali fisik pada permukaan daun menjadi indikator visual yang kuat akan adanya defisiensi unsur hara atau infeksi patogen. Dalam ranah *Computer Vision*, karakteristik visual tersebut diekstraksi menjadi fitur matriks untuk membedakan antara tanaman yang subur dan yang terinfeksi.

Klasifikasi pada pemodelan ini difokuskan pada pengenalan daun padi normal serta identifikasi penyakit utama seperti *Brown Spot*, *Blast*, dan *Tungro*. Daun padi dalam kondisi normal memiliki ciri khas pigmen hijau cerah yang merata tanpa adanya lesi. Sebaliknya, infeksi patogen memunculkan pola visual spesifik; penyakit *Brown Spot* ditandai dengan kemunculan bercak cokelat berbentuk oval pada permukaan daun, sedangkan penyakit *Blast* memunculkan lesi berbentuk belah ketupat dengan pusat berwarna keabu-abuan. Di sisi lain, penyakit *Tungro* yang ditularkan melalui vektor hama umumnya memicu perubahan warna daun menjadi kuning hingga jingga yang dimulai dari ujung helaian daun, sebagaimana dijelaskan dalam penelitian klasifikasi visual oleh [10]. Variasi parameter visual inilah yang menjadi landasan utama bagi algoritma *CNN* dalam memetakan dan mengklasifikasikan setiap kondisi tanaman secara presisi.

3. METODE PENELITIAN


Penelitian ini menggunakan pendekatan kuantitatif eksperimental yang difokuskan pada pengembangan model *Deep Learning* untuk klasifikasi citra. Pendekatan ini mencakup pengumpulan data citra, perancangan model, hingga pengujian metrik performa secara terukur.

3.1. Metode Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan data sekunder berupa dataset citra digital daun padi yang diperoleh dari platform penyedia data publik, yakni Kaggle dan Roboflow. Dataset ini mencakup enam kelas kondisi daun padi, yaitu Bercak Coklat, *Blast*, *Blight*, Daun Busuk, Hawar Daun, dan Tungro. Pemilihan dataset dari platform tersebut dilakukan untuk memastikan kualitas dan variasi citra yang memadai guna menunjang proses ekstraksi fitur pada tahap selanjutnya.

3.2. Tahapan Penelitian

Pengembangan model dalam penelitian ini dilakukan melalui beberapa tahapan sistematis yang berurutan. Secara visual, keseluruhan proses pengembangan model dari tahap awal pengumpulan data hingga tahap implementasi digambarkan pada alur proses tahapan penelitian berikut.



Gambar 2. Alur proses penelitian dan pengembangan model

Adapun penjelasan rinci dari masing-masing tahapan pada Alur proses penelitian dan pengembangan model di atas adalah sebagai berikut:

a. Pengumpulan Data

Dataset citra daun padi yang mencakup 6 kelas (*blight*, bercak coklat, hawar daun, *blast*, tungro,

dan daun busuk) diperoleh secara publik melalui Kaggle dan Roboflow. Data tersebut dibagi menjadi subset *training*, *validation*, dan *testing* untuk melatih model CNN. Pengambilan data lapangan secara langsung belum dilakukan dan direkomendasikan sebagai penelitian lanjutan (*future work*).

b. Pre-processing Data

Tahap *pre-processing* meliputi penyesuaian orientasi (penghapusan EXIF) dan *resizing* citra menjadi 640x640 piksel menggunakan metode *stretch*. Guna mencegah *overfitting* dan memperkaya data latih, dilakukan augmentasi untuk menghasilkan tiga versi tambahan per citra, yang mencakup rotasi acak ($\pm 15^\circ$), *shear* acak ($\pm 10^\circ$), serta probabilitas 50% untuk *flip* horizontal dan vertikal.

c. Modeling

Penelitian ini menggunakan arsitektur *Convolutional Neural Network (CNN)* berbasis *object detection* (arsitektur gelan-c) untuk mengekstraksi fitur visual dan mengklasifikasikan citra. Sesuai dengan konfigurasi pada berkas *hyperparameter*, pelatihan model dirancang menggunakan parameter *batch size* sebesar 16 dan resolusi masukan 640x640 piksel. Selain itu, parameter pelatihan diatur menggunakan *optimizer Stochastic Gradient Descent (SGD)*, dengan *learning rate* awal sebesar 0.01, dan menggunakan fungsi *loss* yang merupakan kombinasi antara *Binary Cross-Entropy (BCE)* untuk klasifikasi kelas dan *Complete Intersection over Union (CIoU)* untuk regresi *bounding box*. Konfigurasi ini diterapkan untuk mengoptimalkan pembaruan bobot secara iteratif, di mana siklus pelatihan dijadwalkan berjalan selama 25 *epoch*.

d. Evaluasi

Kinerja model dievaluasi secara komputasional menggunakan data uji (*testing set*). Instrumen evaluasi divisualisasikan melalui *Confusion Matrix* guna menghitung secara kuantitatif metrik performa seperti *Precision*, *Recall*, *F1-Score*, dan *Mean Average Precision (mAP)*. Pemilihan metrik ini bertujuan untuk mengukur secara objektif tingkat ketepatan klasifikasi model dan memastikan minimnya kesalahan prediksi silang (*misclassification*) antar kelas penyakit.

e. Deployment

Model akhir (*weights*) yang telah melalui proses evaluasi dikonversi ke dalam format operasional. Tahap akhir ini berfokus pada implementasi model ke dalam antarmuka aplikasi berbasis web (*localhost*), yang dirancang untuk memfasilitasi pengguna akhir dalam memproses pindaian atau unggahan citra secara *real-time* dan efisien.

4. HASIL DAN PEMBAHASAN

Pada bagian ini dipaparkan hasil eksperimen pengujian model *Deep Learning* berbasis *CNN*, analisis evaluasi performa melalui metrik kuantitatif,

serta implementasi akhir model ke dalam antarmuka aplikasi berbasis web.

4.1. Hasil Pelatihan Model CNN

Proses pelatihan model dilakukan menggunakan arsitektur *Convolutional Neural Network* berbasis *gelan-c* yang diinisialisasi dengan bobot pra-latih *gelan-c.pt*. Pelatihan ini dikonfigurasi berjalan selama 25 *epoch*, *batch size* 16, dan resolusi masukan sebesar 640×640 piksel dengan mengacu pada berkas *hyperparameter* *hyp.scratch-high.yaml*. Untuk menjaga stabilitas pembelajaran menjelang akhir iterasi, fitur augmentasi *close-mosaic* dinonaktifkan secara otomatis pada *epoch* ke-15. Hasil eksekusi komputasi menggunakan akselerasi GPU pada Google Colab menunjukkan konvergensi yang sangat optimal, di mana model sukses mencatatkan nilai *Precision* sebesar 0.938, *Recall* sebesar 0.943, *mAP@50* sebesar 0.988, serta *mAP@50-95* sebesar 0.767. Tren penurunan nilai *loss* dan peningkatan metrik akurasi secara keseluruhan selama proses pelatihan ini disajikan secara visual pada Gambar 3.

```

gelan-c summary: 467 layers, 25415586 parameters, 0 gradients, 182.5 GFLOPs


```

Class	Images	Instances	P	R	mAP50
all	72	72	0.938	0.943	0.988
Bercak Coklat	72	12	1	0.881	0.995
Blast	72	10	0.795	1	0.968
Blight	72	14	0.981	1	0.995
Daun Busuk	72	7	0.929	1	0.995
Hawar Daun	72	13	0.924	1	0.995
Tungro	72	16	1	0.799	0.979

Results saved to runs/train/exp8

Gambar 3. Hasil training model


Evaluasi performa model selama pelatihan tersebut diperkuat oleh pengujian klasifikasi melalui visualisasi *Confusion Matrix* yang ditunjukkan pada Gambar 4. Berdasarkan matriks evaluasi tersebut, sebagian besar prediksi model terkonsentrasi tepat pada diagonal utama yang berwarna biru tua, menandakan tingginya akurasi sistem dalam mengenali data. Dari ke enam kelas kondisi daun padi yang diuji, lima kelas di antaranya, yaitu Bercak Coklat, Blast, Blight, Daun Busuk, dan Hawar Daun, berhasil mencatatkan akurasi sempurna (1.00) tanpa adanya kesalahan prediksi silang (*misclassification*). Sementara itu, satu kelas lainnya yaitu Tungro memperoleh skor sebesar 0.81. Penurunan performa pada kelas Tungro ini utamanya disebabkan oleh karakteristik visual gejala penyakit tersebut yang memanifestasikan perubahan warna daun menjadi kuning-oranye. Pola perubahan warna ini memiliki tingkat kemiripan visual yang tinggi dengan proses penuaan alami daun padi (klorosis) maupun dengan tahap awal gejala penyakit lain. Akibatnya, model CNN sesekali mengalami kesulitan dalam mengekstraksi fitur diskriminatif yang benar-benar unik pada kelas Tungro, sehingga menyebabkan sebagian kecil citra salah terklasifikasi ke kelas lain. Secara keseluruhan, minimnya area kesalahan prediksi (*false prediction*) pada matriks ini mengonfirmasi keandalan model dalam memisahkan fitur visual antarkelas penyakit secara akurat.



Gambar 4. *Confusion matrix* klasifikasi penyakit daun padi


4.2. Evaluasi Kinerja Model

Tahap Tahap evaluasi dilakukan pada model terbaik (*best.pt*) menggunakan skrip *val.py* terhadap 72 citra *validation set* tanpa augmentasi tambahan. Parameter pengujian dikonfigurasi dengan resolusi citra 640×640 piksel, *batch size* 32, *confidence threshold* 0.001, dan nilai ambang *Intersection over Union* (IoU) sebesar 0.7. Evaluasi ini membuktikan kemampuan generalisasi jaringan yang sangat baik, dengan mencatatkan nilai rata-rata *Precision* sebesar 0.938, *Recall* 0.943, *mAP@50* 0.988, dan *mAP@50-95* mencapai 0.772.



Gambar 5. Diagram batang hasil evaluasi *metrics per class* (*validation set*)


Berdasarkan metrik evaluasi pada Gambar 5 yang menunjukkan performa stabil, pengujian selanjutnya difokuskan pada pengenalan objek secara riil menggunakan *test-set* eksternal di lingkungan komputasi Google Colab. Hasil inferensi model secara kualitatif divisualisasikan melalui penempatan *bounding box* yang sangat presisi dalam melokalisasi area infeksi pada daun Gambar 6. Visualisasi ini membuktikan bahwa arsitektur CNN yang dikembangkan tidak hanya akurat secara angka, tetapi juga andal dalam memetakan letak dan jenis penyakit secara visual langsung pada citra baru.



Gambar 6. Visualisasi hasil deteksi penyakit daun padi pada test-set


4.3. Deployment Aplikasi Berbasis Web

Halaman *dashboard* utama dirancang sebagai pusat kendali dan navigasi antarmuka bagi pengguna akhir, khususnya para petani. Menggunakan arsitektur berbasis web, halaman ini menawarkan kemudahan akses melalui berbagai peramban (*browser*) tanpa memerlukan instalasi tambahan. Antarmuka *dashboard* menyediakan menu utama untuk mengarahkan pengguna ke fitur deteksi utama, baik melalui unggahan gambar maupun pemindaian kamera secara langsung. Desain antarmuka dibuat responsif dan intuitif agar proses monitoring kesehatan tanaman dapat dilakukan secara praktis, instan, dan mandiri langsung di lahan pertanian.




Gambar 7. Tampilan halaman dashboard aplikasi

Selain pusat kendali navigasi, sistem dilengkapi halaman katalog penyakit daun padi sebagai media edukasi dan referensi bagi pengguna. Katalog ini memuat informasi detail mengenai karakteristik visual, gejala klinis, serta langkah pencegahan untuk keenam penyakit yang diuji (*Bercak Coklat*, *Blast*, *Blight*, *Daun Busuk*, *Hawar Daun*, dan *Tungro*). Fitur ini bertujuan membantu petani memahami jenis infeksi secara komprehensif setelah sistem mengeluarkan hasil klasifikasi.



Gambar 8. Tampilan halaman katalog penyakit daun padi


Fungsionalitas utama sistem dalam mendeteksi objek diwujudkan melalui antarmuka berbasis unggah gambar (*image upload*). Pada halaman input ini, pengguna disediakan sarana interaktif untuk memilih dan memasukkan berkas foto daun padi yang diambil dari lapangan dengan format yang didukung seperti JPG, PNG, atau WEBP. Setelah gambar dipilih, pengguna dapat menekan tombol *submit* media untuk memulai proses analisis, atau menggunakan tombol *reset* untuk menghapus input dan mengulang proses unggah dari awal. Antarmuka halaman unggah ini dirancang dengan tata letak yang sederhana guna memastikan para petani dapat mengoperasikan proses input data citra dengan mudah, cepat, dan praktis.




Gambar 9. Tampilan halaman unggah deteksi menggunakan gambar

Setelah proses analisis berjalan, sistem secara otomatis mengeksekusi inferensi model *CNN* di latar belakang dan menampilkan notifikasi bahwa analisis telah berhasil dilakukan. Halaman output hasil analisis ini menyajikan perbandingan antara gambar input asli dan hasil pemrosesan AI secara berdampingan. Hasil deteksi objek ditampilkan dalam bentuk kotak pembatas (*bounding box*) berwarna untuk melokalisasi titik lokasi infeksi lengkap dengan label nama penyakit dan skor tingkat kepercayaan tertinggi. Selain itu, halaman ini juga menyajikan daftar semua kemungkinan prediksi beserta nilai probabilitas dari

masing-masing kelas penyakit untuk membantu pengguna mengevaluasi kondisi tanaman padi secara lebih objektif dan akurat.



Gambar 10. Tampilan halaman *output* deteksi menggunakan gambar




Gambar 11. Tampilan halaman deteksi menggunakan *webcam*

Sebagai alternatif untuk penggunaan langsung di area lahan pertanian, sistem juga menyediakan fungsionalitas deteksi *real-time* berbasis kamera *webcam*. Pada antarmuka ini, pengguna dihadapkan pada area preview video yang akan aktif setelah sistem

memperoleh izin akses perangkat kamera. Pengguna dapat menginisiasi pemindaian dengan menekan tombol "Mulai Deteksi" untuk menjalankan inferensi model secara kontinu, atau "Stop Deteksi" untuk menghentikan proses. Fitur ini dirancang khusus untuk memfasilitasi evaluasi kesehatan tanaman secara cepat tanpa memerlukan langkah pengambilan dan pengunggahan foto terlebih dahulu.

Saat proses pemindaian webcam berjalan, hasil inferensi dari model CNN akan secara langsung dioverlay pada tayangan video live dalam bentuk *bounding box* berwarna hijau, lengkap dengan label klasifikasi penyakit dan skor tingkat kepercayaan (*confidence score*). Sistem secara dinamis akan menyoroti prediksi utama dengan akurasi tertinggi berdasarkan objek yang tertangkap layar. Selain itu, antarmuka ini juga dilengkapi dengan panel riwayat hasil deteksi (*log history*) yang diperbarui secara real-time di bagian bawah tayangan video. Fungsionalitas pemantauan berkelanjutan ini memungkinkan petani untuk memindai rumpun tanaman padi secara luas dan mengidentifikasi sebaran penyakit secara instan, objektif, dan akurat.



Gambar 12. Tampilan halaman *output* deteksi menggunakan webcam

4.3. Pengujian Black Box

Setelah tahap pengembangan selesai, aplikasi menjalani pengujian *Black Box* untuk memvalidasi kelayakan fungsional antarmuka dan interaksi sistem. Pengujian ini difokuskan pada 9 skenario fitur utama aplikasi yang meliputi fungsi navigasi menu, edukasi katalog, fitur unggah citra, hingga deteksi *real-time* berbasis *webcam*. Ringkasan hasil pengujian disajikan pada Tabel 1.

Table 1. Hasil Pengujian *Black Box* Aplikasi Web

No	Skenario Fitur yang Diuji	Hasil yang Diharapkan	Status
1	Navigasi menu pada <i>Dashboard</i>	Sistem responsif memproses perpindahan antar halaman (<i>Deteksi / Katalog</i>).	Lulus
2	Akses menu Profil Pengembang	Sistem menampilkan informasi identitas dan afiliasi pengembang secara lengkap.	Lulus
3	Akses Katalog Penyakit Padi	Gambar penyakit dan teks deskripsi gejala muncul sesuai <i>database</i> .	Lulus
4	Input file citra dan "Submit"	File tervalidasi, terunggah, dan sistem memulai kalkulasi klasifikasi AI.	Lulus
5	Tinjauan Hasil Deteksi Gambar	Sistem menampilkan <i>bounding box</i> , label penyakit, dan tabel persentase probabilitas.	Lulus
6	Tombol "Reset" Form Unggah	Pratinjau terhapus, form kembali kosong dan siap untuk input citra baru.	Lulus

No	Skenario Fitur yang Diuji	Hasil yang Diharapkan	Status
7	Akses Webcam & "Mulai Deteksi"	Kamera aktif dan menampilkan <i>live stream</i> visual objek pada area <i>preview</i> .	Lulus
8	Tinjauan Hasil Deteksi Webcam	Muncul <i>bounding box</i> dan label secara dinamis (<i>real-time</i>) mengikuti arah objek.	Lulus
9	Tombol "Stop Deteksi" Webcam	Akses kamera dimatikan dan beban pemrosesan <i>live stream</i> berhenti.	Lulus

5. KESIMPULAN DAN SARAN

Berdasarkan hasil perancangan dan pengujian yang telah dilakukan, dapat disimpulkan bahwa aplikasi *object detection* berbasis algoritma *Convolutional Neural Network* (CNN) berhasil dikembangkan secara optimal. Pengujian kinerja model terhadap dataset citra daun padi menunjukkan performa generalisasi yang sangat baik, dibuktikan dengan perolehan metrik evaluasi yang meliputi nilai rata-rata *Precision* sebesar 0.938, *Recall* 0.943, *mAP@50* 0.988, dan *mAP@50-95* sebesar 0.772. Berdasarkan *Confusion Matrix*, lima kelas penyakit berhasil mencatatkan akurasi sempurna (1.00), dan kelas Tungro dengan skor 0.81. Selain itu, keandalan sistem juga divalidasi melalui pengujian *Black Box* terhadap 9 skenario fitur utama antarmuka web, yang sukses mencatatkan persentase keberhasilan 100%.

Secara praktis, implementasi sistem ini terbukti mampu memproses citra secara *real-time*, memberikan hasil diagnosis yang lebih cepat dan efisien dibandingkan uji laboratorium konvensional. Pendekatan ini berhasil menjadi solusi teknologi yang mempermudah para petani—terutama yang mengalami penurunan kemampuan visual akibat faktor usia—untuk memantau tingkat kesuburan dan mengidentifikasi penyakit tanaman secara mandiri, akurat, dan tidak bergantung pada pengamatan kasat mata.

Untuk pengembangan selanjutnya, disarankan agar penelitian di masa depan melakukan pengambilan data primer secara langsung di lapangan agar model dapat lebih merepresentasikan kondisi pertanian lokal. Selain itu, cakupan dataset perlu diperluas dengan jenis penyakit padi yang lebih beragam, serta mempertimbangkan implementasi arsitektur *Deep Learning* yang lebih ringan agar proses pemuatan (*loading*) dan eksekusi inferensi pada aplikasi web menjadi lebih maksimal, khususnya saat diakses menggunakan perangkat *smartphone* berspesifikasi rendah.

DAFTAR PUSTAKA

- [1] M. A. Ningrat, C. D. Mual, and Y. Y. Makabori, "Pertumbuhan dan Hasil Tanaman Padi (*Oryza sativa* L.) pada Berbagai Sistem Tanam di Kampung Desay, Distrik Prafi, Kabupaten Manokwari," *Prosiding Seminar Nasional Pembangunan dan Pendidikan Vokasi Pertanian*, vol. 2, no. 1, pp. 325–332, 2021, doi: 10.47687/snppvp.v2i1.191.
- [2] D. Firnia, A. Tresna, and J. Setiawan, "Penyuluhan Evaluasi Status Kesuburan Tanah Untuk Menunjang Peningkatan Produktivitas Padi," *Jurnal Pengabdian Dinamika*, vol. 9, no. 2, pp. 1–6, 2022.
- [3] H. M. Abdillah *et al.*, "Upaya Menangani Gejala Virus Tungro Pada Padi Dengan Melatih Petani Membuat Biakan *Trichoderma* Sebagai Agen Hayati Kesuburan Tanah Dan Kesehatan Tanaman Efforts to Handle Tungro Virus Symptoms in Paddy by Training Farmers to Make *Trichoderma* spp Cultures," *Jurnal Abdimas (Journal of Community Service): Sasambo*, vol. 5, no. 4, pp. 633–644, 2023.
- [4] B. Hardika *et al.*, "Penerapan Klasifikasi Gambar Buah dalam Aplikasi FruityLens Menggunakan Metode CNN," *Jurnal Sistem Informasi dan Ilmu Komputer*, vol. 2, no. 4, pp. 132–142, Nov. 2024, doi: 10.59581/jusiik-widyakarya.v2i4.4275.
- [5] E. Rasywir, R. Sinaga, and Y. Pratama, "Analisis dan Implementasi Diagnosis Penyakit Sawit dengan Metode *Convolutional Neural Network* (CNN)," *Paradigma - Jurnal Komputer dan Informatika*, vol. 22, no. 2, pp. 117–123, 2020, doi: 10.31294/p.v22i2.8907.
- [6] D. Iswantoro and H. D. UN, "Klasifikasi Penyakit Tanaman Jagung Menggunakan Metode *Convolutional Neural Network* (CNN)," *Jurnal Ilmiah Universitas Batanghari Jambi*, vol. 22, no. 2, p. 900, 2022, doi: 10.33087/jiubj.v22i2.2065.
- [7] S. Yuliany, Aradea, and A. N. Rachman, "Implementasi *Deep Learning* pada Sistem Klasifikasi Hama Tanaman Padi Menggunakan Metode *Convolutional Neural Network* (CNN)," *Jurnal Buana Informatika*, vol. 13, no. 1, pp. 54–65, 2022, doi: 10.24002/jbi.v13i1.5022.
- [8] P. Sitompul, H. Okprana, and A. Prasetyo, "Identifikasi Penyakit Tanaman Padi Melalui Citra Daun Menggunakan *DenseNet 201*," *JOMLAI: Journal of Machine Learning and Artificial Intelligence*, vol. 1, no. 2, pp. 143–150, 2022, doi: 10.55123/jomlai.v1i2.889.
- [9] E. Anggiratih, S. Siswanti, S. K. Octaviani, and Arumsari, "Klasifikasi Penyakit Tanaman Padi Menggunakan Model *Deep Learning Efficientnet B3* dengan *Transfer Learning*," *Jurnal Ilmiah SINUS*, vol. 19, no. 1, p. 75, 2021, doi: 10.30646/sinus.v19i1.526.
- [10] C. Hia, M. Tiara, D. R. Hutasuht, E. M. Hutaeruk, and E. P. Korespondensi, "Jurnal Media Informatika [JUMIN] Deteksi Penyakit Blas, Tungro & Bercak Coklat Pada Tanaman Padi Menggunakan Metode *Convolutional Neural Network*," 2019.